

8
2el.



**UNIVERSIDAD NACIONAL AUTONOMA
DE MEXICO**

**ESCUELA NACIONAL DE ESTUDIOS PROFESIONALES
ACATLAN**

**ANALISIS POR SERIES DE TIEMPO DE LAS
CONCENTRACIONES ATMOSFERICAS DE SO₂
EN LA ZMCM.**

T E S I S


QUE PARA OBTENER EL TITULO DE:

**LICENCIADA EN MATEMATICAS
APLICADAS Y COMPUTACION**

P R E S E N T A :

LAURA ERICA CASTAÑEDA PEREZ

ASESORAS: ACT. MA. DEL CARMEN GONZALEZ VIDEGARAY
BIOL. MA. MAGDALENA NAVA NAVA



NAUCALPAN, EDO. DE MEXICO.

1997

**TESIS CON
FALLA DE ORIGEN**



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Para SOCO:

Principalmente dedico este trabajo a mi madre quien siempre ha estado a mi lado y que con su ejemplo me enseñó a luchar por conseguir lo que deseo.

Porque con tenacidad valentía y entrega forjó el respeto que ahora le tengo a ella, a la vida y a mi profesión.

Porque con amor y su vida misma creó en mi una persona que valora y agradece su esfuerzo.

Porque en los momentos difíciles con su sola presencia me demostró que puedo contar con ella.

Y finalmente porque he comprendido que si hay a alguien a la que le debo mi existencia y mi felicidad es a mi madre.

Con todo respeto y agradecimiento a tí que siempre estas en mi mente y en mi corazón

Laura

A mi hermana:

También dedico este trabajo a mi hermana por ser una de las dos personas más importantes y valiosas que tengo a mi lado y porque de ella siempre he recibido respeto, apoyo y cariño.

Gracias Maggi

Pero especialmente deseo dedicarlo a la memoria de la persona que formó parte fundamental en mi vida y que siempre está presente en mis pensamientos y oraciones.

A Rodrigo:

A ti que me permitiste compartir tus alegrías, tristezas y tu soledad, enseñándome con ello a disfrutar intensamente la vida y hacer valiente aun en la adversidad y en la muerte.

A ti que luchaste en todo momento por defender tus ideales y tu personalidad. Y por mostrarme cual era el valor de la amistad y de la hermandad.

A ti que me diste tu respeto y apoyo porque siempre creíste en mi y en mis ideales.

A ti por haber sido mi padre, mi hermano, mi amigo y sobre todo porque fuiste un excelente tío y ahora eres mi mejor recuerdo.

Con mucho amor y nostalgia
Laura

Gracias:

A mi PADRE por formar parte de mi educación.

A mis TÍOS por sus enseñanzas y solidaridad, especialmente a Fermin, Lourdes, Mari, Chata, Bambi y Miguel.

A mis PRIMOS por los buenos tiempos, Claudia, Iván, América y Ricardo.

A mis AMIGOS que siempre creen en mi y están en los momentos importantes para compartirlos, especialmente Alan, Angel y Jaime.

A mis COMPAÑERAS del Instituto por su ayuda generosa y constante, Gabi, Liz, Magda y Elia.

A OCTAVIO

A mis asesoras:

***Por la disponibilidad y confianza en la
realización del trabajo.***

***Y por el esfuerzo y aportación conjunta para
convertirlo en realidad.***

***Biol. Ma. Magdalena Nava Nava
Act. Ma. del Carmen González Videgaray***

***Especial agradecimiento al Sínodo por el
interés en la revisión de este trabajo:***

M. en I. Víctor J. Palencia Gómez

Ing. Elvira Beatriz Clavel Díaz

Act. María del Carmen González Videgaray

Ing. Reyes Laurencio García Moncada

Lic. Jaime Ramírez Muñoz

***Análisis por
series de tiempo
de las
concentraciones
atmosféricas de
SO₂ en la ZMCM***

Índice

Capítulo 1. Contaminación atmosférica en la ZMCM.	1
INTRODUCCIÓN	
1.1 Contaminación atmosférica.	1
1.2 Los contaminantes atmosféricos.	3
1.2.1 Los contaminantes del aire en la ZMCM.	5
1.3 Los efectos de la contaminación del aire.	7
1.3.1 Efectos sobre las propiedades de la atmósfera.	7
1.3.2 Efectos sobre los materiales.	8
1.3.3 Efectos sobre la vegetación.	9
1.3.4 Efectos en la salud humana.	10
1.3.5 Estudios en la ZMCM sobre el impacto de la contaminación del aire en la salud.	14
ÁREA DE ESTUDIO	
1.4 Características fisiográficas de las ZMCM y el problema de la contaminación atmosférica en esta zona.	17
1.4.1 Inventario de emisiones contaminantes, normas y criterios de la calidad del aire en la ZMCM.	20
ANTECEDENTES	
1.5 Programa Integral Contra la Contaminación Atmosférica (PICCA).	25
1.5.1 Paquete Ecológico de PEMEX (Compromisos y metas de la Industria Petrolera).	27
1.6 El Bióxido de Azufre (SO ₂) como uno de los principales contaminantes atmosféricos de la ZMCM.	30
Capítulo 2. Análisis de series de tiempo.	37
2.1 Métodos de Pronósticos.	37
2.1.1 Clasificación de los métodos de pronósticos.	38
2.1.2 Selección del método de pronóstico.	42
2.2 Métodos cuantitativos de pronóstico.	43
2.2.1 Notación para los métodos cuantitativos.	43
2.2.2 Métodos de series de tiempo.	44

- Método gráfico.	46
- Métodos de suavizamiento.	47
- Método de descomposición.	56
- Método de Box-Jenkins	56
2.3 Métodos cualitativos de pronóstico.	57
- Curvas logísticas de aprendizaje.	57
- Método de investigación morfológica.	58
- Método DELPHI.	59
2.4 Método de Box-Jenkins.	60
2.4.1 Autocorrelación y autocorrelación parcial.	60
2.4.2 Proceso Ruido Blanco.	65
2.4.3 Clases de modelos de series de tiempo.	66
- Modelos Autorregresivos (AR).	67
- Modelos de Medias Móviles (MA).	70
- Modelos Mezclados (autorregresivos - medias móviles (ARMA)).	74
- Modelos Estacionarios.	75
- Modelos Autorregresivos integrados medias móviles (ARIMA).	79
2.4.4 Metodología de Box-Jenkins.	80
- Identificación del modelo.	83
- Estimación de parámetros.	86
- Diagnóstico de la adecuación del modelo.	87
- Obtención de pronósticos.	89
2.5 Análisis de Intervención.	92

Capítulo 3. Aplicación del Análisis de series de tiempo al SO₂ 101

3.1 Esquema de trabajo.	101
3.2 Registros de las concentraciones de SO ₂ .	101
3.2.1 Red Automática de Monitoreo Atmosférico (RAMA).	102
3.2.2 Concentraciones mensuales de SO ₂ en la ZMCM.	106
3.3 Aplicación de Box-Jenkins y Análisis de Intervención a los datos de SO ₂ .	107
3.3.1 Ajuste del modelo tiempo ARIMA a las concentraciones mensuales de SO ₂ por Box-Jenkins.	109
3.3.2 Evaluación de las estrategias para la disminución y control de las emisiones generadoras de SO ₂ por Análisis de Intervención.	113
3.3.3 Obtención de pronósticos.	121

Capítulo 4. Análisis de resultados y recomendaciones.	127
4.1 Resultados.	127
4.2 Selección de los modelos.	132
4.2.1 Criterios de selección.	132
4.2.2 Proceso de selección.	133
4.3 Análisis de resultados y discusión.	138
4.4 Pronósticos.	154
CONCLUSIONES.	169
REFERENCIAS.	173
ANEXOS.	177
I. Base de datos de SO₂.	179
II. Resultados de los parámetros.	183
III. Correlaciones.	187
GLOSARIO.	189

Prefacio

El presente trabajo pretende corroborar que la Metodología de Box-Jenkins y el Análisis de Intervención son instrumentos útiles en la descripción y pronóstico de las series de tiempo que representan a las concentraciones de contaminantes en la atmósfera y para evaluar las estrategias aplicadas para su disminución y control.

A partir de ésta suposición y como principal objetivo se realizó el análisis específico de los promedios mensuales de las concentraciones de bióxido de azufre (SO_2) atmosférico en la ZMCM (Zona Metropolitana de la Ciudad de México) para el periodo de 1988-1996; y la evaluación del impacto que provocaron en éstas las estrategias implantadas por la Industria Petrolera (PEMEX) para disminuir y controlar las emisiones a la atmósfera.

Con el análisis de los promedios mensuales de las concentraciones de SO_2 se obtuvo un modelo que se ajusta a la serie de datos y describe su comportamiento en base a su tendencia y estacionalidad, calculando también pronósticos a mediano plazo.

La evaluación de las estrategias implantadas por PEMEX tuvo como fin conocer el impacto que estas lograron sobre las concentraciones del SO_2 en la atmósfera, determinando cuales fueron estadísticamente significativas y el grado de contribución que tuvieron en la disminución del contaminante. Con base en la identificación de la fecha de inicio del impacto se determinó también su tipo de comportamiento (brusco, gradual, temporal y/o permanente).

El trabajo fue dividido en cuatro capítulos que comprenden: el estudio - introducción, marco teórico y antecedentes- de la contaminación atmosférica en la ZMCM; la descripción de las metodologías utilizadas; el desarrollo de la aplicación y el análisis de resultados.

Se dedicó un capítulo exclusivo a la presentación de algunos conceptos importantes sobre contaminación atmosférica en la ZMCM puesto que fueron utilizados posteriormente para el análisis de resultados, siendo además un tema poco conocido por la población y en especial por los habitantes de la Ciudad de México a pesar de ser un problema actual y grave.

Prefacio

En este capítulo también son tratados algunos aspectos del objeto de estudio que es bióxido de azufre (SO_2), un contaminante atmosférico emitido principalmente por la quema de combustibles industriales y que se presenta en la atmósfera de esta zona.

No sólo es importante conocer en que situación se encuentra la ZMCM en cuanto a contaminación atmosférica, sino también conocer que es lo que se ha hecho para su control. Por esta razón se expone de manera general el Programa Contra la Contaminación Atmosférica (PICCA) -el cual procura integrar todos aquellos factores que influyen sobre la contaminación y que son estudiados y sobre todo, intentan ser modificados con base en estrategias orientadas a luchar contra la contaminación atmosférica-; y de manera específica los compromisos de la Industria Petrolera sobre el SO_2 .

Todo trabajo de investigación requiere de un sustento teórico y/o práctico especialmente cuando se trata de aplicar un método matemático a un fenómeno real, por lo que el capítulo 2 contiene la recopilación bibliográfica de la teoría que conlleva la metodología de Box-Jenkins. Se inicia con una comparación de los diferentes Métodos que existen para series de tiempo y donde se encuentra clasificada dicha Metodología, teniendo estos métodos como propósito el realizar pronósticos. Seguido de esto se da una breve explicación de la misma y de los conceptos matemáticos que están relacionados con ella. De igual forma será introducido el Análisis de Intervención considerado como una extensión de Box-Jenkins.

Una vez expuestos los dos capítulos anteriores, se presenta el capítulo tres que explica paso a paso el desarrollo de la metodología de Box-Jenkins sobre las concentraciones de SO_2 y el del Análisis de Intervención sobre las estrategias implantadas por la Industria Petrolera. Inicia con la descripción de la adquisición de los datos y de cómo fueron utilizados, para posteriormente exponer el uso de las metodologías. Este capítulo fue fundamental para el análisis de los resultados, así como para las conclusiones que se obtuvieron.

El capítulo cuatro contiene el análisis y discusión de resultados. Presenta, en forma de gráficas y tablas, todos los resultados obtenidos de la aplicación de Box-Jenkins y del Análisis de Intervención al contaminante atmosférico SO_2 ; además de incluir los modelos ajustados en forma de ecuaciones matemáticas y algunas correlaciones. Las tablas contienen los resultados condensados obtenidos después de cada estimación: los modelos tipo ARIMA e intervenciones ajustados, ambos presentan los estimadores de sus parámetros. Además, los anexos posteriores a estos capítulos contendrán información complementaria del análisis de resultados.

Finalmente son mostrados los pronósticos obtenidos para cada zona de monitoreo y para la ZMCM en general.

Con las conclusiones de la aplicación se da por terminado el presente trabajo. Entre éstas encontramos principalmente que: las Metodologías aplicadas fueron adecuadas para análisis de las concentraciones de SO_2 ; la ZMCM esta fuertemente zonificada; las concentraciones del contaminante no muestran estacionalidad y la mayoría presentan tendencia creciente y, finalmente se detectó que de las nueve medidas implantadas por la Industria Petrolera, cinco fueron las que ocasionaron una disminución significativa en las concentraciones atmosféricas de SO_2 .

Capítulo 1.

Contaminación atmosférica en la ZMCM

1.1 Contaminación Atmosférica

Contaminación del aire puede entenderse como cualquier condición atmosférica en la que ciertas sustancias alcanzan concentraciones lo suficientemente elevadas sobre su nivel ambiental normal como para producir un efecto nocivo en el hombre, los animales, la vegetación o/ y los materiales¹. Cabe aclarar que por "sustancia" entendemos cualquier elemento o compuesto químico, natural o artificial, capaz de permanecer o ser arrastrado por el aire. Estas sustancias pueden existir en la atmósfera en forma de gases, gotas líquidas o de partículas sólidas. Esta definición incluye cualquier sustancia, pero cuando hablamos de "efecto nocivo", entonces nos referimos solamente a aquellas sustancias dañinas a la salud.

El problema de la contaminación del aire, en términos generales, puede representarse simplemente como un sistema integrado por tres componentes básicos²:



Es obvio que la reducción de la contaminación atmosférica en los grandes centros urbanos del mundo exige una gran inversión económica, así como, tal vez, cambios en los modos de vida y los hábitos de uso de la energía.

En su sentido más amplio, la contaminación del aire es un problema mundial, ya que en último término los contaminantes llegan a dispersarse en toda la atmósfera; aunque para el interés de este trabajo, se considerará de manera un poco más detallada los elementos de un problema de contaminación atmosférica en una cuenca aérea como lo es la Zona Metropolitana de la Ciudad de México.

El origen de la contaminación del aire es la fente de emisión. Las fuentes de emisión más importantes son: el transporte, la incineración de residuos, el consumo de combustibles fósiles y los procesos industriales. Algo que está directamente asociado con las fuentes de emisión son los aparatos o procedimientos operativos que impiden que algunos de los contaminantes producidos por la fuente de emisión lleguen a la atmósfera, los cuales se conoce como controles de fuente. Entre los


¹ Seinfeld, John H., *Contaminación Atmosférica "Fundamentos físicos y químicos"*, Instituto de Estudios de Administración Local N. Y. 1975, Mc Graw Hill, Madrid España, 1978, pag. 1

² *item...*

Contaminación Atmosférica en la ZMCM

controles de fuente típicos se encuentran el uso de aparatos para la limpieza de gases, la sustitución de combustibles que originan emisiones mayores por otros que causan emisiones menores, así como modificaciones del propio proceso generador de las emisiones. Ahora bien, los contaminantes son emitidos a la *atmósfera*, que hace de medio para su transporte, dilución y transformación física y química. Posteriormente, los contaminantes pueden ser detectados por medio de instrumentos o por las personas, los animales, las plantas o los materiales. Por último, y como resultado de estas respuestas, las fuentes de emisión y sus controles pueden ser modificados a través de la detección automática a distancia de las concentraciones atmosféricas, o bien a través de la opinión pública y de las medidas legislativas surgidas posteriormente.

El siguiente diagrama esquemático resume los componentes del sistema de la contaminación del aire³.



Hay al menos tres puntos en el sistema de contaminación del aire que pueden ser objeto en principio de medidas de control. En primer lugar, se puede ejercer control en la fuente de emisión con objeto de reducirlas a cantidades menores. En segundo lugar, se podrían ejercer medidas de control sobre la atmósfera, por ejemplo, modificando la estructura térmica de la atmósfera. Por último, podrían reservarse las medidas de control para los receptores, por ejemplo, el uso de máscaras de gas. De las tres posibilidades, el control de la fuente de emisión no sólo es la factible, sino también la más adecuada. Entonces la mejor manera de luchar contra la contaminación atmosférica es impedir que los contaminantes lleguen a la atmósfera. Por tal motivo, este trabajo pretende evaluar las estrategias desarrolladas por la industria petrolera para disminuir las emisiones de azufre (SO₂) desde sus fuentes en la ZMCM (Zona Metropolitana de la Ciudad de México).

En resumen, las partes más importantes en el estudio de la contaminación del aire son:

³ *op. cit.*, pag. 3

- Fuentes de contaminantes atmosféricos.
- Métodos de control.
- Comportamiento de los contaminantes en la atmósfera.
- Efectos de los contaminantes atmosféricos.
- Medidas legislativas y reguladoras.

Este primer capítulo se refiere de manera general a estos cinco componentes, para plantear una mejor imagen del problema que representa la contaminación atmosférica. Siendo importante hacer un análisis detallado sobre las características particulares de este problema en la ZMCM, que representa el área de estudio del trabajo de investigación.

1.2 Los contaminantes atmosféricos

Existe una gran variedad de sustancias capaces de permanecer en suspensión en el aire, por lo que resulta difícil establecer una clasificación específica de las mismas. Sin embargo, se puede dividir a los contaminantes atmosféricos en dos grandes grupos:

Contaminantes primarios: aquellos que proceden directamente de las fuentes de emisión.

Contaminantes secundarios: aquellos que se originan por la interacción química entre los contaminantes primarios y los componentes normales de la atmósfera.

El análisis de las emisiones procedentes de varias fuentes nos proporciona información sobre el tipo y la cantidad de *contaminantes primarios* emitidos por estas fuentes, mientras que mediciones realizadas en la atmósfera sirven para identificar los *contaminantes secundarios*.

La concentración de contaminantes atmosféricos suele expresarse en dos tipos de unidades. La primera, es la de partes por millón en volumen (fracción en volumen $\times 10^6$) cuyo símbolo es ppm, y es empleada para contaminantes gaseosos. Las concentraciones típicas de los contaminantes atmosféricos gaseosos son del orden de 0.0001 por 100 en volumen, o sea de 1 ppm. El uso de ppm como unidad de medida se debe principalmente a las dificultades surgidas con el manejo de porcentajes tan pequeños como éstos. Algunas veces, las concentraciones se expresan también en partes por cien millones (ppcm) o en partes por billón (ppb).

La segunda unidad de medida de concentración frecuentemente utilizada está basada en el peso del contaminante por unidad de volumen de aire, expresada

Contaminación Atmosférica en la ZMCM

en microgramos por metro cúbico, y cuyo símbolo es $\mu\text{g}/\text{m}^3$. Se utiliza esta medida para las partículas y también, a veces, para los gases.

Los contaminantes atmosféricos también pueden clasificarse como:

1. Compuestos del azufre.
2. Compuestos del nitrógeno.
3. Compuestos del carbono (salvo el monóxido de carbono y el dióxido de carbono).
4. Monóxido de carbono y dióxido de carbono.
5. Compuestos de los halógenos (flour, cloro, bromo, iodo,...).
6. Compuestos reactivos (ozono, entre otros).
7. Partículas.

Esta clasificación está de conformidad con la manera habitual de clasificar los contaminantes atmosféricos utilizada en casi todas las publicaciones referentes al tema. Como de hecho las partículas pueden contener azufre, carbono, compuestos del nitrógeno, etc., se supone que los grupos del 1 al 6 se refieren a compuestos en fase gaseosa.

Por último, la tabla 1.2.1 resume la clasificación de los contaminantes atmosféricos gaseosos. Como representación de los óxidos del nitrógeno, NO y NO₂, es frecuente utilizar la fórmula abreviada NO_x; del mismo modo, se emplea algunas veces la fórmula de SO_x para designar los óxidos del azufre, SO₂ y SO₃.

Tabla 1.2.1 Clasificación de los contaminantes atmosféricos gaseoso

Tipo	Contaminantes primarios	Contaminantes secundarios	Fuentes de emisión artificiales
Compuestos del azufre	SO ₂ , H ₂ S	SO ₃ , H ₂ SO ₄ , MSO ₄	Combustión de carburantes conteniendo azufre
Compuestos del nitrógeno	NO, NH ₃	NO ₂ , MNO ₃ , HNO ₃	Combustión de N ₂ y O ₂ durante combustión a alta temperatura
Compuestos del carbono	Compuestos C ₁ -C ₃	Aldehídos, cetonas, ácidos	Combustión de carburantes; refinado del petróleo; uso de disolventes
Óxidos de carbono	CO, CO ₂	Ninguno	Combustión
Compuestos de los halógenos	HF, HCl	Ninguno	Industrias metalúrgicas

FUENTE: Seinfeld, 1978

1.2.1. Los contaminantes del aire en la ZMCM.

En la atmósfera de la ZMCM se encuentran presentes una variedad de sustancias. Entre las más importantes para evaluar la calidad del aire en esta zona, son:

- Partículas suspendidas totales.
- Plomo.
- Monóxido de carbono.
- Óxidos de azufre.
- Óxidos de nitrógeno.
- Hidrocarburos.
- Ozono y otros oxidantes fotoquímicos.

Como se explicó antes, en los primeros seis casos se trata de sustancias emitidas en forma directa por la combustión y otros procesos industriales, así como por la erosión, los incendios y otros fenómenos naturales; por ello se les conoce como contaminantes primarios. Por otro lado, el ozono pertenece a la categoría de los contaminantes secundarios que se produce en la atmósfera como resultado de reacciones fotoquímicas entre contaminantes primarios, principalmente los óxidos de nitrógeno y los hidrocarburos. Algunas partículas, sobre todo las de diámetro más pequeño, también se originan como producto de la interacción de diferentes contaminantes primarios.

A continuación se describen brevemente las características principales de los contaminantes más significativos de la ZMCM y en especial del SO₂.

Partículas suspendidas totales (PST).

Las partículas de origen natural se componen principalmente de suelos y ocasionalmente por partículas de origen biológico. Las que provienen de la combustión generalmente están integradas por partículas atomizadas y cenizas del combustible. Representan el agente más relevante que origina la disminución de la visibilidad.

Debido a su tamaño, las *partículas menores a 10 micrómetros (PM10)* se sedimentan a una velocidad tan lenta que pueden ser inhaladas, lo cual incrementa el potencial tóxico y / o patógeno de sus componentes. La combustión de combustibles fósiles representa el problema más relevante en la emisión de este tipo de partículas, aun que si bien una fracción importante también procede de la reacción entre contaminantes primarios (SO₂ y NO_x) y de fuentes naturales.

Entre las *partículas menores a 2.5 micrómetros (PM2.5)* se incluyen aquellas de mayor penetración en el sistema respiratorio y, por tanto, las más dañinas a la

Contaminación Atmosférica en la ZMCM

salud y las que por su tamaño interfieren con la dispersión de la luz contribuyendo a la disminución de la visibilidad.

Las bacterias, hongos, virus y protozoarios representan a las *partículas aerobiológicas*, cuya importancia radica en el potencial infeccioso y alérgico que depende a la vez de las características del agente patológico, las condiciones ambientales y la resistencia de los posibles huéspedes.

Plomo (Pb).

Proviene principalmente de los aditivos alquilados de la gasolina (sustancias que son agregadas a las gasolinas como aditivos antidetonantes). Así, su importancia como contaminante radica en el uso extensivo e indiscriminado en los vehículos que utilizan gasolina con plomo.

Monóxido de Carbono (CO).

Este es el más abundante y más distribuido de todos los contaminantes del aire, proviene de la quema de combustibles y representa un subproducto de la combustión incompleta. A nivel mundial no se ha observado un cambio significativo en las concentraciones de CO atmosférico durante los últimos 20 años, a pesar de que la contribución que lo origina se ha duplicado en el mismo período.

Óxidos de azufre (SO_x).

Bajo condiciones ambientales, los óxidos de azufre gaseosos se presentan como bióxido de azufre (SO₂) y trióxido de azufre (SO₃). Las emisiones de estos compuestos provienen principalmente de la combustión, como resultado de la oxidación del azufre inorgánico y orgánico contenido en los combustibles.

Los SO_x contribuyen a incrementar los problemas de partículas respirables y de visibilidad. Por otra parte, estos compuestos actúan como precursores en la formación de lluvia ácida.

Óxidos de nitrógeno (NO_x).

El óxido nítrico (NO) y el bióxido de nitrógeno (NO₂) se presentan como contaminantes importantes del aire, aunque otras cuatro variedades pueden también participar en el conjunto de reacciones que provocan los oxidantes fotoquímicos. Los NO_x, que se forman durante la combustión son el producto de la oxidación de nitrógeno atmosférico, o del nitrógeno orgánico del combustible.

Hidrocarburos no metánicos (HC).

La existencia de hidrocarburos en la atmósfera incluye a los hidrocarburos no quemados y a otras especies formadas durante la combustión, así como los compuestos orgánicos volátiles derivados de la fabricación, almacenamiento y aplicación de solventes y pinturas. Otros procesos donde se emiten son la manufactura química, la refinación del petróleo y la operación metalúrgica.

La principal razón para su control radica en que son precursores de *oxidantes fotoquímicos como el ozono (O₃) y el peroxiacetinitrato (PAN), etc.* Los oxidantes fotoquímicos son contaminantes secundarios; es decir, no son descargados directamente a la atmósfera sino que se forman a través de una serie de reacciones químicas catalizadas por la radiación solar. De éstos, el ozono es el compuesto más abundante en la atmósfera urbana.

1.3 Los efectos de la contaminación del aire

Existe evidencia real de que la contaminación atmosférica afecta la salud de las personas y de los animales, daña la vegetación, ensucia y deteriora los materiales, afecta al clima, reduce la visibilidad y la radiación solar, perjudica los procesos de producción, aumenta los riesgos y, en general, dificulta el disfrute de la vida y de las cosas. Aunque algunos de estos efectos son específicos y medibles, como en el caso de la reducción de la visibilidad y los daños causados en la vegetación y en los materiales, la mayoría de ellos son difíciles de medir, como en el caso de los daños causados en la salud de las personas y de los animales, y los obstáculos que presentan para una vida confortable. Como resultado de ello, ha habido desacuerdo en cuanto a los efectos cuantitativos de la contaminación del aire.

En esta sección se *presentará un breve resumen de los más importantes efectos nocivos -demostrados científicamente- causados por la contaminación del aire.*

1.3.1. Efectos sobre las propiedades de la atmósfera

Los contaminantes del aire pueden afectar las propiedades atmosféricas de la siguiente forma:

- Reducción de la visibilidad.
- Formación y precipitación de neblina.
- Reducción de la radiación solar.

- Alteración de las temperaturas y de la distribución de los vientos.

Todos estos efectos están asociados principalmente con la atmósfera urbana. Además, existe actualmente un gran interés en los posibles efectos de los contaminantes del aire, en particular del dióxido de carbono y de las partículas, sobre la atmósfera en general.

1.3.2. Efectos sobre los materiales.

Los principales factores que influyen sobre el deterioro de los materiales en relación con la contaminación del aire son: humedad, temperatura y la radiación solar.

La *humedad* es esencial para que ocurran la mayoría de los mecanismos de deterioro, ya que ciertos contaminantes reaccionan con el agua (humedad en el ambiente) y forman ácidos.

Generalmente entre más alta es la *temperatura* del aire las tasas de reacción son mayores; no obstante, cuando las temperaturas bajan están acompañadas por el enfriamiento de superficies hasta tal punto que la humedad se condensa, entonces las reacciones pueden ser aceleradas.

La *radiación solar* puede considerarse como un agente catalítico (acelera las reacciones químicas) para las sustancias que son emitidas al ambiente.

Los mecanismos de deterioro de los materiales que se atribuyen a los contaminantes del aire son los siguientes:

1. Abrasión.
2. Depositación y remoción.
3. Ataque químico directo.
4. Ataque químico indirecto.
5. Corrosión electroquímica.

En realidad, solamente las partículas sólidas de tamaño relativamente grande y que viajan a velocidad suficientemente fuerte pueden causar deterioro por abrasión (desgastan a los materiales raspándolos).

La sedimentación de partículas pequeñas y sólidas sobre superficies expuestas causan un deterioro estético que, en el caso de ciertos monumentos y edificios, resulta inaceptable.

El ataque químico directo se tipifica por los procesos de solubilización y por las reacciones de oxidación/reducción.

El ataque químico indirecto ocurre cuando los contaminantes son absorbidos y reaccionan con algún componente del absorbente para formar un compuesto destructivo, ya por sus propiedades oxidantes, reductoras, solventes, o bien, porque remueve enlaces activos en la estructura del material.

En cuanto a la corrosión electroquímica, las reacciones de oxidación/reducción causan diferencias químicas y físicas locales sobre las superficies metálicas; a su vez, estas diferencias ocasionan la formación de ánodos y cátodos microscópicos. El potencial electroquímico que desarrollan estas minúsculas baterías provocan la corrosión.

1.3.3. Efectos sobre la vegetación

Las plantas son organismos muy sensibles a la exposición de contaminantes aéreos en virtud de que llevan a cabo un intercambio gaseoso que les resulta vital.

Las hojas son las partes de los vegetales más afectadas por la contaminación. Los daños dependen del contaminante, su concentración, tiempo de exposición y de la resistencia de la planta. Cuando uno de estos organismos se expone a la acción de varios contaminantes, los resultados son más evidentes.

Por otra parte, el crecimiento de las plantas puede ser inhibido, por una exposición continua a 0.5 ppm de NO_2 ; mientras que se requieren niveles arriba de 2.5 ppm durante periodos de cuatro o más horas para producir un manchado de la superficie.

La siguiente tabla resume los síntomas característicos de los daños causados en las plantas por varios contaminantes.

Tabla 1.3.3.1 Resumen de los síntomas por la contaminación atmosférica en la vegetación.

Contaminante	Sintoma	ppm	Tiempo de exposición continua
Ozono (O_3)	Mancha, decoloración manchas blancas, inhibición del crecimiento. En las coníferas, las puntas de las agujas se vuelven marrón y se necrosan.	0.03	4 horas
SO_2	Manchas decoloradas, zonas decoloradas entre las venas, clorosis, parada del crecimiento, reducción del rendimiento	0.03	8 horas
Nitrato peroxiacetilo (PAN)	Superficie inferior de las hojas lustrosas blanca o parda	0.01	6 horas
HF	Quemaduras en las extremidades y los bordes de las hojas, clorosis, reducción del espesor de las hojas, menor rendimiento	0.0001	5 semanas
Cl_2	Zonas decoloradas entre las venas, en la punta y el corte de las hojas	0.10	2 horas
Etileno (C_2H_4)	Hojas marchitas y anormales, las flores caen y no llegan a abrirse	0.05	6 horas

FUENTE: Seinfeld 1978

El resultado neto del daño de los contaminantes del aire es en realidad más importante que el daño superficial aparente a las hojas. Una reducción del área superficial resulta en un menor crecimiento y frutos más pequeños.

1.3.4. Efectos en la salud humana.

El efecto más controvertido y tal vez más importante de la contaminación del aire, es el efecto sobre la salud humana.

Los efectos de la contaminación del aire pueden variar desde la simple irritación transitoria hasta enfermedades agudas o incluso la muerte, en función de la magnitud de los niveles de concentración y de los periodos de exposición de la población afectada.

Consideremos primero los mecanismos por los cuales los contaminantes pueden afectar el cuerpo humano.

Los contaminantes penetran principalmente en el cuerpo humano a través del sistema respiratorio.

Ciertos contaminantes afectan la resistencia de las vías respiratorias del pulmón. Por ejemplo, el SO_2 es muy soluble y, como consecuencia, será pronto absorbido en las vías respiratorias, causando un aumento de la resistencia de éstas (hinchazón), y estimulando la secreción de mucosidad. Por otro lado, el CO , el NO_2 y el O_3 son relativamente insolubles y pueden penetrar profundamente en el pulmón hasta las cavidades alveolares. El dióxido de nitrógeno y el ozono provocan edema pulmonar (hinchazón), que impide el intercambio de gases con la sangre. El monóxido de carbono pasa de las cavidades alveolares a la sangre, donde se combina con la hemoglobina del mismo modo que el oxígeno.

La calidad del aire y sus efectos sobre la salud son funciones extremadamente complejas, puesto que, un mismo efecto puede ser producido por más de un contaminante. Así por ejemplo, tanto el dióxido de azufre como el formaldehído producen irritación y una mayor resistencia de las vías respiratorias del sistema respiratorio superior, y tanto el CO como el NO_2 impiden el transporte de oxígeno por la hemoglobina. En el caso frecuente de la presencia simultánea de varios contaminantes, los efectos observados podrán ser atribuidos a la acción combinada de más de un contaminante. Un buen ejemplo de esto es el caso del SO_2 y de las partículas. Los efectos sobre la salud son mucho más graves cuando ambos están presentes. La explicación de este efecto es que el SO_2 es absorbido en la superficie de las partículas muy pequeñas, las cuales le introducen hasta zonas más profundas de los pulmones.

En seguida se presenta un resumen de los criterios avalados por la Organización Mundial de la Salud y otras instituciones relevantes sobre los efectos sobre la salud para cada tipo de contaminante.

Monóxido de Carbono (CO)

Los efectos causados por exposición al monóxido de carbono vienen reflejados en la capacidad de la sangre para transportar oxígeno. Al inhalarse, el CO interfiere con el transporte del oxígeno (O₂) a los tejidos porque la hemoglobina (que es el pigmento sanguíneo encargado del intercambio gaseoso tisular) tiene una afinidad 200 veces mayor por el CO que por el O₂. Cuando una molécula de hemoglobina adquiere una molécula de CO, se convierte en carboxihemoglobina (COHb). La presencia de carboxihemoglobina es la que disminuye la capacidad total de la sangre de llevar oxígeno a las células. La formación de COHb es un proceso reversible, con una vida media de disociación de unas dos o cuatro horas después de una exposición a bajas concentraciones.

La mayor fuente de CO en las zonas urbanas son los gases de escape de los automóviles. Los niveles típicos en zonas urbanas oscilan entre 5 y 100 ppm. "Además, se ha demostrado experimentalmente que niveles de COHb relativamente bajos pueden afectar la habilidad para estimar intervalos de tiempo, pueden disminuir el tiempo de reacción y reducir la sensibilidad visual en la oscuridad. Todo esto nos obliga a suponer que el CO contribuye a aumentar el número de accidentes de circulación"⁴.

A los niveles del 5% al 10% de COHb es cuando se deterioran la percepción visual, la destreza manual y la habilidad para aprender. Aunque las concentraciones de monóxido de carbono en el aire ambiente son generalmente más bajas, la EPA reconoce que aún con exposiciones de bajo nivel las personas con enfermedades cardiovasculares se encuentran en riesgo.

La exposición a bajos niveles de monóxido de carbono puede ser dañina cuando la gente toma medicamentos, ingiere bebidas alcohólicas o vive en altitudes elevadas.

Óxidos de nitrógeno (NOx)

Estudios de salud ocupacional han demostrado que el bióxido de nitrógeno puede ser fatal a concentraciones elevadas. A menores niveles, pero todavía mayores que los que se respiran en el aire ambiental, irrita los pulmones, es causa de bronquitis y neumonía, y provoca disminución de la resistencia a infecciones respiratorias, por ejemplo la influenza.

⁴ *op. cit.*: pag. 21

El dióxido de nitrógeno (NO_2) se transforma en los pulmones en nitrosoaminas, entre las cuales algunas pueden ser cancerígenas. Además se sabe que el dióxido de nitrógeno irrita los alveolos, produciendo síntomas parecidos a los del enfisema tras una exposición prolongada a concentraciones del orden de 1.0 ppm.

Ozono (O_3)

Todavía no se ha llegado a entender a fondo el efecto del ozono en las funciones pulmonares. En general, concentraciones de ozono próximas a 1.0 ppm producen un estrechamiento de las vías respiratorias del fondo de los pulmones que causa una mayor resistencia al paso del aire. Un tema de actualidad es el efecto atribuido a la exposición a bajos niveles de ozono del envejecimiento acelerado de los tejidos pulmonares por oxidación de ciertos compuestos en las proteínas. Las consecuencias de la exposición crónicas a largo plazo son todavía inciertas pero estudios recientes de epidemiología e inhalación animal sugiere que los niveles ambiente actuales son suficientes para causar el envejecimiento prematuro de los pulmones

La mayoría de la población de E.U. y de la ZMCM está expuesta a concentraciones de ozono suficientes para provocar cambios transitorios medibles en la función pulmonar, síntomas respiratorios y afectación de las vías respiratorias en personas sanas que realizan ejercicio y actividades recreativas en exteriores.

Las investigaciones más recientes indican que los efectos del ozono están relacionados más de cerca con la exposición acumulativa diaria que con las concentraciones máximas de una hora.

Óxidos de azufre (SO_2)

El dióxido de azufre es altamente soluble y como consecuencia es absorbido en los conductos húmedos del sistema respiratorio superior y por la nariz; como consecuencia, muy escasa cantidad llega a los pulmones. Exposición a niveles de SO_2 del orden de 1.0 ppm produce la constricción de las vías respiratorias.

La siguiente tabla muestra la información disponible respecto a los efectos del bióxido de azufre sobre la salud humana. Generalmente los datos se refieren a adultos sanos bajo condiciones experimentales de laboratorio.

Tabla 1.3.4.1 Efectos del bióxido de azufre sobre la salud humana

Concentración (ppm)	Tiempo de exposición	Efectos
0.15 - 0.25 1.0 - 2.0	1 - 4 días 3 - 10 min.	Respuestas cardiorrespiratorias. Respuesta cardiorrespiratoria en individuos sanos.
5.0	1 hora	Sofocamiento e incremento de resistencia en los pulmones.
10.0	1 hora	Peligro severo. algunas hemorragias nasales

FUENTE (Guadi, 1994)

Tal como se ha mencionado, niveles elevados de SO₂ suelen estar asociados con concentraciones elevadas de partículas. En una atmósfera contaminada con partículas suspendidas, el bióxido de azufre es perjudicial pues paraliza los cilios epiteliales del tracto respiratorio. Sin la acción regular del barrido de éstos, las partículas pueden penetrar en los pulmones y sedimentarse. Éstas usualmente acarrean con ellas cantidades concentradas de bióxido de azufre, y llevan directamente a este irritante a un íntimo y prolongado contacto con los tejidos de los pulmones. La combinación partículas bióxido de azufre se menciona como causa de muerte en varias tragedias de contaminación del aire.

En el siguiente cuadro se refieren los efectos sobre la salud, de la exposición combinada al SO₂ y las PST

SO ₂	PST	Efectos
0.03 ppm (media geométrica anual)	100 µg / m ³ (media geométrica anual)	Efectos sobre la visibilidad y molestias leves.
0.04 ppm (media aritmética anual)	250 µg / m ³ (media aritmética anual)	Síntomas respiratorios.
0.09 - 0.10 ppm (media aritmética anual)	250 µg / m ³ (promedio diario)	Empeoramiento de enfermedades pulmonares.
0.91 ppm (promedio diario)	500 µg / m ³ (promedio diario)	Aumento de la mortalidad y de las hospitalizaciones.

FUENTE Guadi, 1994

Partículas finas

La contaminación por partículas finas puede causar el deterioro de la función respiratoria en el corto plazo. En el largo plazo contribuye a enfermedades crónicas, al cáncer y a la muerte prematura.

Las partículas finas de tamaño menor a 10 micrómetros (PM10) son nocivas porque pueden penetrar a las cavidades pulmonares sin ser captadas por la acción de limpieza natural del sistema respiratorio. La EPA estima que en Estados Unidos más del ocho por ciento del cáncer de pulmón de no fumadores se debe a las PM10 contenidas en las emisiones de los vehículos que funcionan con diesel.⁵

Contaminantes aerobiológicos

El impacto potencial de este tipo de contaminantes sobre la salud consiste en la infección por micropartículas viables de microorganismos causantes de diversas enfermedades y alergias. Las principales enfermedades que pueden transmitirse por estos medios incluyen hepatitis, amibiasis, salmonelosis, tifoidea meningitis, asma, neumonía y diversas formas de gastroenteritis y bronquitis.

Plomo (Pb)

El plomo impide la realización de varias de las etapas de formación de la hemoglobina. Según la vía de penetración en el cuerpo, hasta un sesenta por ciento de todo el plomo ingerido puede ser retenido por el cuerpo de forma permanente.

Las enfermedades del sistema respiratorio están generalmente relacionadas con la contaminación del aire. El sistema respiratorio reacciona de dos maneras distintas a los contaminantes atmosféricos. La primera reacción es aguda, tal como la bronquitis irritante, y la segunda es crónica, tal como la bronquitis crónica y el enfisema pulmonar.

La contaminación atmosférica desempeña un papel patógeno en la bronquitis crónica, el enfisema y el asma. Además aumenta la morbilidad y/o la mortalidad en las personas que padecen enfermedades respiratorias.

1.3.5. Estudios en la ZMCM sobre el impacto de la contaminación del aire en la salud.

Los antecedentes de la investigación sobre los efectos de los contaminantes atmosféricos en la salud de los habitantes de la ZMCM son muy recientes. La evaluación y el seguimiento de estos efectos son responsabilidad oficial de la

⁵Quadri de la Torre, Gabriel, *La Ciudad de México y la Contaminación Atmosférica*. Limusa, México D.F. 1994, pag. 53

Secretaría de Salud. Aunque otros grupos de investigación en universidades o instituciones civiles han realizado también estudios de interés sobre el tema, los cuales representan los primeros intentos por diagnosticar específicamente los efectos en la población urbana de la ZMCM.

A continuación se hará mención de las conclusiones preliminares de algunos de estos estudios, como es el caso del reporte de febrero de 1991, *Estado actual de la vigilancia e investigación epidemiológica de los daños a la salud por efecto de la contaminación ambiental de la ciudad de México* (Secretaría de Salud)⁶.

- Se menciona que en el sistema de vigilancia epidemiológica no se observó asociación directa entre los niveles de los contaminantes y la morbilidad respiratoria reportada.
- El análisis de series de tiempo sugiere que existe una asociación positiva entre morbilidad respiratoria y niveles diarios de ozono.
- Utilizando modelos estadísticos se ha calculado que las concentraciones actuales de contaminantes pueden ocasionar un exceso anual de mortalidad de aproximadamente un 5% (aunque esto no ha sido corroborado en realidad).
- Las concentraciones actuales de contaminantes provocan molestias diarias en los residentes de la ciudad y pueden ocasionar un incremento en el riesgo de padecer enfermedades respiratorias y probablemente modifiquen la intensidad de éstas, principalmente en la población susceptible.

En ese mismo estudio se han estimado los daños potenciales a la salud que resultaron de la exposición a ozono (O₃) y partículas suspendidas totales (PST) en dos áreas de la ZMCM, el suroeste (Pedregal) y el noroeste (Tlalneantla). Este análisis se desarrolló bajo ciertos antecedentes:⁷

- La población expuesta se estimó con base en el Censo Nacional de Población de 1980.
- Los efectos fueron estimados mediante modelos matemáticos de dosis-respuesta sobre los siguientes síntomas y enfermedades.
- Los efectos del ozono fueron estimados para un periodo de exposición de una hora con concentraciones promedio típicas de las zonas evaluadas.

⁶Quadri . . . pag. 54
⁷ídem

Contaminación Atmosférica en la ZMCM

Con estos antecedentes se calculó la magnitud del problema de salud pública asociado a la exposición de los contaminantes en la ciudad de México. Los resultados obtenidos fueron:

Morbilidad por ozono

Síntoma	Zona suroeste (Izt. Iztap. Xoch. Tlalp)		Zona noreste (Ecat. Gustavo A. M. V. C.)		Total
	Niños	Ancianos	Niños	Ancianos	
Tos Moderada	50 480	5 680	64 675	7 520	128 355
Garganta irritada	128 850	15 350	168 645	20 480	333 325
Dolor de cabeza	47 160	5 340	60 530	7 072	120 102
Ojos irritados	245 530	20 715	171 300	17 540	455 085
Total	472 020	47 085	465 165	52 612	1 036 867

FUENTE: Cuadr. 1994

**Tasas de morbilidad y mortalidad en exceso por
partículas suspendidas totales**

Efectos	Zona suroeste	Zona noreste	Total
Mortalidad total (miles / 5 años)	0.61	5.0	5.61
Tos crónica en niños (millones / 5 años)	0.04	0.31	0.35
DPAR en adultos (miles de días / 5 años)	348.68	85.93	434.60
Bronquitis crónica en ancianos (miles)	2.7	16.6	19.3

FUENTE: Cuadr. 1994

De acuerdo con las tablas cabe resaltar por ejemplo que en un día típico en las zonas suroeste y noreste puede esperarse que aproximadamente 455,000 niños y ancianos sufran de irritación en los ojos y unos 333,000 aproximadamente de garganta irritada (con las características ambientales actuales). Por otro lado las PST pueden estar provocando (en un lapso de 5 años) una mortalidad en exceso de aproximadamente 5,600 personas.

Otros estudios del mismo reporte, señalan que el plomo puede estar relacionado con problemas de aprendizaje en niños de edad escolar y que la principal fuente de este elemento proviene de la respiración.

En otra investigación se demostró que la contaminación atmosférica en combinación con el tabaquismo potencializa las alteraciones de la función pulmonar.

Sin embargo, no se encontró que la contaminación atmosférica altere por sí sola la función pulmonar.

1.4 Características fisiográficas de la ZMCM y el problema de la contaminación atmosférica en esta zona.

El mal llamado Valle de México que en realidad es una cuenca de tipo endorreico, tiene características geográficas y atmosféricas particulares en el mundo. Se encuentra rodeada de montañas que impiden la entrada de vientos que dispersen los contaminantes. Se localiza a 2,240 metros de altura, lo que enrarece su atmósfera con 23% menos oxígeno que al nivel del mar. Su extensión es de más de 2 000km² y está enclavada sobre la porción suroeste de una cuenca lacustre de fondo plano limitada por grandes complejos montañosos de origen volcánico, al oriente, por la Sierra Nevada, cuyas cimas más elevadas sobrepasan los 5 000m; al sur, por las serranías del Ajusco y Chichinautzin, que virtualmente llegan a los 4 000m; y al poniente, por la Sierra de las Cruces, donde se superan los 3 000m. La parte media de la cuenca queda bloqueada por la Sierra de Guadalupe, donde los cerros más altos alcanzan los 2 600m.

Se presenta una alta incidencia de aire en calma, sobre todo en la temporada seca. Por ello y por la menor cantidad de oxígeno, sus procesos de combustión son ineficientes y por lo tanto más contaminantes. Por su localización geográfica recibe una gran insolación, lo que promueve la acelerada formación de ozono. Su altitud también incide para que la cuenca sufra constantes inversiones térmicas, aproximadamente ocurren 240 de ellas por año. Además sufre de sistemas atmosféricos que atrapan los contaminantes dentro de su cuenta.

En la actualidad la cuenca de México presenta severas alteraciones hidrológicas y ecológicas: prácticamente tres cuartas partes de sus bosques de coníferas y encinos han desaparecido y se han desecado casi la totalidad de sus lagos originales. Esta situación ha traído como consecuencia cambios en las condiciones climáticas a niveles regional y microrregional: por ejemplo, menos humedad y un incremento en las variaciones diarias y estacionales de temperatura.

Por otra parte, el gran desarrollo industrial en las zonas urbanas en los últimos 40 años y la falta de impulso al campo han provocado migraciones masivas a la ZMCM, acarreado como consecuencia la ocupación desordenada del suelo y una gran demanda de servicios, como agua, transporte y energía, lo que a su vez genera múltiples desequilibrios de carácter económico, urbano, energético, social y ambiental.

En la Zona Metropolitana de la Ciudad de México habita más de la quinta parte de la población nacional, se genera el 36% del PIB del país y se consume el 17% de la energía producida*

* SEDFOSOL, Informe de la situación general en materia de equilibrio ecológico en protección al ambiente 1993, 1994 I. N. E., México D.F. 1994

Contaminación Atmosférica en la ZMCM

Existen más de 30 mil industrias y 12 mil establecimientos de servicios, los cuales representan aproximadamente el 25% de la industria instalada en el país. Entre las industrias de la cuenca, 250 manejan residuos peligrosos y 4 mil poseen procesos de combustión o de transformación con emisiones significativas al aire.

La intensidad del uso del suelo y la enorme cantidad de actividades que se realizan en la ZMCM y sus alrededores, mantienen una tendencia creciente de emisión de contaminantes a la atmósfera. Además en nuestra Ciudad, casi todo el bienestar social está fundamentado en el consumo de combustibles que al quemarse generan contaminación atmosférica.

Por todo lo antes mencionado a la ZMCM se le ha puesto al borde de una situación ambiental calificada como insalvable. Sin embargo en la Ciudad se inició un gran esfuerzo por parte del Secretariado Técnico Intergubernamental⁹ (constituido por: las Secretarías de Desarrollo y Fomento Industrial, de Comunicaciones y Transportes, de Energía, Minas e Industria Paraestatal, de Agricultura y Recursos Hidráulicos, de Salud, el Departamento del Distrito Federal, el Gobierno del Edo. de Méx., y los Gobiernos Municipales de la zona conurbada, Petróleos Mexicanos, la Comisión Federal de Electricidad y el Instituto Mexicano del Petróleo) para revertir el deterioro de la calidad de su atmósfera y ha conseguido en corto plazo avances significativos y cuantificables.

Monitoreo.- La lucha contra la contaminación atmosférica es muy reciente en el Valle de México. Solo hasta finales de 1986 se contó con una *Red Automática de Monitoreo Atmosférico* (RAMA), y solo después de la primera mitad de 1987 se obtuvieron datos confiables sobre los niveles de contaminación en el aire. Actualmente la Red cuenta con 32 estaciones de monitoreo atmosférico y 2 unidades móviles de monitoreo atmosférico, las cuales se distribuyen en 17 municipios del Estado de México y en 16 delegaciones del D.F. (área que abarca la ZMCM). La Comisión Metropolitana para la Prevención y Control de la Contaminación Ambiental del Valle de México (CMPCCA/V/M) está a cargo del buen funcionamiento de esta red. Los contaminantes monitoreados son SO₂, NO_x, NO₂, PST, PM₁₀, O₃, CO y parámetros meteorológicos¹⁰.

Desde 1994 el sistema de monitoreo atmosférico de la ZMCM se compone de cinco elementos, siendo el principal la RAMA, mientras que las estaciones piloto, las unidades móviles de monitoreo atmosférico, la red manual y la red meteorológica son los elementos que la complementan o apoyan.

Inventario de emisiones.- No fue hasta 1989 que se elaboró el *primer inventario detallado de emisiones contaminantes*. Solo a partir de este inventario fue

⁹ Comisión Metropolitana para la Prevención y Control de la Contaminación Ambiental en el Valle de México, *Programa Integral Contra la Contaminación Atmosférica. "Un compromiso Común"*, CNIPCCA México D.F., 1990, pag. 2

¹⁰ SEDESOL, pag. 221

posible que el 15 de octubre de 1990, se instrumentara el *Programa Integral Contra la Contaminación Atmosférica (PICCA)* (más adelante se dedica un espacio especial para cada uno de estos dos temas).

En México, a partir del 29 de noviembre de 1982¹¹, la entonces Secretaría de Salubridad y Asistencia, estableció los lineamientos para determinar el criterio base para la evaluación de la calidad del aire; los valores fijados aparecen en la siguiente tabla:

Contaminante	Criterio (norma)
Monóxido de Carbono	11.0 ppm prom mov. 8hrs. a partir de 1995
Bióxido de Azufre	0.13 ppm prom. Mov. de 24 hrs
Bióxido de Nitrógeno	0.21 ppm en 1 hr
Ozono	0.11 ppm en 1hr.
Partículas menores a 10 micrómetros	150 µg/m ³ prom. Mov. de 24 hrs a partir de 1995
Partículas Suspensas Totales	275 µg/m ³ en 24 hrs.
Plomo	1.5 µg/m ³ promedio de 3 meses

ppm partes por millón

µg/m³ microgramos por metro cúbico

FUENTE D.D.F., marzo 1996

También, a últimas fechas, se estableció el Sistema Nacional de Información de la Calidad Ambiental (SNICA), el cual concentra la información de los inventarios de emisiones tanto de fuentes fijas como de fuentes móviles, y el Sistema Nacional de Monitoreo Atmosférico (SNMA).

Legislación. - Fue necesario adicionar la materia de Protección al Ambiente en la Constitución. Para mediados de 1988 finalmente se contó con la Ley General de Equilibrio Ecológico y de Protección al Ambiente (LGEEPA). Esta ley es una legislación reglamentaria extensa de la que a su vez se desprenden reglamentos y normas técnicas en materia de control y prevención de la contaminación atmosférica; la cual indica que -compete a las entidades federativas y municipios, en el ámbito de sus circunscripciones territoriales y conforme a la distribución de atribuciones que establezcan las leyes locales, la prevención y el control de la contaminación de la atmósfera generada en zonas o por fuentes emisoras de jurisdicción estatal o municipal¹². La responsabilidad del desarrollo y la ejecución de la LGEEPA recae esencialmente en el DDF, en el gobierno del estado de México y en la SEDUE (hoy SEMARNAP). A partir de esta ley se inició el desarrollo y la

¹¹ Comisión Metropolitana para la Prevención y Control de la Contaminación Ambiental en el Valle de México... pag. 29

¹² SEDESOL... pag., 214

expedición de las normas que establecen los límites precisos a la generación de contaminantes.

Actualmente se cuenta con 18 Normas Oficiales Mexicanas Ecológicas, que sumadas a las correspondientes a contaminación atmosférica y ruido, totalizan 51 normas relacionadas con la contaminación atmosférica.

1.4.1. Inventario de emisiones contaminantes, normas y criterios de la calidad del aire en la ZMCM.

Para diseñar una política efectiva de gestión de calidad del aire, es esencial la identificación de sus emisiones. Este conocimiento debe estar sistematizado por medio de un inventario que sirva como herramienta para definir prioridades, identificar las medidas de control pertinentes y evaluar los impactos derivados de la instrumentación de estas medidas.

Los inventarios de emisiones son registros organizados y clasificados de las fuentes potencialmente emisoras de contaminantes al aire ubicadas dentro de los límites de una cuenca atmosférica, y que se emplean para establecer la cantidad y la tendencia de las emisiones, los estándares de emisión en las normas de calidad del aire y las prioridades en su control.

A pesar de los esfuerzos realizados por las autoridades y por dependencias e investigadores nacionales y extranjeros, debe reconocerse que la caracterización de las fuentes contaminantes, así como su clasificación y sistematización son problemas que aún no se han resuelto de manera satisfactoria en la ZMCM.

De acuerdo con Quadri (Quadri, 1994), existe una *matriz de emisiones*, la cual es una síntesis y un desarrollo de la información proveniente de diversas fuentes, complementada con evaluaciones propias del autor. Debe destacarse el carácter preliminar de los valores que se reportan

Antes de presentar la tabla de la matriz de emisiones, es necesario presentar una que contiene la clasificación por sectores de actividad urbana y que servirá para interpretar mejor la matriz de emisiones.

Tabla 1.4.1.1 Sectores de actividad urbana considerados en la matriz de emisiones

Transporte	Transporte privado
	Transporte de servicio público a gasolina (taxis y colectivos)
	Transporte de autobuses urbanos (R-100)
	Transporte de autobuses suburbanos (sistema de transporte del edo. de Mex y líneas particulares)
	Transporte foráneo de pasajeros
	Transporte ligero de carga a diesel
Producción y manejo de energéticos	Transporte pesado de carga a diesel
	Transporte de carga a gasolina
	Termoeléctrica Valle de México
Industria	Termoeléctrica Jorge Luque
	PEMEX
Industria	Industrias
Servicios	Servicios
Degradación ecológica	Suelos

FUENTE: Ovarin, 1994

El objetivo de mostrar la *matriz de emisiones* (Tabla 1.4.1.2) es resaltar los resultados obtenidos para el Bióxido de Azufre (SO₂) -siendo el contaminante de interés de este trabajo-, y que más adelante proporcionarán información importante para entender las medidas aplicadas para la disminución y control del mismo.

De esta manera observamos que de acuerdo con la información planteada en la matriz, las principales emisiones de SO₂ provienen del sector industrial y del transporte: el primero contribuye con el 77%, y el segundo con el 16% del total, siendo solo el 2% proveniente del sector energía y el 6% del sector servicios.

Como resultado de la comparación en unidades de toxicidad, la importancia de los sectores industrial, de energía, de servicios y de suelos, aumenta, y la del sector transporte disminuye. Sin embargo, aun con esta perspectiva, la importancia del sector transporte continúa siendo ponderante. Esto significa que sus emisiones al igual que las emitidas por industrias, a parte de ser las más significativas, también representan en conjunto la prioridad de mayor nivel en el control de la contaminación del aire desde el punto de vista toxicológico y de reactividad de las emisiones.

Tabla 1.4.1.2. Matriz de inventario de emisiones (toneladas/año)

Cont	Transporte								Energía			Industria	Servicios	Suelos	Totales
	TRANS PRIV	TSPG	TCG	TCDL	TCDP	R-100	T SUB	T FOR	V. MEX	J LUQ	PEMEX				
NO _x	54 665	6954	4661	14670	1210	4400	10980	800	9 200	1 740	0	33 883	1 434	0	145 947
HC	215 955	36239	17896	1440	120	560	260	100	46	10	25 460	52 792	0	0	350 900
SO ₂	5 218	4 095	608	5 560	20	270	210	0	0	0	0	30 010	260	0	37 105
PM ₁₀	4 45%	0 94%	0 62%	5 58%	0 02%	0 09%	0 08%	0 00%	0 01%	0 01%	0 00%	1 88%	5 51%	0 00%	30 00%
UTE	15 34	3 22	0 19	18 44	0 00	0 34	0 25	0 00	0 00	0 00	0 00	28 97%	4 52%	0 00%	34 14%
UTE	0 47%	0 10%	0 06%	0 57%	0 00%	0 02%	0 02%	0 00%	0 00%	0 00%	0 00%	0 17%	0 50%	0 00%	10 00%
PST	14 516	2323	1440	380	150	260	660	50	124	76	0	64 213	504	225	309 945
CO	2499959	623745	340884	3590	320	3040	6900	550	663	121	0	21 759	0	0	3 438 831
Pb	860	146	74	0	0	0	0	0	0	0	0	0	0	0	1 100

UTE Unidades de Toxicidad Equivalente


% UTE porcentaje con respecto al total de unidades de toxicidad equivalente

FUENTE: Cuadri, 1994

Evaluación de la calidad del aire.

La calidad del aire de una cuenca atmosférica depende en todo momento de la emisión de contaminantes, del comportamiento fisicoquímico de éstos y de la dinámica meteorológica, que determinan su dispersión, transformación y remoción. Así mismo, la calidad del aire se explica por la cantidad de combustibles consumidos (quemados) en una zona determinada, por su calidad, por las tecnologías de combustión y control de emisiones empleadas, por el arrastre de polvos desde zonas desecadas o desprovistas de vegetación, por las condiciones meteorológicas que determinan la dispersión de los contaminantes, y por la fisicoquímica atmosférica que define los procesos y productos de iteracción entre diferentes contaminantes.

Las dos últimas variables están fuera de la influencia humana, mientras que las primeras cuatro dependen de una serie de factores económicos relevantes.



FUENTE: Cuadró, 1994

Ahora bien, los efectos de la contaminación atmosférica dependen a su vez de las concentraciones, la frecuencia y tiempo de exposición.

Varios países desarrollan políticas de control ambiental con base en normas o criterios de calidad del aire. Éstos establecen las concentraciones máximas permisibles de contaminantes para asegurar la protección de la salud y el bienestar de la población. En tanto que representan objetivos de política, dichos valores sirven como referencia de evaluación de la calidad del aire en determinados periodos.

En México, estos parámetros poseen la categoría de *criterios de evaluación de la calidad del aire* (1982). Dichos criterios son, en general, equivalentes a los que rigen en la mayoría de los países industrializados.

Contaminación Atmosférica en la ZMCM

Con base en la información generada por la Red de Automática de Monitoreo Atmosférico (RAMA), la SEMARNAP emite diariamente un reporte sobre la calidad del aire en la forma de *Índice Metropolitano de Calidad del Aire* (IMECA), el cual describe numéricamente los niveles de contaminación. La determinación del IMECA se realiza a partir de los valores de referencia como:

- Un valor IMECA de 100 puntos corresponde a la norma para cada contaminante.

- Un valor IMECA de 500 representa niveles de contaminación por los cuales existen evidencias de daños significativos a la salud.

Entonces la escala IMECA se define conforme a los criterios y concentraciones que se muestran en las siguiente tablas.

Tabla 1.4.1.3. Criterios de evaluación de la calidad del aire

Contaminante	Tiempo de promedio	Concentración límite	Equivalencia en IMECA
Dióxido de Azufre (SO ₂)	24 horas*	0.13 ppm	100
Monóxido de carbono (CO)	8 horas*	13.0 ppm	100
Ozono (O ₃)	1 hora	0.11 ppm	100
Dióxido de nitrógeno (NO ₂)	1 hora	0.21 ppm	100
Piombo (Pb)	3 meses	1.5 µg/m ³	100
Partículas Suspensas Totales (PST)	24 horas	275 µg/m ³	100
Partículas suspendidas menores a 10 µm (PM10)	24 horas*	150 µg/m ³	100

* promedio móvil (prom. mov.)

Tabla 1.4.1.4. Concentraciones límite de la escala IMECA y criterios de calificación

IMECA	Calidad del aire	Contaminantes y tiempo de promedio					O ₃ (1h)
		PST (24hrs)	PM10 prom mov de 24hrs	SO ₂ prom mov de 24hrs	NO ₂ (1h)	CO prom mov de 8hrs	
0 - 100	Satisfactoria	275*	150*	0.13**	0.21**	13**	0.11**
101 - 200	No satisfactoria	546*	350*	0.35**	0.66**	22**	0.23**
201 - 300	Mala	637*	420*	0.56**	1.10**	31**	0.35**
301 - 500	Muy mala	1000*	600*	1.00**	2.00**	50**	0.60**

* µg/m³

** ppm

FUENTE Quadri, 1994

Tabla 1.4.1.5. Índice metropolitano de la calidad del aire

IMECA	Calidad del aire	Indicaciones y efectos
0 - 100	Satisfactoria	Situaciones favorables para la realización de todo tipo de actividades físicas
101 - 200	No satisfactoria Mala	Molestias menores en personas sensibles
201 - 300		Aumento de molestias e intolerancia relativa al ejercicio en personas con padecimientos respiratorios
301 - 500	Muy mala	Aparición de diversos síntomas e intolerancia al ejercicio en la población sana

FUENTE: SEDESOL, 1994

1.5 Programa Integral Contra la Contaminación Atmosférica (PICCA)

Desde el 15 de octubre de 1988 se ha venido instrumentado el Programa Integral Contra la Contaminación Atmosférica (PICCA) en la Zona Metropolitana de la Ciudad de México. El objetivo de este programa ha sido generar un proceso sistemático con alcances de corto, mediano y largo plazo, abocado a mejorar la calidad del aire en la ZMCM, de manera coordinada con todas las entidades competentes, las organizaciones sociales y con la participación de la población.

Cientos de profesionistas de las ramas ambientales y de una amplia gama de otras especialidades han participado en el desarrollo e instrumentación del PICCA, desde sus muy diversos núcleos de trabajo: centros de investigación superior y universidades, dependencias gubernamentales, cámaras y asociaciones industriales, etcétera.

El Departamento del Distrito Federal, la entonces SEDUE, Petróleos Mexicanos, el Instituto Mexicano del Petróleo y el Gobierno del Estado de México prepararon este conjunto de medidas para aplicarse tanto en las unidades y sistemas de transporte como en la industria, los servicios, las actividades de producción de energéticos y en zonas suburbanas. El programa se coordina por medio de la Comisión Metropolitana para la Prevención y Control de la Contaminación Ambiental en el Valle de México (CMPCCAVM); y Petróleos Mexicanos, a través del mejoramiento de combustibles, se le asignaron mayor cantidad de compromisos que conllevó a una mayor contribución al presupuesto para la aplicación del PICCA.

El PICCA es una estrategia flexible a la que progresivamente se le han ido incorporando nuevas medidas una vez que se alcanza su viabilidad técnica, financiera y social.

Este Programa actúa en cinco líneas estratégicas de acción:

1. La promoción de la investigación local, la educación ambiental, así como la participación ciudadana.

Se ha venido incorporando una nueva cultura ambiental en los programas educativos, se han producido múltiples materiales didácticos y programas de participación ciudadana.

2. El mejoramiento en la calidad de los combustibles, empleando criterios ambientales para que éstos sean cada vez más limpios, menos reactivos y menos tóxicos.

Para tener mejores combustibles se han realizado, en muy corto plazo, transformaciones muy significativas. Ahora las gasolinas son oxigenadas para mejorar su combustión y reducir la generación de contaminantes a la altura de la cuenca de México. Se cuenta con gasolina sin plomo, que ha hecho posible la introducción de convertidores catalíticos en los vehículos y, junto con la reducción de 92% en el contenido de plomo en la gasolina Nova, han permitido reducir las concentraciones de plomo en la atmósfera hasta cumplir con la normatividad que protege la salud.

Actualmente, la calidad ambiental de las gasolinas de la cuenca de México es superior a la del promedio en los Estados Unidos y cumple con la estricta normatividad vigente en el estado de California.

Por otra parte, se sustituyó el combustóleo por gasóleo industrial, que contiene 33% menos azufre y 99.5% menos impurezas. En octubre de 1993 se introdujo el Diesel Sin con el contenido de azufre más bajo en el ámbito mundial. Estas medidas, junto con la creciente introducción de gas en industrias y transporte, han permitido que el bióxido de azufre en nuestra atmósfera ya no rebasa la norma que protege la salud.

3. La ampliación y el mejoramiento del transporte colectivo y el control de emisiones de los vehículos en circulación.

Dentro de esta línea de trabajo se busca reducir la generación de emisiones contaminantes por pasajero transportado. Por ello se ha enfatizado la ampliación continua y permanente del Metro. Los taxis y microbuses se están cambiando por nuevos vehículos que incorporan el convertidor catalítico. Se están renovando los trolebuses y se introdujo nuevo equipo en el Tren Ligero que va a Xochimilco.

4. La modernización de la industria, incluyendo el mejoramiento de sus procesos y el control de sus emisiones contaminantes.

Los compromisos y mecanismos para el control de las emisiones industriales han sido reforzados. A partir de julio de 1992, todas las industrias tienen que cumplir con una verificación obligatoria de sus emisiones cada año, para garantizar el cumplimiento de la normatividad ambiental.

5. La restauración ecológica del Valle de México y la reforestación.

Se han expropiado y preservado para la Ciudad áreas ecológicamente frágiles como el Ajusco, Xochimilco, el Desierto de los Leones, la Sierra de Guadalupe y la Sierra de Santa Catarina. Se han creado múltiples parques urbanos y antiguos tiraderos de basura están siendo convertidos en zonas arboladas.

1.5.1. Paquete Ecológico de PEMEX (Compromisos y metas de la Industria Petrolera).

El mejoramiento de los combustibles que se emplean en la Zona Metropolitana de la Ciudad de México constituye la estrategia principal del Programa Integral Contra la Contaminación Atmosférica, tanto desde el punto de vista económico y financiero, como de las metas que se pueden alcanzar en la reducción de emisiones contaminantes.

El *compromiso* que se impuso PEMEX fue el de producir mejores combustibles en los plazos más cortos. Para ello, se realizaron importantes erogaciones para adicionar MTBE (éter metil terbutílico) a las gasolinas y distribuir la nueva gasolina Magna Sin.

Las *medidas* necesarias para alcanzar estos compromisos se agruparon en el denominado Paquete Ecológico de PEMEX, el cual consistía básicamente en las siguientes acciones¹³:

1. *Elaboración de gasolinas de calidad ecológica internacional.*
Producción y distribución de gasolinas sin plomo "Magna Sin", para todos los automotores que para 1991 incluían convertidor catalítico.
2. *Elaboración de diesel con bajo contenido de azufre.*
Este proyecto consistía en instalar cuatro plantas hidrosulfuradoras, con el fin de obtener diesel con bajo contenido de azufre. Con esta medida se reduciría el contenido de azufre del 0.5%, a solamente el 0.1%. Es decir, permitiría reducir en 80% el azufre contenido en el diesel, con lo que se disminuirían las emisiones de partículas y bióxido de azufre a la atmósfera.
3. *Elaboración de combustóleo con bajo contenido de azufre.*
Más de la mitad de combustóleo que se consumía en 1990 en la ZMCM contenía un promedio de 4% de azufre. Con la ejecución de esta medida, dicho contenido se reduciría a solamente 0.8%, una disminución de más del 80% en relación al contenido en ese momento. Se estima que las emisiones de dióxido de azufre en

¹³Comisión Metropolitana para la Prevención y Control de la Contaminación Ambiental en el Valle de México, Programa Integral Contra la Contaminación Atmosférica. "Un compromiso Común", CMPCCA México D. F. 1990, pag. 36

Contaminación Atmosférica en la ZMCM

la ZMCM disminuirían en 54.4% respecto a las que se generaban por concepto de la quema de este combustible.

A partir de 1986, Petróleos Mexicanos se dio a la tarea de elaborar combustóleo ligero con un contenido de azufre controlado (3%).

4. *Elaboración de los compuestos oxigenados TAME y MTBE.*

Esta medida comprendía la instalación de plantas para la obtención de éter metil terbutílico (MTBE) y Eter ter-amil metílico (TAME). La adición de MTBE y el TAME tenía el fin de optimizar la combustión y elevar el índice de octano de las gasolinas.

5. *Suministro de gasolinas sin plomo a los vehículos 1991 y con convertidor catalítico.*

El gobierno Federal y la Industria Automotriz acordaron en 1986 la instalación de convertidores catalíticos a partir de 1991. Por tal motivo, PEMEX programó la introducción de la gasolina MAGNA SIN, la cual posee un contenido de plomo inferior a los 0.01 g por galón.

6. *Continuar con el suministro de gasolinas oxigenadas en la ZMCM.*

El 20 de noviembre de 1989 se introdujeron gasolinas adicionadas con MTBE, el cual es un compuesto que compensa el déficit de oxígeno atmosférico y, en consecuencia, contribuye a aumentar la eficiencia de combustión. Además, incrementa el índice de octano.

7. *Recuperación de azufre en la Refinería 18 de Marzo.*

Esta medida contemplaba la modernización de la actual planta recuperadora del azufre contenido en los gases provenientes de la planta catalítica de la refinería Azcapotzalco, en el Distrito Federal, y la instalación de una segunda planta del mismo tipo. Su objetivo era ampliar la eficiencia del proceso de recuperación de dicho elemento para reducir las emisiones de la refinería de Azcapotzalco a la atmósfera de la ZMCM.

8. *Recuperación de vapores de HC y cambio de quemadores en la Refinería 18 de Marzo.*

Esta media consistía en la instalación de una planta recuperadora de hidrocarburos, así como en la instalación y prueba de un quemador de bajo NO_x en un equipo de combustión.

9. *Monitoreo de emisiones en chimeneas de la Refinería 18 de Marzo.*

Las emisiones de la Refinería 18 de Marzo eran muy diversas, por lo que fue necesario monitorearlas periódicamente. Esta información permitiría adoptar medidas inmediatas para el control de emisiones contaminantes. De igual manera, se apoyaría a la Autoridad en la determinación de la calidad del aire en las inmediaciones de este centro de trabajo.

En cumplimiento de esta medida, PEMEX instaló en la Refinería 18 de Marzo medidores de oxígeno.

10. Instalación de membranas flotantes en los tanques de almacenamiento de combustibles.

El programa de instalación de membranas internas flotantes comprendía 23 tanques de almacenamiento de petróleo y de gasolina, que evitará pérdidas por evaporación hacia la atmósfera en un 98%.

11. Instalación de equipos para la recuperación de vapores en terminales de recibo y distribución de combustibles, y gasolineras.

Con relación a la medida en las terminales de recibo y distribución de Petróleos Mexicanos, se modificó las instalaciones para el llenado de autotanques por la parte inferior, con lo que se disminuye la emisión de vapores de hidrocarburos.

Resultados de la aplicación del PICCA

Con el programa se lograron los siguientes resultados:

- Que en la Ciudad de México no se rebasen las normas internacionales de plomo.
- Logró, en forma permanente, que en el aire de la Ciudad de México no se rebasen las normas nacionales e internacionales de bióxido de azufre. El programa permitió reducir en dos terceras partes, las concentraciones de bióxido de azufre en la atmósfera, lo que representó un importante avance para la salud humana.
- Se frenó el incremento en el aire de los niveles de partículas originadas por la destrucción de bosques, erosión de suelos y tiraderos clandestinos.
- Con este programa se redujo en forma significativa los hidrocarburos así como los óxidos de nitrógeno, ambos precursores del ozono

Como se menciona en el PICCA, "si en 1986 no se hubiera empezado a sustituir combustóleo por gas en las termoeléctricas, y si en 1989 no se hubiera organizado la verificación vehicular, ni se hubieran introducido las gasolinas oxigenadas y el programa HOY NO CIRCULA; y sobre todo, si no se contara con el Programa Integral Contra la Contaminación Atmosférica el problema de la contaminación del aire habría atentado contra la viabilidad de la Ciudad" (SEDUE, 1994).

1.6 El Bióxido de Azufre (SO₂) como uno de los principales contaminantes atmosféricos de la ZMCM

Como se mencionó anteriormente, el dióxido de azufre tiene un efecto irritante por ser muy soluble, la mayor parte de lo que se inhala se absorbe en la nariz y en las vías respiratorias superiores, siendo muy escasa la cantidad que llega a los pulmones. Cuando la atmósfera esta contaminada con partículas suspendidas, el bióxido de azufre es transportado por éstas hasta los tejidos de los pulmones, incrementando su potencial de daño. Sin embargo, la importancia del bióxido de azufre como contaminante va más allá de su concentración como tal en la atmósfera. Una vez en el aire, se transforma en sulfatos por medio de reacciones que involucran la formación de ácido sulfúrico, por lo que contribuye en forma importante a la producción de lluvia ácida y la depositación de partículas que acidifican el suelo, los cuerpos de agua y corroen materiales. Además, los sulfatos incrementan la concentración de partículas suspendidas en el aire y contribuyen sensiblemente a la disminución de la visibilidad. A este respecto, en la ZMCM se han encontrado evidencias de que el contenido de sulfatos es relativamente alto en el norte de la ciudad y que la lluvia presenta en ocasiones niveles ligeramente ácidos.

El dióxido de azufre proviene principalmente de la quema de combustibles que contienen azufre -combustóleo y diesel-, además de producirse en los procesos de refinación del petróleo. El petróleo mexicano se caracteriza por su alto contenido natural del azufre el cual permanece en la composición de los productos petrolíferos como una impureza. En los procesos de combustión, el azufre contenido en el combustóleo, gasóleo, diesel o gasolina, se transforma en bióxido de azufre.

Ahora bien, las emisiones de SO₂ provienen principalmente del sector industrial, el cual es responsable potencial de la emisión anual de 90 mil toneladas de bióxido de azufre. De ellas 49% las emite la industria de celulosa y papel y 16% se debe a la producción de textiles. El resto se reparte entre las demás ramas industriales.

De acuerdo con lo anterior, el SO₂ es el elemento que más contribuye a la contaminación por industria, siendo un producto de la combustión del combustóleo y del gas, representa 58% del total de UTE (unidad de toxicidad equivalente) emitidos al año por el sector industrial.

El total de establecimientos de servicios emiten a la atmósfera 6569 toneladas anuales de SO₂. A nivel regional o delegacional, la delegación Cuauhtémoc es la que presenta mayores emisiones (33.4%), le sigue la Miguel Hidalgo con 19.1% y la Venustiano Carranza con 8.4%. En estas tres delegaciones se concentra poco más del 60% del SO₂¹⁴.

¹⁴ Quadri ... pag. 152

Por tipo de actividad los establecimientos que generan mayores problemas son los baños, pues emiten 54.4%, siguen en importancia los deportivos con 13.9%, las tintorerías con 11.1%, y los hoteles con 10.7%. En promedio, un baño público emite 19 veces más SO_2 que una tintorería, y 8 veces más que un hotel¹⁵.

Porcentajes de emisión del SO_2 por giro respecto del total de emisiones de los establecimientos mercantiles en el D.F.

Establecimiento	% de emisión	Establecimiento	% de emisión
Panaderías	5.5	Tintorerías	11.1
Hoteles	10.6	Deportivos	14.0
Baños	54.5	Hospitales	2.1
Molinos	0.1	Otros	2.1

FUENTE: Quadri, 1994

Emisión anual de SO_2 por establecimientos mercantiles en el D.F..

Delegación	SO_2 , ton/año	%	Delegación	SO_2 , ton/año	%
Azcapotzalco	174.14	4.21	Iztapalapa	148.52	3.59
V. Carranza	346.03	8.37	B. Juárez	265.24	6.41
Cuajimalpa	6.52	0.16	G. A. Madero	304.18	7.35
Cuauhtémoc	1 382.19	33.42	Miapa Alta	0.33	0.08
M. Contreras	54.90	1.33	A. Obregón	197.90	4.78
Coyoacán	223.90	5.40	Tláhuac	0.33	0.08
M. Hidalgo	788.08	19.06	Tlalpan	60.00	1.45
Iztacalco	153.38	3.71	Xochimilco	30.10	0.73
			Total	4 135.13	100.00

FUENTE: Quadri, 1994

En cuanto al consumo de combustibles, la gasolina y el diesel constituyen el 90% de la energía consumida por el sector transporte; el gas, el combustóleo y el diesel representan el 70% de la energía utilizada por la industria; el diesel y las kerosinas aportan cerca del 77% de los energéticos empleados en el sector agropecuario y el gas licuado aporta un 32% de la energía consumida por los sectores comercial, residencial y privado¹⁶. Por lo tanto es importante conocer la relación de combustibles vendidos en la ZMCM y su contenido de azufre, para así saber el total de emisiones que generan estos combustibles. La siguiente tabla muestra dicha relación.

¹⁵ Quadri, ..., pag. 158

¹⁶ Instituto Mexicano del Petróleo. *Impacto en la calidad del Aire en la ZMCM debido a la reducción en las emisiones del Dióxido de Azufre*. Informe técnico GCA-9527, SGIDTTI/GCA, Inédito, México D.F. 1995, pag. 5, 6

Contaminación Atmosférica en la ZMCM

Combustible	Periodo de venta	Contenido de Azufre (% en peso)	Densidad (kg/l)
Gasolina Extra	1987 - Ago 1990	0.15	0.748
Gasolina Nova	1986 - a la fecha	0.15	0.748
Gasolina Magna-Sin	Sep 1990 - a la fecha	0.1	0.748
Diesel-Sin	Oct 1993 - a la fecha	0.05	0.838
Diesel Desulfurado	1986 - a la fecha	0.5	0.83
Diesel Nacional	1986 - Abr 1991	2.0	0.83
Combustóleo Pesado	1986 - 1991	4.0	0.9993
Combustóleo Ligero	1986 - 1991	1.8	0.9948
Gasóleo Industrial	Abr 1991 - a la fecha	2.0	0.89

FUENTE: IMP, 1995

En resumen, las principales emisiones del bióxido de azufre provienen del sector industrial y del transporte (ver tabla 1.4.1.1); el primero contribuye con 77%, el segundo con 16% del total, en los cuales se utilizan combustibles que contienen azufre.

Por todo lo anterior, en la Ciudad de México, para el control de las emisiones de bióxido de azufre a la atmósfera, se han realizado acciones orientadas a la elaboración de combustibles con menor contenido de azufre para todos los usos, así como la sustitución por combustibles más limpios en las termoeléctricas, la industria, el transporte y los servicios (PICCA y Paquete Ecológico). El siguiente cuadro contiene las medidas más importantes y la fecha de su aplicación.

Tabla 1.6.1 Medidas implementadas por la Industria Petrolera para disminuir las emisiones de azufre a la atmósfera de la ZMCM.

No	MEDIDA	Fecha de aplicación
1	Introducción de Magna-Sin (0.1% de azufre)	septiembre - 90
2	Cierre de la Refinería 18 de Marzo	marzo - 91
3	Introducción de Gasóleo (2.0% de azufre). Se deja de vender Diesel Nacional (2.0% de azufre)	abril - 91
4	Se prohíbe la venta de Combustóleo (4.0 - 1.8% de azufre)	diciembre - 91

5	Medidas para la época Invernal. Se elimina el consumo total de combustibles con contenido de azufre > 2.0%. Esta medida se mantuvo en definitiva dentro de la ZMCM.	dic - marzo 91 - 92
6	Medidas para el Invierno. Reducción adicional del contenido de azufre en gasóleo, de 2.0 a 1.5%.	dic. - marzo 92 - 93
7	Introducción de Diesel-Sin (0.05% de azufre)	octubre - 1993
8	Medidas para el Invierno. Reducción adicional del contenido de azufre en gasóleo, de 2.0 a 1.5%.	dic - marzo 93 - 94
9	Medidas para el Invierno. Reducción adicional del contenido de azufre en gasóleo, de 2.0 a 1.5%.	dic - marzo 94 - 95

Como resultado de lo anterior y de acuerdo con el estudio realizado en el IMP sobre *El impacto en la Calidad del Aire en la ZMCM debido a la reducción en las emisiones del dióxido de azufre*¹⁷, se tiene que:

- El beneficio de las medidas de PEMEX es notorio a partir de la introducción del gasóleo y la suspensión del uso de combustibles con alto contenido de azufre (1991).
- El porcentaje de reducción de la emisión de compuestos de azufre en el periodo 1989-1995 (75%) por las medidas implementadas exclusivamente por PEMEX, es similar al porcentaje de reducción esperado por el PICCA (79%), aún cuando no todas las medidas de control propuestas en el PICCA eran de la competencia de PEMEX y no todas se llevaron a cabo.
- La tendencia promedio de la concentración de dióxido de azufre en el aire ha disminuido significativamente a partir de 1992, teniendo un valor estable de 15 ppb a partir de 1993 a la fecha. Este valor es prácticamente la décima parte del valor asignado a la norma mexicana correspondiente (130 ppb).
- De 1988 a 1994 la reducción en la concentración de SO₂ en el aire ha sido del 35% en promedio y de 75% la reducción en la emisión de compuestos de azufre a la atmósfera, esto es, no se encuentran en proporción directa, indicando que no todo el SO₂ en la atmósfera es debido al consumo de combustibles fósiles, quizás es incorporado a la ZMCM por el viento proveniente de otras regiones.
- Como era de esperarse, las concentraciones más altas de este contaminante se presentan en las áreas de mayor actividad industrial -como Xalostoc- y de tránsito (principalmente de vehículos a diesel) -como Merced-, identificadas en el cuadrante noroeste y centro de la Ciudad, disminuyendo en forma gradual hacia el sur.

¹⁷ Instituto Mexicano del Petróleo.... pag. 12

Contaminación Atmosférica en la ZMCM

- Además, los valores más elevados ocurrieron en invierno cuando las condiciones de dispersión son reducidas y durante el verano los menores valores debido a la influencia de las lluvias.

Así pues, observamos que las estrategias realizadas por PEMEX para la disminución y el control de la emisión de contaminantes a la atmósfera han resultado favorables en su conjunto para el SO_2 . El resultado mas significativo de estas estrategias, es que han logrado mantener a este contaminante por debajo de la norma establecida (0.13 ppm). Pero lo importante ahora es saber si estas medidas seguirán manteniendo estable al bióxido de azufre por debajo de la norma, o en su lugar tienden a crecer hasta llegar nuevamente a violar la norma de 0.13 ppm. Además también es importante conocer cuál fue el impacto que tuvo cada una de las estrategias por sí sola.

Considerando que las observaciones anteriores son importantes de aclarar y con esto tener un mejor conocimiento de la eficiencia del trabajo realizado por PEMEX y el Instituto Mexicano del Petróleo, este trabajo pretende dar respuesta a estas interrogantes aplicando el Análisis de Series de Tiempo y el Análisis de Intervención a los registros mensuales de las concentraciones de bióxido de azufre en la atmósfera durante el periodo en el que se han aplicado las estrategias de la Industria Petrolera.

Capítulo 2.

Análisis de series de tiempo.

El interés primordial de este capítulo es describir detenidamente la metodología de Box-Jenkins y mencionar brevemente los conceptos teóricos que están relacionados con ella. Por tal razón, se dedica un espacio específico para estos temas (sección 2.4); no sin antes, mostrar un panorama general de los métodos de pronósticos más comunes en una recopilación bibliográfica y dejar bien especificado el lugar que le corresponde dentro de los mismos (Secciones 2.1, 2.2, 2.3).

2.1 Métodos de Pronósticos

En la actualidad tomar decisiones importantes requieren de pronósticos del futuro; por lo que virtualmente todos los gerentes o administradores necesitan algún tipo de pronósticos.

El pronóstico es una técnica que ayuda a predecir lo que ocurrirá en el futuro¹. Es un elemento necesario del proceso de planeación, pero no es la planeación en sí. El pronóstico nos dice lo que pasará si las tendencias históricas no cambian; si esto no sucede, cada pronóstico debe ajustarse de lo contrario resultara engañoso.

Los pronósticos, pueden diferir en cuanto a su importancia, al marco de referencia y al nivel administrativo. Debido a diferencias como éstas, existen muchos métodos de pronóstico.

Puesto que no solo una técnica de pronóstico es aplicable a todos los procesos de decisión en una organización (ninguna resulta ser la mejor para todos los objetivos), surge la inquietud de mostrar brevemente las técnicas de pronósticos más comunes, así como sus características, limitaciones, problemas y recomendaciones; con el fin de obtener un compendio de ellas y poder elegir la más adecuada según las necesidades del análisis, además de mostrar que la de Box-Jenkins es la adecuada para el presente trabajo.

Con base en: Gallagher (1989), Makridakis (1989) y Prawda (1994) se comenzará por clasificar los tipos de métodos de pronósticos disponibles, así como los elementos que determinan la elección adecuada de cada uno de ellos; y conforme se vayan estudiando, se irán aclarando sus diferencias.

¹ Prawda, Juan., *Métodos y modelos de investigación de operaciones. Vol 2. Modelos Estocásticos*, Limusa, México D.F., 1984.

2.1.1. Clasificación de los métodos de pronósticos.

Dado que existen muchos métodos de pronósticos, es necesario comprender su clasificación (figura 2.1.1.1). A las técnicas de pronósticos, la mayoría de los autores, las dividen en dos grandes grupos: cuantitativas y cualitativas o tecnológicas. Los estudios están más desarrollados en el primer grupo que en el segundo.

En la clasificación general los métodos de pronósticos también pueden dividirse dependiendo del tiempo que abarcan los pronósticos, estos pueden ser a *corto, mediano y largo plazo*.

Los *métodos de pronósticos a corto plazo* tienen un horizonte de tiempo de un día a un mes hacia el futuro. La mayor utilidad de estos pronósticos está al manejar las operaciones diarias de un sistema.

Con los *métodos de pronósticos a mediano plazo* se hacen proyecciones de un mes a un año hacia el futuro. Estos pronósticos son importantes como ayuda en decisiones sobre qué recursos se necesitan y cómo pueden usarse de la manera más eficaz.

Los *métodos de pronósticos a largo plazo* tienen un horizonte de más de un año. Los pronósticos a largo plazo son quizá los más importantes, ya que ayudan a proporcionar una guía directriz para la organización. Sin embargo, también son las más difíciles en obtener su confiabilidad, pues mientras más largo sea el horizonte de tiempo a pronosticar, mayor es la incertidumbre que existe sobre el futuro.

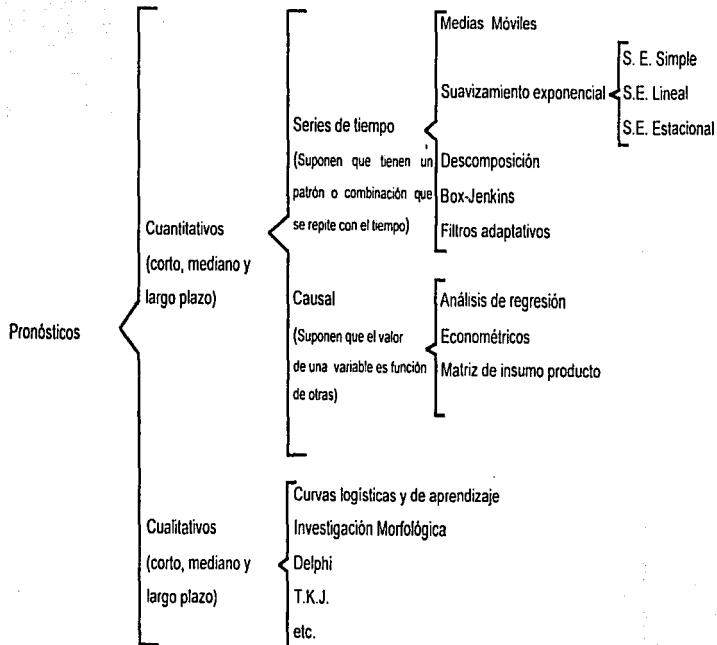
Estas categorías no son mutuamente excluyentes y, de hecho, cualquier método particular puede describirse de varias formas

En cuanto a los *métodos cuantitativos*, aunque varía en su complejidad, todos emplean modelos matemáticos que requieren datos para las variables independientes con objeto de generar un pronóstico.

Por otra parte, los *métodos cualitativos* con frecuencia se usan para situaciones a largo plazo, altamente inciertas en las cuales el empleo de un modelo matemático no parece apropiado. Por ejemplo, al intentar predecir el momento en que ocurrirán adelantos tecnológicos, la situación está tan plagada de incertidumbre que es más común que se apliquen los métodos cualitativos que los cuantitativos. En estos casos es normal que el juicio subjetivo sea la base para llegar a un pronóstico.

Claramente, un amplio rango de modelos pueden ser usado, pero para los métodos cuantitativos estos están comprendidos en dos categorías bien definidas.

Figura 2.1.1.1 Clasificación de los métodos de pronósticos.




El primer tipo de modelos cuantitativos de pronósticos y quizás el más común es el modelo de *series de tiempo*. Los métodos de análisis de series de tiempo utilizan solo datos históricos para la variable que se pronostica; es decir, se analizan los valores pasados de la variable de interés con objeto de hacer pronósticos del futuro. Dos factores son importantes en un modelo de series de tiempo: la serie que será pronosticada y el periodo de tiempo que será utilizado.

Un modelo de series de tiempo siempre asume que algún patrón de comportamiento o una combinación de patrones es recurrente sobre el tiempo. Así, al identificar y extrapolar estos patrones, podrán ser desarrollados los pronósticos para los periodos de tiempo subsecuentes. Los pronósticos cambian con el tiempo y éste está relacionado al periodo que toma el cambio en el pasado.

En suma, la importancia de esta secuencia de periodos, es que éstos son una variable en un modelo de series de tiempo; éste asume explícitamente que el patrón de su comportamiento puede ser identificado solamente con base en los datos históricos de esta serie. Los medios de este modelo, por sí solos, no serán particularmente útiles en la predicción del impacto de ciertas decisiones que quizás se harán. Cualquier método de pronóstico que utilice un modelo de series de tiempo dará el mismo pronóstico para el siguiente periodo, pese a las acciones que puedan existir -es por esto que, se utiliza el Analisis de Intervención como una herramienta adicional y la cuál se estudiará más adelante-.

Las series de tiempo tratan al sistema como una caja negra y no hace intentos por descubrir los factores que afectan a su comportamiento. Como se muestra en la figura 2.1.1.2 el sistema está simplemente indicado como un Proceso Generado Desconocido.

Figura 2.1.1.2..Serie de tiempo.



FUENTE: Makridakis, 1989

Las series de tiempo casi siempre representan el comportamiento de sistemas muy complejos y su objetivo primordial no es describirlo sino pronosticarlo; por tal motivo existen tres razones principales para desear tratar al sistema como una caja negra. La primera, el sistema quizás no se entiende y posiblemente sea extremadamente difícil medir las relaciones asumidas que determinan su comportamiento. Segundo, el principal interés, a lo mejor solo sea el de predecir que pasará, más no porque pasó. Tercero, mientras que a veces pueda ser de poca

importancia saber porque pasan las cosas además de predecir que pasará, el costo de hacerlo era extremadamente alto en el pasado, mientras que el costo actualmente -usando un método de series de tiempo, por ejemplo- quizás sea relativamente bajo².

El segundo tipo de métodos cuantitativos de pronósticos es el *método causal*; éstos consideran a los factores que influyen o están relacionados con la variable que se está pronosticando. Mientras que puede no haber una relación causa-efecto directa, es típico que exista una relación lógica entre las variables que se usan para generar el pronóstico y el pronóstico que resulta³.

Bajo estos modelos cualquier cambio en las entradas podrá afectar las salidas del sistema en el camino de la predicción, asumiendo que la relación es constante. La primera tarea de pronosticar es encontrar la relación observando la salida del sistema y relacionándola con las correspondientes entradas. Cualquier proceso, si es llevado a cabo correctamente, podrá hacer posible la estimación del tipo y extensión de la relación entre las entradas y las salidas. Estas relaciones podrán ser usadas para predecir los futuros estados del sistema previendo que las entradas sean conocidas para esos futuros estados.

Básicamente, el método causal, asume que el valor de una cierta variable (la salida) es una función de una o más variables (las entradas). En sentido estricto, un modelo de series de tiempo podrá ser llamado como un modelo causal, entonces los valores actuales son asumidos como una función del periodo de tiempo solamente⁴. El termino "modelo causal", sin embargo, está generalmente reservado para modelos con otras variables diferentes que el tiempo.

La verdadera fuerza de un modelo causal como un modelo de pronóstico es que puede desarrollar un rango de pronósticos correspondiente al mismo rango de valores para las diferentes variables de entrada. Sin embargo, una desventaja de este método es que requiere de información de varias variables en conjunto para la variable que dará el pronóstico. Como un resultado, estos datos requeridos son mucho más grandes que aquellos de los modelos de series de tiempo. En suma, puesto que los modelos causales generalmente relacionan muchos factores, usualmente toman más tiempo para desarrollarse y son más sensibles al cambio en cuanto a sus relaciones, más que los modelos de series de tiempo. Además, requieren de una estimación de valores futuros de los factores de entrada antes de que las variables de salida puedan ser pronosticadas.

² Makridakis, Spuros, G., Wheel, Wright, Steven, *Forecasting methods for management*, John Wiley & Sons, Inc., fifth edition, U.S.A. 1989 pag. 52

³ Gallagher, Charles A., Watson, Hugh, J., *Métodos cuantitativos para la toma de decisiones en administración*, Mc Graw Hill, Mexico 1982,., pag. 116

⁴ Makridakis, ... pag. 52

2.1.2. Selección del método de pronóstico.

El mayor concepto introducido en esta sección es que, para cada situación de cualquier pronóstico es necesario tener ciertas características genéricas; sin olvidar que cada categoría de los métodos de pronósticos tiene ciertas capacidades y limitaciones. Entonces la tarea clave es encontrar una buena combinación entre una situación y un método, antes de realizar los pasos detallados de la colección de datos, aplicación del método, evaluación de los resultados y la realización de modificaciones que son necesarias para mejorar la predicción.

Existen condiciones esenciales que determinan la técnica que se utilizará⁴:

- a) *El horizonte que se contempla.* Algunos métodos son más apropiados para ciertos horizontes de tiempo. El punto en el tiempo para el que se hace el pronóstico reduce los métodos entre los que se puede elegir. Como se mencionó anteriormente este horizonte de tiempo puede ser a corto plazo - inmediato (menos de un mes), mediano (de 1 a 3 meses)-, medio plazo (3 meses a 2 años) y largo plazo (más de 2 años).
- b) *El nivel de detalle.* Puede ser grueso, como en macroplaneación (o planeación agregada); o fina, como en un departamento de producción. O bien el grado en que los datos históricos o el juicio subjetivo pueden influir en el pronóstico.
- c) *El número de objetos o unidades que se debe predecir.* Varía de unos cuantos (que requieren reglas complejas), hasta cientos o miles (que requieren reglas simples de decisión).
- d) *El patrón de comportamiento.* Con datos de series de tiempo, el patrón de comportamiento de los mismos influye en la decisión de selección. Por ejemplo, algunos métodos son buenos en particular para detectar tendencias y otros no lo son.
- e) *El uso de pronósticos* (si es para control o planeación). En caso de control, se requiere un pronóstico por excepción para detectar rápidamente cuando un proceso se encuentra fuera de límites tolerables. En el caso de planeación el énfasis del pronóstico consiste en identificar los patrones básicos de la información requerida y extrapolarla al futuro.
- f) *La existencia o inexistencia* de un proceso de planeación. Como el pronóstico es una herramienta de la planeación, es importante observar qué tipo de planeación se desarrolla⁵. A menos de que el proceso de planeación sea proactivo o interactivo, el pronóstico tendrá poca utilidad para la toma de decisiones. En el caso inactivo y reactivo el pronóstico puede servir como un mero marco de referencia.

⁴ Prawda ... pag. 92-4

⁵ Existen 4 tipos de planeación: inactiva (no hacer nada), reactiva (el pasado fue siempre mejor que el presente y obviamente mejor que el futuro). Proactiva (optimizar al sistema sin cambiarlo) e interactiva (cambiar un sistema para asemejarlo a un ideal concebido), (Prawda, 1984).

- g) El *costo* del pronóstico. Las consideraciones sobre costo-beneficio son importantes. Cuando el pronóstico se hace para respaldar la toma de decisiones más o menos importantes deben emplearse métodos menos costoso. No obstante, el tiempo y el gasto dedicados a los pronósticos deben aumentar con la importancia de la decisión.
- h) La *disponibilidad de recursos* para obtener los pronósticos. La disponibilidad de una computadora y de paquetes de programas también influye en la selección. Algunos de los métodos más complejos requieren tal volumen de cálculos que se necesita una computadora.

Todos estos argumentos deben servir para aclarar que la selección de un método de pronóstico requiere muchas consideraciones. Sin olvidar que el conocimiento del analista sobre varios métodos restringe hasta cierto punto los métodos que puede usar.

2.2 Métodos cuantitativos de pronósticos.

2.2.1 Notación para los métodos cuantitativos

En la preparación de un pronóstico con cualquier método cuantitativo, uno debe contar con cierto número de valores observado, datos pasados u observaciones. Porque estos valores varían, están generalmente representados por una variable tal como "X". Una variable es simplemente el símbolo del valor en algún punto.

Porque la variable que representa a las observaciones, toma diferentes valores dependiendo de un periodo de tiempo, un camino de identificación del periodo es también necesario. Usualmente esto se hace, asignando números consecutivos a los periodos de tiempo consecutivo. Estos podrían estar referidos como los periodos de tiempo 1, 2, 3, 4, Obviamente el periodo tiene que estar definido desde el principio. Dependiendo de la situación, puede estar definido por un día, una semana, un mes, un año o algún otro espacio de tiempo. Una vez que los periodos de tiempo fueron establecidos, los valores observados pueden estar referidos con el uso de subíndices; por ejemplo, X_{10} podrá referirse al valor observado en el periodo 10.

Aunque "X" o algún otro símbolo generalmente identifica al real (histórico) valor observado de una variable, un símbolo diferente es usado frecuentemente para representar el valor pronosticado de esa variable. En este trabajo, los símbolos F_{t+1} , \hat{X}_{t+1} o \hat{Z}_{t+1} serán usados para denotar los pronósticos del periodo $t+1$. Como un resumen de la relación entre valores observados y valores pronosticados en una situación de serie de tiempo, considérese la Tabla 2.1.2.1.

Tabla 2.1.2.1. Notación utilizada en las series de tiempo

	Valores de pronóstico											
Valores observados	X_1	X_2	X_3	X_4	...	X_{t-2}	X_{t-1}	X_t				
Periodo i	1	2	3	4	...	$t-2$	$t-1$	t				
Valores estimados	\hat{X}_1	\hat{X}_2	\hat{X}_3	\hat{X}_4	...	\hat{X}_{t-2}	\hat{X}_{t-1}	\hat{X}_t				
Valores error	e_1	e_2	e_3	e_4	...	e_{t-2}	e_{t-1}	e_t				

F_{t+1} F_{t+2} F_{t+3} ... F_{t+m}
 $(t+1)$ $(t+2)$ $(t+3)$... $(t+m)$
 \hat{X}_{t+1} \hat{X}_{t+2} \hat{X}_{t+3} ... \hat{X}_{t+m}

↓
Presente

FUENTE: Makridakis, 1989

La aleatoriedad estará siempre presente, es decir siempre existirá alguna desviación entre los pronósticos y los valores actualmente observados. Una meta común en la aplicación de las técnicas de pronóstico es la minimización de esa desviación o errores en los pronósticos (residuales). Esos errores están definidos como la diferencia entre el valor real y el que será pronosticado.

Podemos escribirlo como:

$$e_t = X_t - F_t \quad (2.1.2.1)$$

El subíndice i indica que es el error del periodo de tiempo i que esta siendo examinado. Como se muestra en la tabla 2.1.2.1, un valor de error está asociado con cada observación para la cual existe tanto un valor real como un pronóstico.

2.2.2. Métodos de series de tiempo.

En los métodos de series de tiempo se utilizan los datos históricos de una variable para generar un pronóstico del futuro. Estos métodos suponen que la variable pronosticada tiene información útil para el desarrollo del pronóstico sobre su comportamiento anterior. queda implícito que es probable que lo que sucedió en el pasado continúe ocurriendo en el futuro.

En una serie histórica de datos, conocida como *serie de tiempo*, existen 4 patrones básicos que pueden o no presentarse en la serie y que son fundamentales para la selección de la técnica de pronósticos¹: horizontalidad², la tendencia, la estacionalidad y el ciclo.

El patrón de *tendencia* existe cuando una serie histórica tiende a disminuir o aumentar sus valores medios con el tiempo. La tendencia refleja un movimiento general a largo plazo, incrementando o disminuyendo el valor de una variable sobre el tiempo. Por ejemplo la generación de energía eléctrica de un país.

¹ Prawda..., pag. 926

² En rigor, la horizontalidad es un caso particular de la tendencia ; por ello, se debería hablar de 3 patrones, no de 4.

Cuando una serie de tiempo no tiene una tendencia determinada, se dice que existe el patrón de *horizontalidad*. Estadísticamente esto se conoce como *estacionariedad*. Cuando este patrón existe, las series son conocidas como *estacionarias*, esto es, no hay tendencia al incremento o al decremento sobre el tiempo en cualquier camino sistemático. De esta manera, lo más probable es que el siguiente valor de la serie estará alrededor del valor de la media.

El elemento del tiempo es generalmente uno de los más importantes a considerar en un patrón horizontal. Un caso típico lo forma el número de productos defectuosos en una línea de producción, que por lo general es una constante de la misma.

La componente *estacional* refleja cambios en puntos fijos en el tiempo. En general, se considera que esta componente ocurre con un periodo de un año o menos. La estacionalidad existe cuando una serie de tiempo fluctúa de acuerdo con un factor que depende de un periodo definido del año, es decir, la serie fluctúa de acuerdo a algún factor estacional o temporal. Los periodos estacionales pueden estar definidos por los meses o las cuatro estaciones del año, pero estos podrán también ser las horas del día, los días de la semana, o los días en un mes. El patrón de estacionalidad existe por diferentes razones: factores internos o factores externos como la meteorología. Como ejemplo se observa que la mayoría de las áreas de recreo tienen una estación pico de turismo.

Un patrón *cíclico* es similar a un patrón de estacionalidad pero las fluctuaciones ocurren más lentamente; son cambios graduados en el tiempo. Y la longitud de un ciclo sencillo es generalmente más grande que un año. Algunas series como el producto interno bruto (PIB) y el precio de los metales, contienen un patrón cíclico. Así tenemos que, cuando existe un patrón de cambio en el tiempo con duración de más de un año, el patrón refleja una componente cíclica.

El patrón cíclico es uno de los más difíciles de predecir, porque no se repiten los mismos intervalos constantes de tiempo, su duración no es uniforme. En muchos casos, los ciclos son poco importantes o muy difíciles de identificar por lo cual se dejan fuera del análisis de la serie de tiempo.

Suelen existir otros patrones que pueden ser encontrados en una serie de tiempo, pero los cuatro que aquí se han mostrado son los más importantes (Makridakis, 1989). Estos frecuentemente podrán ser encontrados juntos o individualmente. En efecto, algunas series actualmente combinan una tendencia y un patrón estacional; y un patrón cíclico en adición con uno horizontal; lo cual es parte de todas las series. Sin embargo, alguno de estos patrones puede dominar la serie, por lo tanto, existen técnicas de descomposición -más adelante se verán- que permiten identificar al elemento dominante.

Una última componente de los datos de una serie de tiempo puede ser la variación aleatoria. Esto es lo que queda después que se han separado las demás componentes. Es el ruido inexplicable que queda. Por lo tanto, el valor real, de un registro de la serie, será la suma de los patrones más el elemento aleatorio.

Existen una gran variedad de métodos de análisis de series de tiempo que pueden usarse. Los distintos métodos varían en cuanto al funcionamiento, exactitud para los diferentes horizontes de tiempo, capacidad para detectar puntos de cambio, aplicaciones apropiadas, requerimientos de datos, costo, necesidad de computadora y paquetes de programas y tiempo que se requiere para desarrollar un pronóstico. De acuerdo con el objetivo de este capítulo en mostrar un panorama general de los métodos y hacer énfasis en el seleccionado para el análisis de los datos de bióxido de azufre atmosférico, no se examinarán todos métodos de series de tiempo, sin embargo se hace una recopilación de los más conocidos y usados (siendo estos los antecesores del método de Box-Jenkins); además de anexas bibliografía donde se pueden encontrar más de ellos⁷. *Los métodos para el análisis de series de tiempo* aquí presentados son:

- a) Método gráfico.
- b) Métodos de suavizamiento
 - b.1) Promedios móviles (medias móviles).
 - b.2) Suavizamiento exponencial
- c) Descomposición.
- d) Box-Jenkins.

a) Método gráfico.

Antes de proseguir se ilustra un enfoque que no requiere de un modelo matemático: el graficar los datos y obtener un pronóstico a partir de la gráfica. Más que confiar en el poder analítico de las matemáticas y la estadística, el método gráfico depende de la experiencia y capacidad del analista para identificar subjetivamente, los patrones en los datos y hacer proyecciones basadas en esos patrones.

Aun cuando se planea emplear métodos de pronósticos más complicados, se recomienda que primero se grafiquen los datos. Casi siempre es posible juzgar a partir de la gráfica cuan fuertes son las variaciones por tendencia, estacionales, cíclicas o aleatorias. Esta información ayuda a seleccionar un método apropiado de pronóstico. Aunque se puedan identificar perfectamente los componentes de la serie, es muy difícil hacer pronósticos precisos con el método gráfico y es en este punto en que los métodos basados en las matemáticas y la estadística son particularmente útiles.

⁷ Las bibliografías utilizadas en este capítulo y que están incluidas en las referencias, contienen un estudio más detallado de diferentes métodos de pronósticos por series de tiempo.

b) Métodos de suavizamiento.

En algunas situaciones no es práctico desarrollar y aplicar un método sofisticado de pronóstico. Lo que se necesita es una técnica que pueda desarrollar fácilmente cada una de ellas y que pueda proveer de razonablemente buenos pronósticos sobre un horizonte corto de tiempo.

En tal situación frecuentemente se usan una clase de pronósticos que se conocen como *Métodos de suavizamiento*. Con los métodos de este tipo, los datos históricos son usados para obtener un valor "suavizado" en la serie. Ese valor suavizado es entonces extrapolado y se convierte en el pronóstico para el valor futuro de la serie.

Hay dos subclases de métodos de suavizamiento. El primero es el "método de promedios (o medias) móviles", que se ajusta a la definición convencional de un promedio, es decir, igual a ponderar (suavizar) el número de valores incluidos en el promedio. El segundo método es el de "suavizamiento exponencial" que aplica un fluctuante conjunto de pesos a los datos del pasado. Estos pesos decaen de una manera exponencial desde el más reciente valor, hasta el más distante. La noción básica inherente en un suavizamiento exponencial es que hay algunos patrones elementales en los valores de las variables que serán pronosticadas y que las observaciones históricas de cada variable representan el patrón elemental, además de fluctuaciones aleatorias.

La meta de estos métodos de pronóstico es distinguir entre las fluctuaciones aleatorias y el patrón elemental, por "suavizamiento" (promedio) de los valores históricos. Esto es, eliminando la aleatoriedad encontrada en la secuencia histórica y basando un pronóstico en el patrón suavizado del dato.

b.1) Promedios móviles (medias móviles).

Promedios móviles es un modelo de pronósticos útil y sencillo. Sobre todo se usa para hacer pronósticos a corto plazo. Es una técnica no estadística que requiere de una serie histórica para suavizar o alisar el valor que se pronosticará; Este pronóstico se utiliza, a su vez, para predecir otros valores futuros.

Metodología:

- Se escoge un número de datos que se promediarán (N).
- Se obtiene el promedio de los datos los cuales serán los N números anteriores inmediatos al pronóstico.
- El promedio es el número que se utilizará como pronóstico.

Con un promedio móvil, sólo se usan las últimas N observaciones.

El término promedio móvil es usado porque en cada nueva observación puede estar disponible un promedio para que uno nuevo pueda ser calculado y usado como un pronóstico. Cada vez que se dispone de una nueva observación, el promedio se mueve para incluir la observación más nueva y dejar a la más vieja de las que se usaron antes.

El método de promedios móviles se puede representar matemáticamente como¹⁰:

$$F_{t+1} = S_t = \frac{X_t + X_{t-1} + \dots + X_{t-N+1}}{N} = \frac{1}{N} \sum_{i=t-N+1}^t X_i \quad (2.2.2.1)$$

donde:

F_{t+1} = pronóstico para el tiempo $t+1$
 S_t = valor suavizado para el tiempo t
 X_i = valor actual para el tiempo i
 i = período de tiempo
 N = número de valores incluidos en el promedio.

Cabe añadir que para realizar el primer pronóstico con esta técnica, se requieren tantas observaciones como el valor asignado a N .

Para encontrar la exactitud del pronóstico, se procede a encontrar el error absoluto¹¹, dado por

$$|e_t| = |S_t - X_t| \quad t = 1, 2, \dots, n \quad (2.2.2.2)$$

con su respectivo valor medio y desviación estándar dados por:

$$\bar{e}_t = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (2.2.2.3)$$

$$\sigma_{e_t} = \left[\frac{1}{n} \sum_{i=1}^n (\bar{e}_t - |e_i|)^2 \right]^{1/2} \quad (2.2.2.4)$$

Existen varias observaciones sobre los promedios móviles.

¹⁰ Makridakis.... pag. 69

¹¹ Prawda.... pag.930

Primero, el número de términos que se incluyen en el cálculo del promedio móvil influyen en la respuesta del promedio. Cuanto más pequeño es el número de términos incluidos, mayor es la sensibilidad del promedio a los cambios y viceversa. Es decir, si las observaciones incluidas en el promedio móvil son un número grande, entonces también será mayor el efecto de suavizamiento en el promedio. En una situación dinámica en que los cambios son muy rápidos y se desea detectarlos, debe usarse un promedio móvil de unos cuantos términos. Por otro lado, si el sistema es más o menos estable y la mayoría de los cambios de un periodo a otro se deben a la variación aleatoria, debe emplearse un número mayor de términos con objetos de minimizar la respuesta a la variación aleatoria. Si se desea un valor suavizado porque (pensamos) que las observaciones contienen una considerable aleatoriedad, o porque que hay un pequeño cambio en el modelo original, un número grande de observaciones podrán ser utilizados para el cálculo de pronósticos por promedios móviles. De otra manera, si (sentimos que) el modelo original en los datos es cambiante o (que) existe una pequeña aleatoriedad en los valores observados, un número mucho más pequeño de observaciones podrá utilizarse para calcular el promedio móvil.

Segundo, un promedio móvil siempre tiene un retraso respecto de la tendencia. La magnitud del retraso depende de la fuerza de la tendencia y del número de términos en el promedio móvil. Cuanto más fuerte es la tendencia mayor es el retraso. Al usar más términos para calcular el promedio, el retraso también es mayor.

Un promedio móvil también tendrá un retraso respecto de cualquier patrón cíclico y fracasará en tomar al cuenta una variación estacional. Estas son limitaciones bastante serias para los promedios móviles como método de pronósticos y ayudan a explicar por qué es más común que se use para pronósticos a corto plazo.

Existen extensiones al modelo básico de promedios móviles diseñadas para reducir estas limitaciones, pero no se incluirán en este trabajo.

En resumen, este método tiene serias limitaciones, las más importantes son¹²:

- a) Al requerirse tantas observaciones históricas como valores de N , se presentan problemas de almacenamiento de información.
- b) Al existir cambios en el patrón de la serie, por la presencia marcada de una tendencia, ciclaje, estacionalidad o una combinación de éstas, la técnica de promedios móviles simples no se adapta rápidamente al cambio.

¹² Prawda.... pag. 931

b.2) Suavizamiento exponencial.

Una alternativa a los promedios móviles, popular entre los analistas, es el suavizamiento exponencial¹³. Igual que los promedios móviles, se usa para pronósticos a corto y mediano plazo. Pero por algunas limitaciones en el uso de los promedios móviles, más analistas prefieren aplicar el método de suavizamiento exponencial.

El suavizamiento exponencial tiene varias características que hacen atractivo su empleo. Primero, no requieren mucho espacio de almacenamiento cuando se trabaja con computadoras. Al hacer un pronóstico, todo lo que se requiere es la constante de suavizado α (parámetro de forma), la observación más reciente y el pronóstico anterior. No es necesario guardar todas las observaciones previas. Segundo, en este modelo nunca se descarta por completo ninguna observación; siempre queda incorporada de alguna manera en el pronóstico anterior.

En principio el suavizamiento exponencial opera de una manera análoga a la de promedios móviles cuadrados, en cuanto a suavizar las observaciones históricas y elimina la aleatoriedad. Aunque el procedimiento matemático, de cualquier modo es diferente.

La siguiente ecuación es la forma general para calcular un pronóstico por el método de suavizamiento exponencial

$$F_{t+1} = \alpha X_t + (1 - \alpha) F_t \quad (2.2.2.5)$$

Con la ecuación (2.2.2.5) queda eliminado el problema de tener una cantidad grande de datos históricos como en los promedios móviles. Mejor dicho, solo la más reciente observación, el más reciente pronóstico, y un valor de α (parámetro de forma) es lo que se requiere para un nuevo pronóstico.

Así tenemos también que¹⁴:

$$F_{t+1} = \alpha X_{t-2} + (1 - \alpha) F_{t-2} \quad (2.2.2.6)$$

bien, podemos utilizar

$$F_{t+1} = \alpha X_t + \alpha(1 - \alpha) X_{t-1} + \alpha(1 - \alpha)^2 X_{t-2} + \alpha(1 - \alpha)^3 X_{t-3} + \alpha(1 - \alpha)^4 X_{t-4} + \dots$$

y con esta ecuación podemos ver como se resuelve otra limitación de los promedios móviles, que es el disminuir el peso a las viejas observaciones; esto es entonces

¹³ Este método se conoce como suavizamiento exponencial, porque la contribución que hace cualquier observación a un pronóstico decrece de manera exponencial al pasar el tiempo.

¹⁴ Makridakis..., pag. 69

que α es un valor entre 0 y 1, y los pesos $\alpha, \alpha(1-\alpha), \alpha(1-\alpha)^2, \alpha(1-\alpha)^3, \dots$ tienen un decrecimiento exponencial. Por eso, el nombre de suavizamiento exponencial.

Otra forma de escribir las fórmulas es:

$$F_{t+1} = F_t + \alpha(X_t - F_t) \quad \text{o} \quad F_{t+1} = F_t + \alpha e_t \quad (2.2.2.7)$$

Y de la cual es evidente que cuando $\alpha = 1$, el nuevo pronóstico incluirá un substancial ajuste para cualquier error que ocurra en el precedente pronóstico. Igualmente cuando $\alpha = 0$, el nuevo pronóstico no podrá mostrar mucho ajuste por el error del pronóstico previo. Por lo que el valor de alfa puede ajustarse de tal manera que los pronósticos respondan, rápida o lentamente, a los cambios posibles en el sistema. Un valor alto de alfa es análogo al cálculo de los promedios móviles basándose en un número pequeño de observaciones, o viceversa.

Con respecto a alfa, un valor de $\alpha = (.9)$ tiene un pequeño suavizamiento en el pronóstico, de otra manera si el valor es pequeño como $\alpha = (0.1)$ tiene un considerable suavizamiento.

Esto indica que un valor pequeño de α tiende a producir un pronóstico que es más suavizado (esto es que pierde las fluctuaciones), que un valor grande de α . Por su puesto, para valores altos de alfa, la repercusión de las observaciones anteriores disminuye con rapidez. Es entonces, una seria limitación de este método el determinar los valores apropiados del peso α .

Cuando se hace el primer pronóstico con un modelo de suavizamiento exponencial ocurre que, como es el primero, no existe un pronóstico previo que pueda usarse con el término $(1-\alpha)F_t$. Para solucionar este problema, se supone que el pronóstico anterior es el mismo que la observación más reciente. Matemáticamente, esto equivale a asignar un peso de 1 a alfa cuando se hace el primer pronóstico. Para los pronósticos subsecuentes ya se tiene el anterior que puede usarse en el modelo.

A pesar de que el método de suavizamiento exponencial es ligeramente mejor que el de promedios móviles, es preferible utilizarlo por la conveniencia de utilizar solo los últimos datos y además darle mayor peso a éstos.

Así mismo, el número reducido de datos que se requieren, asociado con el suavizamiento exponencial y la intuitiva atracción de sopesar más fuertemente a los más recientes datos, hace que más analistas seleccionen al suavizamiento exponencial sobre un modelo de medias móviles.

Al usar un suavizamiento exponencial, solo se necesita tener las observaciones más recientes, el pronóstico más reciente y un valor para α . El uso

del modelo de suavizamiento exponencial simple es fácil y además barato, porque un programa de computación puede encontrar automáticamente el mejor valor de α . Además, la evidencia empírica y la experiencia de los usuarios de pronósticos han confirmado que el suavizamiento exponencial es un método exacto, efectivo y confiable para un gran rango de aplicaciones de pronósticos

Aun así, el pronóstico tiene un retraso respecto de las observaciones reales. Aun cuando los datos no contienen variación estacional o cíclica, el modelo básico de suavizamiento exponencial también se queda corto al no tomar en cuenta estas fuentes de variación. Debido a tales diferencias, este modelo se emplea sobre todo para pronósticos a corto plazo.

Las técnicas de suavizamiento simple tal como medias móviles y suavizamiento exponencial, pueden ser usadas efectivamente y con un bajo costo cuando el patrón histórico de los datos puede ser tratado como horizontal. De otra manera, estas técnicas quizás no sean efectivas en el manejo de tendencias o de patrones estacionales. Otras formas de suavizamiento pueden ser desarrolladas para tratar con estas situaciones¹⁵.

- Suavizamiento exponencial lineal (HOLT'S).

A continuación se da un breve resumen del método de suavizamiento lineal, que puede ser usado efectivamente con datos que presenten una tendencia. Este método es barato y puede ser aplicado fácilmente.

El método de suavizamiento exponencial simple es teóricamente efectivo cuando los datos presentan una tendencia horizontal (o bien no tienen tendencia). Si el método de suavizamiento exponencial simple es usado con unos datos con tendencia, el pronóstico atrasará esa tendencia. El método de suavizamiento exponencial lineal evita este problema explícitamente, reconociendo y tomando en cuenta la presencia de una tendencia.

Este método reconoce que en una tendencia el error es constante y lo usa en la siguiente ecuación para calcular una estimación suavizada de la tendencia en la serie de datos¹⁶

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1} \quad (2.2.2.8)$$

¹⁵ Makridakis..., pag. 69

¹⁶ Makridakis..., pag. 77

donde:

S_t = equivalente al valor obtenido por el suavizamiento exponencial simple.

β = coeficiente suavizador, análogo a α

T_t = tendencia suavizada en la serie de datos

El principio básico de esta ecuación es la misma que la del suavizamiento exponencial simple. La más reciente tendencia ($S_t - S_{t-1}$) [representa la tendencia en el dato], es pesada por β y la tendencia suavizada T_{t-1} , es pesada por $(1-\beta)$. La suma de estos valores pesados es el nuevo valor de la tendencia suavizada.

También tenemos:

$$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (2.2.2.9)$$

La única diferencia entre ésta y la del suavizamiento exponencial simple es el término adicional T_{t-1} , que se le suma a S_{t-1} , para ajustar el valor suavizado a un modelo de tendencia en una serie de datos.

Los valores de α y β se encuentran probando con varias combinaciones de valores que proporcionen un conjunto de valores que minimice la media del cuadrado del error.

Debe ser notorio que el valor de S es actualizado primero, y entonces la tendencia T es actualizada. Al usar esta serie de valores suavizados S y el componente T de la tendencia suavizada se prepara para el pronóstico.

$$F_{t+m} = S_t + mT_t \quad (2.2.2.10)$$

Así, el pronóstico del periodo 11 el cual esta solo un periodo adelantado (esto es $m=1$) será:

$$F_{11} = S_{10} + (1)T_{10}$$

Resulta a veces más fácil utilizar las siguientes fórmulas aunque son equivalentes a las anteriores.

$$\begin{aligned} S_t &= S_{t-1} + T_{t-1} + \alpha e_t = F_t + \alpha e_t \\ T_t &= T_{t-1} + \alpha \beta e_t \end{aligned} \quad (2.2.2.11)$$

- Suavizamiento de estacionalidad exponencial (SEE).

Este método produce resultados similares a los de suavizamiento exponencial lineal, pero este tiene una ventaja extra, la de ser capaz de tratar con datos estacionales y además con datos que tienen tendencia.

Las funciones son¹⁷:

$$\begin{aligned}S_t &= \alpha \frac{X_t}{I_{t-1}} + (1-\alpha)(S_{t-1} + T_{t-1}) \\T_t &= \beta(S_t - S_{t-1}) + (1-\beta)T_{t-1} \\I_t &= \gamma \frac{X_t}{S_t} + (1-\gamma)I_{t-1}\end{aligned}\tag{2.2.2.12}$$

donde:

S = Valor suavizado de desestacionalidad de series.
T = Valor suavizado de tendencia.
I = valor suavizado del factor estacional.
L = longitud o estacionaridad.

El pronóstico basado en este método es calculado como:

$$F_{t+m} = (S_t + mT_t) I_{t-t+m}\tag{2.2.2.13}$$

Uno de los problemas que acompañan a este método es determinar los valores para α , β y γ los cuales minimizan los errores. La mejor forma de acercarse es con base en prueba y error. La búsqueda para los mejores valores es hacer un cuadro aproximado donde los resultados usen diferentes valores para α , β y γ , y se comparen para encontrar la combinación que minimice los errores.

- Usando suavizamiento exponencial lineal después de quitar la estacionalidad en una serie de datos.

Si una serie de datos contiene un comportamiento estacional, hay una alternativa diferente al de usar el método de Suavizamiento de estacionalidad exponencial. Esta alternativa consiste primero en desestacionalizar a la serie de datos y entonces usar suavizamiento exponencial lineal en la serie.

¹⁷ Makridakis...pag. 80

- Disminución de la tendencia con suavizamiento exponencial.

Otra variación útil del suavizamiento exponencial fue introducida por Gardner y Mckenzie en 1985¹⁸. Se distingue del suavizamiento lineal Holt's por disminuir la tendencia lineal siendo extrapolada moviéndola más adelante en el futuro. Prácticamente hablando, esto tiene mucho sentido porque la mayoría de las series de datos no crecen o decrecen por siempre.

Este método incluye un parámetro extra ϕ , el cual aplica la disminución óptima para tratar diferentes valores y encontrar uno que minimice los errores. Las ecuaciones del método son¹⁹:

$$\begin{aligned} S_t &= \alpha X_t + (1 - \alpha)(S_{t-1} + T_{t-1})\phi \\ T_t &= \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}\phi \\ F_{t+m} &= S_t + \sum_{i=1}^m \phi T_i \end{aligned} \quad (2.2.2.14)$$

También se pueden usar las ecuaciones que estén en términos del error.

$$\begin{aligned} e_t &= X_t - F_t \\ S_t &= S_{t-1} + \phi T_{t-1} + \alpha e_t \\ T_t &= \phi T_{t-1} + \beta e_t \end{aligned} \quad (2.2.2.15)$$

La ecuación para el pronóstico es la misma.

- Otras formas de suavizamiento.

Aunque, hay muchas otras formas de suavizamiento, lo importante es encontrar (entre las presentadas hasta este momento) la más adecuada para casi todas las situaciones que se presenten en las aplicaciones. Así tenemos que, el suavizamiento exponencial simple es usualmente apropiado para datos mensuales o cuando la tendencia en los datos es frágil o no existente.

El suavizamiento de Holt's puede ser usado favorablemente cuando hay una tendencia persistente y constante en los datos, como frecuentemente se ve con los datos anuales²⁰.

¹⁸ Makridakis... pag. 88

¹⁹ Makridakis... pag. 80

²⁰ Makridakis... pag. 89

c) Método de descomposición

La representación general matemática del método de descomposición aproximada es²¹:

$$X_t = f(S_t, T_t, C_t, R_t)$$

donde:

X_t = valor de la serie de tiempo (dato actual) para el periodo t .

S_t = componente estacional para el periodo t .

T_t = componente de tendencia para el periodo t .

C_t = componente cíclico para el periodo t .

R_t = componente de aleatoriedad (o error) para el periodo t .

La forma más funcional de relacionar estos cuatro submodelos puede tomar una variedad de formas, pero la más indicada es sumar (simplemente sumando los cuatro elementos) y multiplicar (tomando el producto de los cuatro elementos). La forma multiplicativa es una de las más cómodamente usadas.

La representación matemática es:

$$X_t = S_t \cdot T_t \cdot C_t \cdot R_t$$

Lo básico de los métodos de descomposición es intuir (prueba-error) y podrán ser fácilmente entendidos.

La descomposición puede ser utilizada para identificar estos submodelos o entender las pasadas fluctuaciones, y entonces pronosticar valores futuros.

Usando la descomposición, un dato es expresado como $X = S \cdot T \cdot C \cdot R$, donde X representa el valor observado actual y en donde el propósito es identificar a T , C y S (todo lo que sobre será R).

d) Método de Box-Jenkins

Box-Jenkins es una técnica elaborada y compleja que requiere una gran cantidad de datos históricos. Consiste en un enfoque sistemático para identificar un modelo apropiado, elegido entre una abundante variedad de modelos. Los datos históricos se usan para probar la validez del modelo, el cual genera a su vez un procedimiento de pronósticos confiable.

²¹ Makridakis...pag.96

El método de Box-Jenkins es iterativo por naturaleza. De manera general la metodología consiste: Primero, en elegir un modelo; para hacerlo, es necesario calcular autocorrelaciones y autocorrelaciones parciales y examinar sus patrones. Una vez que se ha identificado el modelo, es decir, que se ha identificado la forma funcional, se deben estimar los parámetros asociados. Estas estimaciones se hacen usando los datos históricos. La forma funcional se convierte entonces en una función conocida y se pueden calcular los residuos y examinar su comportamiento. De igual manera, se puede examinar el comportamiento de los parámetros estimados. Si tanto los "residuos" como los "parámetros estimados" se comportan como se espera en el modelo supuesto, el modelo queda validado. Si no, el modelo debe modificarse y el procedimiento se repite hasta que se valide el modelo. En este punto, se puede obtener un pronóstico.

2.3 Métodos cualitativos de pronósticos.

Estos métodos, conocidos también como pronósticos tecnológicos, se utilizan en los casos en que no se tiene una serie histórica.

Los métodos cualitativos generalmente se utilizan cuando se quiere predecir el tiempo en que se adaptará una nueva tecnología, o predecir el tiempo de duración de la tecnología que va a imperar en el futuro.²²

Los métodos cualitativos pueden ser exploratorios o normativos. Los primeros parten de un diagnóstico del presente y pretenden proyectar lo que será el futuro; los segundos parten de un futuro y de él derivan las tecnologías, acciones, programas, estrategias, etc., que moverán el presente a este escenario idealizado. Los métodos exploratorios explican qué pasará; los normativos lo que hay que hacer para alcanzar un futuro propuesto.

A continuación se describen brevemente y solo como referencia, algunos métodos cualitativos.

a) Curvas logísticas y de aprendizaje

Este método exploratorio tiende a ajustar una curva a lo largo de una serie de puntos. Estas curvas tienen normalmente una forma de S alargada, ya que toda tecnología atraviesa por una fase de desarrollo inicial lenta, una de crecimiento acelerado y después una de saturación.

²² Prawda..., pag. 949

La idea principal de este método es que todas las tecnologías tienden a un comportamiento igual y que, conociendo el estado de desarrollo de una tecnología determinada, se puede predecir cualitativamente su futuro mediante las curvas S.

Existen varias curvas de tipo S que se pueden ajustar a una serie de puntos conocidos (y las cuales pueden ser consultadas en libros específicos sobre estos temas).

b) Método de investigación morfológica

Este método normativo ideado por el astrónomo suizo Zwicky, consiste en enumerar y analizar exhaustivamente, en forma sistemática, todas las posibles combinaciones que puede adoptar una tecnología específica²³.

La principal ventaja de este método tan sencillo pero poderoso, es identificar aquellas combinaciones factibles de desarrollarse, que de otra manera se perderían en el análisis no sistematizado del diluvio de ideas.

El método morfológico de Zwicky elimina inmediatamente aquellas combinaciones no factibles o que causan conflictos. Las combinaciones restantes pueden originar rediseños o nuevos tipos de inventos. Se cuenta con una metodología sistemática para analizar tantas posibles combinaciones.

Los pasos de este método son²⁴:

- a) El problema debe definirse y formularse claramente.
- b) Se deben identificar todos los parámetros que pueden caracterizar y afectar una solución.
- c) Se debe construir una matriz multidimensional, de acuerdo con las combinaciones dadas por todos los valores y formas que pueden tomar los diferentes parámetros.
- d) Se deben analizar y evaluar todas las entradas de la matriz multidimensional.
- e) Las entradas que son factibles de desarrollarse deben evaluarse, quizá con una relación costo-beneficio y elegir aquella (s) que tengan la mejor relación.

²³ Prawda..., pag. 954

²⁴ Prawda..., pag. 953

c) Método DELPHI

Como lo menciona Prawda "Este método normativo, ideado por Olaf Helmer en 1966, es posiblemente la técnica cualitativa que más se utiliza" (Prawda, 1984).

Se requiere, primero, el establecimiento de un grupo de expertos relacionados con el tema a pronosticar. El grupo debe ser anónimo, o sea, sus miembros no deben saber que forman parte de un panel de expertos. Sólo el grupo coordinador, que organiza el pronóstico, conoce a todos los elementos del panel.

Consta de 4 fases. En la primera se prepara un cuestionario, abierto, no muy estructurado, relativo al tema del pronóstico; se envía a los expertos que se han seleccionado y ellos, a su vez, envían sus respuestas al grupo coordinador. Sus respuestas son canalizadas por el grupo coordinador. Este sistematiza la información, quizá por eventos discretos y/o por eventos cronológicos y la agrupa en forma estadística, calculando medias y percentiles en las respuestas.

En la fase 2 se prepara una lista consolidada de eventos derivados de la información de la fase anterior. La lista se envía a los expertos para que estimen y justifiquen en qué periodos ocurrirán los eventos.

Posteriormente las respuestas se envían al grupo coordinador para que vuelva a consolidar la información, con su respectivo análisis estadístico.

La fase 3 es similar a la anterior, con la excepción de que aquellos individuos del grupo que difieren de las opiniones emitidas por la mayoría, deben justificar su desacuerdo.

En la fase 4 se tiende a consolidar aquellos pronósticos donde impera un consenso por parte del grupo de expertos.

Este método tiene varias desventajas:

- El escoger un grupo de expertos idóneos, de acuerdo con lo que se quiere pronosticar, es sumamente difícil.
- Puede existir mucho ruido en la comunicación, por ejemplo, que el grupo coordinador interprete incorrectamente lo que los expertos escriben en sus cuestionarios.
- Pueden existir sesgos en la coordinación, debido a la personalidad dominante de uno o varios de los integrantes del grupo.

Ahora bien, existen muchos otros métodos cualitativos de pronóstico, por ejemplo: el método TKJ, las comparaciones tecnológicas de Gerstendfeld, el árbol de relevancia, etc.; los cuales pueden ser consultados en algunos libros referentes a este tema.

2.4 Método de Box-Jenkins.

En las secciones anteriores varios métodos de series de tiempo fueron presentados, uno de ellos fue el de suavizamiento exponencial simple, el cuál basa un pronóstico en el peso (suavizamiento) de la información anterior de una serie de tiempo. Otro método fue el de descomposición de una serie de tiempo, que consiste en identificar el tipo de patrones de información presentados -tendencia, estacionalidad y ciclaje- y preparar pronósticos para cada uno de esos patrones como una parte de la predicción de valores futuros de la serie de tiempo.

Pero además de los anteriores, existe un método más general y teórico de series de tiempo que será presentado en esta sección y utilizado en este trabajo. Este método puede aplicarse a cualquier patrón de información, y debe entenderse que es adecuado para seleccionar el modelo específico más apropiado de un conjunto disponible de ellos en el propio método. Este procedimiento comúnmente utilizado para la aplicación de tales modelos fue propuesto por Box y Jenkins en 1976²¹.

Prawda menciona que: "Más que un método avanzado, Box-Jenkins es una filosofía para pronosticar, que funciona en casi todo tipo de situaciones, por complejas que resulten" (Prawda 1984, pag. 943).

Algunas herramientas básicas para aplicar esta técnica, se presentarán en la primera parte de esta sección; seguido de ésto, serán descritos una variedad de modelos ARMA y ARIMA, y finalmente se mostrará la metodología propuesta por Box-Jenkins para la selección de algunos de estos modelos.

2.4.1 Autocorrelación y autocorrelación parcial.

AUTOCORRELACIÓN

La autocorrelación es una herramienta clave en la identificación de la estructura y patrones de la serie histórica y para la determinación de un modelo apropiado correspondiente a la serie de datos.

Es importante saber primero que la *correlación* es una medida de asociación (relación mutua) entre dos variables, y describe lo que tiende a pasarle a una si hay un cambio en la otra.

²¹ Box, G., Jenkins, G., *TIME SERIES ANALYSIS forecasting and control*, Prentice-Hall, Inc., U.S.A. 1976.

Así, un coeficiente de autocorrelación es similar al coeficiente de correlación excepto que éste describe la relación mutua entre valores de la misma variable pero en diferentes periodos de tiempo. Es decir, la autocorrelación mide la correlación entre los valores de la serie de tiempo, separados por un número fijo de periodos que se llama *espacio*. Entonces, la autocorrelación para un espacio de dos periodos mide la correlación en cada tercera observación, o sea, es la correlación entre la serie de tiempo original y la misma serie de tiempo desplazada dos periodos hacia adelante.

El grado de una correlación es medido por el coeficiente (r), el cual varía entre +1 y -1. Un valor cercano a +1 implica una fuerte relación positiva entre las dos variables. Esto significa que cuando el valor de una variable aumenta, el valor de la otra tiende a incrementarse también. Similamente, un coeficiente de correlación cercano a -1 indica lo contrario -el incremento en una variable estará asociado con el decremento de la otra- Un coeficiente de 0 indica que las dos variables no están relacionadas, -no importa que pase con una variable, nada se podrá decir acerca del valor de la otra-.

Para un proceso de serie de tiempo $\{ Z_t \}$, podemos considerar a Z_t y Z_{t+1} como dos variables y calcular su coeficiente de correlación (autocorrelación), a Z_t y Z_{t+2} como otras dos variables, Z_t y Z_{t+3} también como otras dos, y así sucesivamente, para cada uno de estos conjuntos de par de variables hay un coeficiente de correlación correspondiente, el significado de estos es el interés de la autocorrelación. Un coeficiente de 0.7 entre Z_t y Z_{t+1} , por ejemplo, implicaría que los valores sucesivos con un periodo (lag - espacio) entre ellos están positivamente correlacionados con cada uno de los otros, y por lo tanto tienden a moverse en la misma dirección. Similamente un coeficiente de -0.8 entre Z_t y Z_{t+2} nos dirá que los valores sucesivos de Z en dos periodos (time lags - espacio) después, están negativamente correlacionados y tienden a moverse en direcciones opuestas.

Ahora bien, para un proceso estacionario $\{ Z_t \}$, tenemos la media $E(Z_t) = \mu$ y la varianza $\text{Var}(Z_t) = E(Z_t - \mu)^2 = \sigma^2$, las cuales son constantes, y las covarianzas $\text{Cov}(Z_t, Z_s)$ las cuales son funciones solo de la diferencia de tiempo $|t - s|$. Por lo tanto, en este caso, escribimos la covarianza entre Z_t y Z_{t+k} como:

$$\gamma_k = \text{Cov}(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu), \quad (2.4.1.1)$$

y la correlación entre Z_t y Z_{t+k} como:

$$\rho_k = \frac{\text{Cov}(Z_t, Z_{t+k})}{\sqrt{\text{Var}(Z_t)} \sqrt{\text{Var}(Z_{t+k})}} = \frac{\gamma_k}{\sigma^2} \quad (2.4.1.2)$$

donde notamos que $\text{Var}(Z_t) = \text{Var}(Z_{t+k}) = \gamma_0$. Como funciones de K , γ_k es llamada la función de autocovarianzas y ρ_k es llamada la función de autocorrelación (ACF) en el análisis de series de tiempo, ya que ellas representan la covarianza y la correlación entre Z_t y Z_{t+k} para el mismo proceso, separado solo por K retrasos de tiempo.

La función de autocorrelación es frecuentemente graficada solo para los periodos no negativos. Esta gráfica es algunas veces llamada correlograma²⁶.

Las autocorrelaciones proporcionan información importante a cerca de la estructura de un conjunto de datos y de sus patrones. En un conjunto de datos completamente aleatorios la autocorrelación entre valores sucesivos podrá ser cercano a, o igual a cero, pero los valores con una fuerte estacionalidad o ciclaje estarán altamente autocorrelacionados.

En resumen, lo que hace particularmente útil a estas autocorrelaciones es que sus coeficientes pueden ser usados para revelar el tipo de información con la que estamos tratando y nos ayuda a identificar el modelo adecuado a la serie de tiempo²⁷.

AUTOCORRELACIÓN PARCIAL

Una medida estadística que es similar a la autocorrelación en algunas de las características que posee en cuanto a que son útiles en la identificación apropiada del modelo de pronóstico, es la autocorrelación parcial. La autocorrelación parcial es una autocorrelación condicional entre la serie de tiempo original y la misma serie de tiempo trasladada hacia adelante en un número fijo de periodos, manteniendo fijo el efecto de los otros espacios de tiempo.

Anunado a la autocorrelación entre Z_t y Z_{t+k} , quizás deseamos investigar la correlación entre Z_t y Z_{t+k} , después de su mutua dependencia lineal en las variables intermedias Z_{t+1} , Z_{t+2} , Z_{t+3} , ..., Z_{t+k-1} que tienen que ser removidas. Esta es la siguiente correlación condicional:

$$\text{Cov}(Z_t, Z_{t+k} \mid Z_{t+1}, \dots, Z_{t+k-1})$$

y es usualmente referida como la autocorrelación parcial (PAC) en el análisis de series de tiempo.

²⁶ Wei, William, *Time Series Analysis Univariate and Multivariate Methods*, Addison- Wesley Publishing Company, Inc. U.S.A. 1990, pag. 10

²⁷ Makridakis, ..., pag.30

Dados algunos pasos anteriores se tiene que la autocorrelación parcial entre Z_t y Z_{t-k} será igual a la autocorrelación ordinaria entre $(Z_t - \bar{Z}_t)$. Así, teniendo P_k que denota la autocorrelación parcial entre Z_t y Z_{t-k} , tenemos:

$$P_k = \frac{\sum_{t=k+1}^n (Z_t - \bar{Z}_t)(Z_{t-k} - \bar{Z}_{t-k})}{\sqrt{\sum_{t=k+1}^n (Z_t - \bar{Z}_t)^2} \sqrt{\sum_{t=k+1}^n (Z_{t-k} - \bar{Z}_{t-k})^2}} \quad (2.4.1.3)$$

Así, la autocorrelación parcial (PAC) entre Z_t y Z_{t-k} puede también ser obtenida como el coeficiente de regresión asociado con Z_t cuando retrocede Z_{t-k} en sus K variables retrasadas Z_{t-1} , Z_{t-2} , Z_{t-3} , ..., Z_{t-k+1} y Z_t como la siguiente ecuación.

$$Z_{t-1} = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_k Z_{t-k} + v_{t-1} \quad (2.4.1.4)$$

Porque ϕ_{kk} ha llegado a ser una notación estándar para la PAC en la literatura de series de tiempo, también la usaremos en este trabajo. Una función de K y ϕ_{kk} es usualmente llamada *función de autocorrelación parcial (PACF)*.

El cálculo y uso de estas "parciales" como son frecuentemente llamadas, así como de las autocorrelaciones, son bastante técnicas y el lector interesado podrá consultar los libros que se mencionan en las referencias de este trabajo.

ACF y PACF muestrales.

Hasta ahora, solo hemos considerado las funciones de autocorrelación teóricas las cuales describen conceptualmente a un proceso estocástico. Sin embargo, en la práctica, puesto que se desconoce el proceso real de una serie de tiempo, estos valores son desconocidos también. En lugar de obtener las ACF y PACF a partir del modelo, deben usarse las funciones para identificar el modelo, pero, como se carece de las funciones teóricas, es necesario utilizar las funciones muestrales (o estimadas) calculadas a partir de la muestra de tamaño n (donde n es el número de datos disponibles). Por lo tanto, en la práctica, tenemos una serie de tiempo finita Z_1, Z_2, \dots, Z_N de N observaciones, de las cuales, solamente podemos obtener estimadores de las autocorrelaciones.

Autocorrelaciones muestrales

De acuerdo a Box y Jenkins²⁸, el estimador más satisfactorio en cuanto a sus propiedades es:

$$\hat{\rho}_k = \hat{r}_k = C_k / C_0 \quad (2.4.1.5)$$

²⁸ Box, G., Jenkins, G.... pag. 32

donde:

$$c_k = \frac{1}{n} \sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z}), \quad k = 0, 1, 2, \dots, K$$

De nuevo como las ACF teóricas son desconocidas, la varianza aproximada de este estimador es:

$$S_{c_k} = \text{Var} = \frac{1}{n} (1 + 2 \sum_{i=1}^{k-1} r_i^2), \quad k > q. \quad (2.4.1.6)$$

La raíz cuadrada de la fórmula (2.4.1.6) es el *error estándar* para muestras grandes. Estas medidas tienen como objetivo el determinar cuando puede considerarse que una autocorrelación es estadísticamente significativa, es decir, sirven para construir pruebas de hipótesis que permitan probar si una autocorrelación puede considerarse igual a cero, con un nivel de confianza dado.

Visto de otra forma, puede probarse la hipótesis utilizando los intervalos de confianza (del 95% en general), de modo que los valores de r_k que queden fuera del intervalo formado por $[-2Sr_k, 2Sr_k]$, pueden considerarse como significativos²⁹.

Autocorrelaciones parciales muestrales.

De acuerdo a Durbin (1960), las PACF's muestrales pueden estimarse utilizando las ecuaciones de YULE_WALKER:

$$\hat{P}_{kk} = r_{kk} = \begin{cases} r_1 & k = 1 \\ \frac{r_k - \sum_{j=1}^{k-1} r_{k-j} r_j}{1 - \sum_{j=1}^{k-1} r_j^2} & k = 2, 3, \dots \end{cases} \quad (2.4.1.7)$$

donde:

$$r_j = r_{k-1, j} - r_{k-2, j-1}, \quad j = 1, 2, \dots, k-1$$

Como se ve, para calcular las autocorrelaciones parciales no se tiene una fórmula sencilla, aunque el desarrollo del algoritmo no es complicado de implementar.

²⁹ González Videgaray, M. C., *Modelos de Decisión con procesos estocásticos II*, UNAM ENEP Acatlán, México Méx., 1990, pag. 35

Según Quenouille (1949):

$$\text{Var}(r_{kk}) \approx \frac{1}{n}, \quad k > p \quad (2.4.1.8)$$

donde n es el número de observaciones disponibles y p representa las primeras p autocorrelaciones parciales que se suponen distintas de cero. Depende sólo del tamaño de la muestra.

Igualmente, puede tomarse la decisión en base al intervalo de confianza, que en este caso, será de $[-2\sqrt{n}, 2\sqrt{n}]^{30}$

Al evaluar las autocorrelaciones y las autocorrelaciones parciales debe evitarse dar demasiada significancia a los detalles de los estimadores. Si los picos aparecen en algún intervalo que tenga interpretación física (1,2 o estacional como 12 o 24), puede considerarse que vale la pena incluirlos en el modelo. De otra forma, agregarlos puede complicar el modelo sin mejorar significativamente los resultados.

Por supuesto, las autocorrelaciones muestrales no siempre se ajustarán exactamente a las autocorrelaciones poblacionales³¹.

2.4.2. Proceso Ruido blanco.

Un proceso $\{a_t\}$ es llamado un proceso ruido blanco, si es una secuencia de variables aleatorias no correlacionadas para una distribución dada con media constante $E(a_t) = \mu_a$, usualmente asumida como cero, una varianza $\text{Var}(a_t) = \sigma_a^2$ y $\text{cov}(a_t, a_{t+k}) = 0$ para todo $k \neq 0$. Por definición (inmediatamente sigue que) un proceso de ruido blanco $\{a_t\}$ es estacionario con función de autocovarianza

$$\gamma_k = \begin{cases} \sigma_a^2 & k = 0 \\ 0 & k \neq 0, \end{cases} \quad (2.4.2.1)$$

función de autocorrelación:

$$\rho_k = \begin{cases} 1 & k = 0 \\ 0 & k \neq 0 \end{cases} \quad (2.4.2.2)$$

y función de autocorrelación parcial :

³⁰ González..., pag. 37

³¹ *ibid*

$$\phi_k = \begin{cases} 1 & k = 0 \\ 0 & k \neq 0 \end{cases} \quad (2.4.2.3)$$

El fenómeno básico del proceso ruido blanco es que sus ACF y PACF son iguales a cero.

Aunque este proceso casi nunca ocurre en una aplicación de series de tiempo, juega un papel importante como un elemento básico en la construcción de un modelo de series de tiempo, justo como las funciones seno y coseno en el análisis de Fourier²².

Un proceso de ruido blanco es gaussiano si su función de distribución es normal. En las siguientes discusiones, a menos que se mencione otro caso, {a} está siempre referido como un *proceso de ruido blanco gaussiano* con media cero.

2.4.3. Clases de modelos de series de tiempo.

La filosofía de Box-Jenkins utiliza tres tipos de modelos:

- a) Autorregresivos.
- b) Medias móviles.
- c) Mezclados (autorregresivos con medias móviles).

Estas tres clases generales o tipos de modelos de series de tiempo pueden, para todo propósito práctico, describir cualquier tipo o patrón de la información en las series de tiempo.

El modelo AR fue descrito por Yule (1926-1927) hace más de 60 años; en 1937 Slutsky propuso el modelo MA y en 1954 Wold describió los modelos mezclados ARMA. Pero a pesar de que existió un trabajo previo de estos modelos, su desarrollo y aplicación fue muy limitado, principalmente por razones computacionales, pero con la disponibilidad de las computadoras, la utilización de estos modelos se hizo posible²³.

Es importante aclarar que la presentación de los modelos en este trabajo es de manera general y en base a la revisión de bibliografía sobre estos temas, por lo tanto, si el lector lo desea podrá consultarla para mayores especificaciones. Así, en esta presentación sólo se mencionaran las principales características de cada modelo, las cuales serán utilizadas en los siguientes capítulos.

²² Wei... pags. 16 y 17

²³ Makridakis... pag. 133

Tampoco los modelos estacionales serán presentados, puesto que no fueron necesarios en el análisis de las series de tiempo del bióxido de azufre, pero a pesar de esto, se invita al lector a estudiarlos, siendo muy útiles para análisis de series de tiempo en general.

Antes de presentar cada uno de los modelos, es necesario describir, algunos operadores que son utilizados en los mismos. Se utilizará extensivamente el operador de salto hacia atrás B el cual se define por $B^m z_t = z_{t-m}$. El operador inverso es llamado el operador de salto hacia adelante $F = B^{-1}$ dado por $Fz_t = z_{t+1}$, así $F^m z_t = z_{t+m}$. Otro importante operador es el operador diferencia hacia atrás ∇ es cual puede ser escrito en términos de B , siendo¹⁴:

$$\nabla z_t = z_t - z_{t-1} = (1 - B)z_t$$

También ∇ tiene un inverso, el operador S dado por

$$\begin{aligned} S^{-1} z_t &= Sz_t = z_t + z_{t-1} + z_{t-2} + \dots \\ &= (1 + B + B^2 + \dots) z_t \\ &= (1 - B)^{-1} z_t \end{aligned}$$

a) Modelos Autorregresivos (AR).

Un proceso estocástico, el cual puede ser extremadamente útil en la representación de ciertas series que ocurren en la práctica, es el llamado modelo *autorregresivo*. En este modelo, el valor actual del proceso esta expresado como proceso lineal finito de valores previos del mismo y un salto a_t .

Un modelo es llamado *autorregresivo (AR) de orden p* , si es de la forma¹⁵

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + e_t \quad (2.4.3.1)$$

donde Z_t es la variable dependiente, y $Z_{t-1}, Z_{t-2}, Z_{t-3}, \dots, Z_{t-p}$ son las variables independientes. En este caso, las variables independientes son valores de la misma variable (de aquí el nombre auto), pero de periodos previos ($t-1, t-2, t-3, \dots, t-p$). Finalmente e_t es el error o término residual que representa las perturbaciones aleatorias que no pueden ser explicadas por el modelo.

El modelo descrito por la ecuación (2.4.3.1) es llamado *autorregresivo* por que es similar a la ecuación de regresión ($y = a + b_1 X_1 + b_2 X_2 + \dots + b_p X_p + e$). La

¹⁴ Box, G., Jenkins, G....

¹⁵ *idem*

Análisis de series de tiempo

única diferencia es que $X_1 = Z_{1,1}$, $X_2 = Z_{1,2}$, $X_3 = Z_{1,3}$, ..., $X_p = Z_{1,p}$ y así las variables independientes son simplemente valores retardados de la variable dependiente con tiempos retardados de 1, 2, 3, ..., p periodos.

Si definimos un operador autorregresivo de orden p dado por

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

entonces el modelo autorregresivo podrá ser escrito de la forma simplificada:

$$\phi(B)\bar{Z}_t = v_t \quad (2.4.3.2)$$

El modelo contiene $p+2$ parámetros desconocidos μ , ϕ_1 , ϕ_2 , ..., ϕ_p , σ_v^2 , los cuales en la práctica serán estimados utilizando la información de la serie. El parámetro adicional σ_v^2 es la varianza del proceso ruido blanco v_t .

Ahora bien, si tenemos:

$$\phi(B)\bar{Z}_t = v_t$$

la ecuación anterior es equivalente a:

$$\bar{Z}_t = \psi(B)v_t \quad (2.4.3.3)$$

con

$$\psi(B) = \phi^{-1}(B)$$

El proceso autorregresivo puede ser estacionario o no estacionario. Para que el proceso sea estacionario, los ϕ 's deberán ser escogidos de tal manera que los valores de v_1 , v_2 , v_3 , ... en $\psi(B) = \phi^{-1}(B)$ formen una serie convergente. Siempre que $\sum_{j=1}^{\infty} |\phi_j| < \infty$, el proceso será invertible. Al ser estacionario, las raíces de $\phi_p(B) = 0$ deberán estar fuera del círculo unitario.

El proceso AR es utilizado en situaciones en las cuales el valor presente de una serie de tiempo depende de sus valores anteriores más un salto aleatorio. Yule (1927) uso un proceso AR para describir el fenómeno del número de manchas solares y el comportamiento de un simple péndulo.

AUTOCORRELACIONES EN UN MODELO AR(p).

En general, para un proceso AR(p):

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p} \quad k > 0 \quad (2.4.3.4)$$

Al conjunto de p ecuaciones anteriores se les llama ECUACIONES DE YULE-WALKER. A partir de ellas pueden calcularse las autocorrelaciones que, de acuerdo a las condiciones de estacionaridad, serán siempre decrecientes infinitas.

Así, tenemos la siguiente relación recursiva para la ACF:

$$\rho_k = \phi_1 \rho_{k-1} + \dots + \phi_p \rho_{k-p}, \quad k > 0$$

en la cual vemos que la ACF $_{\rho_k}$ está determinada por la ecuación diferenciada $\phi_k(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \rho_k = 0$ para $k > 0$.

AUTOCORRELACIONES PARCIALES DE UN MODELO AR(p)

Al construir un modelo autorregresivo puede verificarse si la inclusión de una nueva Z_{t+k} en el modelo representará los datos en forma más adecuada. Supóngase que después de ajustar un modelo AR(k-1) deseamos ver si lo adecuado será un AR(K). Debemos entonces incluir a Z_{t+k} . Si el valor de $\phi_{k,k}$ es "grande", significará que debe incluirse Z_{t+k} . De otra forma, no será conveniente agregarlo.

Este coeficiente mide entonces el "exceso" de correlación no tomada en cuenta por el modelo AR(k-1); esto es, mide el efecto "parcial" de Z_{t+k} para explicar el comportamiento de Z_t en un modelo que ya incluye $Z_{t-1}, \dots, Z_{t-k+1}$. El coeficiente autorregresivo en el modelo de mayor orden, $\phi_{k,k}$, se define como la autocorrelación parcial al intervalo K y se denotará como $\rho_{k,k}$ ($\phi_{k,k}$ de acuerdo a la notación de Box-Jenkins). La gráfica de las $\rho_{k,k}$ será la función de autocorrelación parcial o PACF³⁶.

Por lo tanto, la PACF $\phi_{k,k}$ podrá desaparecer después de p longitudes. De modo que en un modelo AR(p), las PACF's nos sirven para determinar el valor de "p". Esta es una propiedad útil en la identificación de un modelo AR para la construcción de un modelo de series de tiempo.

Modelo Autorregresivo de orden 1, AR(1)

Se dice que una serie de tiempo (estacionaria) es gobernada por un proceso autorregresivo de primer orden si los valores actuales de la serie Z_t pueden expresarse como una función lineal del primer valor anterior y un choque aleatorio e_t .

$$Z_t = \phi_1 Z_{t-1} + e_t$$

³⁶ González.... pag. 31

o

$$(1 - \phi_1 B)Z_t = \epsilon_t$$

donde ϕ_1 es el parámetro autorregresivo que describe el efecto de un cambio de Z_t en Z_{t-1} .

Como se mencionó anteriormente el proceso es siempre invertible. Para ser estacionario, la raíz de $(1 - \phi_1 B) = 0$ debe estar fuera del círculo unitario. Esto es, para un proceso estacionario, nosotros tenemos $|\phi_1| < 1$. El proceso AR(1) es algunas veces llamado proceso de Markov porque el valor de Z_t está completamente determinado por el conocimiento de Z_{t-1} .³⁷

ACF de un AR(1).- Su función de autocorrelación está dada por:

$$\rho_k = \phi_1 \rho_{k-1} = \phi_1^k, \quad k \geq 1,$$

donde usamos el factor de $\rho_0 = 1$. Por lo tanto, cuando $|\phi_1| < 1$ y el proceso es estacionario, la ACF decae exponencialmente en una de las dos formas dependiendo del signo de ϕ_1 . Si $0 < \phi_1 < 1$, todas las autocorrelaciones son positivas; si $-1 < \phi_1 < 0$, el signo de la autocorrelación muestra un comportamiento alternativo, empezando con un valor negativo. Las magnitudes de esas autocorrelaciones decrecen exponencialmente en ambos casos.

PACF de un AR(1).- Para un proceso AR(1), la PACF está dada por

$$\phi_{k|k} = \begin{cases} \rho_1 = \phi_1, & k = 1 \\ 0, & \text{para } k \geq 2. \end{cases}$$

Por lo tanto, la PACF de un proceso AR(1) muestra un pico negativo o positivo de longitud 1 dependiendo del signo de ϕ_1 , y después se corta.

b) Modelos de Medias Móviles (MA).

No todas las series pueden ser manejadas con el modelo autorregresivo, por lo tanto; otro tipo de modelos de gran importancia práctica en la representación de series de tiempo observadas, es el llamado *proceso finito de medias móviles*. Aquí, hacemos a Z_t linealmente dependiente de un número *finito* de q valores previos de ϵ .³⁸

³⁷ Wei, ..., pag. 33

³⁸ Box, G. Jenkins, G....

Así,

$$\hat{Z}_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.4.3.5)$$

es llamada un *proceso de medias móviles (MA) de orden q*.

La ecuación (2.4.3.5) es similar a la ecuación del modelo autorregresivo, excepto de que implica que la variable dependiente Z_t depende de valores previos del término error ($e_t, e_{t-1}, e_{t-2}, \dots, e_{t-q}$) más que de la variable misma. De acuerdo a la ecuación (2.4.3.5), el valor futuro de Z podrá ser pronosticado utilizando el error de cada uno de los periodos pasados. Es decir, el proceso es con base en los choques aleatorios ponderados en el tiempo y acumulados.

Se ha llamado medias móviles por la similitud con el método de suavizamiento antes descrito. Este nombre, también, es algo engañoso porque los pesos de $1, -\theta_1, -\theta_2, -\theta_3, \dots, -\theta_q$, que multiplican a los e 's no necesitan ser de una unidad total ni necesitan ser positivos -como una media aritmética-. Sin embargo esta nomenclatura es usada comúnmente³⁹.

Si definimos un *operador de medias móviles* de orden q dado por

$$\alpha(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

entonces el modelo de medias móviles puede ser escrito económicamente como:

$$Z_t = \alpha(B)e_t \quad (2.4.3.6)$$

que contiene $q + 2$ parámetros desconocidos $\mu, -\theta_1, -\theta_2, -\theta_3, \dots, -\theta_q, \sigma_e^2$ los cuales en la práctica se estiman utilizando la información de la serie.

Porque $1 + \theta_1 + \theta_2 + \theta_3 + \dots + \theta_q < \infty$, un proceso finito de medias móviles es siempre estacionario. Este proceso es invertible si las raíces de $\alpha(B) = 0$ están fuera del círculo unitario.

Una razón importante para usar las medias móviles es que el número de parámetros puede reducirse drásticamente y, como los parámetros deben estimarse con un número finito de puntos, es importante representar el proceso con el menor número posible de parámetros. A esto se llama principio de PARSIMONIA (parsimony), este principio pretende encontrar el modelo más representativo con la mayor economía de parámetros⁴⁰.

³⁹ Box, G., Jenkins, G.... pag. 10

⁴⁰ González... pag. 20

Parsimonia - Porque los modelos matemáticos que necesitamos emplear, contienen ciertas constantes o parámetros cuyos valores deben ser estimados a partir de los datos de la serie, es importante que en la práctica utilicemos el menor número posible de parámetros para una representación adecuada. El rol central jugado por este *principio de parsimonia* en el uso de parámetros, será aclarar como debemos proceder en la elección del modelo⁴¹

Los procesos de medias móviles son útiles en la descripción de fenómenos en los cuales los eventos producen un efecto inmediato que solo perdura después de un periodo corto de tiempo. Este proceso se obtuvo como resultado del estudio de Slutsky (1927) en los efectos de los promedios móviles de eventos aleatorios⁴². Wold (1938) probó que un proceso estacionario que es puramente no determinístico (es decir, un proceso contiene un componente no determinístico que puede ser pronosticado o predicho exactamente desde su propio pasado) puede ser siempre expresado en la forma 2.4.3.5 Así, la representación es también conocida como representación de Wold en la literatura, y cualquier proceso que puede ser representado en esta forma es llamado un proceso no determinístico⁴³.

AUTOCORRELACIONES DE UN MODELO MA(q)

Para este modelo MA(q) la varianza es:

$$\gamma_0 = \sigma_\epsilon^2 \sum_{j=0}^q \theta_j^2 \quad (2.4.3.7)$$

donde $\theta_0 = 1$, y las autocovarianzas son

$$\gamma_k = \begin{cases} \sigma_\epsilon^2 (-\theta_k + \theta_1 \theta_{k-1} + \dots + \theta_{q-k} \theta_q), & k = 1, 2, 3, \dots, q \\ 0, & k > q \end{cases} \quad (2.1.3.8)$$

Por lo tanto la función de autocorrelación esta dada por

$$\rho_k = \begin{cases} \frac{\sigma_\epsilon^2 (-\theta_k + \theta_1 \theta_{k-1} + \dots + \theta_{q-k} \theta_q)}{\sigma_\epsilon^2 \sum_{j=0}^q \theta_j^2}, & k = 1, 2, \dots, q \\ 0 & k > q \end{cases} \quad (2.1.3.9)$$

⁴¹ Box, G., Jenkins, G.... pag. 17

⁴² Wei.... pag. 46

⁴³ Wei.... pag. 25

La función de autocorrelación de un proceso MA(q) se corta después de q periodos. Esta propiedad es importante para la identificación de cualquier serie de tiempo que este generada por un proceso de Medias Móviles.

AUTOCORRELACIONES PARCIALES DE UN MODELO MA(q)

La PACF para el proceso general MA(q) disminuye como una mezcla de un decaimiento exponencial y/o reducción en forma de hondas, dependiendo de la naturaleza de las raíces de $(1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) = 0$. La PACF contendrá una reducción en forma de hondas si alguna de las raíces son complejas.

Modelo de Medias Móviles de primer orden MA(1)

Cuando $\theta(B) = (1 - \theta_1 B)$, tenemos un proceso de medias móviles de primer orden.

$$\begin{aligned} Z_t &= e_t - \theta_1 e_{t-1} \\ &= (1 - \theta_1 B)e_t \end{aligned}$$

donde $\{e_t\}$ es un proceso de ruido blanco con media igual a cero y varianza σ_e^2 . La media de $\{Z_t\}$ es $E(Z_t) = \mu$

ACF de un MA(q).- La función de autocorrelación es

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

la cual se corta después de la longitud 1.

Porque $1 + \theta_1^2$ es siempre seguro, el proceso MA(1) es siempre estacionario. No obstante, para que un proceso sea invertible, las raíces de $(1 - \theta_1 B) = 0$ deben estar fuera del círculo unitario. Porque $B = 1/\theta_1$, requerimos a $|\theta_1| < 1$ para que el proceso MA(1) sea invertible.

PACF de un MA(1).- En general

$$\phi_{kk} = \frac{-\theta_1^k (1 + \theta_1^{2k})}{1 - \theta_1^{2k+2}} \quad \text{para } k \geq 1.$$

Contrariamente a su ACF, la cual se corta después de 1 longitud, la PACF de un modelo MA(1) decae exponencialmente en una de las dos formas dependiendo

del signo de θ_i . Si se sustituye el signo, puede empezar con un valor positivo; de lo contrario decae en el lado negativo.

c) Modelos Mezclados -autorregresivos-medias móviles- (ARMA).

La tercera clase de posibles modelos es un modelo mixto. Frecuentemente el patrón de la información será mejor descrito por un proceso mixto de elementos AR y MA.

Como se tiene mostrado, un proceso estacionario e invertible puede ser representado con cualquiera de las dos maneras, en una forma MA o en una forma AR. No obstante, un problema con ambas representaciones es que quizás contiene demasiados parámetros. Esto es verdad, aun para un modelo MA de orden finito y un modelo AR de orden finito, que frecuentemente toman un alto orden para una buena aproximación. Así, para lograr una gran flexibilidad en la construcción de un modelo que se ajuste a la serie de tiempo, algunas veces es ventajoso incluir ambos términos. Esto nos conduce al siguiente modelo mezclado autorregresivo-medias móviles⁴⁴:

$$\bar{Z}_t = \phi_1 \bar{Z}_{t-1} + \dots + \phi_p \bar{Z}_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (2.4.3.10)$$

o

$$\phi(B)\bar{Z}_t = \theta(B)e_t \quad (2.4.3.11)$$

en la cual empleamos $p + q + 2$ parámetros desconocidos μ , ϕ_1, \dots, ϕ_p , $\theta_1, \dots, \theta_q$, σ_e^2 , que son estimados a partir de los datos de la serie.

Es evidente que la ecuación (2.4.3.11) es simplemente la combinación de las ecuaciones (2.4.3.2) y (2.4.3.6). Muestra que los valores futuros de Z dependen tanto de valores pasados de Z como de los errores pasados entre el actual y los valores pronosticados.

Para que el proceso sea invertible requerimos que las raíces de $\theta_q(B) = 0$ estén fuera del círculo unitario. Para que sea estacionario, requerimos que las raíces de $\phi_p(B) = 0$ estén fuera del círculo unitario. También asumimos que $\theta_q(B) = 0$ y $\phi_p(B) = 0$ parten de raíces no comunes. De ahora en adelante, nos referimos a estos procesos como un modelo ARMA(p,q), en el cual p y q son usados para indicar los órdenes de la asociación de los polinomios AR y MA respectivamente.

⁴⁴ Box, G., Jenkins, G...

LA ACF Y PACF DE UN MODELO ARMA(p,q).

La ACF de un modelo ARMA(p,q) decae después de q retrasos justo como un proceso AR(p) el cual depende sólo de parámetros autorregresivos en el modelo. No obstante, la primera q autocorrelación $\rho_1, \rho_2, \dots, \rho_q$, depende de ambos parámetros autorregresivo y medias móviles en el modelo y sirve como un valor inicial para el patrón. Esta distinción es útil en la identificación del modelo.

Porque un modelo ARMA contiene al proceso MA como un caso especial, su PACF será también una mezcla de un decaimiento exponencial y/o disminución con ondas, dependiendo de las raíces de $\hat{\alpha}(B) = 0$ y $\hat{\phi}(B) = 0$.

Por lo tanto, en la práctica, una serie de tiempo estacionaria puede ser obtenida con cualquiera de los modelos antes mencionados (AR, MA o ARMA) en los cuales p y q no son mayores de 2 y frecuentemente menores a éste.

A manera de resumen, se presenta la tabla 2.4.3.1, la cual contiene las principales características que poseen estos modelos, así como las diferencias entre ellos.

MODELOS ESTACIONARIOS.

Un proceso se dice que es estrictamente estacionario si sus propiedades no se afectan por un cambio en la serie original. Usualmente estos procesos pueden ser descritos por su media, varianza y función de autocorrelación.

Si no hay tendencia puede asumirse que la media es constante y que el valor observado para cada período puede representarse por esta media. Esta suposición es sólo una condición para la estacionaridad. Una segunda condición es que la varianza del proceso sea también constante. Finalmente, debe imponerse una condición más sobre la correlación de los datos. Este valor sólo dependerá de k , en el caso de series estacionarias, es decir, la relación entre dos variables sólo depende del intervalo que las separa.

Los modelos de series de tiempo que se han discutido hasta el momento, son todos procesos estacionarios. No obstante, muchas aplicaciones de series de tiempo, particularmente aquellas que son obtenidas de la economía y de otras áreas, son no estacionarias. Con respecto a la covarianza de los procesos estacionarios, las series no estacionarias pueden darse de diferentes maneras. Ellas podrán tener media no constante μ_t , varianza no constante σ_t^2 , o tienen ambas propiedades.

Tabla 2.4.3.1. Resumen de las propiedades de los procesos autorregresivos, medias móviles y mezclado ARMA

	Proceso autorregresivo	Proceso de medias móviles	Proceso mezclado
Modelo en términos de Z 's previos	$\alpha(B)Z_t = e_t$	$\theta'(B)Z_t = e_t$	$\theta'(B)\alpha(B)Z_t = e_t$
Modelo en términos de e 's previos	$Z_t = \phi'(B)e_t$	$Z_t = \theta(B)e_t$	$Z_t = \phi'(B)\theta(B)e_t$
Valores π	serie finita	serie infinita	serie infinita
Valores ν	serie infinita	serie finita	serie infinita
Condición de estacionaridad	las raíces de $\alpha(B) = 0$ están fuera del círculo unitario	siempre es estacionario	las raíces de $\alpha(B) = 0$ están fuera del círculo unitario
Condición de invertibilidad	siempre es invertible	las raíces de $\theta(B) = 0$ están fuera del círculo unitario	las raíces de $\theta(B) = 0$ están fuera del círculo unitario
Función de autocorrelación	infinita (decae exponencialmente y/o disminuye en forma de ondas)	finita Se trunca en q	infinita (decae exponencialmente y/o disminuye en forma de ondas)
Función de autocorrelación parcial	finita Se trunca en p	infinita (decae exponencialmente y/o disminuye en forma de ondas)	infinita (decae exponencialmente y/o disminuye en forma de ondas)

FUENTE: Box-Jenkins, 1976, pp 79

En esta sección se ilustrará la construcción de una clase muy útil de modelos de series de tiempo no estacionarios, el autorregresivo integrado medias móviles (ARIMA). Algunas diferencias y transformaciones para estabilizar la varianza son introducidas para conectar a los modelos de series de tiempo estacionarios con los no estacionarios.

Estabilización de la varianza.

Hay muchas series de tiempo que son estacionarias en la media, pero no estacionarias en la varianza. Para resolver este problema necesitamos una apropiada transformación estabilizadora de la varianza.

Existen varias transformaciones posibles para inducir una varianza constante. La idea básica es transformar los datos de modo que las curvas tiendan a cambiar por rectas y al mismo tiempo hacer la varianza constante. Las transformaciones más usadas son las logarítmicas y las raíces cuadradas, en general, estas transformaciones son útiles cuando:

- La varianza es proporcional al crecimiento de la serie.
- El nivel medio de la serie se incrementa/decrementa a una tasa constante

Pueden usarse otras transformaciones de tipo exponencial como recíproco, recíproco de la raíz cuadrada, etc.

Generalmente, para la estabilización de la varianza, se usa la transformación de potencia⁴⁵

$$T(Z_t) = Z_t^{(\lambda)} = \frac{Z_t^\lambda - 1}{\lambda} \quad (2.4.3.12)$$

introducida por Box y Cox (1964), λ es llamado el parámetro de la transformación. Algunos valores de λ comúnmente utilizados y sus transformaciones asociadas son:

Valores de λ (lambda)	Transformación
-1.0	$1 / Z_t$
-0.5	$1 / \sqrt{Z_t}$
0.0	$\ln Z_t$
0.5	$\sqrt{Z_t}$
1.0	Z_t , no transformación

FUENTE: Wei, 1990, pag 84

Nota: Una transformación estabilizadora de varianza, si se necesita, deberá ser utilizada antes de cualquier otro análisis como las diferencias.

⁴⁵ Wei..., pag. 84

Eliminación de la tendencia.

Existen varios métodos para eliminar la tendencia, uno de ellos es usar un modelo de regresión, que se usa cuando la tendencia es fija y determinística. El problema real radica en que es sumamente difícil saber cuando un cambio en el nivel de la serie se debe a que la tendencia sea determinística o estocástica. Por ésta y otras razones se usan las diferencias, no siempre es lo más efectivo, aunque generalmente funciona para series con un número grande de observaciones⁶⁶.

Muchas series, actualmente, presentan un comportamiento no constante y en particular no varían alrededor de una misma clase. Tales series quizás, sin embargo, exhiban un comportamiento homogéneo de un tipo. En particular, aunque exista un nivel general alrededor del cual las fluctuaciones ocurren, éstas pueden ser diferentes en tiempos diferentes, el comportamiento general de la serie quizás sea similar, aun cuando las diferencias en el nivel sean utilizadas.

En términos de los modelos ARMA el proceso es no estacionario si algunas raíces de su polinomio AR no se encuentran fuera del círculo unitario. No obstante, por la naturaleza de la homogeneidad, el comportamiento local de este tipo de series no homogéneas es independiente a sus niveles (Box y Jenkins, 1976). Tal comportamiento puede ser representado por un operador autorregresivo generalizado $\phi(B)$, en el cual uno o más de los ceros del polinomio $\phi(B)$ (una o más de las raíces de la ecuación $\phi(B) = 0$) es unitario. Así el operador $\phi(B)$ puede ser escrito

$$\phi(B) = \phi(B)(1 - B)$$

donde $\phi(B)$ es un operador estacionario. Así un modelo general, el cual presenta un comportamiento homogéneo no estacionario, es de la forma:

$$\phi(B)Z_t = \phi(B)(1 - B)^d Z_t = \theta(B)e_t \quad (2.4.3.13)$$

esto es

$$\phi(B)w_t = \theta(B)e_t \quad (2.4.3.14)$$

donde

$$w_t = \nabla^{-d} Z_t \quad (2.4.3.15)$$

El comportamiento homogéneo no estacionario puede entonces ser representado por un modelo que utiliza la d -ésima diferencia y convierte al proceso en estacionario. En la practica d usualmente es 0,1 y como valor máximo 2.

⁶⁶ González.... pag. 11

ESTA TESIS NO DEBE SALIR DE LA BIBLIOTECA

Método de Box-Jenkins

Modelos autorregresivos integrados medias móviles (ARIMA)

Puesto que, el proceso estacionario resultante de una serie no estacionaria homogénea debidamente diferenciada no es necesariamente ruido blanco, la serie diferenciada $(1-B)^d Z_t$, sigue un proceso general estacionario ARMA. Entonces, el proceso definido por (2.4.3.14) y (2.4.3.15) provee de un poderoso modelo para describir series de tiempo estacionarias y no estacionarias y es llamado proceso autorregresivo integrado medias móviles (ARIMA), de orden (p,d,q) .

El proceso esta definido por

$$w_t = \phi_1 w_{t-1} + \dots + \phi_p w_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (2.4.3.16)$$

con $w_t = \sum_{j=0}^{\infty} Z_j$. Note que si reemplazamos a w_t por $Z_t - \mu$ entonces $d = 0$. Este modelo incluye, como un caso especial, al modelo mezclado estacionario, y también al modelo puro autorregresivo y la modelo puro de medias móviles. Cuando $p = 0$, el modelo ARIMA es también llamado modelo integrado medias móviles de orden (d,q) y es denotado como el modelo IMA (d,q) : al igual que ARI (autorregresivo integrado) cuando $q = 0$.

La razón de la inclusión de la palabra "integrado" (la cual, quizás podría ser mas adecuada "sumada") en el título ARIMA, es por lo siguiente:

La relación que es inversa a (2.4.3.15) es

$$Z_t = S^d w_t$$

donde se recalca que, S es el operador de suma definido por

$$S w_t = \sum_{j=0}^{\infty} w_{t-j} = w_t + w_{t-1} + w_{t-2} + \dots$$

Por lo tanto, se le llama *integrado* ya que al calcular los pronósticos será necesario efectuar el proceso opuesto a las diferencias: "integrar" o sumar los valores para reconstruir la variable original.

Por muchas razones -que no serán discutidas en este trabajo-, algunas veces es útil considerar una pequeña extensión de los modelos ARIMA, los cuales adhieren un termino constate θ_0 . Así, una forma mucho más general del modelo ARIMA es:

$$\phi(B)Z_t = \phi(B)\nabla^d Z_t = \theta_0 + \theta(B)e_t \quad (2.4.3.17)$$

donde

Análisis de series de tiempo

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

Y se tiene que:

- 1) $\phi(B)$ será llamado el *operador autorregresivo*.
- 2) $\psi(B) = \nabla^d \phi(B)$ será llamado el *operador autorregresivo generalizado* (operador de diferencias).
- 3) $\theta(B)$ será llamado el *operador de medias móviles*.

Así, el proceso general autorregresivo integral medias móviles (ARIMA) podrá ser generado desde un proceso ruido blanco e_t , por medio de tres operadores "filtros". Este punto será explicado en la siguiente sección referida a la metodología de Box-Jenkins.

2.4.4. Metodología de Box-Jenkins.

En 1976, George E. P. Box y Gwilym M. Jenkins publican su libro TIME SERIES ANALYSIS. Forecasting and Control, en el cual proponen una metodología para desarrollar el análisis de series de tiempo y mencionan cuatro aplicaciones prácticas del pronóstico de series de tiempo.

Este método consiste en extraer los movimientos predecibles de los datos observados. La serie de tiempo se descompone en varios componentes, algunas veces llamados "filtros", precisamente porque la filosofía del método consiste en detectar las distintas componentes usando los operadores "filtro", hasta obtener residuales no predecibles cuyo comportamiento tiene poca influencia en el resultado final.

Como se mencionó anteriormente, el enfoque de Box-Jenkins hace principalmente uso de tres operadores "filtro": el autorregresivo, el de integración (o suma) y el de medias móviles.



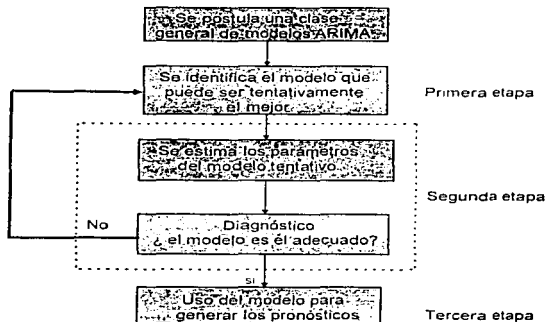
FUENTE Makridakis 1989

El proceso iterativo de BOX-JENKINS consiste en cuatro pasos para construir modelos lineales de series de tiempo:

1. *Identificación* de las especificaciones preliminares del modelo.
2. *Estimación* de los parámetros.
3. *Diagnóstico* de la adecuación del modelo.
4. *Pronóstico* de realizaciones futuras.

Este proceso iterativo está basado en el diagrama esquemático mostrado en la figura 2.4.4.1. Primero, una clase general de modelos de pronósticos es postulada, entonces tres etapas son propuestas. En la *primera etapa* es identificado un modelo específico que puede ser considerado tentativamente como el mejor modelo de pronóstico a la serie de tiempo. La *segunda etapa* consiste en el ajuste del modelo sobre la información histórica disponible en la serie y desarrollar un diagnóstico para determinar si es el adecuado. Si no, se debe regresar a la primera etapa y un modelo alternativo es identificado de aquellos disponibles de la clase general. Cuando un modelo adecuado fue aceptado, la *tercera etapa* es desarrollada y consiste en la obtención de un pronóstico para algún periodo futuro de tiempo.

Figura 2.4.4.1. Metodología de Box-Jenkins



FUENTE: Makridakis, 1989, pag. 133

Análisis de series de tiempo

Normalmente se supone que los valores sucesivos de la serie de tiempo bajo consideración, están disponibles para el análisis. Si es posible, más de 50 y preferentemente 100 observaciones (o más) deben ser utilizadas. Si esto no es posible, uno procede a utilizar la experiencia y la información pasada para construir un modelo preliminar. Este modelo se actualiza constantemente conforme más observaciones se tengan disponibles.

En el ajuste dinámico del modelo, un análisis teórico puede algunas veces no solo decirnos la forma apropiada del modelo, sino también nos provee con buenos estimadores de los valores numéricos de los parámetros. Los cuales, más tarde, podrán ser analizados.

Resumiendo el proceso iterativo de la construcción del modelo para pronóstico y control, el cual fue aplicado por Box-Jenkins tenemos:

1. A partir de la interacción entre la teoría y práctica, se considera una clase útil de modelos.
2. Porque esta clase es muy extensa para ser convenientemente ajustada a la serie de tiempo, se desarrolla un método para identificar una subclase de estos modelos disponibles.
3. El modelo tentativo es ajustado a la información y sus parámetros son estimados. Los estimadores obtenidos durante la etapa de identificación pueden ahora ser usados como valores iniciales en métodos iterativos más refinados para la estimación de parámetros.

El diagnóstico es aplicado con el objeto de encontrar una posible falta de ajuste y diagnosticar la causa. Si no se indica una falta de ajuste, el modelo está listo para usarse. Si cualquier anomalía es encontrada, el ciclo iterativo de identificación, estimación y diagnóstico, es repetido hasta encontrar una representación adecuada.

Es importante saber que hay modelos que se ajustan a los datos pero que generan pronósticos inaceptables. En este caso hay que regresar a la identificación, o inclusive, revisar si el modelo es realmente el adecuado. Por otro lado, de acuerdo al objetivo final, puede sacrificarse el ajuste por la precisión en los pronósticos.

Los procedimientos empleados en la identificación son inexactos y requieren de mucho razonamiento y experiencia, así como del conocimiento del fenómeno en

cuestión. La idea es elegir un modelo sencillo y tratar de mejorarlo. Por supuesto, no se podrá hablar de un modelo óptimo⁴⁷.

a) IDENTIFICACIÓN DEL MODELO.

Hablando teóricamente, debemos recordar que un proceso ARIMA de orden (p, d, q) proporciona una clase de modelos capaces de representar cualquier serie de tiempo, las cuales a pesar de que no son necesariamente estacionarias, si son homogéneas y están en equilibrio estadístico.

El proceso ARIMA esta definido por la ecuación

$$\phi(B)(1 - B)^d Z_t = \theta_0 + \theta(B)e_t,$$

donde $\phi(B)$ y $\theta(B)$ son operadores en B de grado p y q respectivamente, en los cuales sus raíces están fuera del círculo unitario.

Hay que notar que este modelo es muy general, conteniendo modelos autorregresivos, modelos de medias móviles, modelos autorregresivos-medias móviles y la forma integral para los tres.

Esta ecuación puede ajustarse para cualquier patrón de la información. Sin embargo, los valores de p (0, 1, 2...) y q (0, 1, 2...) deben ser especificados antes de que el modelo pueda ser aplicado. Obviamente p y q pueden tomar cualquier valor, aunque raramente son más grandes que 2.

Entonces, la identificación del modelo se refiere a la metodología para identificar las transformaciones requeridas, tal como la transformación estabilizadora de la varianza y la transformación de diferencias, la decisión para incluir el parámetro determinístico θ_0 , cuando $d > 1$, y los órdenes adecuados de p y q del modelo. Sin embargo, el problema que existe, es cómo escogerlos, de tal manera que, un modelo pueda ser ajustado a la información sin tener que probar todas las posibles combinaciones.

Entonces, nuestro objetivo será obtener un modelo adecuado pero parsimonioso. Cuidado y esfuerzo son necesarios en la selección del modelo, el proceso de selección es necesariamente interactivo, esto es, un proceso de evolución, adaptación o de prueba y error. No es una exageración decir que la parte más difícil de la metodología de Box-Jenkins es identificar un modelo apropiado; pero a pesar de esto y de que los procedimientos son inexactos y requieren del juicio personal del investigador, existen sistemas de identificación e incluso algunos

⁴⁷ Gonzalcz., pag. 7

de los nuevos paquetes de cómputo permiten una identificación automática o semiautomática.

Ahora bien, la *tarea de identificación* para escoger un modelo tentativo, se puede dividir en los siguientes pasos:

1a.- Graficar los datos de la serie de tiempo y escoger las transformaciones adecuadas.- En cualquier análisis de series de tiempo, el primer paso es la gráfica de los datos. Haciendo cuidadosamente el examen de la gráfica, usualmente tendremos una buena idea a cerca de que si la serie contiene una tendencia, estacionalidad, brincos, varianza no constante y/o otros fenómenos anormales y no estacionarios. Este entendimiento frecuentemente proporciona una base para postular una posible transformación de los datos.

La teoría básica detrás de los modelos ARMA implica sólo la horizontalidad (en términos estadísticos, estacionaridad) de los datos. Así, antes de intentar identificar p y q en la ecuación general del modelo, la información debe ser estacionaria (sin tendencia y con varianza constante).

Como se mencionó antes, en el análisis de series de tiempo, las transformaciones comúnmente utilizadas son la estabilizadora de la varianza y la diferencia. Algunas veces, las diferencias crean algunos valores negativos y no siempre podremos aplicar una transformación estabilizadora de la varianza después de hacer las diferencias. Por lo tanto una transformación estabilizadora de la varianza, si es necesario, es frecuentemente elegida antes de que hagamos cualquier otra transformación. A la serie resultante de este análisis, comúnmente se le llama *serie transformada*.

Si la serie tiene un patrón estacional, en adición a los tipos de diferencias ordinarias (llamadas cortas o periodo a periodo), podrían también ser necesarias unas diferencias estacionales (o largas) para asegurar la estacionaridad en la información.

2a.- Calcular y examinar las ACF y PACF muestrales para confirmar el grado necesario de la diferenciación.- Si la ACF muestral decae lentamente y la PACF muestral se corta después de la longitud 1, esto indica que la diferenciación es necesaria. En un caso dudoso, la diferencia es generalmente recomendada.

3a.- Calcular y examinar las ACF y PACF muestrales de la serie propiamente transformada y diferenciada, para identificar el orden de p y q . Hay que recordar que p es el orden mayor del polinomio autorregresivo y q el orden mayor del polinomio medias móviles. Usualmente el orden necesitado de estos parámetros son menor o igual a 2. Identificamos el orden de p y q mediante la

comparación del patrón de las ACF y PACF muestrales con el patrón teórico de las mismas en los modelos conocidos.

La siguiente tabla sintetiza los resultados importantes para esta selección.

Características de las ACF y PACF teóricas para un modelo estacionario.		
Proceso	ACF	PACF
AR (p)	Decae exponencialmente o con ondas.	Se trunca después de p
MA (q)	Se trunca después de p	Decae exponencialmente o con ondas
ARMA (p, q)	Disminuye después de ($q-p$)	Disminuye después de ($p-q$)

FUENTE: Wei, 1990 pag. 106

Por lo que, como regla general, cuando las autocorrelaciones decrecen exponencialmente a 0, el modelo es un AR y su orden está determinado por el número de autocorrelaciones parciales que son significativamente diferentes de 0. Si las autocorrelaciones parciales decrecen exponencialmente a 0, el modelo es un MA y su orden está determinado por el número de autocorrelaciones estadísticamente significativas.

Para construir un modelo ARIMA razonablemente, necesitamos un mínimo de $n = 50$ observaciones y el número de ACF y PACF muestrales calculadas deberán ser aproximadamente $n/4$, aunque ocasionalmente, con una buena calidad de la información se podrá identificar un modelo adecuado con una pequeña cantidad de muestras (ACF y PACF).

4a.- Prueba para determinar el término de tendencia θ_0 , cuando $d > 0$. Si hay una razón para creer que la serie diferenciada contiene un media con tendencia determinística, uno puede incluir a θ_0 inicialmente y descartarla en la estimación del modelo final si la estimación preliminar resulta ser no significativa. Al igual que con la estimación de los parámetros p y q se utiliza el estadístico t para saber si θ_0 es estadísticamente significativa (Ver Wei, 1990, pag.106-107).

Información estacional.

Quando los datos son estacionales, la ecuación general del modelo ARIMA (p, d, q) podría no ser suficiente y debe ser complementada con parámetros estacionales. Los modelos estacionales pueden también ser AR, MA y ARMA. En la realidad muchos modelos incluyen ambos parámetros, estacionales y no

estacionales, y así, con una combinación de ecuaciones de los modelos AR, MA y ARMA, usualmente se prepara un modelo estacional ARIMA $(p,d,q)(P,D,Q)_s$

Para estimar los valores estacionales de p y q (usualmente denotados por P y Q), se sigue el mismo proceso que se usó con la información no estacional. Esto es, las ACF y PACF son analizadas, pero en esta ocasión las autocorrelaciones y autocorrelaciones parciales no estacionales son ignoradas y sólo aquellas estacionales son examinadas. Sin embargo, desafortunadamente, en algunas ocasiones no hay suficientes autocorrelaciones y autocorrelaciones parciales para proporcionar un proceso preciso de identificación como en el caso de la información no estacional. Así, el cálculo considerable y la prueba-error son requeridos. Afortunadamente P y Q son usualmente 0 o 1, lo cual hace relativamente fácil la tarea de selección.

b) ESTIMACIÓN DE PARAMETROS.

Una vez escogido el modelo tentativo examinando las autocorrelaciones y autocorrelaciones parciales, los parámetros de los modelos son estimados.

Como algo muy general, consideramos el modelo ARMA (p,q) . Así que discutimos la estimación de los parámetros $\phi = \phi_1, \phi_2, \phi_3, \dots, \phi_p$, $\mu = E(Z_t)$, $\theta = \theta_1, \theta_2, \theta_3, \dots, \theta_q$ y $\sigma_e^2 = E(e_t^2)$ en el modelo

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \phi_3 Z_{t-3} + \dots + \phi_p Z_{t-p} + e_t + \theta_1 e_{t-1} - \theta_2 e_{t-2} - \theta_3 e_{t-3} - \dots - \theta_q e_{t-q}$$

donde $Z_t = Z_t - \mu$, Z_t ($t = 1, 2, 3, \dots, n$) son n observaciones estacionarias o una serie de tiempo estacionaria propiamente transformada, y $\{e_t\}$ son v.a.i.d. (variable aleatoria independiente idénticamente distribuida) $N(0, \sigma_e^2)$ ruido blanco.

Para estimar estos parámetros, puede usarse el método de *mínimos cuadrados*, pero de acuerdo con Wei (1990) lo más recomendable es utilizar *máxima verosimilitud*, que resultará equivalente al de mínimos cuadrados.

Estos dos métodos son bien conocidos en la parte estadística de estimación de parámetros, por lo tanto para su uso es necesario conocer y entender algunos conceptos adicionales. El uso de estos métodos en la estimación de los parámetros de los modelos ARIMA resulta muy complicado sin conocerlos previamente, afortunadamente los paquetes de cómputo actuales realizan este procedimiento automáticamente e incluso realizan las pruebas de hipótesis para saber si son estadísticamente significativos; por lo tanto en este trabajo no se explicarán dichos métodos, pero el lector interesado en este tema podrá consultar la bibliografía propuesta.

c) DIAGNÓSTICO DE LA ADECUACIÓN DEL MODELO.

La construcción del modelo de series de tiempo es un procedimiento iterativo. Empieza con la identificación del modelo y la estimación de los parámetros. Después de la estimación de los parámetros, tenemos que si el modelo asumido es satisfactorio. Entonces, una vez que los parámetros óptimos son estimados, los errores e_t pueden ser examinados. La suposición básica es que el proceso $\{e_t\}$ es ruido blanco. Esto es, los e_t 's son saltos aleatorios no correlacionados con media cero y varianza constante. En cuanto a esto, hay dos posibles resultados: 1) que los errores sean aleatorios con lo cual se piensa que el modelo ajustado tiene eliminados los patrones sobre la información y lo que queda son errores aleatorios; o 2) que el modelo tentativamente identificado no tiene todos los patrones removidos lo que indica que los e_t no son aleatorios.

Por lo tanto, la evaluación del modelo diagnosticado es realizado a través de un análisis cuidadoso de la serie de los residuales $\{e_t\}$. Porque esta serie residual es el producto de la estimación de los parámetros, la verificación del modelo diagnosticado esta usualmente contenido en la fase de estimación en un paquete de series de tiempo.

Al verificar si los errores están normalmente distribuidos, uno puede construir un histograma de los residuales estandarizados $\hat{e}_t / \hat{\sigma}_e$ y compararlos con la distribución normal estándar usando la prueba de bondad de ajuste *Chi-cuadrada*⁴. Al verificar si la varianza es constante, podemos examinar la gráfica de los residuales o evaluar el efecto de los diferentes valores λ , por medio del método de Box-Cox. Para verificar si los residuales son ruido blanco, calculamos las ACF y PACF muestrales de los residuales para ver si ellos no tienen algún patrón de comportamiento y son todos estadísticamente insignificantes (es decir, dentro de dos desviaciones estándar si $\alpha = 0.5$).

Afortunadamente, las autocorrelaciones de los residuales (errores) pueden ser calculadas fácilmente. Así, las autocorrelaciones pueden decirnos como valores sucesivos de los residuales se relacionan con los demás, si hay aleatoriedad, entonces las autocorrelaciones no deben ser significativamente diferentes de 0.

Buscando en los resultados de este análisis de residuales si el modelo mostrado es inadecuado, un nuevo modelo puede ser fácilmente derivado. Por supuesto no se podrá hablar de un modelo óptimo, sin embargo, se trata de mejorarlo hasta donde sea posible sin olvidar el principio de parsimonia.

Según González (González, 1990), si se detecta falta de ajuste deben buscarse diferentes especificaciones:

⁴ Wei, ..., pag. 149

- Análisis de estacionaridad.
- Modelo sub-especificado (agregar parámetros).
- Modelo sobre-especificado (omitir parámetros).

Análisis de estacionaridad. Debe tenerse cuidado de no sobrediferenciar el modelo. Esto genera un modelo más complicado, lo cual va en contra del principio de parsimonia.

Si el proceso no es estacionario, la selección no funcionará, ya que ésta es una de las suposiciones originales. En este caso es conveniente analizar nuevamente todas las alternativas para convertir una serie en estacionaria, y finalmente compararlas con objeto de elegir aquella que de un mejor resultado en cuanto a ajuste y pronósticos.

Modelo subespecificado. Para verificar que el modelo tentativo contiene el número apropiado de parámetros, puede incluirse un parámetro adicional para ver si de esta adición se obtiene un mejor modelo.

Existe un grave riesgo al ajustar parámetros extra al modelo de series de tiempo llamado la *redundancia de parámetros*. La redundancia de parámetros ocurre cuando se agrega al mismo tiempo un parámetro autorregresivo y uno de medias móviles. Por lo tanto, como regla, nunca se deberá agregar un parámetro AR y uno MA en forma simultánea.

Modelo sobreespecificado. Los parámetros redundantes o excesivos pueden localizarse usando cuidadosamente el estadístico *t* de los coeficientes y el estimador de las correlaciones entre los estimadores.

Puede usarse la desviación estándar para evaluar la significancia estadística de un coeficiente. Como regla de dedo puede decirse que un coeficiente es significativamente distinto de cero si el valor absoluto del estimador puntual es al menos dos veces el error estándar.

Un parámetro insignificante es una indicación de que el modelo puede estar sobreespecificado y deberá simplificarse. Si este parámetro insignificante es el de mayor orden, entonces, en general, el modelo ARIMA puede simplificarse eliminando este parámetro del modelo.

Si el parámetro insignificante no es el de mayor orden, entonces examinar las correlaciones entre los estimadores ayudará a saber cuál parámetro eliminar.

Si el parámetro insignificante no es el de mayor orden pero esta fuertemente correlacionado con el de mayor orden, se deberá evaluar el modelo sin el parámetro

de orden mayor. Si esta correlación no existe, se reestimaré el modelo ARIMA suprimiendo el parámetro insignificante.

En el caso de que el parámetro insignificante no sea el de mayor orden y no exista correlación, seguramente estará reflejando un efecto de fluctuación estacional.

Construyendo y pronosticando con modelos estacionales

Porque los modelos estacionales son formas especiales de los modelos ARIMA introducidos en la sección 2.2.3, la identificación del modelo, la estimación de los parámetros, la evaluación del modelo y la obtención de pronósticos, para estos modelos sigue el mismo método descrito en las secciones anteriores. La descripción de estos modelos no será repetida aquí.

d) OBTENCIÓN DE PRONÓSTICOS.

Uno de los más importantes objetivos en el análisis de una serie de tiempo es pronosticar sus valores futuros. Así, si el propósito final de la modelación de series de tiempo es el control de un sistema, su operación esta usualmente basada es un pronóstico. El termino pronóstico es usado más frecuentemente en la literatura reciente de series de tiempo, más que el de predicción. Sin embargo, los resultados de los pronósticos están derivados de una teoría general de predicción desarrollada por Kolmogorov (1939, 1941), Wiener (1949), Kalman (1960), Yaglom (1962) y Whittle (1983), entre otros.

Una vez que el modelo fue identificado, los parámetros estimados y los residuales muestran ser aleatorios, los pronósticos con ese modelo son una cuestión mecánica y directa. Un programa de cómputo es necesario para realizar los cálculos de identificación y estimación, y pueden prever de todos los pronósticos que se deseen junto con un intervalo de confianza para ellos casi siempre de 95% o 99%.

Se llama fecha de *origen* al periodo actual, esto es, al periodo n y supóngase que se desea pronosticar h periodos de tiempo hacia adelante, hasta el periodo $n+h$, esto es, se desea conocer el valor de la observación no realizada Z_{n+h} . El intervalo de tiempo h se llama *horizonte*, también se denota como $Z_n(h)$ al valor futuro estimado de la variable aleatoria.

Análisis de series de tiempo

Entonces, dada Z_{t+n} como una variable aleatoria cuya distribución es condicional a los datos pasados y presentes, así como la especificación de su modelo ARIMA:

$$\phi(B) \nabla^d Z_t = \theta(B)e_t \quad (2.4.4.1)$$

Tenemos:

Mínima media del error al cuadrado del pronóstico. Teniendo el conocimiento de una serie hasta una t original, la mínima media del error al cuadrado del pronóstico $Z_t(l)$ ($l > 0$) de Z_{t+l} es la expectativa condicional

$$\hat{Z}_t = \{Z_{t+l}\} = E\{Z_{t+l} | Z_t, Z_{t-1}, \dots\} \quad (2.4.4.2)$$

Errores del pronóstico. Una consecuencia necesaria es que los errores del pronóstico son los e_t generados en el modelo y no están correlacionados.

Cálculo de los pronósticos. Es usualmente fácil en la práctica calcular los pronósticos directamente de la ecuación diferenciada:

$$\hat{Z}_t = \phi_1 \{Z_{t-1}\} + \dots + \phi_{p-d} \{Z_{t-p-d}\} + [e_{t+1}] - \theta_1 [e_{t+1-1}] - \dots - \theta_q [e_{t+1-q}] \quad (2.4.4.3)$$

Donde:

$$\hat{Z}_t(l) = E\{Z_{t+l}\}$$

$\hat{Z}_t(l) = E\{Z_{t+l} | Z_t, Z_{t-1}, \dots\}$ $l \geq 1$ para hacer el pronóstico de l se deben conocer los de $l-1, l-2, \dots$ etc.

$\hat{Z}_t(l) = Z_{t+l}$ $l \leq 0$ si no hay pronósticos debe tomarse los datos reales.

$\hat{e}_t(l) = 0$ $l \geq 1$ los siguientes errores se toman como cero.

$\hat{e}_t(l) = Z_{t+l} - \hat{Z}_{t+l-1}(l) = e_{t+l}$ $l \leq 0$ los errores anteriores se toman las diferencias.

Esto es:

- Reemplace el error actual con cero.
- Y los pasados, e_{t+h} $l \leq 0$ con los residuales.
- Cambie cada error futuro e_{t+h} $l \leq h$ con su valor esperado cero.
- Reemplace las observaciones Z_{t+h} $l \leq 0$ con los valores observado.

- e) Reemplace cada valor futuro de Z_{t+h} , $0 < h < h$ con el pronóstico adecuado $\hat{Z}_t(h)$, de modo que hay que pronosticar Z_{t+1}, \dots, Z_{t+h} para pronosticar Z_{t+h} .

Limites de probabilidad para los pronósticos. Estos pueden obtenerse:

- (a) primero calculando los valores ψ :

$$\begin{aligned} \psi_0 &= 1 \\ \psi_1 &= \varphi_1 - \theta_1 \\ \psi_2 &= \varphi_1 \psi_1 + \varphi_2 - \theta_2 \\ &\vdots \\ &\vdots \\ \psi_j &= \varphi_1 \psi_{j-1} + \dots + \varphi_{p+d} \psi_{j-p-d} - \theta_j \end{aligned} \quad (2.4.4.4)$$

donde $\theta_j = 0, j > q$

- (b) para cada nivel deseado de probabilidad ϵ , y para cada horizonte de tiempo l , sustituir en:

$$\bar{Z}_{t+l}(\pm) = \hat{Z}_t(l) \pm u_{\frac{\epsilon}{2}} \left(1 + \sum_{j=1}^{l-1} \psi_j^2 \right)^{\frac{1}{2}} \sigma_e \quad (2.4.4.5)$$

donde en la práctica σ_e es reemplazado por un estimador s_e , de la desviación estándar del proceso ruido blanco e_t , y $u_{\frac{\epsilon}{2}}$ es la desviación excedente por una porción $\epsilon/2$ en la unidad de la distribución normal.

Actualizando pronósticos. Cuando una nueva desviación Z_{t+1} , es dada, los pronósticos pueden ser actualizados desde $t+1$, calculando el nuevo error de pronóstico $e_{t+1} = Z_{t+1} - \hat{Z}_t(1)$ y usando la ecuación diferenciada (2.4.4.3) con $t+1$ reemplazando t . Sin embargo, un método alternativo es usando la siguiente ecuación:

$$\hat{Z}_{t+1}(l) = \hat{Z}_t(l+1) + \psi_l e_{t+1} \quad (2.4.4.6)$$

y entonces generar los pronósticos pasados $Z_{t-1}(l)$ usando la ecuación diferenciada (2.4.4.3).

2.5. Análisis de intervención.

Las series de tiempo frecuentemente están afectadas por ciertos eventos externos, tales como, días de fiestas, ventas, promociones y otros cambios en las políticas de cierto sistema; a estos eventos externos presentes en las series de tiempo se les conoce como *intervenciones*. Una intervención, entonces, puede ser interpretada como la ocurrencia de un *evento exógeno* al comportamiento histórico de la variable en estudio.

En ocasiones, cuando se realiza el análisis de una serie de tiempo, puede suceder que se desee medir explícitamente la influencia de estas intervenciones, esto es, ya sea porque se juzgue de importancia la contribución de dicho evento para explicar el comportamiento de la variable que se estudia o bien porque se tema que el fenómeno anormal pueda afectar la estimación de los parámetros y los resultados del modelo, en general.

Entonces, a la técnica que evalúa los efectos de los factores exógenos de una serie de tiempo y que será presentada en esta sección, se le conoce como *Análisis de Intervención*. Esta técnica está basada en el artículo de Box y Tiao (1975) en el cual aparece prácticamente por primera vez¹⁹.

El análisis de intervención ha sido sucesivamente utilizado para estudiar el impacto del control de la contaminación atmosférica y las políticas económicas (Box y Tiao, 1975), el impacto del embargo del petróleo Árabe (Montgomery y Weatherby, 1980), el impacto del apagón de Nueva York (Izenman y Zabell, 1981) y algunos otros eventos.

Es importante aclarar que aquí sólo se discutirá el análisis cuando el compás de tiempo de la intervención es conocido (Análisis de intervención); aunque el método se puede generalizar para estudiar el impacto de los eventos cuando el compás de tiempo de la intervención es desconocido (Análisis de "outlier") (Ver Wei, 1990).

También es necesario considerar que los efectos causados directamente por la intervención de fenómenos externos al comportamiento de una serie de tiempo, puede ser de naturaleza muy variada. En particular, si se piensa que una serie de tiempo estacionaria Z_t , está constituida por dos partes una determinística que refleja esencialmente el nivel de la serie y otra estocástica que da origen a las fluctuaciones alrededor de dicho nivel, podrán distinguirse tres tipos de efectos: (1) aquellos que se dejan sentir como una elevación o caída momentánea del nivel y que desaparecen sin influir sobre el comportamiento posterior de la serie, (2) los que

¹⁹ Guerrero, V., *Análisis estadístico de series de tiempo econométricas*, U.A.M., Iztapalapa, México D.F. 1991, pag. 236

ejercen una influencia sostenida (no momentáneamente) sobre el nivel de la serie, pero dejan intacta la estructura básica de su parte estocástica, y (3) los efectos que, independientemente de influir o no sobre la parte determinística, si alteran la estructura de la parte estocástica. Las intervenciones que causan los efectos de tipo 1 y 2 son los que, de manera ortodoxa, pueden estudiarse mediante el análisis de intervención, mientras que las intervenciones causantes de efectos del tipo 3 requerirán otro tipo de análisis.

Dado que una intervención conocida ocurre en el tiempo T , existe una evidencia de cambio en la serie de tiempo (tal como el incremento o decremento del nivel de la media) y si esto pasa, entonces lo que interesa saber es ¿cuánto?. Se puede inicialmente pensar que la tradicional prueba de t -simple puede ser utilizada para analizar este problema en términos de comparación de los datos anteriores a la intervención con los posteriores. Sin embargo, la prueba t asume tanto la normatividad y la independencia. Aunque la prueba t es conocida por ser robusta con respecto a la asunción de la normalidad, esto es extremadamente sensible a la violación de la asunción de la dependencia como lo muestran Box y Tiao (1965), quienes desarrollaron el análisis de intervención al estudiar un cambio estructural en la serie de tiempo debido a los eventos externos⁵⁰.

Hay dos tipos comunes de variables de intervención. Una representa una intervención ocurrida en el tiempo T la cual permanece efectivamente de ahí en adelante (*Brusco permanente*), esto es, la intervención es una función paso

$$S_t^{(1)} = \begin{cases} 0 & t < T, \\ 1 & t \geq T. \end{cases} \quad (2.4.5.1)$$

La otra representa una intervención teniendo lugar solo en un período de tiempo (*Brusco temporal*). Así, esta es una función pulso

$$P_t^{(1)} = \begin{cases} 1 & t = T, \\ 0 & t \neq T. \end{cases} \quad (2.4.5.2)$$

Note que la función pulso puede ser producida diferenciando la función paso $S_t^{(1)}$. Por lo tanto un modelo de intervención puede ser representado tanto con la función paso como con la función pulso. El uso de una forma específica esta usualmente basado en la conveniencia de la interpretación.

Hay algunas posibles respuestas de la intervención pulso o paso. Algunas comúnmente utilizadas son:

⁵⁰ Wei..., pag. 184

Análisis de series de tiempo

1. Un impacto fijo es sentido b periodos después de la intervención. Así, dependiendo en el tiempo de intervención, el impacto es:

$$\omega B^b S_t^{(1)} \quad (2.4.5.3)$$

o

$$\omega B^b P_t^{(1)} \quad (2.4.5.4)$$

2. Un impacto de una intervención es sentido b periodos después de la intervención, pero la respuesta es gradual (*Gradual permanente o gradual temporal*). Para una entrada paso tenemos

$$\frac{\omega \delta^b}{(1-\delta B)} S_t^{(1)}, \quad (2.4.5.5)$$

o para una entrada pulso

$$\frac{\omega \delta^b}{(1-\delta B)} P_t^{(1)}, \quad (2.4.5.6)$$

donde $0 \leq \delta \leq 1$. Para $\delta=0$, (2.5.5) y (2.5.6) se reducen a (2.5.3) y (2.5.4) respectivamente. Si $\delta=1$, el impacto crece linealmente fuera de límite. Para más caso, tenemos $0 < \delta < 1$ donde la respuesta es gradual.

Más generalmente, una respuesta puede representarse como una función racional

$$\frac{\omega(B)B^a}{\alpha(B)} \quad (2.4.5.7)$$

donde $\omega(B) = \omega_0 + \omega_1 B + \dots + \omega_n B^n$ y $\alpha(B) = 1 - \alpha_1 B - \dots - \alpha_p B^p$ son polinomios en B , B es el tiempo de retraso para el efecto de la intervención y los valores de ω_i 's en el polinomio $\omega(B)$ frecuentemente representan los efectos iniciales esperados de la intervención. El polinomio $\alpha(B)$, por otra parte, mide el comportamiento de los efectos permanentes de la intervención. Las raíces de $\alpha(B) = 0$ están asumidas dentro o fuera de un círculo unitario. La raíz unitaria representa un impacto que se incrementa linealmente, y las raíces exteriores del círculo unitario representan un fenómeno que tiene una respuesta gradual.


De manera general y resumiendo lo antes mostrado, tenemos que el análisis de intervención hace distinción principalmente entre los tres mayores tipos de impactos⁵¹:

- a) Brusco Permanente.
- b) Gradual Permanente.

⁵¹ Statistica for Windows (Volumen III), *Statistics II 1984-1994*, StatSoft, Inc., U.S.A. 1994.


c) Brusco Temporal.

a) *Impacto Brusco Permanente.*- Un impacto con este patrón simplemente implica que la media general de la serie de tiempo cambia después de la intervención; el cambio general es denotado por ω (omega). Este impacto se ilustra en seguida:



FUENTE: STATISTICA Ver 3.1, 1992

b) *Impacto Gradual Permanente.*- El impacto con patrón gradual permanente implica que el incremento o decremento debido a la intervención es gradual, y que el impacto permanente definitivo llega a ser evidente sólo después de algún tiempo (ilustrado a continuación)



FUENTE: STATISTICA Ver 3.1, 1992

Este tipo de intervención puede ser expresado por la siguiente:

$$\text{Impacto}_t = \delta * \text{Impacto}_{t-1} + \omega$$

para toda $t \geq$ al tiempo del impacto, si no = 0

El impacto está definido por los dos parámetros δ (delta) y ω (omega). Si δ es cercano a cero, entonces la cantidad definitiva permanente del impacto podrá ser evidente solo después de algunas observaciones; si δ es cerrada a 1, entonces este

impacto definitivo permanente podrá solamente ser evidente después de muchas más observaciones.


Mientras el parámetro δ sea mayor a cero y menor a 1 (los límites de un sistema estable), el impacto podrá ser gradual y se refleja en un cambio asintótico en la media general que se calcula.

cambio asintótico en el nivel = $\omega/(1 - \delta)$

El paquete STATISTICA Ver 4.5 aquí utilizado, podrá automáticamente calcular este cambio asintótico.

Cuando se esté evaluado un modelo que se ajuste, es importante que ambos parámetros sean estadísticamente significativos; en otro caso un podrá encontrar conclusiones paradójicas.

c) *Impacto Brusco temporal.*- Este impacto implica un incremento o decremento brusco inicial debido a la intervención, la cual después lentamente decae, fuera de cambiar permanentemente la media de la serie.



FUENTE STATISTICA Ver. 3.1, 1992

Este tipo de intervención puede ser expresado por lo siguiente:

- Antes de la intervención: $Impacto_t = 0$
- En el tiempo de la intervención: $Impacto_t = \omega$
- Después de la intervención: $Impacto_t = \delta * impacto_{t-1}$

Este tiempo de impacto está también definido por los dos parámetros δ y ω . Mientras que el parámetro δ sea mayor que cero y menor que 1 el impacto brusco inicial podrá gradualmente decaer. Si δ es cercano a cero, entonces el descenso será muy rápido, y el impacto desaparecerá totalmente después de algunas observaciones. Si δ es cercano a 1, entonces el descenso será muy retardado y la intervención afectará a la serie después de muchas más observaciones. Es

importante que cuando se éste evaluando el modelo, también se verifique que ambos parámetros sean estadísticamente significativos.

Este análisis de intervención puede verse como una extensión del análisis de los procesos ARIMA, ya que un modelo para una serie Z_t que contenga los efectos de una intervención, puede expresarse como:

$$Z_t = \varepsilon_{it} + N_t$$

donde N_t es un modelo ARIMA, estacionario e invertible, que representa a la parte estocástica de la serie y el cual puede expresarse como:

$$\phi(B)\nabla^d Z_t = \theta_0 + \theta_1 B \varepsilon_t \quad (2.4.5.8)$$

mientras que ε_{it} es una función que permite representar los efectos de la intervención; dicha función debe ser tal que permita apreciar los cambios ocurridos en la serie no sólo en el momento en que ocurrió la intervención, sino los que se dieron posteriormente, atribuibles a ella, es decir se requiere que ε_{it} sea en realidad un modelo dinámico de la intervención

$$\varepsilon_{it} = \frac{\alpha_1 B^k}{1 - \alpha_1 B} I_{jt} \quad (2.4.5.9)$$

Por lo tanto, para múltiples entradas de intervención, tenemos la siguiente clase general de modelos llamados *Modelo dinámico general de intervención*

$$Z_t = \sum_{j=1}^k \frac{\alpha_j B^k}{1 - \alpha_j B} I_{jt} + \frac{\theta_0 + \theta_1 B \varepsilon_t}{\theta(B)} \quad (2.4.5.10)$$

donde I_{jt} , $j = 1, 2, \dots, k$ son las variables de intervención, estas variables de intervención pueden ser funciones de paso o pulso⁵².

Conviene además advertir que el supuesto de estabilidad implica la existencia de un cierto *nivel de equilibrio* de la ecuación (2.4.5.9) (que se refiere a la "ganancia" o cambio eventual atribuible a la intervención). Dicho nivel se calcula como el límite de la función ε_{it} cuando t tiende a infinito, al hacer ese cálculo con los modelos explícitos, puede observarse que el nivel de equilibrio de este modelo con $b = 0$ es cero, mientras que el correspondiente nivel para el modelo con $b = 1$ está dado por⁵³:

$$\varepsilon_{it}^* = \frac{\alpha_1 \varepsilon_{it} - \alpha_2 \varepsilon_{it}}{1 - \alpha_1 - \alpha_2} = \frac{\alpha_1 \varepsilon_{it}}{1 - \alpha_1 - \alpha_2} \quad (2.4.5.11)$$

⁵² Guerrero... pag. 239

⁵³ *idem*

El principal propósito de los modelos de intervención es la de medir el efecto de la intervención. Así, con respecto a las variables de intervención I_{it} , las series de tiempo libres de intervenciones son llamadas *series ruido* y denotadas por N_{it} , y donde sus modelos son por lo tanto conocidos como *modelos ruido*. El modelo ruido es usualmente encontrado usando el procedimiento de identificación de la Metodología de Box-Jenkins tomando a la serie de tiempo Z_t antes del dato de la intervención, es decir $\{Z_t; t < T\}$. Si el diagnóstico obtenido del modelo obtenido revela un modelo adecuado. Entonces podemos hacer inferencias apropiadas a cerca de la intervención. De otro modo, las modificaciones apropiadas deberán ser hechas al modelo chequeando nuevamente la estimación y el diagnóstico.

En la práctica, Box y Tiao sugieren que la forma específica del modelo sea puesta con base en el conocimiento teórico que se tenga, tanto de la serie en estudio como del fenómeno externo que tuvo lugar. Sin embargo, en muchas ocasiones el conocimiento teórico es muy pobre, al grado de no permitir una especificación precisa de un modelo dinámico, en tal caso sería conveniente postular varios modelos de intervención alternativos, o bien otra posibilidad es dejar que los datos mismos indiquen la forma de la función.

De acuerdo con Guerrero (Guerrero 1991), es importante hacer notar que en algunos casos la intervención puede ser recursiva o tener efectos recursivos, es decir, su efecto aparece no sólo una vez en el tiempo, sino que se repite varias veces. En estas condiciones conviene decir que la intervención estará constituida por varias *componentes estructurales*, una componente por cada vez que se repite el fenómeno de intervención.

De manera general, se puede decir que la metodología del análisis de intervención consiste, primero, en determinar el momento en el que, según se piense, la intervención pudo haber influido de manera exógena sobre el comportamiento de la variable de interés. Posteriormente se procede a postular un *modelo ruido* para conocer el comportamiento de la serie antes de la intervención, y después un modelo dinámico para representar el efecto de la intervención en los datos posteriores a esta, acto seguido se estima el modelo completo para todo el período muestral de observación, es decir se estiman simultáneamente tanto los parámetros que aparecen en la función de intervención como los del modelo determinado previamente para la parte estocástica; por último se verifica que se satisfagan los supuestos del modelo completo.

Capítulo 3.

***Aplicación del
Análisis de series
de tiempo al SO₂***

3.1 Esquema de trabajo

Como se planteó en los objetivos, el fin de este trabajo es analizar a las concentraciones de bióxido de azufre en la atmósfera de la ZMCM y evaluar las estrategias implantadas por la Industria Petrolera para la disminución y control de las emisiones que las generan, mediante el uso de la metodología de Box-Jenkins y el Análisis de Intervención respectivamente; ya que surge como inquietud el comprobar que estas metodologías son una buena herramienta para describir y evaluar el fenómeno de la contaminación atmosférica, específicamente a las concentraciones de contaminantes en la atmósfera. Como se mencionó en el capítulo I, el bióxido de azufre es uno de los contaminantes más peligrosos por sus efectos en la salud y en los materiales, lo que hace necesario su análisis, descripción y con ello su control.

Uno de los requerimientos al aplicar la metodología de Box-Jenkins y el Análisis de Intervención, es el conocer previamente las características del fenómeno a analizar y asegurarse de que respondan a las necesidades del análisis.

Por lo cual, una vez que se investigó el fenómeno de la contaminación atmosférica en la ZMCM y se obtuvo toda la información necesaria para aplicar la metodología de Box-Jenkins al análisis de las concentraciones del bióxido de azufre en la atmósfera, fue necesario plantear un esquema de trabajo que pudiera obtener los mejores resultados de la aplicación. Este capítulo describe dicho esquema de trabajo con la finalidad de facilitar el análisis de resultados y que trabajos posteriores puedan utilizarlo como referencia. Este esquema, señala los pasos que se siguieron para aplicar la Metodología de Box-Jenkins y el Análisis de Intervención a las concentraciones de bióxido de azufre, puesto que, como es sabido, solo el uso adecuado de los métodos matemáticos podrán generar resultados veraces y confiables.

3.2 Registros de las concentraciones del SO₂ .

Lo primero que se debe de cuidar para en el uso adecuado de los modelos matemáticos, específicamente de los estadísticos, es la obtención de los datos de forma tal que sean representativos del fenómeno. Para esto, es bueno conocer la fuente de donde son tomados y la forma en que son estudiados, es decir, es importante saber si la fuente es fidedigna y asegurarse de que los datos no hayan sido alterados por alguna razón externa al análisis.

3.2.1. Red Automática de Monitoreo Atmosférico (RAMA).

Como se mencionó anteriormente, la fuente de donde son tomados los datos es un punto muy importante para la aplicación de la estadística. Por lo tanto, es necesario puntualizar que para este trabajo, los datos de las concentraciones del SO₂ en la atmósfera fueron obtenidos de la Red Automática de Monitoreo Atmosférico (RAMA).

Como se mencionó en el capítulo 1, a partir de 1986, la Ciudad de México cuenta con dos redes de monitoreo atmosférico una automática y otra manual. La red automática mide contaminantes gaseosos, mientras que la manual mide material particulado. Ambas redes fueron diseñadas y operan conforme a los criterios establecidos por la Organización Mundial de la Salud y las Agencias de Protección Ambiental de los Estados Unidos y Alemania¹.

La Red Automática de Monitoreo Atmosférico (RAMA) cuenta con un centro de cómputo que enlaza telefónicamente 32 estaciones fijas y 2 móviles, las cuales están distribuidas en el área urbana de la Zona Metropolitana de la Ciudad de México específicamente en 17 municipios del Edo de México y en las 16 delegaciones del D Federal². Esta red, que opera los 365 días del año y las 24 horas del día en forma continua, permite registrar los siguientes contaminantes y parámetros meteorológicos.

- ozono
- *bióxido de azufre*
- óxidos de nitrógeno
- monóxido de carbono
- partículas menores a 10 micrómetros
- temperatura
- velocidad y dirección del viento
- humedad relativa.

La RAMA es auditada cada seis meses por la Agencia de Protección Ambiental de los Estados Unidos (EPA), y la Dirección de Ecología del Departamento del Distrito Federal es la entidad encargada de su operación³.

En el último reporte de la Organización Mundial de la Salud (OMS) y el Programa de las Naciones Unidas para el Medio Ambiente (PNUMA), la Red Automática de Monitoreo de la Ciudad de México recibió, junto con la de la ciudad de Los Ángeles la más alta calificación en cuanto a calidad y cobertura.

¹ Comisión Metropolitana para la Prevención y Control de la Contaminación Ambiental en el Valle de México, *La contaminación Atmosférica en el Valle de México (Acciones para su control 1988-1994)*, CMI/CEA, México D.F. 1994.

² SEDESOL, *Informe de la situación general en materia de equilibrio ecológico en protección al ambiente 1993-1994*, I. N. E., México D.F. 1994, pag. 221.

³ Comisión Metropolitana, pag. 38.

Los datos colectados en la RAMA son distribuidos al público mediante un sistema de comunicación que entaza, vía módem telefónico o fax, las estaciones de radio y televisión, Locatel, los centros de investigación y las oficinas del gobierno.

La información generada por la red de monitoreo es transmitida cada hora por las estaciones de radio y las cinco pantallas espectaculares dispuestas en las principales avenidas de la Ciudad. Los periódicos la reportan diariamente, y la Comisión Metropolitana la publica en reportes mensuales y anuales.

Las mediciones de la RAMA son representativas del "aire ambiente", están determinadas por los criterios de calidad del aire y constituyen un promedio virtual de las concentraciones de contaminantes a las que una persona está expuesta a lo largo del día y en cualquier lugar en que se encuentre. Las estaciones de monitoreo se han convertido en puntos de referencia para realizar campañas de investigación en salud, meteorología, química atmosférica e instrumentación analítica. Su información, recopilada a través de los años, es útil también para evaluar la efectividad de las medidas tomadas para el control de la contaminación atmosférica*

La Zona Metropolitana de la Ciudad de México esta dividida principalmente en 5 zonas de monitoreo -noroeste, noreste, centro, sureste y suroeste- lo que hace más fácil el análisis de las concentraciones de los contaminantes atmosféricos. Cada una de estas zonas consta de diferentes estaciones de monitoreo, así por ejemplo, la zona noroeste abarca diez estaciones, mientras que la noreste contiene ocho; la zona centro registra en cinco estaciones; la suroeste y sureste lo hacen en cinco y cuatro respectivamente.

Cuadro 3.2.1.1. Estaciones de monitoreo de la RAMA.

Zona				
Noroeste NO	Noreste EN	Centro CE	Suroeste SO	Sureste SE
Vallejo Tacuba ENEP Acatlán Azcapotzalco Tlalnepantla IMP	Laureles La presa La villa Sn Agustín Xalostoc Aragón	Lagunita Merced Hangares Benito Juárez Insurgentes	Sta Ursula Pedregal Plateros Cuajimalpa Tlalpan	C. de la Estrella UAM Iztapalapa Taxqueña Tlahuac
Cuiclahuac Tuititlán Atizapán V. Flores	Netzahualcoyotl Chapingo			

* Comisión Metropolitana.... pag. 35.

Cabe aclarar que no todas las estaciones de monitoreo registran la totalidad de contaminantes ni parámetros meteorológicos, así pues, podemos encontrar estaciones que registran sólo un contaminante y otras que registran varios. Únicamente existen seis estaciones que registran la mayoría de los contaminantes y meteorológicos, por esta razón son las más utilizadas para caracterizar las zonas al realizar trabajos de descripción por zona de monitoreo. Además de que éstas iniciaron desde 1986 y registran los datos más fidedignos de la RAMA porque su mantenimiento es continuo y están en constante observación.

Las seis estaciones más completas son: Tlalnepanitla, Tacuba, Cerro de la Estrella, Pedregal, Xalostoc y Merced; como se observa en el cuadro anterior estas estaciones se encuentran en zonas diferentes (excepto Tlalnepanitla y Tacuba), lo que permite que con sólo estas se puedan obtener los resultados para cada zona de monitoreo, así como para la ZMCM en general. Para la zona noroeste se toman en cuenta Tlalnepanitla y Tacuba debido a que esta zona es muy extensa y discrepante en sus características.

Cuadro 3.2.1.2. Las seis principales estaciones de monitoreo de la R.A.M.A. y sus registros

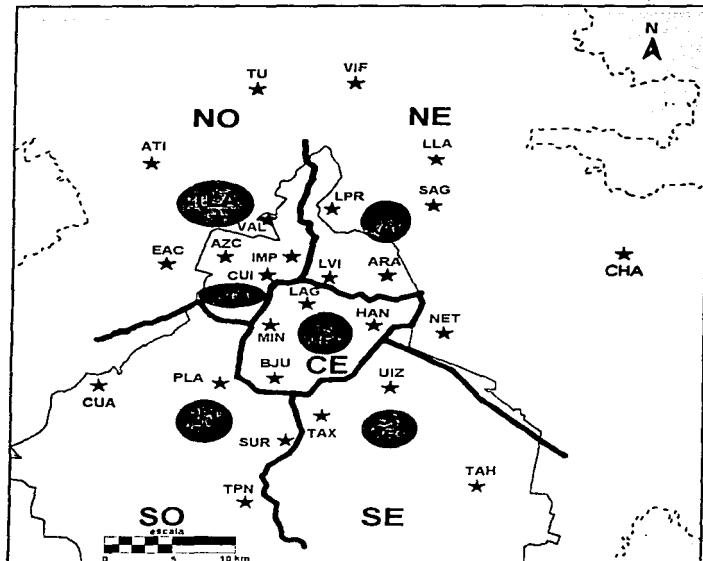
Zona	Estación	O ₃	CO	SO ₂	Met.	NO _x	NO _x	PM ₁₀	HC	H ₂ S
NO	Tlalnepanitla	•	•	•	•	•	•	•	•	
NO	Tacuba	•	•	•	•	•	•	•	•	
NE	Xalostoc	•	•	•	•	•	•	•	•	
CE	Merced	•	•	•	•	•	•	•	•	•
SO	Pedregal	•	•	•	•	•	•	•	•	•
SE	C Estrella	•	•	•	•	•	•	•	•	

O₃ - ozono
 CO - monóxido de carbono
 SO₂ - dióxido de azufre
 Met - parámetros meteorológicos
 NO₂ - dióxido de nitrógeno
 NO_x - óxido de nitrógeno
 PM₁₀ - Partículas menores a 10 micrometros
 HC - hidrocarburos
 H₂S - ácido sulfhídrico
 FUENTE DDF 1996





La ubicación de las estaciones de monitoreo se incluye la figura 3.2.1.1 que muestra la localización geográfica de todas las estaciones resaltando las seis mencionadas anteriormente.

Como se ha planteando en esta sección, resalta la importancia de mencionar que para el análisis de las concentraciones del SO₂ en la atmósfera de la ZMCM, los datos proceden de la R.A.M.A. siendo los registros de las concentraciones de SO₂ en ppm (partes por millón), además de que se consideraron los seis sitios de muestreo representativos de las cinco zonas en que esta dividida la ZMCM.

Figura 3.2.1.1. Localización de las estaciones de monitoreo de la R.A.M.A. en la ZMCM.



Simbología

-  Limite de la zonificación
-  Limite de la zona metropolitana
-  Limite de la Ciudad de México
-  Estación de monitoreo

FUENTE: D O F . 1996

3.2.2. Concentraciones mensuales del SO₂ en la ZMCM.

El análisis de las concentraciones de SO₂ en la ZMCM puede realizarse de dos maneras; la primera es examinando por separado cada una de las seis zonas de monitoreo; la otra es obteniendo un promedio aritmético de todas estas estaciones de monitoreo y analizar solo una serie de datos que represente a toda la Zona Metropolitana. En este trabajo se realizan los dos tipos de análisis con el objeto de compararlos y detectar con ello la similitud o disparidad en el comportamiento del SO₂ atmosférico al zonificar la ZMCM y al estudiarla conjuntamente.

Por otra parte y de acuerdo a los objetivos del trabajo se analizarán en forma mensual los registros de las concentraciones del contaminante en la atmósfera, para determinar si existe un periodo estacional anual o por estaciones del año, para posteriormente determinar si las características meteorológicas o socioeconómicas específicas de cada periodo influyen en las concentraciones de SO₂. Las concentraciones mensuales de SO₂ aquí analizadas, están comprendidas dentro del periodo de enero de 1988 a marzo de 1996, siendo que la implantación de las estrategias por la Industria Petrolera para la disminución y control de las emisiones de azufre están registradas mensualmente durante este periodo, por lo que se espera que su impacto sea detectado de la misma manera.

Los datos mensuales de las concentraciones atmosféricas de SO₂ para cada zona de monitoreo, se obtuvieron promediando los datos horarios que registra la RAMA en cada una de las seis estaciones principales de monitoreo. Para la ZMCM también se obtuvo un promedio aritmético general uniendo las seis estaciones.

Los promedios de las estaciones de monitoreo se calcularon con la suma y división de los 720 datos registrados en un mes por la RAMA, que resultan de los 24 datos horarios de cada uno de los días del mes (dependiendo del mes esta suma puede ser de 744 para aquellos de 31 días o de 672 para los de 28). Así tenemos que, los promedios mensuales para cada estación son calculados de la forma:

$$\text{registro_mensual_por_zona} = \frac{\sum_{i=1}^{30} \sum_{j=1}^{24} \text{registro}_{ij}}{24 \times 30} = \frac{\sum_{i=1}^{30} \sum_{j=1}^{24} \text{registro}_{ij}}{720}$$

donde:

i = los días del mes (30, 28 ó 29)

j = horas del día (24)

Para el caso de los datos mensuales que representan a la ZMCM en general, fueron obtenidos de la suma de 720 datos de cada estación de monitoreo:

$$\text{registro_mensual_para_ZMCM} = \frac{\sum_{k=1}^6 \sum_{i=1}^{30} \sum_{j=1}^{24} \text{registro}_{kij}}{5 \times 24 \times 30} = \frac{\sum_{k=1}^6 \sum_{i=1}^{30} \sum_{j=1}^{24} \text{registro}_{kij}}{3600}$$

donde:

k = las estaciones de monitoreo (6)

i = los días del mes (30, 28 o 29)

j = horas del día (24)

Estos promedios fueron adquiridos de la base de datos perteneciente al IMP (Instituto Mexicano del Petróleo) la cual está organizada en estructura SOMOD (Sistema Objeto Multinodal Orientado a Disco) y se alimenta con los registros obtenidos de la RAMA de los contaminantes monitoreados. Los cálculos son realizados con el programa de cómputo SIMEDA que fue implantado por trabajadores del Instituto Mexicano del Petróleo⁵.

Concretando, para el análisis de las concentraciones de SO_2 se contará con seis series de tiempo que representan a sus concentraciones mensuales en cada zona -noroeste (Tacuba y Tlalnepantla), noreste (Xalostoc), centro (Merced), suroeste (Pedregal) y soroeste (Cerro de la Estrella)- y una más para la ZMCM. Estas series comprenden el período de enero de 1988 a marzo del 96.

3.3 Aplicación de la Metodología de Box-Jenkins y el Análisis de Intervención a los datos del SO_2 .

El análisis de las series de tiempo -de las concentraciones de bióxido de azufre en la atmósfera de la ZMCM- se realizó en tres partes.

- La primera es el ajuste de un modelo tipo ARIMA a cada una de las series, obteniendo así su descripción y características más sobresalientes (varianza, estacionalidad, tendencia).
- La segunda comprende la aplicación del Análisis de Intervención que consiste en evaluar el impacto de cada una de las medidas implantadas por PEMEX para la disminución y control de las emisiones de azufre y que influyen directamente en las concentraciones atmosféricas del SO_2 .
- Y en la última se obtienen los pronósticos y el análisis de estos.

⁵ Instituto Mexicano del Petróleo, *Sistema para el manejo estadístico de datos cromométricos en la ZMCM*, Informe técnico GCA95-013, SPA/GCA, Inédito, México D.F. 1996

Tanto para la aplicación de la Metodología de Box-Jenkins, el Análisis de Intervención, como para la obtención de pronósticos, se utilizó un software que realizó los cálculos que suelen ser muy laboriosos y difíciles de hacer a mano. El *STATISTICA for Windows, Ver 4.5, StatSoft*, es un paquete orientado a resolver métodos estadísticos tanto descriptivos como matemáticos⁶. Con base en una recopilación de varios estudios realizados sobre la evaluación de los diferentes paquetes estadísticos que actualmente se encuentran en el mercado, el *STATISTICA* está catalogado como uno de los más amigables, eficientes y confiables⁷, por lo tanto es utilizado aquí como apoyo para el análisis de las concentraciones atmosféricas de SO₂ en la ZMCM.

Para hacer uso de este paquete, los datos de las concentraciones mensuales del SO₂ obtenidos del SOMOD se importaron a una base de datos del *STATISTICA*. Esta base de datos la llamaremos (nombre usado sólo con fines de redacción) "XMSO2_96" y la cual contiene los registros mensuales en ppm (pares por millón) obtenidos de la RAMA para el período de 1988 a 1996 de cada una de las estaciones de monitoreo así como la de la ZMCM. Para mayor referencia ver el Anexo I que contiene la Base de Datos completa con todos los registros mensuales del SO₂ de todas las estaciones de monitoreo

Figura 3.3.1. Base de datos mensuales de SO₂ "XMSO2_96"

ESTACION	MES	AÑO	TEMPERATURA	HUMEDAD	VIENTO	PRECIPITACION	PM10	PM2.5	O3	NO2	SO2	CO	POND. SO2	POND. CO
ESTACION 1	1	1988	044	011	041	044	044	044	044	044	044	044	044	044
	2	1988	057	050	084	044	044	044	044	044	044	044	044	044
	3	1988	052	067	084	044	044	044	044	044	044	044	044	044
	4	1988	052	067	084	044	044	044	044	044	044	044	044	044
	5	1988	049	054	079	042	042	042	042	042	042	042	042	042
	6	1988	047	057	064	040	040	040	040	040	040	040	040	040
	7	1988	047	049	049	057	023	037	037	037	037	037	037	037
	8	1988	044	044	044	044	044	044	044	044	044	044	044	044
	9	1988	040	040	040	040	040	040	040	040	040	040	040	040
	10	1988	044	044	044	044	044	044	044	044	044	044	044	044
	11	1988	044	044	044	044	044	044	044	044	044	044	044	044
	12	1988	044	044	044	044	044	044	044	044	044	044	044	044
ESTACION 2	1	1988	044	044	044	044	044	044	044	044	044	044	044	044
	2	1988	044	044	044	044	044	044	044	044	044	044	044	044
	3	1988	044	044	044	044	044	044	044	044	044	044	044	044
	4	1988	044	044	044	044	044	044	044	044	044	044	044	044
	5	1988	044	044	044	044	044	044	044	044	044	044	044	044
	6	1988	044	044	044	044	044	044	044	044	044	044	044	044
	7	1988	044	044	044	044	044	044	044	044	044	044	044	044
	8	1988	044	044	044	044	044	044	044	044	044	044	044	044
	9	1988	044	044	044	044	044	044	044	044	044	044	044	044
	10	1988	044	044	044	044	044	044	044	044	044	044	044	044
	11	1988	044	044	044	044	044	044	044	044	044	044	044	044
	12	1988	044	044	044	044	044	044	044	044	044	044	044	044
ESTACION 3	1	1988	044	044	044	044	044	044	044	044	044	044	044	044
	2	1988	044	044	044	044	044	044	044	044	044	044	044	044
	3	1988	044	044	044	044	044	044	044	044	044	044	044	044
	4	1988	044	044	044	044	044	044	044	044	044	044	044	044
	5	1988	044	044	044	044	044	044	044	044	044	044	044	044
	6	1988	044	044	044	044	044	044	044	044	044	044	044	044
	7	1988	044	044	044	044	044	044	044	044	044	044	044	044
	8	1988	044	044	044	044	044	044	044	044	044	044	044	044
	9	1988	044	044	044	044	044	044	044	044	044	044	044	044
	10	1988	044	044	044	044	044	044	044	044	044	044	044	044
	11	1988	044	044	044	044	044	044	044	044	044	044	044	044
	12	1988	044	044	044	044	044	044	044	044	044	044	044	044

⁶ STATISTICA for Windows (Volumen III). *Statistics II 1984-1994*. StatSoft, Inc. U.S.A.

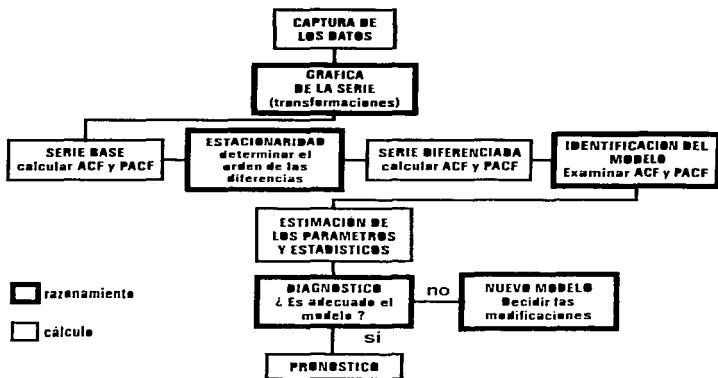
⁷ Winlab Products Comparisons, *Detailed Technical Description, Brochure of STATISTICA ver 3.5M*, StatSoft, Inc., U.S.A. 1995.

Solo con este formato de base de datos dado por el STATISTICA, es posible aplicar la Metodología de Box-Jenkins y el Análisis de Intervención en dicho paquete. Los datos contenidos en la base de datos XMSO2_96 pueden ser consultados en el anexo I.

3.3.1 Ajuste del modelo tipo ARIMA a las concentraciones mensuales de SO₂ por la Metodología de Box-Jenkins .

Para la primera parte se utilizó el algoritmo que sugiere González Videgaray⁶. Este algoritmo divide a la Metodología de Box-Jenkins en varios pasos, de los cuales, algunos son cálculos -y que se obtendrán con el STATISTICA- y otros son razonamientos que debe realizar el analista haciendo uso de su experiencia y conocimiento del fenómeno.

Figura 3.3.1.1. Algoritmo de la Metodología de Box-Jenkins



FUENTE: González, 1990

⁶ González Videgaray, M. C., *Modelos de Decisión con procesos estocásticos II*, UNAM - ENEP Acatlán, México Mex., 1990., pág. 7

Por su estructura, el diagrama es dinámico y no secuencial, lo que significa que el orden de los pasos se van realizando de acuerdo a las necesidades específicas del ajuste.

La metodología de Box-Jenkins y el algoritmo sugieren:

- Como primer paso el graficar la serie de tiempo para la identificación de tendencia y del comportamiento de varianzas.
- Si la gráfica muestra una tendencia y una varianza no constante, entonces el segundo paso de la metodología es eliminar la tendencia y convertir la varianza en constante utilizando las transformaciones adecuadas⁹. Es importante que primero se convierta a la varianza constante y después se elimine la tendencia.
Si se desea tener una varianza constante las transformaciones más utilizadas son las logarítmicas, raíces cuadradas y sus recíprocos, siendo las que modifican a los datos de tal manera que las curvas tiende a cambiar a rectas, haciendo al mismo tiempo a la varianza constante.

Si se desea eliminar la tendencia y se tiene un gran número de datos se utilizan las diferencias, que consisten en restar los valores de las observaciones uno de otro en un orden preestablecido¹⁰.

La metodología sugiere estas transformaciones para convertir la serie - si no lo es ya - en una serie estacionaria (la serie de tiempo se hace estable), ya que los modelos ARIMA solamente se ajustan a este tipo de series.

- Nuevamente se grafica la serie para verificar su estacionaridad y poder realizar el siguiente paso de la metodología.
- El tercer paso consiste en obtener las funciones de correlación y autocorrelación (cabe aclarar que estas funciones las obtiene el software seleccionado al igual que las transformaciones lineales y las diferencias).
- Utilizando esta información y como cuarto paso, se determina el modelo tipo ARIMA que se ajusta mejor a la serie de tiempo (se ajusta el modelo a la serie de las concentraciones mensuales de SO₂). Recordando que estos tipos de modelos están compuestos a su vez por los modelos AR y MA; en este paso también se obtiene el estimador (o estimadores según sea el caso) para los parámetros de estos modelos (esta estimación también la realiza el STATISTICA).
- Como último paso la metodología Box-Jenkins propone la comprobación del ajuste del modelo sobre la serie, esto se hace mediante la observación de la

⁹ STATISTICA for Windows (Volumen III), *Statistics II 1984-1994*, StatSoft, Inc. U.S.A.

¹⁰ Gonzalez, pag. 10

gráfica de los residuales y sus funciones de autocorrelación. Si los residuales se comportan como una variable aleatoria independiente e idénticamente distribuida con función de probabilidad normal, es decir, si estos se comportan como ruido blanco entonces el modelo es el adecuado; indicando que el modelo identifica todas las características predecibles de la serie de tiempo y sus residuales representan la aleatoriedad de la misma.

Cabe aclarar que si los residuales no se comportan como ruido blanco entonces el modelo no es el adecuado, y habrá que mejorarlo repitiendo nuevamente la metodología desde el tercer paso, con el propósito refinar el modelo hasta que se ajuste lo mejor posible a la serie.

Con la aplicación de la metodología de Box-Jenkins a la base de datos XMSO2_96 (utilizando el algoritmo de González Videgaray y el paquete STATISTICA), se ajustan los modelos tipo ARIMA a cada una de las siete series que representan las concentraciones mensuales de SO₂ de la ZMCM y en las zonas en que esta dividida.

Una vez que se obtengan los modelos que se ajusten a cada serie de tiempo, se proseguirá a la descripción detallada por zona, analizando sus modelos y las características de cada una de ellas. Cabe aclarar que algunos de los modelos son utilizados exclusivamente en esta primera parte.

La descripción de las series de tiempo mediante la identificación de sus componentes como la varianza, tendencia y periodo estacional, permitirá conocer el comportamiento de las concentraciones mensuales de SO₂ (ver capítulo 2). Así tenemos que las características de cada una de estas componentes son:

La **varianza** nos permitirá saber si las concentraciones mensuales del contaminante tiende a estabilizarse, dispersarse o agruparse. Si existe un intervalo en donde se registren todas las concentraciones del SO₂ se dice que los datos son estables (varianza constante). Si la varianza es creciente entonces los datos se dispersan uno con respecto al otro, lo que indicaría que entre los registros mensuales de SO₂ (máximos y mínimos) existe una diferencia cada vez más amplia. En el caso contrario tenemos una varianza decreciente, es decir la diferencia entre un registro y otro suele ser menor cada mes.

La **tendencia** identificará el cambio sistemático de las concentraciones de SO₂ a través de los meses. Si se detecta una tendencia decreciente indicará un cambio sistemático haciendo que las concentraciones mensuales de SO₂ tiendan a disminuir a través del tiempo. Si la tendencia es creciente el dato aumenta con respecto al anterior ($t-1$), por lo tanto se afirmará que las concentraciones mensuales de SO₂ atmosférico tienden a crecer con el tiempo.

Si en una serie existe algún periodo de tiempo que tenga un comportamiento específico y que se repita consecutivamente en toda la serie, entonces la serie de tiempo es **estacional** y decimos que tiene periodos estacionales de longitud "s": *"Las concentraciones mensuales de SO_2 no presentaron un periodo estacional de 12 (anual) ni uno de 4 (estaciones del año), esto demostró que el comportamiento del SO_2 en la atmósfera no se vio influenciado por las condiciones específicas de cada mes o de cada estación del año"*.

Así pues, podremos describir a las concentraciones mensuales de SO_2 en la atmósfera de la ZMCM por la dispersión y tendencia de sus registros, así como por los periodos estacionales que puedan presentar, siendo necesario tomar en cuenta las características de cada zona monitoreada (noroeste, noreste, centro, sureste, suroeste). Para lograr una descripción real y una interpretación de resultados correcta, es necesario que, además del conocimiento de las características de la ZMCM (Capítulo 1), se identifiquen las características específicas de cada zona de monitoreo, y con esto poder explicar porque los modelos que se ajustan a ellas son diferentes y algunos presentan la parte AR y otros la parte MA (Capítulo 2).

La desigualdad entre las zonas monitoreadas, básicamente consiste en que: algunas desarrollan principalmente actividades industriales y otras son áreas residenciales; la flota vehicular que circulan en ellas también es diferente, así como las condiciones meteorológicas, específicamente el flujo de los vientos que hace que las concentraciones de SO_2 (bióxido de azufre) se muevan de una zona a otra¹¹.

Las zonas noroeste (Tlalnepantla y Tacuba) y noroeste (Xalostoc) comprenden la gran mayoría de las Industrias del área metropolitana del valle de México, por ejemplo en la zona noroeste se encuentra la Refinería "18 de marzo" y en la zona el uso del suelo está destinado a la industria. Dadas estas características se esperaría que los modelos que se ajustasen a las series de tiempo de estas zonas contengan marcadamente la parte AR (factor determinado) que indicará que las concentraciones del SO_2 dependen en gran medida de las emisiones de azufre por la industria.

En la zona centro (Merced) las concentraciones se deben en su mayoría por las emisiones del autotransporte, siendo esta la zona que contiene la mayor influencia vehicular. También se esperaría que el modelo representativo de esta zona tuviera la parte AR muy marcada.

La dirección del flujo de los vientos de norte a sur hace que las concentraciones de SO_2 que se registran en las zonas sureste (Pedregal) y sureste (Cerro de la Estrella) se deban principalmente por las concentraciones que son arrastradas del norte; por lo que, las condiciones meteorológicas son el principal

¹¹ Quadri de la Torre, G., Sánchez L.R., *La ciudad de México y la contaminación Atmosférica*. LIMUSA, México D.F. 1990.

factor que propicia su presencia¹². Se esperaría que los modelos que se ajusten a Pedregal y al Cerro del Estrella detecten fuertemente la parte MA (factor aleatorio).

Cabe aclarar que la relación entre el comportamiento de las concentraciones atmosféricas de SO₂ y las características específicas de las zonas se ha detectado solamente para los registros horarios y semanales, pero se esperaría que también las detecten los modelos que se ajusten a las concentraciones mensuales.

3.3.2 Evaluación de las estrategias para la disminución y control de las emisiones que forman al SO₂ por Análisis de Intervención.

La segunda parte del análisis de las series de tiempo consiste en evaluar las estrategias implantadas por la industria petrolera para la disminución y control de las emisiones de azufre, utilizando las concentraciones mensuales de SO₂.

Esta evaluación tiene como propósito:

- Identificar las medidas que tuvieron un impacto positivo logrando una disminución de las concentraciones atmosféricas del SO₂.
- Describir el patrón de cambio debido a este impacto, y...
- Medirlo a través de la estimación los parámetros del modelo.

Identificación de las medidas.

Como se mostró en el capítulo I (ver sección 1.5), la Industria Petrolera desarrollo "El Paquete Ecológico" que consiste en la implementación de estrategias para la disminución y control de las emisiones de contaminantes a la atmósfera. Dentro de estos contaminantes se encuentra el SO₂ que es considerado como responsabilidad directa de PEMEX y al cual se le dio mayor interés, puesto que la emisión de azufre quemado por los combustibles industriales es la principal fuente para la formación de bióxido de azufre en la atmósfera¹³, de tal manera que gran parte de las estrategias estuvieron orientadas a la reformulación de los mismos. Con base en esto existen 9 estrategias del Paquete Ecológico que fueron implantadas específicamente para disminuir las emisiones de azufre a la atmósfera (ver Tabla 1.6.1, cap.I); y son precisamente estas medidas las que se evaluarán en el presente trabajo, siendo de gran interés identificar cuales fueron las que lograron un cambio importante en las concentraciones de SO₂ atmosférico, capaz de ser detectado por el Análisis de Intervención.

¹² ítem

¹³ México, Programa Integral Contra la Contaminación Atmosférica, Un compromiso Común, Octubre 1990. Comisión Metropolitana Contra la Contaminación Atmosférica, México D.F., 1990.

Descripción del impacto de las medidas.

Con el Análisis de Intervención no sólo será importante conocer cuales fueron las medidas que propiciaron cambios significativo en las concentraciones de SO₂, sino también identificar su patrón de cambio. Es decir, poder saber si estas medidas fueron significativas y suficientes para propiciar un cambio permanente en las concentraciones de SO₂ (Brusco Permanente, Cap. 2), logrando además de que no se vuelvan a registrar valores tan altos como los anteriores a su aplicación; o bien, si solo se percibió un cambio positivo que duro algún tiempo e hizo que las concentraciones disminuyeran en este periodo, para después volver a registrar valores como los anteriores a las medidas (Brusco Temporal, Cap2.).

Medición del impacto detectado.

Para conseguir que las estrategias fueran eficientes y cumplieran con su objetivo de disminuir y controlar las emisiones de SO₂ a la atmósfera, PEMEX¹⁴ redujo el contenido de azufre en los combustibles para que el contaminante no volviera a violar las normas de calidad del aire. El Análisis de Intervención nos dará los parámetros necesarios para conocer la magnitud de disminución en las concentraciones y en el mejor de los casos el tiempo que tardaron para lograr su estabilidad, sin olvidar que también existe la posibilidad de que no todas las medidas alcanzarán la estabilidad permanente, así que en este caso se medirá el tiempo en que lo lograron.

Para la evaluación de las medidas de control y disminución de las concentraciones de SO₂ se aplicó el Análisis de Intervención (capítulo II) que se puede considerar como una metodología "adicional" a la de Box-Jenkins para el Análisis de las Series de Tiempo; por consecuencia esta metodología conserva los mismos lineamientos para el ajuste y evaluación de los modelos y sus intervenciones.

El análisis de Intervención se puede resumir en los siguientes pasos:

1. Identificación del dato correspondiente a la fecha de la intervención.
2. División de la serie original en dos. La *serie ruidó* que contiene los datos hasta antes de la intervención, y la *serie con intervención* que contiene los datos posteriores a la intervención.
3. Obtención del *modelo ruidó* (ajuste de un modelo tipo ARIMA a la serie ruidó por Box-Jenkins).
4. Definición del patrón de comportamiento de la intervención.

¹⁴ *Izum.*

5. Incluir a la intervención el modelo ruido (unión de las series) y obtener el modelo general.
6. Obtención de los parámetros de la intervención y del modelo ARIMA.
7. Diagnóstico de la intervención.

La metodología que se siguió para la aplicación del Análisis de Intervención, al igual que la aplicada para Box-Jenkins consiste en un conjunto de pasos que requieren del razonamiento del analista y otros que son calculados por la computadora, siendo también dinámica y utilizada de acuerdo con las necesidades del estudio.

Para obtener los resultados del análisis de las medidas aplicadas para la disminución y control de las emisiones de SO_2 en la ZMCM, se utilizó el paquete STATISTICA y se aplicó el algoritmo mostrado en la Figura 3.3.2.1.

- Este algoritmo sugiere como primer paso identificar la fecha de intervención. Es muy importante conocer el dato a partir del cual la intervención aparece, siendo el que divide a las series; y obtiene la serie ruido a la que posteriormente se le ajusta el modelo ARIMA. En el caso específico del STATISTICA la identificación de la intervención consiste en conocer el número del caso que le asigna el paquete al dato correspondiente a la fecha de intervención.

En este estudio, el paso consistió en identificar de la base de datos XMSO2_96 el número de caso que le corresponde a la fecha en que se implementó cada una de las medidas para la disminución y control de las emisiones de SO_2 (Tabla 3.3.2.1)

- El ajustar un modelo tipo ARIMA a la serie ruido por la metodología de Box-Jenkins implica un análisis como el de la primera parte (Sec. 3.3.1) y para ello también se utiliza el algoritmo de González Videgaray (Figura 3.3.1.1). Es importante que el ajuste del modelo sea el correcto ya que de esto dependerá que la intervención y el modelo completo tenga también un buen ajuste, en caso contrario los resultados obtenidos serán inadecuados y no representarán adecuadamente al fenómeno.

Además, para que el STATISTICA haga un ajuste de la intervención es indispensable conocer antes al "modelo ruido" que es utilizado como dato de entrada para el análisis de intervención (Figura 3.3.2.2), lo que reafirma la importancia de que el ajuste al *modelo ruido* sea el adecuado.

Figura 3.3.2.1. Algoritmo para el Análisis de Intervención.

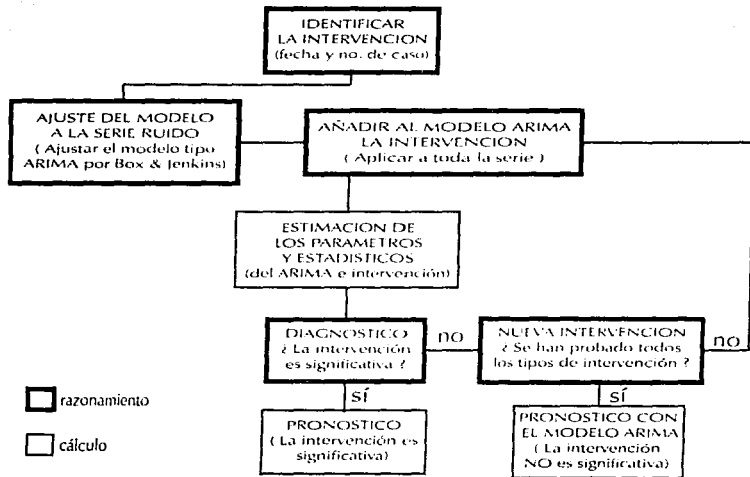


Tabla 3.3.2.1. Medidas para la disminución y control del SO₂ aplicadas en el periodo de enero de 1988 a marzo de 1996.

No.	MEDIDA	Fecha de aplicación	No. del caso	Costo de Aplicación ^{15,16} (millones de dólares)
1	Introducción de Magna-Sin (0.1% de azufre)	Sept - 90	33	810 81
2	Cierre de la Refinería 18 de Marzo	Marzo - 91	39	500
3	Introducción de Gasóleo (2.0% de azufre). Se deja de vender Diesel Nacional (2.0% de azufre)	Abril - 91	40	483 00
4	Se prohíbe la venta de Combustóleo (4.0 - 1.8% de azufre)	Dic - 91	48	35.1
5	Medidas para la época Invernal Se elimina el consumo total de combustibles con contenido de azufre > 2.0%. Esta medida se mantuvo en definitiva dentro de la ZMCM	Dic-marzo 91-92	48-51	-
6	Medidas para el Invierno Reducción adicional del contenido de azufre en gasóleo, de 2.0 a 1.5%	Dic-marzo 92 - 93	60-63	-
7	Introducción de Diesel-Sin (0.05% de azufre)	Octubre- 1993	70	118.33
8	Medidas para el Invierno. Reducción adicional del contenido de azufre en gasóleo, de 2.0 a 1.5%.	Dic-marzo 93 - 94	72-75	-
9	Medidas para el Invierno Reducción adicional del contenido de azufre en gasóleo, de 2.0 a 1.5%.	Dic-marzo 94 - 95	84-87	-

¹⁵ Para estas medidas no se tiene el dato

¹⁵ Laey, R., *La calidad del aire en el valle de México*, Colegio de México, México 1993, pag. 58

¹⁶ México, *Programa para Mejorar la Calidad del Aire en el Valle de México 1995-2000*, Departamento del Distrito Federal y Gobierno del Estado de México, México 1996, pag. 110-112

Figura 3.3.2.2. STATISTICA. Pantalla de inicio del Análisis de Intervención.

Modeling Time Series: ARIMA (Intervention Analysis)

Lock Variable Long variable (series name) OK (Begin parameter estimation) Exit

Number of backups per variable (series) 2 Save variables Delete

ARIMA model parameters

Estimate constant Seasonal log 1 2

Autoregressive 0 1 2 P - Seasonal 0 1 2

Moving aver. 0 1 2 Q - Seasonal 0 1 2

Transform variable (series) prior to analysis

Natural Log Power transform 2 0 1

Difference 1. Lag 0 1 2 No. of passes 0 1 2

1 Lag 0 1 2 No. of passes 0 1 2

Other transformations & plots

Estimation of Maximum Likelihood

Approximate (McLeod & Sales) Exact (Melard)

Backcast cases 0

Options (start vals. # iterations, convergence)

Specify times and types of interventions

Interv.	At case number	Type of intervention
<input checked="" type="checkbox"/> 1	0	Abrupt, Permanent
<input type="checkbox"/> 2	0	Abrupt, Permanent
<input type="checkbox"/> 3	0	Gradual, Permanent
<input type="checkbox"/> 4	0	Abrupt, Permanent
<input type="checkbox"/> 5	0	Abrupt, Permanent
<input type="checkbox"/> 6	0	Abrupt, Permanent

Review types of impact patterns

La gráfica muestra la pantalla de inicio en el STATISTICA para trabajar con el Análisis de Intervención y señala la importancia de conocer al modelo ruido como dato de entrada.

- Una vez identificado el modelo ruido, se prosigue a introducir el tipo de intervención, para esto es necesario conocer la fecha y el tipo de intervención. De acuerdo con McDowall, McCleary, Meidinger y Hay (1980) el STATISTICA distingue entre tres grandes tipos de intervenciones: *gradual permanente*, *brusco temporal* (Capítulo II) (figura 3.3.2.3).

De esta forma, habrá que identificar a cuál de estos tres tipos de intervención se ajusta la medida de control analizada en el momento, y el número de caso que corresponde en la base de datos "XMSO2_96" a la fecha de implantación.

- El siguiente paso consiste en calcular los parámetros tanto del modelo ruido tipo ARIMA como los de la intervención. Cabe aclarar que los parámetros del modelo ARIMA son calculados para el caso en que no existe ninguna

intervención, así que es necesario calcularlos nuevamente al introducir una intervención.

Como se observa en el algoritmo (figura 3.3.2.1) estos cálculos los realiza el paquete STATISTICA, que no sólo calcula el valor del parámetro sino que también permite conocer el valor de los estadísticos t y p que indican si el parámetro es estadísticamente significativo.

En una intervención, si los parámetros no son (o no es, según el tipo de intervención) significativos, esto indicaría que: o la intervención tampoco lo es para provocar un cambio importante en los datos; o su patrón de comportamiento no es el adecuado.


- Al igual que en la Metodología de Box-Jenkins es importante el diagnóstico de la intervención y para ello también se utiliza los estadísticos t y p de los parámetros, el análisis de residuales con base en sus funciones de autocorrelación y autocorrelación parcial (ACF y PACF), y el histograma de ajuste a la normal.

En el caso de que los parámetros (de la intervención y del modelo ARIMA) sean significativos y el análisis de residuales indique que hay un buen ajuste, denotará que la medida analizada es significativa y causa un cambio en las concentraciones atmosféricas del SO_2 , teniendo un comportamiento específico e identificado, y a partir de entonces se podrá continuar con la descripción de las concentraciones mensuales de SO_2 en la atmósfera y la obtención de los pronósticos.

Cuando los parámetros no son estadísticamente significativos y por lo tanto no existe un buen ajuste del modelo, implica que la intervención no es significativa y se prosigue a buscar un nuevo tipo de intervención. Si ya fueron probados los tres tipos de intervención y ninguno es el adecuado, entonces se dice que no existe una intervención que sea capaz de registrar un cambio significativo en los datos. Entonces los pronósticos y la descripción de la serie de tiempo se obtienen exclusivamente del modelo ruido que se ajustó a la que no tenía intervención.

Para el caso del SO_2 , esto indicaría que la medida analizada no es lo suficientemente significativa para provocar un impacto positivo en las concentraciones atmosféricas del contaminante.

Figura 3.3.2.3. STATISTICA. Tipos de intervención.



Esta pantalla muestra las gráficas de los tres tipos de intervención que el STATISTICA hace distinción y analiza.

La sección de Análisis de Intervención del STATISTICA permite analizar hasta seis intervenciones en la misma serie de tiempo, siendo especialmente importante para el propósito de este trabajo, ya que son varias las medidas que se aplicaron para el control de las concentraciones atmosféricas de SO₂. Utilizando este paquete se podrá modelar en conjunto a las concentraciones mensuales del SO₂ con todas las medidas importantes que causaron un cambio significativo en ellas.

Para poder saber cuales medidas son significativas y que serán incluidas en el modelo final, es necesario analizar a cada una de ellas (Tabla 3.3.2.1), por lo que el algoritmo de la figura 3.3.2.1 será utilizado en varias ocasiones. Cabe recordar que este análisis incluye cada zona de monitoreo (noreste, noroeste, centro, sureste y suroeste) y ZMCM, así como las once medidas desarrolladas por la Industria Petrolera para el control de la contaminación atmosférica por SO₂ (figura 3.3.2.4). Finalmente para cada punto de monitoreo se obtendrá un modelo global de la forma:

$$Z_t = \sum_{j=1}^k \frac{\omega_j(B)B^{l_j}}{\delta_j(B)} I_{jt} + \frac{\theta(B)}{\phi(B)} e_t$$

donde:

l_j = Tipo de intervención.

$\omega_j(B)$: $\delta_j(B)$ vectores de los parámetros de la intervención

Este modelo general ajustado a las concentraciones mensuales de SO_2 este compuesto por:

- El modelo ruido (ARIMA).
- Las "n" medidas que resultaron significativas.
- El tipo de intervención de cada una de ellas y
- Sus parámetros.

3.3.3 Obtención de pronósticos.

La tercera y última parte del trabajo consiste en la obtención de los pronósticos para cada serie (5 puntos de monitoreo y ZMCM) y descripción del comportamiento del contaminante en un futuro inmediato.

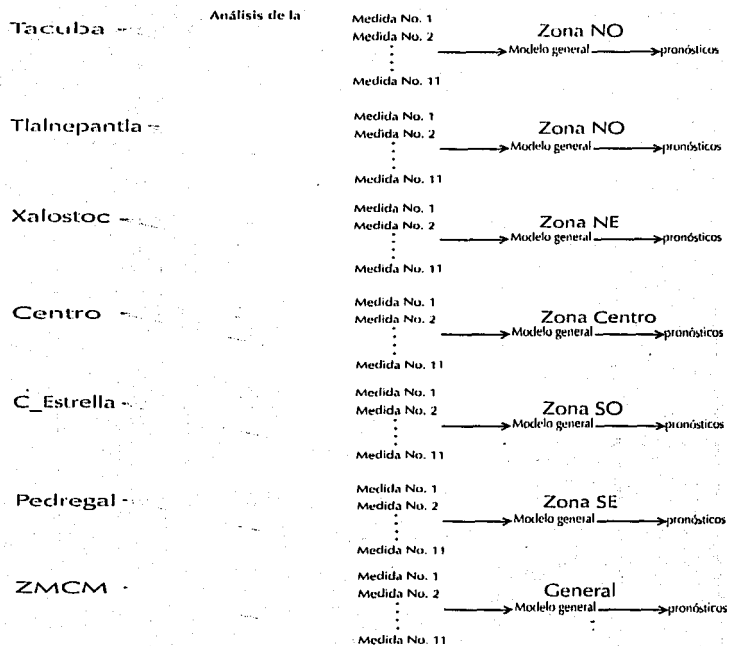
Como se describió en el capítulo II, Box-Jenkins es una metodología confiable sólo para obtener pronósticos a corto y mediano plazo¹⁷, es por esto que los pronósticos obtenidos para las concentraciones mensuales de SO_2 sólo se harán para los meses inmediatos al de marzo de 1996 sin que sea sobrepasado este año.

Los pronósticos se calcularán con el paquete STATISTICA en el cual, previamente se debe definir el número de pronósticos a calcular, el dato de inicio para estos y su nivel de confianza.

La ventaja del paquete en cuanto a decidir el número de pronósticos y el número de caso para el inicio de la serie de pronósticos, permite que su análisis sea más efectivo, puesto que la mejor forma de saber si un modelo está arrojando buenos pronósticos, es compararlos con los datos reales. Por ejemplo, si tenemos una serie de tiempo real con "N" datos, sería interesante conocer si el modelo que se ajustó a ella arroja un número pequeño de pronósticos (m) se que asemejen a los últimos k datos de la serie. En este caso el STATISTICA recibe como valores de entrada a m como el número de pronósticos y a N-k el número del caso de inicio;

¹⁷ Prawda...

Figura 3.3.2.4 Árbol de procedimiento para el análisis de las medidas para la disminución y control de SO_2 .



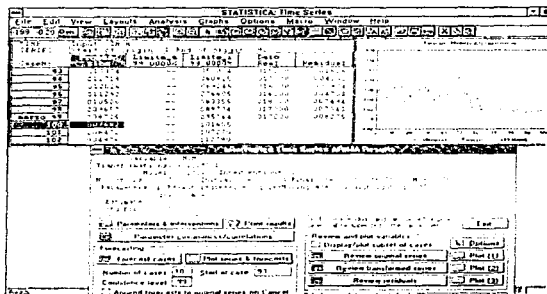
dando como resultado una tabla que contiene: los valores reales de la serie, los pronósticos, los residuales y los intervalos de confianza; además de una gráfica que contiene la serie original, la serie de pronósticos y los límites del confianza. Esta evaluación resulta de la prueba final para decidir que modelo es el adecuado (figura 3.3.3.1).

De esta manera, los modelos finales que se ajusten a las concentraciones mensuales de SO_2 , podrán ser nuevamente evaluados (antes será la evaluación de residuales y de parámetros) al comparar los registros reales de las concentraciones mensuales de enero, febrero y marzo ($k=3$) de 1996 con los pronósticos de los mismos meses.

Finalmente se obtendrán los pronósticos para los siguientes siete meses (abril-octubre) ($m=7+3$) que permitirán conocer el comportamiento de las concentraciones atmosféricas de SO_2 .

Con la obtención de los pronósticos se da por terminado el análisis de las series de tiempo para las concentraciones mensuales de SO_2 . Cabe recordar que en este estudio son siete las series de tiempo por analizarse (seis para cada uno de los puntos de muestreo y una para la ZMCM), así como la obtención de pronósticos y su descripción. Una vez que se detecten las características individuales para cada serie de tiempo, se realizará un cuadro comparativo para analizar las principales características y diferencias entre sus modelos ARIMA e intervenciones.

Figura 3.3.3.1 Análisis de pronósticos



Esta gráfica muestra los pronósticos y su análisis en forma de tabla o gráfica realizados por el paquete STATISTICA

Capítulo 4.

***Análisis de
resultados y
recomendaciones***

4.1 Resultados

En esta sección se expondrán los resultados obtenidos de la aplicación de las metodologías Box-Jenkins y Análisis de Intervención a seis series de tiempo que representan las 5 zonas de monitoreo atmosférico, para posteriormente, analizar los obtenidos para la ZMCM en general.

La *Tabla de Resultados 4.1.1* contiene los modelos tipo ARIMA que se ajustaron a cada una de las series y sus principales características (Box-Jenkins). La *Tabla de Resultados 4.1.2* comprende los resultados del análisis de intervención en el estudio relacionado con el impacto que tuvieron las medidas implantadas por la Industria Petrolera para la disminución y control de las emisiones de SO_2 a la atmósfera en cada zona de monitoreo.

Tabla 4.1.1. Tabla de resultados de Box-Jenkins

Zona	Estación	Tendencia	Varianza (transformación)	Modelo (ARIMA)
NO	Tlalnepantla	descendente	constante (c)	(0, 1, 2)
NO	Tacuba	descendente	constante	(0, 1, 2)
NE	Xalostoc	constante	constante	(1, 0, 0)
C	Merced	descendente	constante	(0, 1, 2)
SO	Pedregal	constante	constante	(1, 0, 0)
SE	C Estrella	descendente	decreciente (x^2)	(1, 1, 0)

De acuerdo con la tabla 4.1.1, los resultados se presentan en tres rubros, (tendencia, varianza y modelo) siendo los que identifican las características de una serie de tiempo. Y a partir de estos, también se puede identificar la similitud y disparidad entre las diferentes zonas de monitoreo.

Así tenemos que, con respecto a la **TENDENCIA** solo las zonas noroeste, centro y sureste muestran una tendencia descendente, siendo necesario aplicar una diferencia e incluirla en el modelo tipo ARIMA. Para las zonas noreste y suroeste no fue necesario hacer transformaciones a la tendencia de los datos por lo tanto se considera que estas zonas tienen una tendencia constante.

En cuanto a la **VARIANZA** o dispersión de los datos, en términos generales no se detecta una disparidad entre las zonas monitoreadas. En el caso de Tlalnepantla (zona noroeste) fue necesario incluir una constante, de aquí que, en términos de dispersión, los datos registrados por la estación Tacuba se comportan de diferente manera que los de Tlalnepantla.

Sólo en la zona sureste se registraron datos dispersos, por lo que se aplicó una transformación de potencia al cuadrado (x^2).

Con lo que respecta a los **MODELOS ARIMA**, en la zona centro y noroeste se obtuvo el mismo modelo (0,1,2) que indica una similitud del patrón de comportamiento de los registros mensuales de estas zonas. La zona noreste y suroeste presentaron modelos iguales (ARIMA (1,0,0)); en el caso de la zona sureste el modelo manifestó una semejanza con el anterior, aunque, a este último se le incluye la transformación de la tendencia (ARIMA(1,1,0)).

Tabla 4.1.2 Tabla de resultados del Análisis de intervención

Zona	Estación	Medida*	No. de caso de inicio**	Tipo de intervención
NO	Tlalnepantla	-	-	-
NO	Tacuba	1	37	Brusco temporal
		4	49	Brusco temporal
		6	60	Gradual permanente
EN	Xalostoc	4	49	Brusco Permanente
		5	51	Brusco Temporal
C	Merced	4	49	Brusco Permanente
		7	70	Brusco Permanente
SO	Pedregal	1	34	Brusco permanente
		5	53	Brusco temporal
SE	C. Estrella	4	49	Gradual permanente

* Número correspondiente al asignado a cada medida en la tabla 3.3.2.1

** Número que se registra como el inicio del impacto de cada medida y que corresponde al número de caso que se le asignó a cada registro mensual en la base de datos XMSO2_96

Por otra parte los resultados sobre las **MEDIDAS** para el control y disminución de las emisiones de SO_2 señalan que:

- *A un mes de haber entrado en vigor, la medida No. 4 fue la más significativa y aunada con la medida No.5 provocaron un cambio significativo en los registros (excepto en Pedregal). El patrón de cambio se registró como brusco permanente en la mayoría de las intervenciones.*

Entre las medidas que fueron significativas también se encuentran:

- *Medida 1.* En la estación Tacuba se detectó el cambio a partir del mes 37 cinco meses después y siendo además temporal. En el caso de Pedregal la influencia fue inmediata presentándose al siguiente mes y teniendo un patrón de comportamiento brusco permanente.
- *Medida 5.* La influencia de esta medida fue únicamente temporal para las estaciones Pedregal (SO) y Xalostoc (NE) manifestándose un retardo de dos y un mes respectivamente. Sin embargo para Xalostoc esta medida tuvo un impacto negativo.
- *Medida 6.* Esta es la única intervención que presenta un cambio gradual permanente en la zona Tacuba.
- *Medida 7.* Se detectó que en la zona centro (Merced) su patrón de comportamiento fue brusco permanente, y se manifestó un mes después de aplicada la medida.

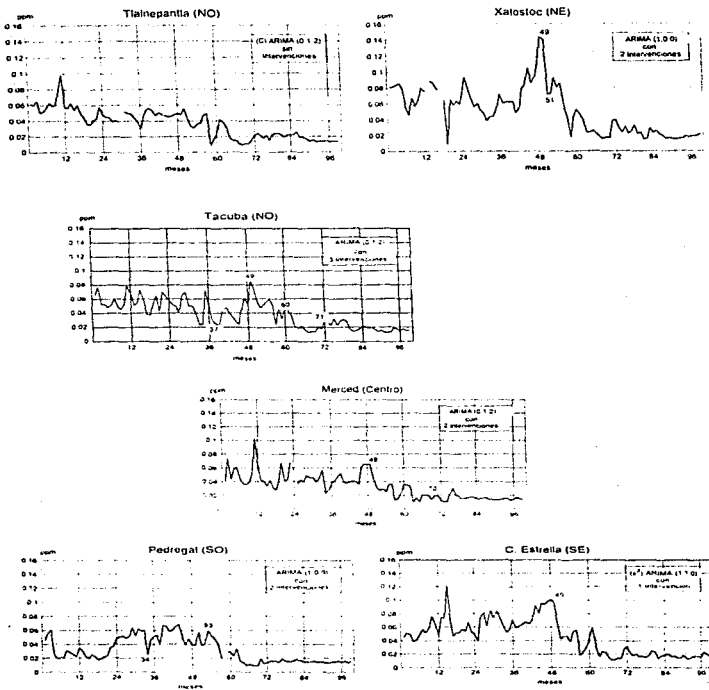
Por sitio de muestreo, destaca la estación Tacuba por la cantidad de medidas que ahí se detectaron como significativas, teniendo influencia en los meses 37 (enero del 92), 49 (enero del 93) y 60 (diciembre de 94), dos de ellas temporal y la otra permanente; caso contrario fue Tlalnepantla que sus datos no mostraron intervención alguna. Nuevamente resalta la disparidad entre estas dos estaciones de monitoreo del noroeste.


Por último, las medidas 2, 3, 8 y 9 no causaron impacto sobresaliente en alguna de las estaciones de monitoreo; más adelante en el análisis de resultados se expondrán las posibles causas del ausentismo de estas medidas.

De acuerdo con estos resultados podemos asumir que cada estación de monitoreo tiene características específicas, haciendo necesario su estudio individualmente. Por lo tanto, los resultados obtenidos para cada una de ellas no generalizan el comportamiento de la ZMCM, es por esto que sus resultados globales son presentados aparte.

Análisis de Resultados y recomendaciones

Figura 4.1.1 Gráficas de la zonas monitoreadas en la ZMCM





Resultados para la ZMCM


Tabla 4.1.3. Resultados para la ZMCM (Box-Jenkins y Análisis de intervención)

Zona	Tendencia	Varianza (transformación)	Modelo (ARIMA)	Medida (Número, caso y tipo)		
				4	49	B P*
ZMCM	exponencial descendente	decreciente (x^2)	(0, 2, 1)			

*Brusco permanente

En términos generales los datos de la ZMCM muestran tendencia exponencial decreciente de ahí el número de diferencias que fueron utilizadas para transformar los datos; también se requirió una transformación para convertir a la varianza en constante (x^2) que indica que los datos originales poseen una dispersión decreciente. El modelo que se ajustó a la serie ZMCM es un modelo ARIMA (0,2,1).

El análisis de Intervención demostró que sólo en el mes 49, coincidente con la medida 4, se detectó un cambio estadísticamente significativo en la ZMCM, lo que reafirma la importancia de esta medida.



4.2. Selección de los modelos.

Antes de continuar con el análisis de resultados se expondrá brevemente los criterios y el proceso de selección tomados en cuenta para elegir a los modelos que mejor se ajustaron a las series de tiempo. Hay que recordar que la aplicación de la Metodología de Box-Jenkins y el Análisis de Intervención arrojan resultados confiables siempre y cuando el analista tenga experiencia y conozca lo suficiente el fenómeno para hacer la mejor elección del modelo e interpretación de los resultados.

4.2.1 Criterios de selección.

Para este trabajo se determinaron los siguientes criterios:

- a) Criterios de selección del modelo ARIMA. [Metodología de]
- b) Análisis de residuales. [Box-Jenkins]
- c) Localización geográfica de la zona.
- d) Actividad industrial y afluencia vehicular.
- e) Condiciones meteorológicas.

- f) Criterios de selección para intervenciones. [Análisis de]
- g) Análisis de residuales. [Intervenciones]
- h) Fecha y objetivo de la medida.
- i) Pronósticos (mínimo error de pronóstico).

Los *criterios de selección del modelo ARIMA* y el *análisis de residuales* se refieren a las pruebas matemáticas y estadísticas que señala la metodología de Box-Jenkins para la elección y comprobación del modelo.

Conocer la *localización geográfica* de las estaciones de monitoreo (figura 3.2.1.1) -noroeste, noreste, centro, suroeste y sureste- facilitó determinar los criterios que consisten básicamente en las diferencias entre zonas como son, la *actividad industrial, afluencia vehicular y condiciones meteorológicas*.

Con los *criterios de selección para intervenciones* y el *análisis de residuales* se identificó el número de caso y el patrón de comportamiento de la intervención que influyó en la serie. Para precisarlas y evaluarlas se debe conocer también la *fecha y objetivo de la medida*.

Aunque los pronósticos son el resultado terminal del análisis suelen ser también un criterio para la elección del modelo, siendo el crucial para la decisión final tomando en cuenta que. "Si los pronósticos se ajustan a los datos reales entonces el modelo igualmente se ajusta a la serie real".

4.2.2 Proceso de selección.

En base a los criterios antes mencionados se llevó a cabo la elección del modelo ARIMA que mejor describe a las concentraciones atmosféricas de SO_2 para las diferentes áreas de la ZMCM. A continuación se presenta una descripción minuciosa de la selección de los modelos en cada zona monitoreada.

Cabe aclarar que los modelos presentados no son los únicos que se ajustaron a las series, pero resulta vano incluirlos todos puesto que muchos de ellos están implícitos en éstos; principalmente lo que diferencia a un modelo de otro es el análisis de intervención.

Tacuba (NO).

Para esta estación de monitoreo tenemos los siguientes modelos:

No.	Transformación	Modelo (ARIMA)	Intervención ¹					Ajuste ¹ (E., MB., B., R.)**	Pronósticos ²
			1	2	3	4	5		
1	ln(x)	(0, 1, 2)	37 B.T.	40 B.P.	60 G.P.			R	B.

¹ Los criterios para la clasificación de Excelente, Muy Bueno, etc., fueron en base al análisis de residuales: gráfica, funciones de autocorrelación (ACF y PACF) y su gráfica de ajuste a la normal. Este criterio es utilizado también para ajustar los modelos de las siguientes estaciones de monitoreo.

² Su clasificación se determinó tomando en cuenta el error de pronóstico (diferencia entre el pronóstico y el dato real). Esta clasificación es utilizada también para los pronósticos de las estaciones siguientes.

Análisis de Resultados y recomendaciones

2	ln(x)	(0, 1, 2)	37 B.T.	40 B.P.	60 G.P.	71 B.P.	R.	M.B.
3	ln(x)	(0, 1, 2)	37 B.T.	60 G.P.	70 B.P.		M.B.	B.
4	ln(x)	(0, 1, 2)	37 B.T.	60 G.P.	70 G.P.		M.B.	B.
5		(0, 1, 2)	37 B.T.	49 B.T.	60 G.P.		M.B.	M.B.

** (E) Excelente, (M B) Muy Bueno, (D) Bueno, (R) Regular

* (B.P) Brusco Permanente, (B.T) Brusco Temporal, (G.P) Gradual Permanente

Cinco fueron los modelos que mejor se ajustaron a la serie de datos de Tacuba, de los cuales había que escoger el más adecuado. La tabla muestra que en algunos modelos el ajuste no fue bueno mientras que los pronósticos si lo eran, o viceversa, por lo que se tuvo que tomar en cuenta otros aspectos (criterios de selección) e ir descartando aquellos modelos que no cumpliera con alguno de los criterios.

Así tenemos que, el primero y segundo modelo cumplieron medianamente el criterio a), puesto que algunas autocorrelaciones de residuales sobrepasaron los límites de confianza y su gráfica escasamente se ajustó a la normal.

En cuanto a las medidas o intervenciones en los mismos modelos, en el caso 40 se detectó un cambio, pero al observarlo gráficamente no se presenta ninguno, por tal motivo se probaron otros modelos que no incluían a esta intervención -obteniéndose los modelos 3 y 4- y otros que cambiaron la fecha (modelo 5).

En los modelos obtenidos con la primera prueba (3 y 4) el ajuste fue bueno a pesar de que los pronósticos no lo fueron; la diferencia entre estos dos radicaba en el patrón de cambio de la intervención número 3. Observando la gráfica se decidió que el modelo no. 4 era preferible al 3 siendo que el patrón de cambio -en la intervención 3- se asemeja un gradual permanente.

Finalmente se creó el modelo 5 en el cual se canjeó el mes 49 por el 40, obteniendo así un modelo más adecuado que cumplió con todos los criterios de selección, teniendo el mejor ajuste y generando mejores pronósticos que los anteriores. Siendo este, el escogido para representar a la estación Tacuba.

Tlalnepantla (NO).

Como se mencionó en el apartado anterior, esta estación de monitoreo no presentó ninguna intervención y por lo tanto no hubo ningún modelo que, al incluir

una o varias intervenciones cumpliera con los criterios f) y g), parte medular en la evaluación del modelo. Por si fuera poco, el modelo es un caso típico de ARIMA (0,1,2) el cual se asemeja mucho al modelo teórico y por tanto no es necesario compararlo con otros: en todo caso, la confrontación consistió en incluir o no a la constante de cambio (ver capítulo 2), seleccionando al modelo que la incluye, ya que en las pruebas de hipótesis resultó significativa.

Xalostoc (NE).

Esta zona de monitoreo fue de las únicas que presentó cambios en los modelos tipo ARIMA siendo además significativos para el análisis. El primer modelo que se ajustó a la serie Xalostoc fue un ARIMA (0,1,1) con transformación de potencia (x^2), mientras que el elegido fue un ARIMA (1,0,0) sin transformación; de acuerdo con el *principio de parsimonia* se decidió por este último, puesto que es más sencillo un modelo *autorregresivo* que uno de *medias móviles* (Ver capítulo 2).

No.	Transformación	Modelo (ARIMA)	Intervención*					Ajuste (E., MB., B., R.)**	Pronósticos (E., MB., B., R.)**
			1	2	3	4	5		
1	(x^2)	(0, 1, 1)	49 B.T.					R	B.
2	(x^2)	(0, 1, 1)	49 B.P.	50 B.P.				B	M.B.
3	—	(1, 0, 0)	49 B.P.					E	M.B.
4	—	(1, 0, 0)	49 B.P.	51 B.T.				E.	M.B.

** (E.) Excelente, (M.B.) Muy Bueno, (B.) Bueno, (R.) Regular
 * (B.P.) Brusco Permanente, (B.T.) Brusco Temporal, (G.P.) Gradual Permanente

Refiriéndonos a las intervenciones, en los cuatro modelos se detectó un cambio a partir del caso número 49 y sólo en el primer modelo fue brusco temporal, patrón que es totalmente contradictorio con la gráfica que muestra un cambio permanente.

Otras intervenciones que se registraron, fueron en los casos 50 y 51 con patrones de cambio brusco permanente y brusco temporal respectivamente; para la intervención del caso 51, el patrón de cambio se ajusta mejor a la gráfica y es la que se incluye en el modelo ARIMA (1,0,0) que -como antes se mencionó- fue el elegido para representar a la estación Xalostoc.

Análisis de Resultados y recomendaciones

Merced (Centro)

Al igual que en Xalostoc y Tacuba, esta estación de monitoreo cuenta con una tabla que comprende los modelos con mejor ajuste y que permitieron la obtención del modelo final.

No.	Transformación	Modelo (ARIMA)	Intervención*					Ajuste (E., MB., B., R.)**	Pronósticos (E., MB., B., R.)**
			1	2	3	4	5		
1	—	(0, 1, 2)	49 G.P.					M.B	M.B.
2	—	(0, 1, 2)	49 B.P.					E.	M.B.
3	—	(0, 1, 2)	49 B.P.	60 B.P.				E.	B.
4	—	(0, 1, 2)	49 B.P.	70 B.P.				M.B.	M.B.

** (E.) Excelente, (M B.) Muy Bueno, (B.) Bueno, (R.) Regular
 * (B.P.) Brusco Permanente, (B.T.) Brusco Temporal, (G.P.) Gradual Permanente

Como primera opción de modelo era aquel que contenía sólo a la intervención en el caso 49, sus resultados mostraban que era muy buena opción, pero faltaba probar otros tipos de intervención para el mismo caso encontrando así al modelo número 2 que superaba al anterior en el ajuste. Se continuó probando otros modelos que incluyeran tanto a la intervención del caso 49 como a otras, hallándose el modelo 3 y 4.

El modelo 3 obtuvo un nivel excelente en el ajuste, pero los pronósticos no fueron mejores que los del modelo 4, que además presentó muy buen ajuste, criterio para decidir que este último era el adecuado para representar a la estación Merced.

Posiblemente se podría pensar que el modelo No.2 era mejor candidato, pero la razón que decidió escoger al 4, fue que este incluye a otra intervención en el caso 70 y con esto se refleja mejor la realidad.

Pedregal (SO).

La serie Pedregal es un caso típico del modelo autorregresivo y no fue necesario utilizar alguna transformación para que el modelo ARIMA (1,0,0) se ajustara a la serie, el problema surgió con el análisis de intervención. De todas las opciones que se probaron ninguna mostró el ajuste esperado y solo fueron tres los modelos que pudieron tomarse en cuenta para representar a serie de tiempo.

No.	Transformación	Modelo (ARIMA)	Intervención*					Ajuste (E., MB., B., R.)**	Pronósticos (E., MB., B., R.)**
			1	2	3	4	5		
1	—	(1, 0, 0)	33 B.T.					B.	R.
2	—	(1, 0, 0)	33 B.T.	53 B.T.				R.	R.
3	—	(1, 0, 0)	34 B.P.	53 B.T.				B.	B.

** (E.) Excelente, (M B.) Muy Bueno, (B.) Bueno, (R.) Regular

* (B.P.) Brusco Permanente, (B.T.) Brusco Temporal, (G.P.) Gradual Permanente

Como se indica en la tabla, los dos primeros modelos arrojaron pronósticos poco confiables, razón decisiva para rechazarlos; a pesar de que el tercer modelo mejora en los pronósticos no deja de tener un ajuste mediocre debido a que en la segunda intervención se detecta un cambio brusco temporal y la gráfica muestra un cambio permanente.

Cerro de la Estrella (SE).

Para la estación Cerro de la Estrella únicamente se encontraron dos modelos que se ajustaron a la serie de tiempo, pero entre ellos existen diferencias que hicieron difícil la elección.

En el primer caso encontramos un ARIMA (1,0,0) sin transformaciones e intervenciones que además de ser sencillo ("Principio de Parsimonia"), logró un ajuste muy bueno, su único problema fueron los pronósticos que resultaron muy diferentes a los datos reales. En el caso opuesto se encuentra el segundo modelo que es más complicado por incluir al modelo ARIMA (1,0,0) dos transformaciones lineales -diferencia y potencia- y una intervención gradual permanente en el mes 49, por supuesto este modelo es más complicado que el anterior y el ajuste no fue mejor, su ventaja reside en la precisión de los pronósticos. *Debido a la importancia de los pronósticos, el segundo fue el elegido como el más adecuado.*

No.	Transformación	Modelo (ARIMA)	Intervención*					Ajuste (E., MB., B., R.)**	Pronósticos (E., MB., B., R.)**
			1	2	3	4	5		
1	—	(1, 1, 0)						M.B.	B.
2	(x ²)	(0, 1, 1)	49 G.P.					B.	M.B.

** (E.) Excelente, (M B.) Muy Bueno, (B.) Bueno, (R.) Regular

* (B.P.) Brusco Permanente, (B.T.) Brusco Temporal, (G.P.) Gradual Permanente.

ZMCM (Zona Metropolitana de la Ciudad de México)

Inicialmente el modelo que se ajustó a la ZMCM fue un ARIMA (0,1,0) - caminata aleatoria³. lo que determinaba que no existía ninguna intervención y que los pronósticos serían simplemente el dato anterior más un error aleatorio. El modelo mostró un ajuste bueno aunque algunas autocorrelaciones finales sobrepasaban los límites de confianza, resulta obvio saber que no se analizaron los pronósticos ya que estos dependían en gran medida del error aleatorio.

Buscando otro modelo que tuviera mejor ajuste, se encontró un ARIMA (0,2,1) con transformación de potencia (x^2), a pesar de que este modelo es más complicado que la "caminata aleatoria", el ajuste fue mejor y los pronósticos muy buenos. A este modelo se le detectó una intervención brusca permanente a partir del caso número 49 y el cual se ajusta a la gráfica.

No.	Transformación	Modelo (ARIMA)	Intervención*					Ajuste (E., MB., B., R.)**	Pronósticos (E., MB., B., R.)**
			1	2	3	4	5		
1		(0, 1, 0) cam. Aleatoria						B.	—
2	(x^2)	(0, 1, 1)	49 B.P.					B	M.B.

** (E.) Excelente (M.B.) Muy Bueno, (B.) Bueno, (R.) Regular

* (B.P.) Brusco Permanente (B.T.) Brusco Temporal, (G.P.) Gradual Permanente

4.3. Análisis de resultados y discusión.

Los resultados demostraron que en cada una de las zonas de monitoreo, el comportamiento de las concentraciones de SO₂ es diferente, y como se ha ido mencionando a través del trabajo, esta disparidad es atribuida a la diversidad de condiciones que propician este fenómeno en cada zona monitoreada.

La desigualdad entre las zonas monitoreadas básicamente consiste en que: algunas desarrollan principalmente actividades industriales y otras son áreas residenciales; la flota vehicular que circula en ellas, también es diferente; las condiciones meteorológicas, específicamente el flujo de los vientos hace que las concentraciones de dióxido de azufre se muevan de una zona a otra⁴.

También cabe aclarar que la relación causa-efecto entre el comportamiento de las concentraciones atmosféricas de SO₂ y las características específicas de una zona, no es tan directa como se pensó al inicio del análisis.

³ Wei, William W.S., *Time series analysis (univariate and multivariate methods)*, Addison-Wesley Publishing Company, Inc., U.S.A. 1990.

⁴ Lacy Tamayo, R., *La calidad del aire en el Valle de México*, El Colegio de México, México D.F. 1993.

Así, las zonas noroeste (Tlalnepantla y Tacuba) y noroeste (Xalostoc) comprenden la gran mayoría del sector industrial en la ZMCM. Por ejemplo en la zona noroeste se encuentra la Refinería "18 de marzo", y en la zona noreste el uso del suelo es principalmente industrial. Dadas estas características se esperaba que los modelos que se ajustaran a las series de tiempo de estas dos zonas, presentarán marcadamente la parte AR (factor determinado) que indica que las concentraciones del bióxido de azufre dependerían en gran medida de la industria.

En la zona centro (Merced) las concentraciones se deben en su mayoría a las emisiones de autos, siendo esta la zona que contiene la mayor influencia vehicular. También se esperaba que el modelo representativo de esta zona, tuviera la parte AR muy marcada, presentando ambas zonas la parte MA

La dirección del flujo de los vientos de norte a sur hace que las concentraciones de SO_2 que se registran en las zonas suroeste (Pedregal) y sureste (Cerro de la Estrella), se deban principalmente por las concentraciones que son arrastradas del norte, por lo que, las condiciones meteorológicas son el principal factor que propicia su presencia. Se esperaba que los modelos que se ajustaran a Pedregal y Cerro de la estrella detectarían fuertemente la parte MA (factor aleatorio), detectando la parte AR.


Por la tabla 4.1.1, se puede observar que los modelos que se ajustaron a estas zonas, difieren en su mayoría a los esperados. La zona norte obtuvo modelos AR, mientras que la sur mostró modelos MA y la zona centro no fue la excepción. También hay que destacar que con el análisis de intervención, nuevamente se comprobó que la diversidad entre la zonas es un factor determinante para el comportamiento del SO_2 atmosférico, siendo que el impacto de las medidas implantadas por PEMEX para su disminución y control, no fue uniforme para todas las estaciones; además de que no todas fueron significativas.

Zona Noroeste.

Así tenemos que, los modelos de la zona noroeste (Tlalnepantla, Tacuba) indican que las concentraciones de SO_2 en esta área se deben en su totalidad por factores externos e impredecibles -los cuales son traducidos como factores meteorológicos-, lo que indica que no se puede asegurar que la industria de esta zona, genera la acumulación del contaminante, ni tampoco que se tiene controlado el problema. Posiblemente el estudio detallado y específico de los fenómenos meteorológicos así como otras fuentes de emisión de esta zona, ayudarían al verdadero control de este contaminante.

En estos términos se puede decir que la zona de Tlalnepantla muestra los mayores problemas, ya que no existe ningún indicador que muestre la existencia de control en las concentraciones de SO_2 para esta zona. Lo anterior obedece a que la gráfica y el modelo muestran una tendencia decreciente debido a algún factor externo y aleatorio como lo muestra la parte MA(2) del modelo y no a las medidas implantadas por PEMEX (ya que en el análisis no fueron significativas).

Figura 4.3.1 Registros mensuales de SO_2 en la zona noroeste.




El seguir realizando estudios sobre las características meteorológicas en esta zona ayudaría a entender mejor el fenómeno y así lograr su control; además, de buscar e identificar aquellas otros factores que no se han tomado en cuenta (otras fuentes de emisión) y que en términos del análisis, resultan determinantes para el comportamiento de las concentraciones del bióxido de azufre en el área de Tlalnepantla.

Para Tacuba aunque el modelo ARIMA no muestra la aportación y el esfuerzo de la Industria Petrolera por disminuir y controlar al SO_2 atmosférico, las intervenciones muestran que esta área fue la más beneficiada con estas estrategias implantadas por PEMEX, lo que es atribuible a la cantidad de industrias que existen en la zona. De la misma forma, y como se esperaba, las medidas detectadas en Tacuba estuvieron enfocadas principalmente a la disminución de azufre en combustibles utilizados por la industria: en diciembre de 1991 se prohíbe la venta de combustóleo (4.0 - 1.8% de azufre), viéndose sus resultados solo un mes después de su implantación y siendo tan importante, que logró una reducción de aproximadamente 0.04 ppm sobre el valor promedio de las

concentraciones del contaminante. Como una medida de invierno, en diciembre - marzo de 1993, medida número 6- se hace una reducción adicional del contenido de azufre en gasóleo (2.0 a 1.5%), lo que causó una disminución paulatina hasta finalmente lograr bajar el valor medio de las concentraciones en aproximadamente 0.007 ppm.

También en esta zona circula diariamente un flota vehicular considerable, por lo que la introducción de la magna-sin en septiembre de 1990 redujo temporalmente las concentraciones de este contaminante.

Figura 4.3.2. Registros mensuales de SO₂ en la zona noroeste.



Es importante mencionar que el cierre de la Refinería "18 de marzo" en 1991 (medida número 2), no tuvo ninguna repercusión significativa que fuera detectada por el análisis, lo que significa, que a pesar de ser una de las estrategias más importantes y de la que se esperaba redujera en gran cantidad a las concentraciones del SO₂ en la zona noroeste (específicamente las registradas en la estación de Tacuba), no fue lo suficientemente eficiente para disminuir su valor promedio.

Zona Noreste (Xalostoc).


El modelo que se ajustó a la estación Xalostoc, muestra claramente que las concentraciones de SO₂ en la zona noreste, dependen en su mayoría de las emisiones por industria. Como se sabe, esta área es la que abarca la mayor parte de las industrias de la ZMCM; así mismo podemos esperar que el problema del

SO₂ siga tendiendo a disminuir y a estabilizarse, siempre y cuando se continúen implantando estrategias para la disminución de SO₂ por parte de la industria.

Debido a que la parte noroeste es una zona industrial, se esperaba que las estrategias implantadas por PEMEX causarían un gran impacto; sin embargo sólo fue una, la medida que pudo alcanzar tal meta, la prohibición de la venta de combustóleo en diciembre de 1991 y causó un descenso en el valor medio de las concentraciones del contaminante (hasta 0.03 ppm), siendo tan significativa que su impacto fue inmediato (solo un mes después) y permanente, logrando con esto el decremento y la estabilización de los registros.

En marzo de 1992 se detectó como significativo el aumento de las concentraciones de SO₂ en zona noreste, que colocaron a la media 0.06 ppm por arriba de lo ya logrado, sin embargo después de algún periodo de 3-4 meses se detectó nuevamente un descenso en las concentraciones. Posiblemente esto se debió a que justo en ese mes (marzo) terminó la vigencia de la medida de invierno 92-93, lo que desajustó el descenso de las concentraciones, esto indica la importancia de esta medida durante ese invierno.

Figura 4.3.3. Registros mensuales de SO₂ en la zona noreste.



A pesar de un buen ajuste del modelo y conocer la fuente principal de las concentraciones de SO₂, Xalostoc es la zona que registra los valores más altos de contaminación por SO₂ (bióxido de azufre), lo que hace suponer que es necesario que las estrategias sean tan drásticas (como la prohibición de combustóleo) que logren, de esta forma, la reducción del valor promedio de las concentraciones.


Zona Centro (Merced).

Según el modelo ARIMA (0,1,2), las concentraciones de SO_2 en la zona de la Merced, están determinadas por las condiciones atmosféricas más que por las fuentes móviles (autotransporte) y fuentes fijas (industrias). Posiblemente esto se deba al arrastre del contaminante por el viento, que va de norte a sur pasando por el centro.

Partiendo de lo anterior, resulta claro entender porque en esta zona de monitoreo también se registró como significativa la disminución de las concentraciones a causa de la prohibición de combustóleo, porque a pesar de no ser una zona industrial, las emisiones que aquí se concentran -en su mayoría- son las transportadas de la zona norte y en donde esta medida causó su mayor impacto (0.02 ppm).

Otro cambio significativo en las concentraciones de bióxido de azufre, fue el causado en octubre de 1993 con la introducción de Diesel-Sin; dicho combustible es utilizado por los camiones de carga.

Figura 4.3.4. Registros mensuales de SO_2 en la zona centro.




Desde el punto de vista de los modelos, resalta la similitud que tiene esta zona con la noroeste en particular la estación Tacuba, por lo que sería interesante realizar estudios sobre esta igualdad y de las características que puedan tener en común, ya que con tal información se podrían elaborar otras estrategias que

causen un impacto favorable en ambas zonas (ejemplo: la prohibición de la venta de combustóleo).

Zona Suroeste (Pedregal).

Para la zona suroeste el modelo que mejor se ajustó a la serie de tiempo fue un ARIMA (1,0,0) que significa que las concentraciones de SO_2 son ocasionadas principalmente por las fuentes fijas y/o móviles, que en este caso probablemente se deban más por las fuentes móviles. La flota vehicular que circula en el área del suroeste de la ZMCM suele ser muy alta, además de ser uno de lugares que con frecuencia se forman congestionamientos automovilísticos. Normalmente se cree que las concentraciones de SO_2 en la zona suroeste son principalmente ocasionadas por el arrastre de las del norte, situación que no fue tan directa para el análisis puesto que no mostró una parte MA(q) en el modelo. Por lo cual sería adecuado realizar una investigación sobre la relación que existe entre las concentraciones del norte y del sur, o en todo caso tomar otras estaciones de monitoreo de la zona suroeste y volver a hacer el análisis; con el objeto de reafirmar los resultados del actual análisis o mostrar que la estación Pedregal no es precisamente la mejor estación que podría representar el problema de SO_2 en la ZMCM y posiblemente tampoco a la zona suroeste.

Figura 4.3.5. Registros mensuales de SO_2 en la zona suroeste.



Una de las medidas de PEMEX que impactó en Pedregal fue la introducción de la Magna-Sin (septiembre de 1990), combustible que es utilizado por los automóviles con convertidor catalítico. El impacto de esta medida, gráficamente resulta negativo puesto que, solo el primer mes descienden considerablemente para después volver a subir; sin embargo numéricamente fue positivo siendo que antes de la intervención se nota una tendencia al incremento la cual se ve trunrada con la introducción de esta medida, y a pesar de que solo un mes después nuevamente suben las concentraciones, nunca alcanzan valores más altos que los anteriores; finalmente, después de algún periodo de tiempo largo (2 o 3 años), las concentraciones disminuyen (hasta 0.03 ppm) y tienden a estabilizarse, conservándose así en la actualidad.

Por último, en mayo de 1992 se detectó otro cambio en el valor promedio de las concentraciones de SO_2 , como consecuencia de la medida 5.

Como ya se mencionó, el modelo que se ajusto a la serie de tiempo de la zona suroeste no fue del todo satisfactorio, por lo que se aconseja tomar precauciones con la descripción e interpretación de los resultados, así como de los pronósticos.

Zona Sureste (Cerro de la Estrella).

La varianza decreciente entre los registros de las concentraciones de SO_2 atmosférico tomadas en la zona sureste, indican claramente la disposición de estas a estabilizarse, siendo detectado por el modelo al tener que incluir una transformación lineal (x^2). Por otra parte, la gráfica y el modelo también muestran una tendencia decreciente en las concentraciones, además de ajustarse a ellas una parte autorregresiva (AR) que denota la estrecha relación que existe entre la concentración actual y la anterior y posterior a esta, más que de las condiciones ambientales que puedan prevalecer en ese momento (que son mas difíciles de analizar y controlar)


Tal modelo es un ejemplo claro de las características que se deben de cumplir, para poder asegurar que las concentraciones de SO_2 están finalmente controladas y que el proceso de mejoramiento de la calidad del aire a cumplido con sus objetivos.

Lo importante en este caso es conocer cuales fueron las condiciones y peculiaridades de la zona sureste, que ocasionaron una disminución en las concentraciones de SO_2 , porque a partir de esto habrá una mejor planeación de las futuras estrategias que se desarrollaran para tal fin. Además de no olvidar que en esta zona las emisiones de SO_2 a la atmósfera son muy reducidas, ya que no

existe un número considerable de industrias ni tampoco una flota vehicular tan grande que puedan ocasionar el incremento de este contaminante.

Independiente del comportamiento de las concentraciones de SO_2 en esta zona y de que en ella no exista un gran número de industrias, se detecto una disminución significativa del contaminante debido a la prohibición del uso de combustóleo a partir de diciembre de 1991. uno de los principales combustibles para la industria. Con esta medida se logró la reducción total de 0.05 ppm sobre el valor promedio, y este impacto fue detectado a partir del siguiente mes de haber entrado en vigor la medida y en un periodo de tiempo no muy largo. Posiblemente esto se deba al gran impacto que tuvo esta medida en casi todas las zonas monitoreo de donde son acarreadas las concentraciones, y lo que no haría raro la repercusión en aquellas en donde son depositadas.

Figura 4.3.6. Registros mensuales de SO_2 en la zona sureste.



ZMCM

El modelo general de la ZMCM -al igual que el de la zona sureste- muestra una varianza y tendencia decreciente indicando que, en general las concentraciones de SO_2 en el Valle de México tienen una disposición a disminuir y estabilizarse (Figura 4.3.8), prueba de esto es que, desde 1994 no se sobrepasa

la norma oficial de 0.13 ppm³ -IMECA 100- (Figura 4.3.9). El modelo también muestra que las concentraciones de bióxido de azufre para la ZMCM se ven fuertemente influenciadas por las condiciones meteorológicas de espacio-tiempo y otras fuentes de emisión, lo que hizo necesario la incorporación de un modelo de medias móviles.

Figura 4.3.8. Promedio mensual de las concentraciones de SO₂ atmosférico





Figura 4.3.7. Excedencias en las concentraciones de SO₂ atmosférico.




³ Cabe recordar que la serie de tiempo para el presente análisis al igual que su gráfica representan el promedio mensual de todos los datos registrados de las concentraciones de SO₂, por tal motivo en la misma no se muestran las excedencias puntuales que ha tenido el bióxido de azufre en la atmósfera.

El análisis de series de tiempo reafirma la observación hecha por varios autores, de que la contaminación atmosférica en el Valle de México es un problema tan complejo que involucra muchos factores y que para su estudio es de suma importancia tomarlos en cuenta.

Uno de los principales objetivos de la Industria Petrolera al producir combustibles más limpios, fue disminuir el contenido de azufre que provoca una reducción de las emisiones de SO_2 a la atmósfera. Estudios realizados en el IMP (Instituto Mexicano del Petróleo) demostraron que, efectivamente, las emisiones a la atmósfera de este contaminante han disminuido, ya que tanto la gráfica como su modelo, muestran una tendencia general decreciente y otra estacional (figura 4.3.9)⁸.

Figura 4.3.9. Emisiones de azufre a la atmósfera.



FUENTE: IMP, Abril 1996

En este sentido, se evaluó la relación entre las emisiones de azufre a la atmósfera por combustibles y las concentraciones de SO_2 mediante un análisis de correlación, mostrando que la relación entre emisiones por combustibles y concentración promedio de SO_2 es significativa (0.69, $p < 0.05$), relacionándose los datos en un 48%. Este porcentaje de correlación denota la complejidad de comportamiento en las concentraciones de SO_2 atmosférico, porque a pesar de

⁸ Instituto Mexicano del Petróleo, *Los Combustibles de la Zona Metropolitana de la Ciudad de México (ZMCM)*, Informe técnico GCA%-005, SPA GCA, Inédito, México D.F. 1996.

ser alto, no puede considerarse que las emisiones de azufre por combustibles determinen en un 100% las concentraciones, sin tomar en cuenta otros factores de emisión y condiciones meteorológicas de espacio-tiempo. Para reforzar lo dicho se obtuvo la relación entre emisiones y promedios de máximos que es de solo un 40%.

Aunque si bien, la relación que existe entre las ventas, las emisiones y las concentraciones de bióxido de azufre en la atmósfera no es muy estrechas, sí propició que en estas últimas resultara significativo (solo un mes después) el cambio que ocasionó la prohibición de combustibles en diciembre de 1991 siendo además la única intervención detectada. Como se ha observado durante todo el análisis, esta medida fue muy significativa en casi todas las estaciones de monitoreo y como era de esperarse, también se vió reflejada en la ZMCM. Con lo que se comprueba lo trascendental de aplicar este tipo de medidas, que al ser tan necesarias y adecuadas producen eficiencia tanto en costos como en beneficios.

La prohibición del uso y venta de combustóleo en la ZMCM, hizo necesario para su remplazo la elaboración e introducción de combustibles más limpios -con menos contenido de azufre-, así tenemos que, a partir de esta fecha se introdujo gasóleo (combustible industrial con un bajo contenido de azufre del 2.0% y que fue introducido 8 meses antes), y en octubre de 1993 se vende diesel sin, combustible utilizado por los camiones de carga. La introducción de ambos combustibles fueron de suma importancia a pesar de que, por sí solas, no resultaron significativas en el análisis de intervención.

De acuerdo con los costos registrados por la Industria Petrolera⁷ para la reducción de emisiones de SO₂ a la atmósfera, solo una pequeña cantidad fue destinada a la elaboración de gasóleo y diesel sin -para eliminar la venta de combustóleo- (Cuadro 4.3.1), y es aquí donde resalta nuevamente el gran éxito de estas medidas, que con un bajo costo (aproximadamente el 8% para diesel sin y posiblemente ninguno para el gasóleo, por ser un combustible que resulta de la mezcla de otros ya existentes) obtuvieron el mayor impacto, con lo que concluimos que *la prohibición de combustóleo y el remplazo por gasóleo y diesel sin, fue una estrategia eficaz (menor costo-mayor rendimiento) por parte de PEMEX, caso contrario a, aquella que involucra el cierre de la refinería "18 de marzo" donde su costo fue muy elevado y su impacto no fue tan significativo y capaz de ser detectado por el análisis de intervención.*

⁷ Departamento del Distrito Federal, *Programa para Mejorar la Calidad del Aire en el Valle de México 1993-2000*, México D.F. 1996., pag. 110, 111


⁸ Lacey Tamayo, R., *La calidad del aire en el Valle de México*, El Colegio de México, México D.F. 1993, pag. 58-61.

Cuadro 4.3.1. Costos para la implantación y desarrollo de estrategias

No.	Medida	Ejecutor	Inversión (millones de dólares)	
			Esperado	Gastado
1	Elaboración de gasolinas de calidad ecologica internacional	PEMEX	725.00 (34%)	810.81 (57%)
2	Elaboración de diesel con bajo contenido de azufre	PEMEX	424.00 (20%)	118.33 (8%)
3	Elaboración de combustoleo con bajo contenido de azufre	PEMEX	483.00 (22.6%)	—
4	Clausura definitiva de la refineria "18 de Marzo"	PEMEX	500.00 (23.4%)	500.00 (35%)
TOTAL			2123.00	1429.14


Resumiendo, tales resultados son muy significativos para el programa de mejoramiento de la calidad del aire, puesto que el compromiso cumplido por la Industria Petrolera de producir combustibles más limpios y así reducir las emisiones de azufre (figura 4.3.10), se ha visto reflejado con una atmósfera más limpia de bióxido de azufre, no obstante el incremento de el consumo de combustible (figura 4.3.11) hace que este problema no se tenga controlado aun.

Figura 4.3.10. Situación general del bióxido de azufre en la atmósfera de la ZMCM



La introducción de las nuevas estrategias para la reducción de SO_2 atmosférico deben seguir el patrón de aquellas que fueron eficaces, por que hay que recalcar que a pesar de que el bióxido de azufre ya no ha sobrepasado la norma permisible, no se puede decir que esta totalmente controlado, porque mientras que el consumo de combustibles siga creciendo como hasta ahora⁹ y no haya nuevas reformulaciones en ellos, dentro de algún tiempo -posiblemente largo- las emisiones de azufre aumentaran y por lo tanto las concentraciones de SO_2 en la atmósfera también.

Figura 4.3.11. Consumo mensual de combustibles.



FUENTE: IMP, 1996

Análisis de Correlación.

Como parte final de la descripción sobre el comportamiento de las concentraciones de SO_2 en la atmósfera de la ZMCM, se realizó un análisis de correlación que, en términos generales, muestra la relación que existen entre las diferentes zonas de monitoreo y los factores que la determinan. El propósito de dicho análisis es encontrar el grado de conexión entre emisiones de azufre y concentraciones de SO_2 en cada zona de monitoreo; así como, identificar claramente cual puede ser la estación monitoreada que represente mejor a la ZMCM.

Los resultados muestran que la estación Xalostoc es la que más se asemeja a la ZMCM -en términos de concentraciones mensuales de SO_2 -, con un 85% de relación entre sus datos, tal resultado confirma que, el impacto detectado

⁹ Instituto Mexicano del Petróleo, *Los Combustibles de la Zona Metropolitana de la Ciudad de México (ZMCM)*, Informe técnico GCA/96-005, NPA GCA, inédito, México D.F., 1996

Análisis de Resultados y recomendaciones

en la zona noreste por la prohibición de la venta de combustóleo como una medida de la Industria petrolera, se vió reflejado en las concentraciones generales de la ZMCM.

Por el contrario, la estación que menos se relaciona con el Valle de México es Pedregal (suroeste) que registró solo un 56% de relación entre los registros.

Como se mencionó anteriormente, las emisiones de azufre a la atmósfera por combustibles se relacionan en un 48% con las concentraciones de SO₂ atmosféricas de la ZMCM, y solo en un 28% con las de Xalostoc, teniendo la relación más alta con las de Tlalnepanitla en un 55% (Anexo III).

Con respecto a los máximos promedios móviles de SO₂ registrados para la ZMCM, destaca la relación que tiene con las concentraciones mensuales registradas en Xalostoc (77%), la cual es mayor (72%), a la detectada entre estos y correspondientes a las de ZMCM; lo que no resulta raro, al saber que en dicha estación se registran los valores más altos de SO₂, y por tanto -en la mayoría de las ocasiones- son los que determinan a los máximos promedios móviles de la ZMCM. En estos términos, nuevamente la zona suroeste es la que menos se relaciona con la ZMCM (31%) (Anexo III).


A manera de tabla y resumiendo con un diagrama, se muestran los niveles de relación entre las zonas de monitoreo, remarcando las más sobresalientes.

Tabla 4.3.1. Porcentajes de relación de los datos entre las estaciones de monitoreo.

	Noroeste Tacuba	Noroeste Tlalne	Noreste Xalostoc	Sureste C. Estre	Suroeste Pedregal	Centro Merced
Noroeste	-	-	-	-	-	-
Noroeste	52	-	-	-	-	-
Noreste	50	48	-	-	-	-
Sureste	44	55	55	-	-	-
Suroeste	21	29	41	44	-	-
Centro	56	58	48	48	26	-
ZMCM	71	66	85	81	56	67

Relación más alta -
Relación más baja

Máxima Relación entre zonas monitoreadas



Así, de acuerdo al análisis de correlación se concluye lo siguiente :

- La zona noreste (Xalostoc) es la que tuvo mayor parecido -en cuanto al comportamiento de las concentraciones de bióxido de azufre- con la ZMCM, caso contrario a la sureste (Pedregal) que presentó la menor correlación.
- En la ZMCM las emisiones mensuales de azufre a la atmósfera se relacionan en un 48% y 40% con las concentraciones mensuales de SO_2 y los máximos promedios móviles mensuales respectivamente, lo que significa que las concentraciones quedan explicadas en un 48% por las emisiones. Esto sugiere que, para la evaluación de las estrategias referentes a las emisiones de azufre se realice también el análisis en las concentraciones mensuales de SO_2 .
- En términos de concentraciones de bióxido de azufre, es sobresaliente la estrecha relación que muestra la zona noreste (Xalostoc) con la sureste (C. Estrella), y la noroeste con la centro; lo que reafirma la similitud entre los modelos ARIMA ajustados a cada una de ellas.
- Pedregal -que mostró el ajuste menos satisfactorio con los modelos ARIMA y las intervenciones-, también presentó muy poca correlación con las demás zonas de monitoreo, incluyendo a la ZMCM, lo que indica lo poco significativa que es esta zona para representar a la ZMCM en el estudio del comportamiento del bióxido de azufre. Es decir, Pedregal es una zona disímil a la ZMCM en términos de SO_2 .

4.4. Pronósticos

Como uno de objetivos del análisis de series de tiempo (Metodología de Box-Jenkins) y como parte final del trabajo de investigación, se obtuvieron los pronósticos de las concentraciones de SO_2 para los próximos siete meses de cada zona monitoreada, incluyendo a la ZMCM.

Como se explicó (Capítulo II), la importancia de la Metodología de Box-Jenkins radica en la obtención de pronósticos, lo que la hace una herramienta útil para la planeación y la toma de decisiones. Específicamente en este trabajo, la obtención de pronósticos aportará información para las estrategias planeadas a futuro, además de proporcionar una evaluación de las ya establecidas.

También sabemos que la metodología es considerada como una de las más confiables por la precisión de pronósticos a corto plazo, dando pauta a la comprobación del ajuste de los modelos ARIMA a las series de tiempo y sus pronósticos. Siguiendo tales especificaciones se efectuó la obtención de diez pronósticos mensuales, de los cuales los tres primeros sirven como comprobación, extrapolándolos con los tres últimos registros reales de la serie de tiempo, así tenemos que, los pronósticos para los meses de enero, febrero y marzo de 1996 servirán para la verificación de los modelos, y los siete pronósticos restantes serán para los meses de abril a octubre de 1996.

Para la obtención de los pronósticos, nuevamente se hizo uso del paquete STATISTICA (Capítulo III) que calcula de manera automática su valor, pero no obstante, se dan a conocer las ecuaciones que los generan y las que posteriormente permiten la actualización de los mismos; cabe aclarar que estas ecuaciones no son dadas por el paquete y que fueron desarrolladas aquí. Por lo tanto se incluyen las ecuaciones que originan a los pronósticos de las concentraciones de SO_2 de cada zona de monitoreo.

A continuación, para cada zona de monitoreo (incluyendo a la ZMCM) se hace la presentación de la ecuación matemática -desarrollada para este trabajo- y los pronósticos que genera el paquete STATISTICA (Anexo II).

Esta presentación se hará de dos maneras: la primera consiste de una tabla que contiene a los pronósticos y sus residuales, además de los límites superior e inferior del intervalo de confianza; la segunda consiste de dos figuras que sitúan gráficamente a los pronósticos junto a la serie real de las concentraciones atmosféricas de SO_2 .

Tlalnepantla (NO)

Modelo: (c) ARIMA (0,1,2)

$$\Delta Z_t = (c) + (1 - 0_1 B - 0_2 B^2) e_t$$

$$\vdots$$

$$Z_t = (c) + Z_{t-1} + e_t - 0_1 e_{t-1} - 0_2 e_{t-2}$$


con

$$(c) = -0.000499$$

$$0_1 = 0.302562$$


$$0_2 = 0.402411$$

TLALNEPANTLA					
Fecha (1996)	Dato real	Pronóstico	Residual	Límites de confianza (del 99%)	
				Inferior	Superior
enero	0.0140	0.0130	0.0010		0.0344
febrero	0.0140	0.0122	0.0018		0.0382
marzo	0.0130	0.0117	0.0013		0.0384
abril		0.0112			0.0387
mayo		0.0107			0.0389
junio		0.0102			0.0391
julio		0.0097			0.0393
agosto		0.0092			0.0394
sept		0.0087			0.0395
octubre		0.0082			0.0397



Análisis de Resultados y recomendaciones

Los pronósticos muestran que las concentraciones mensuales de SO_2 en esta zona tienden a bajar en los próximos siete meses, siendo un resultado favorable en el problema de la contaminación. Esta baja es atribuida a la constante (valor negativo) incluida en el modelo, que es una tasa de disminución, y su importancia radica en conocer cual es el fenómeno que la propicia y de ser posible, incluirlo en las demás zonas de monitoreo. Aunque hay que notar que los pronósticos siempre están por debajo de los datos reales (enero, febrero, marzo), lo que hace suponer que existe un desfaseamiento ocasionado -posiblemente también- por esta constante.



Tacuba (NO)

Modelo: ARIMA (0,1,2)

$$\Delta Z_t = (1 - \theta_1 B - \theta_2 B^2) e_t$$


$$Z_t = Z_{t-1} + e_t - \theta_1 e_t - \theta_2 e_{t-2}$$

con

$$\theta_1 = 0.302562$$

$$\theta_2 = 0.402411$$


TACUBA					
Fecha (1996)	Dato Real	Pronóstico	Residual	Límites de confianza (del 99%)	
				Inferior	Superior
enero	0.0180	0.0169	0.0011		0.0444
febrero	0.0150	0.0179	-0.0029		0.0476
marzo	0.0160	0.0179	-0.0019		0.0478
abril		0.0179			0.0480
mayo		0.0179			0.0481
junio		0.0179			0.0482
julio		0.0179			0.0484
agosto		0.0179			0.0485
sept		0.0179			0.0487
octubre		0.0179			0.0488



Los pronósticos obtenidos para Tacuba resultaron desfasados hacia arriba - excepto el primero -, tal característica hacen suponer que como en el caso de Tlalnepantla, existe un factor no identificado que ocasiona el aumento en los pronósticos y/o en las concentraciones con respecto a los últimos registros. Si se tratase solamente del aumento en los pronósticos, bastaría con identificar y eliminar al factor para lograr un mejor ajuste de los pronósticos a la serie real; si no fuera posible disminuir los pronósticos, entonces sería conveniente encontrar la causa que ocasionará en los próximos meses el aumento en las concentraciones de SO₂ en la atmósfera, y tratar de controlar este problema.

Análisis de Resultados y recomendaciones

La gráfica muestra una tendencia constante en los pronósticos, haciendo suponer que las concentraciones mensuales también se encontrarán estables en los próximos siete meses. A pesar de que el valor de todas las predicciones es constante en 0.18 ppm y resulta difícil de creer cuando se trata de concentración de SO₂ en la atmósfera, lo importante es conocer su comportamiento futuro, más que el valor puntual que registrará.



Xalostoc (NE)

Modelo: ARIMA (1,0,0)

$$(1 - \phi_1 B)Z_t = e_t$$

⋮

$$Z_t = \phi_1 Z_{t-1} + e_t$$


con

$$\phi_1 = 0.973543$$


XALOSTOC					
Fecha (1996)	Dato Real	Pronóstico	Residual	Límites de confianza (del 99%)	
				Inferior	Superior
enero	0.0190	0.0200	-0.0010		0.0570
febrero	0.0200	0.0209	-0.0009		0.1023

marzo	0.0220	0.0219	0.0001	0.1565
abril		0.0228		0.2178
mayo		0.0237		0.2850
junio		0.0246		0.3573
julio		0.0255		0.4340
agosto		0.0263		0.5147
sept		0.0272		0.5988
octubre		0.0280		0.0859

Sus pronósticos muestran que las concentraciones de SO_2 en la zona noreste aumentarán considerablemente en los próximos siete meses. Situación que es posible dada las condiciones de esta zona (industrias) y porque estos pronósticos son los que mejor se ajustaron a sus datos reales (observar los residuales). Si se observa la gráfica o los registros de la base de datos (anexo I), a mediados de 1995 se nota nuevamente la tendencia que tienen las concentraciones a incrementarse y que se reafirma con los pronósticos. Es importante saber las causas que lo propiciaron, puesto que el análisis de correlaciones mostró que los registros mensuales de SO_2 en Xalostoc son los que tienen mayor relación con las concentraciones mensuales y máximos promedios móviles de la ZMCM.



Análisis de Resultados y recomendaciones



Merced (Centro)

Modelo: ARIMA (0,1,2)

$$\Delta Z_t = (1 - \theta_1 B - \theta_2 B^2) e_t$$

⋮

$$Z_t = Z_{t-1} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2}$$



con

$$\theta_1 = 0.509093$$

$$\theta_2 = 0.465384$$

MERCEDES					
Fecha (1996)	Dato Real	Pronóstico	Residual	Límites de confianza (del 99%)	
				Inferior	Superior
enero	0.0170	0.0158	0.0012		0.0452
febrero	0.0140	0.0162	-0.0022		0.0489
marzo	0.0140	0.0162	-0.0022		0.0489
abril		0.0162			0.0489
mayo		0.0162			0.0490
junio		0.0162			0.0490
julio		0.0162			0.0490
agosto		0.0162			0.0490
sept.		0.0162			0.0490
octubre		0.0162			0.0490

El modelo que se ajustó y que generó los pronósticos de la estación Merced es muy parecido al de Tacuba, por lo que sus pronósticos también muestran un pequeño desfaseamiento con los datos reales y una tendencia constante con valores iguales a 0.016 ppm al igual que en Tacuba y todas las demás estaciones de monitoreo, el objeto de los pronósticos es conocer el comportamiento futuro que tendrán las concentraciones mensuales de SO_2 , más que el valor numérico que tendrán sus registros, por lo cual se puede concluir que las concentraciones de SO_2 en la zona centro tienden a estabilizarse en los próximos siete meses.



Cerro de la Estrella (SE)

Modelo: (x^2) ARIMA (1,1,0)

$$(1 - \phi_1 B) \Delta Z_t^2 = e_t$$



$$Z_t^2 = Z_{t-1}^2 + \phi_1 [Z_{t-1}^2 - Z_{t-2}^2] + e_t$$

con

$$\phi_1 = -0.312362$$

CERRO DE LA ESTRELLA					
Fecha (1996)	Dato Real	Pronóstico	Residual	Límites de confianza (del 99%)	
				Inferior	Superior
enero	0.0230	0.0157	0.0073		0.0707
febrero	0.0200	0.0155	0.0045		0.0775
marzo	0.0170	0.0155	0.0015		0.0844
abril		0.0155			0.0894
mayo		0.0155			0.0938
junio		0.0155			0.0977
julio		0.0155			0.1011
agosto		0.0155			0.1042
sept		0.0155			0.1071
octubre		0.0155			0.1097

Sus pronósticos fluctúan de 0.01545 a 0.0155 unidades de un mes con respecto a otro, pero para el caso práctico de las partes por millón (ppm) sólo son significativos los tres primeros decimales, por lo que todos pronósticos de Cerro de la Estrella se redondearon a 0.015 ppm, haciendo que se establezcan y tengan una tendencia constante como los de las estaciones anteriores. Así, se puede concluir también, que las concentraciones de SO₂ en la zona sureste serán estables para los próximos meses.

**Pedregal (SO)**

Modelo: ARIMA (1,0,0)

$$(1 - \phi_1 B)Z_t = e_t$$


Análisis de Resultados y recomendaciones


$$Z_t = \phi_1 Z_{t-1} + e_t$$

con

$$\phi_1 = 0.989897$$

PEDREGAL					
Fecha (1996)	Dato Real	Pronóstico	Residual	Límites de confianza (del 99%)	
				Inferior	Superior
enero	0 0160	0 0120	0 0040		0 0394
febrero	0 0130	0 0101	0 0029		0 0711
marzo	0 0160	0 0081	0 0079		0 1099
abril		0 0062			0 1547
mayo		0 0043			0 2046
junio		0 0024			0 2590
julio		0 0006			0 3176
agosto		-0 0013			0 3800
sept		-0 0031			0 4459
octubre		-0 0049			0 5150





Con anterioridad se mencionó el problema que presentó esta estación con el ajuste del modelo ARIMA a su serie de tiempo y con el análisis de intervención, porque a pesar de varios intentos por mejorar el modelo y las intervenciones, solo el modelo presentado anteriormente (ARIMA (1,0,0), con dos intervenciones en octubre de 1990 y mayo de 1992 respectivamente), cumplió con los residuales y tuvo el mejor ajuste. Debido a este problema, a pesar de que los pronósticos obtenidos con este modelo fueron los mejores matemáticamente, no son los más adecuados puesto que tienden a decrecer muy rápido e incluso tomar valores negativos lo cual no es posible al hablar de concentraciones atmosféricas. Así que no sería adecuado hacer alguna inferencia -a partir de estos pronósticos- del comportamiento de las concentraciones de SO_2 en la zona suroeste. Lo anterior hace suponer que el análisis realizado no fue el adecuado y habría que realizarse un más detallado, o en el peor de los casos, la Metodología de Box-Jenkins no es la más adecuada para analizar a la concentraciones mensuales registradas en la estación de Pedregal.

ZMCM

Modelo: (x^2) ARIMA (0,2,1)

$$\Delta_2 Z_t^2 = (1 - \theta_1 B)e_t$$

$$\vdots$$


$$Z_t^2 = 2 Z_{t-1}^2 - Z_{t-2}^2 + e_t - \theta_1 e_{t-1}$$


con

$$\theta_1 = 0.850009$$

ZMCM					
Fecha (1996)	Dato real	Pronóstico	Residual	Límites de confianza (del 99%)	
				Inferior	Superior
enero	0 0180	0 0159	0 0021		0 0538
febrero	0 0170	0 0158	0 0012		0 0653
marzo	0 0170	0 0157	0 0013		0 0744
abril		0 0156			0 0822
mayo		0 0154			0 0895
junio		0 0153			0 0963
julio		0 0152			0 1028
agosto		0 0151			0 1090
sept		0 0150			0 1151
octubre		0 0149			0 1210

En general, los registros mensuales de los últimos años para la ZMCM tienden a estabilizarse por debajo de 0.02 ppm, reafirmando esto, con los pronósticos obtenidos para los próximos meses los cuales se estabilizan al rededor del 0.016 ppm. El que los pronósticos se establezcan y tengan una tendencia constante hace pensar que, en general el problema del SO_2 en la Zona Metropolitana de la Ciudad de México está controlado para 1996, aun que no hay que olvidar la estación Xalostoc. Con estos resultados podemos entonces concluir que el esfuerzo realizado por la industria petrolera de controlar y disminuir las emisiones de azufre a la atmósfera se ha visto reflejado -al igual que en los próximos meses- en la disminución de las concentraciones atmosféricas de SO_2 . Solo basta decir, que los pronósticos son para los próximos siete meses y que después de este periodo no se puede asegurar que las concentraciones de dióxido de azufre sigan estables, ya que como se ha mencionado, los pronósticos en Xalostoc indican que las concentraciones se incrementarán, además de que las ventas de combustibles en la ZMCM también tienden a aumentar por lo que se emitirá más azufre a la atmósfera, incrementando también (en menor escala) las concentraciones de SO_2 en la ZMCM.





Conclusiones

Con este trabajo se puede sustentar que la Metodología de Box-Jenkins al igual que el Análisis de intervención son una herramienta ventajosa, en la descripción del comportamiento de contaminantes en la atmósfera y la evaluación de estrategias para su control. A partir de ésto y cumpliendo con los objetivos del trabajo, se obtuvieron resultados importantes sobre el comportamiento de las concentraciones del dióxido de azufre en la atmósfera de la Zona Metropolitana de la Ciudad de México (ZMCM) y sobre la evaluación de las estrategias implantadas por la Industria Petrolera para disminución y control de las emisiones que generan a este contaminante.

Como uno de los resultados de la aplicación de las metodologías se comprobó que la zonificación de la ZMCM es muy marcada con base en características específicas de cada área, como puede ser el uso de suelos y aspectos meteorológicos; de hecho estas subzonas no presentan alguna similitud entre ellas. Esta característica se vio reflejada en los modelos que se ajustaron a cada serie de tiempo representativas de las subzonas, encontrándose diferencias significativas y detectando intervenciones de distinto tipo y en fechas diferentes. De la misma manera no se puede hablar de una subzona representativa de la ZMCM puesto que su modelo es distinto a los puntos individuales, aunque es importante señalar que la noreste es la que más se asemeja. Por lo que los puntos de muestreo deben ser estudiados de manera individual si el propósito es describir el comportamiento de concentraciones en la atmósfera de la ZMCM

Por Box-Jenkins, tenemos por ejemplo, que las zonas NO y SE muestran una tendencia decreciente que es incluida en el modelo, mientras que la zona suroeste fue la única que mostró una varianza no constante. Finalmente tenemos que Tlalnepantla, Tacuba (NO) y Merced (C) presentaron modelos semejantes entre sí, al igual que Pedregal (SO) y Xalostoc (NE).

Con base en el análisis de correlaciones que se realizó para determinar la relación de las zonas de monitoreo con la ZMCM, también se encontró que la estación de monitoreo más indicada para representar a la ZMCM es Xalostoc (NE), presentando el coeficiente de correlación mas alto (debido principalmente porque es la que presenta los niveles más altos de SO_2), situación contraria a Pedregal, que es

Conclusiones

la estación que mostró la menor relación, además de que presentó un mal ajuste con el análisis de Box - Jenkins y de Intervenciones.

Con las correlaciones interzonales nuevamente se notó la relación en el comportamiento de las concentraciones de SO_2 , que existe entre la zona Noroeste (Tacuba) y la zona Centro (Merced), es importante señalar aquí, que la cercanía de estas dos estaciones de monitoreo - más que la de Tlalnepantla con Tacuba - podría ser la que determine esta característica, siendo importante considerarlo en la zonificación de esta área.

Por otro lado tenemos que existe una fuerte relación entre las emisiones de azufre por combustibles y las concentraciones de SO_2 , en la atmósfera y a la que se le atribuye el impacto favorable de las estrategias implantadas por PEMEX. Aunque cabe resaltar que la relación entre emisiones de azufre y los promedios de máximos móviles de SO_2 , es significativa pero no estrecha, lo que demuestra (al igual que los modelos MA encontrados en las series de tiempo) que existen otros factores que también determinan la formación de este contaminante en la atmósfera.

El Análisis de Intervención nos permitió conocer cuales fueron las estrategias implantadas por la Industria Petrolera que favorecieron a la disminución de SO_2 en la atmósfera, esta información podrá ser utilizada para evaluar de la misma forma las nuevas acciones implantadas durante 1995 al 2000.

De acuerdo a este análisis, la estrategia más eficaz realizada por la Industria Petrolera fue la prohibición de la venta de combustóleo en la ZMCM a partir de diciembre de 1991, puesto que tuvo un impacto favorable en la disminución de las concentraciones de bióxido de azufre en casi todas las zonas de monitoreo y en la ZMCM en general, siendo además una de las más económicas con base en la tabla de costos. Esta medida se registro estadísticamente significativa mostrando un patrón de cambio brusco permanente lo que significa que su impacto se reflejó rápidamente y disminuyó a las concentraciones de una manera constante.

Aunada a esta medida, la introducción de magna sin, la reducción adicional del contenido de azufre en gasóleo como parte de las medidas para la época invernal y la introducción de diesel Sin (detectadas solo en algunas zonas de monitoreo) lograron disminuir hasta 0.02ppm a las concentraciones de SO_2 siendo que la norma para este contaminante se determina satisfactoria en 0.13ppm (IMECA 100). Con esto se comprueba que los esfuerzos realizados por la industria petrolera fueron efectivos en su mayoría y que la implementación de medidas como las antes mencionadas podrían mejorar en mucho la calidad de la atmósfera de la ZMCM.

Los pronósticos para los siete meses posteriores, en general, fueron buenos puesto que presentaron un ajuste adecuado y el error de pronóstico fue el mínimo,

lo que refleja que los modelos encontrados fueron los más indicados para las series de tiempo.

Es importante destacar que los mejores modelos se obtuvieron específicamente para la ZMCM y la zona NE.

La mayoría de los pronósticos muestran que las concentraciones de bióxido de azufre en la atmósfera de la ZMCM tienden a estabilizarse en menos de 0.02 ppm, reflejando nuevamente el esfuerzo de PEMEX para combatir este problema; pero no hay que olvidar que, aunque la disminución de azufre en los combustibles conlleva a la disminución de concentraciones de bióxido de azufre en la atmósfera, el consumo de combustibles muestra un incremento constante que ocasiona un aumento -aunque en menor escala- de las emisiones de azufre y por lo tanto podrían aumentar levemente las concentraciones de SO_2 .

Referencias Biblio-hemerográficas

- 1.- AMGE., *VI Simposium de Geofísica*, México Abril 1994.
- 2.- Box, G., Jenkins, G., *TIME SERIES ANALYSIS forecasting and control*, Prentice-Hall, Inc., U.S.A. 1976.
- 3.- Ceballos Soberanis, J.A., *Evolución de la calidad de los combustibles Industriales*, in memorias de Seminario "Calidad de Combustibles en México" PEMEX - Refinación, IMP, México D.F. 1994.
- 4.- Celestinos, J. A., *Evolución de la calidad de las gasolinas en México*, in memorias de Seminario "Calidad de Combustibles en México" PEMEX - Refinación, IMP, México D.F. 1994.
- 5.- Comisión Metropolitana para la Prevención y Control de la Contaminación Ambiental en el Valle de México., *La contaminación Atmosférica en el Valle de México (Acciones para su control 1988-1994)*, CMPCCA, México D.F. 1994.
- 6.- Comisión Metropolitana para la Prevención y Control de la Contaminación Ambiental en el Valle de México., *Programa Integral Contra la Contaminación Atmosférica "Un compromiso Común" Octubre 1990*, CMPCCA, México D.F. 1990.
- 7.- Departamento del Distrito Federal, *Compendio Estadístico 1986-95*, México, DGPC/DRAMA, México D.F. 1996
- 8.- Departamento del Distrito Federal, *Informe Anual de la calidad del aire*, DGPC/DRAMA, México D.F. 1996.
- 9.- Departamento del Distrito Federal, *Informe mensual de la calidad del aire*, DGPC/DRAMA, México D.F. marzo 1996.
- 10.- Departamento del Distrito Federal, *Programa para Mejorar la Calidad del Aire en el Valle de México 1995-2000*, México D.F. 1996.
- 11.- Gallegher, Charles y Watson, Hugh., *Métodos cuantitativos para la toma de Decisiones en Administración*, McGraw Hill, México D.F. 1982.
- 12.- González Videgaray, M. C., *Modelos de Decisión con procesos estocásticos II*, UNAM ENEP Acatlán, México Méx. 1990.

Referencias

- 13.- Guerrero, V., *Análisis estadístico de series de tiempo econométricas*, U.A.M., Iztapalapa, México D.F.1991.
- 14.- Instituto Mexicano del Petróleo, *Impacto en la calidad del Aire en la ZMCM debido a la reducción en las emisiones de Dióxido de Azufre.*, Informe técnico GCA-9527, SGIDTTI /GCA., Inédito, México D.F. 1995.
- 15.- Instituto Mexicano del Petróleo, *Los Combustibles de la Zona Metropolitana de la Ciudad de México (ZMCM)*, Informe técnico GCA96-005, SPA/GCA, Inédito, México D.F. 1996.
- 16.- Instituto Mexicano del Petróleo, *Sistema para el manejo estadístico de datos aerométricos en la ZMCM*, Informe técnico GCA95-013, SPA/GCA, Inédito, México D.F. 1996.
- 17.- Lacy Tamayo R. *Efectos del uso de gasolinás en la calidad del aire del Valle de México*, in memorias de Seminario "Calidad de Combustibles en México" PEMEX - Refinación, IMP, México D.F. 1994.
- 18.- Lacy Tamayo, R., *La calidad del aire en el Valle de México*, El Colegio de México, México D.F.1993.
- 19.- Makridakis, Spuros, G., Wheel, Wright, S., *Forecasting Methods for Management*, John Wiley & Sons, Inc., fifth edition, U.S.A. 1989.
- 20.- Mendenhall W., Scheaffer R., Wackerly D., *Estadística Matemática con Aplicaciones*, Grupo Editorial Iberoamérica, México D.F. 1996.
- 21.- SEDESOL, *Informe de la situación general en materia de equilibrio ecológico en protección al ambiente 1993-1994*, I. N. E., México D.F. 1994.
- 22.- Prawda, Juan., *Métodos y modelos de investigación de operaciones. Vol. 2. Modelos Estocásticos*, LIMUSA, México D.F.1984.
- 23.- Quadri de la Torre, G., Sánchez L.R., *La ciudad de México y la contaminación Atmosférica*, LIMUSA, México D.F.1990.
- 24.- Rosas Jaramillo, J.A., *Evolución de la calidad del diesel en México*, in memorias de Seminario "Calidad de Combustibles en México" PEMEX - Refinación, IMP, México D.F. 1994.
- 25.- Sánchez Martínez, S., in memorias de Seminario "Calidad de Combustibles en México" PEMEX - Refinación, IMP, México D.F. 1994.

Referencias

26.- Seinfeld, John H., *Contaminación Atmosférica "Fundamentos físicos y químicos"*, Instituto de Estudios de Administración Local N. Y. 1975, McGraw-Hill, Madrid España 1978.

27.- Statistica for Windows (Volumen III), *Statistics II 1984-1994*, StatSoft, Inc., U.S.A. 1994.

28.- Walpole R., Myers R., *Probabilidad y Estadística*, McGraw Hill, Cuarta Edición, México D.F. 1992

29.- Wei, William W. S., *Time Series Analysis (univariate and multivariate Methods)*, Addison-Wesley Publishing Company, Inc., U.S.A. 1990.

Anexos

ANEXO I
Base de datos de los registros mensuales de SO₂ en ppm obtenidos de la RAMA para el periodo 1988-1996.

Año	MES	TACUBA	TALNEPA	XALOSTOC	C_ESTREL	PEDREGAL	MERCED	ZMCM
1988	1	0.064	0.061	0.081	0.045	0.046	0.041	0.055
	2	0.077	0.065	0.082	0.051	0.056	0.073	0.067
	3	0.052	0.05	0.084	0.049	0.06	0.044	0.058
	4	0.052	0.052	0.086	0.038	0.024	0.058	0.049
	5	0.048	0.056	0.079	0.041	0.019	0.06	0.05
	6	0.052	0.063	0.056	0.048	0.02	0.043	0.043
	7	0.06	0.059	0.046	0.057	0.021	0.037	0.044
	8	0.049	0.061	0.068	0.052	0.031	0.036	0.047
	9	0.046	0.08	0.057	0.059	0.028	0.04	0.046
	10	0.054	0.098	0.065	0.076	0.025	0.051	0.055
	11	0.079	0.058	0.08	0.065	0.022	0.102	0.068
	12	0.068	0.056	0.076	0.048	0.035	0.067	0.059
1989	1	0.051	0.063	0.074	0.074	0.03	0.042	0.049
	2	0.055	0.054	0.089	0.073	0.022	0.04	0.052
	3	0.073	0.06	0.085	0.121	0.019	0.033	0.07
	4	0.059	0.049	0.078	0.073	0.024	0.041	0.055
	5	0.038	0.043	0.047	0.047	0.023	0.031	0.035
	6	0.037	0.035	0.065	0.052	0.018	0.028	0.038
	7	0.053	0.035	0.01	0.052	0.019	0.041	0.041
	8	0.065	0.041	0.066	0.057	0.022	0.057	0.051
	9	0.043	0.043	0.059	0.054	0.023	0.041	0.044
	10	0.07	0.058	0.054	0.067	0.035	0.043	0.055
	11	0.064	0.048	0.06	0.053	0.037	0.068	0.054
	12	0.058	0.045	0.073	0.049	0.047		0.057

Año	MES	TACUBA	TLALNEPA	XALOSTOC	C_ESTREL	PEDREGAL	MERCED	ZMCM
1990	1	0,052	0,045	0,094	0,04	0,051	0,037	0,061
	2	0,049	0,039	0,08	0,074	0,052	0,043	0,06
	3	0,041	0,04	0,066	0,082	0,049	0,04	0,058
	4	0,065	0,039	0,056	0,062	0,051	0,049	0,058
	5	0,07		0,061	0,085	0,064	0,046	0,069
	6	0,05	0,052	0,053	0,074	0,052	0,046	0,055
	7	0,05	0,05	0,049	0,094	0,062	0,04	0,061
	8	0,041	0,049	0,039	0,074	0,059	0,045	0,05
	9	0,024	0,044	0,044	0,062	0,059	0,057	0,045
	10	0,024	0,039	0,044	0,052	0,025	0,022	0,036
	11	0,072	0,03	0,053	0,057	0,045	0,028	0,051
	12	0,05	0,046	0,072	0,071	0,051	0,038	0,056
1991	1	0,03	0,054	0,061	0,059	0,053	0,041	0,046
	2	0,025	0,056	0,062	0,062	0,04	0,047	0,049
	3	0,023	0,053	0,063	0,064	0,067	0,052	0,056
	4	0,042	0,047	0,063	0,068	0,065	0,039	0,057
	5	0,048	0,051	0,049	0,065	0,058	0,038	0,052
	6	0,041	0,048	0,054	0,07	0,061	0,039	0,05
	7	0,035	0,047	0,079	0,092	0,065	0,041	0,056
	8	0,029	0,045	0,084	0,081	0,068	0,04	0,059
	9	0,024	0,046	0,105	0,096	0,051	0,036	0,055
	10	0,047	0,048	0,086	0,094	0,039	0,051	0,055
	11	0,062	0,049	0,094	0,098	0,048	0,066	0,076
	12	0,052	0,048	0,112	0,101	0,039	0,065	0,074

Año	MES	TACUBA	TLALNEPA	XALOSTOC	C_ESTREL	PEDREGAL	MERCED	ZMCM
1992	1	0,086	0,056	0,145	0,097	0,038	0,055	0,086
	2	0,074	0,043	0,14	0,067	0,057	0,044	0,075
	3	0,055	0,033	0,072	0,042	0,038	0,031	0,048
	4	0,047	0,031	0,074	0,046	0,04	0,027	0,045
	5	0,051	0,036	0,093	0,046	0,059	0,029	0,056
	6	0,055	0,037	0,081	0,038	0,052	0,025	0,049
	7	0,059	0,047	0,086	0,053	0,048	0,035	0,056
	8	0,051	0,049	0,057	0,056	0,04	0,037	0,047
	9	0,024	0,009	0,043	0,018	0,02	0,013	0,025
	10	0,049	0,016	0,018	0,023		0,015	0,024
	11	0,032	0,022	0,043	0,029	0,029	0,022	0,032
	12	0,046	0,042	0,053	0,045	0,028	0,036	0,041
1993	1	0,043	0,038	0,048	0,059	0,023	0,035	0,043
	2	0,038	0,031	0,04	0,031	0,033	0,033	0,035
	3	0,02	0,018	0,024	0,016	0,015	0,01	0,019
	4	0,019	0,015	0,024	0,024	0,014	0,016	0,021
	5	0,022	0,015	0,026	0,023	0,01	0,01	0,02
	6	0,017	0,01	0,022	0,015	0,011	0,021	0,017
	7	0,013	0,01	0,018	0,011	0,01	0,021	0,015
	8	0,014	0,011	0,016	0,012	0,009	0,02	0,014
	9	0,014	0,011	0,018	0,014	0,009	0,014	0,014
	10	0,02	0,016	0,017	0,013	0,019	0,019	0,017
	11	0,018	0,021	0,038	0,026	0,012	0,02	0,021
	12	0,029	0,024	0,04	0,032	0,013	0,012	0,025

Año	MES	TACUBA	TLALNEPA	XALOSTOC	C_ESTREL	PEDREGAL	MERCED	ZMCM
1994	1	0,028	0,021	0,029	0,023	0,015	0,01	0,022
	2	0,023	0,017	0,024	0,018	0,016	0,011	0,019
	3	0,032	0,021	0,031	0,02	0,016	0,022	0,024
	4	0,023	0,015	0,023	0,015	0,014	0,03	0,021
	5	0,029	0,022	0,026	0,017	0,019	0,021	0,022
	6	0,031	0,024	0,033	0,015	0,015	0,019	0,023
	7	0,028	0,024	0,022	0,018	0,015	0,015	0,02
	8	0,017	0,022	0,024	0,025	0,015	0,015	0,019
	9	0,014	0,019	0,015	0,023	0,017	0,016	0,017
	10	0,015	0,022	0,016	0,014	0,018	0,017	0,016
	11	0,018	0,022	0,029	0,018	0,017	0,017	0,019
	12	0,022	0,022	0,023	0,018	0,015	0,015	0,019
1995	1	0,021	0,025	0,026	0,021	0,015	0,015	0,02
	2	0,019	0,019	0,022	0,016	0,015	0,016	0,018
	3	0,02	0,019	0,019	0,017	0,016	0,017	0,018
	4	0,017	0,017	0,016	0,014	0,014	0,014	0,015
	5	0,014	0,014	0,017	0,014	0,015	0,014	0,015
	6	0,016	0,016	0,016	0,018	0,014	0,013	0,016
	7	0,013	0,013	0,015	0,013	0,013	0,013	0,013
	8	0,012	0,014	0,016	0,014	0,014	0,014	0,014
	9	0,014	0,014	0,016	0,016	0,015	0,015	0,015
	10	0,019	0,014	0,019	0,017	0,015	0,015	0,017
	11	0,018	0,014	0,018	0,017	0,016	0,013	0,016
	12	0,015	0,014	0,019	0,015	0,014	0,014	0,016
1996	1	0,018	0,014	0,019	0,023	0,016	0,017	0,018
	2	0,015	0,014	0,02	0,02	0,013	0,014	0,017
	3	0,016	0,013	0,022	0,017	0,016	0,014	0,017

ANEXO II

Resultados de los parámetros y modelos

TACUBA (NO)

Input TACUBA (xms0_96 sta)									
Transformations D(1) (Interrupted ARIMA)									
Model (0,1,2) Seasonal lag 12 MS Residual= 00010									
	Param	Asympt Std Err	Asympt t(90)	p	Lower 95% Conf	Upper 95% Conf	Interv. Case No	Interv. Type	Asympt Change
q(1)	0,57479222	0,10018297	5,73742421	1,2759E-07	0,37576125	0,77382318			
q(2)	0,31655215	0,09624513	3,28901977	0,00143576	0,12534439	0,50775991			
Omega(1)	-0,02064997	0,00859579	-2,40233569	0,01834502	-0,037727	-0,00357294		37 Abr/Temp	
Delta(1)	0,89955501	0,10527165	8,54508319	3,0383E-13	0,6904145	1,10689552		37 Abr/Temp	
Omega(2)	0,04031222	0,01032056	3,90601052	0,00018122	0,01980862	0,06081579		49 Abr/Temp	
Delta(2)	0,58868003	0,17272498	3,40935064	0,00097626	0,2457317	0,93202836		49 Abr/Temp	
Omega(3)	-0,00724926	0,00352925	-2,05405131	0,04287147	-0,01426072	-0,00023779		60 Grd/Perm	
Delta(3)	0,75204867	0,12165245	6,1819442	1,8172E-08	0,51036484	0,9937325		60 Grd/Perm	-0,02923561

TLALNEPANTLA (NO)

Input TLALNEPA (xms0_96 sta)									
Transformations D(1)									
Model (0,1,2) Seasonal lag 12 MS Residual= 00006									
	Param	Asympt Std Err	Asympt t(95)	p	Lower 95% Conf	Upper 95% Conf			
Constant	-0,0004592	0,00024743	-2,01756348	0,04645774	-0,00099041	-7,995E-06			
q(1)	0,30256226	0,09539919	3,1715391	0,00204219	0,11317092	0,4919536			
q(2)	0,40241053	0,10112821	3,9792113	0,00013511	0,20164564	0,60317541			

XALOSTOC (NE)

Input: XALOSTOC (xms02_96.sta)								
Transformations: none (Interrupted ARIMA)								
Model (1,0,0) Seasonal lag: 12 MS Residual= 00024								
	Param	Asympt Std Err.	Asympt t(95)	p	Lower 95% Conf	Upper 95% Conf	Interv. Case No	Interv. Type
p(1)	0,9735433	0,02971899	32,7582891	0	0,91454364	1,03254295		
Omega(1)	0,03582997	0,01595641	2,24549022	0,0270551	0,00415248	0,06750746		49 Abr/Perm
Omega(2)	-0,06534655	0,01590138	-4,1094885	8,4115E-05	-0,09691479	-0,03377831		51 Abr/Temp
Delta(2)	0,99318168	0,03022564	32,8569088	0	0,93317619	1,05318717		51 Abr/Temp

MERCED (C)

Input: MERCED (xms02_96.sta)								
Transformations: D(1) (Interrupted ARIMA)								
Model (0,1,2) Seasonal lag: 12 MS Residual= 00012								
	Param	Asympt Std Err.	Asympt t(94)	p	Lower 95% Conf	Upper 95% Conf	Interv. Case No.	Interv. Type
q(1)	0,50909305	0,08970578	5,67514217	1,5293E-07	0,33098012	0,68720598		
q(2)	0,46538435	0,09111368	5,10773289	1,7025E-06	0,284476	0,6462927		
Omega(1)	-0,01670711	0,00434135	-3,84836613	0,00021665	-0,02532697	-0,00808725		49 Abr/Perm
Omega(2)	-0,01032318	0,00462062	-2,23415531	0,02784321	-0,01949752	-0,00114883		70 Abr/Perm

CERRO DE LA ESTRELLA (SE)

Input: C_ESTREL (xms02_96 sta)									
Transformations: x^2,D(1) (Interrupted ARIMA)									
Model (1,1,0) Seasonal lag 12 MS Residual= 00000									
	Param	Asympt Std Err	Asympt t (95)	p	Lower 95% Conf	Upper 95% Conf	Interv. Case No	Interv. Type	Asympt. Change
p(1)	-0,31236181	0,09823527	-3,17973174	0,00199078	-0,50738348	-0,11734014			
Omega(1)	-0,00306191	0,00124508	-2,45920909	0,01573372	-0,0055337	-0,00059012	49 Grd/Perm		
Delta(1)	0,69647606	0,14339986	4,85688087	4,6862E-06	0,41179133	0,98116079	49 Grd/Perm		-0,01008787

PEDREGAL (SE)

Input: PEDREGAL (xms02_96 sta)									
Transformations: none (Interrupted ARIMA)									
Model (1,0,0) Seasonal lag 12 MS Residual= 00009									
	Param.	Asympt Std Err.	Asympt t (95)	p	Lower 95% Conf	Upper 95% Conf	Interv. Case No.	Interv. Type	
p(1)	0 9898965	0 01774212	55 793596	0	0 95467394	1 02511906			
Omega(1)	-0 03309635	0 00977495	-3 38583447	0 00103328	-0 05250208	-0 01369063		34 Abr/Perm	
Omega(2)	0 02121181	0 00905318	2 34302335	0 02121414	0 00323898	0 03918465		53 Abr/Temp	
Delta(2)	0 71046977	0 29446587	2 41274062	0 01775242	0 1258811	1 29505844		53 Abr/Temp	

ZONA METROPOLITANA DE LA CIUDAD DE MÉXICO

Input ZMCM (xms02_96 sta)							
Transformations: x^2,2^D(1) (Interrupted ARIMA)							
Model (0,2,1) Seasonal lag 12 MS Residual= 00000							
	Param	Asympt Std Err.	Asympt t(95)	p	Lower 95% Conf	Upper 95% Conf	Interv. Case No. Interv. Type
q(1)	0.85000915	0.05216872	16.2934641	2.9306E-29	0.74644114	0.95357715	
Omega(1)	0.00215564	0.00087965	2.45055273	0.01609346	0.0004093	0.00390197	49 Abri/Perm

ANEXO III
Tabla de correlaciones

STAT. BASIC STATS	Correlations (xmso2_96.sta) Marked correlations are significant at $p < .05000$ N=86 (Casewise deletion of missing data)										
Variable	TACUBA	TLALNE	XALOST	C_ESTR	PEDREG	MERCED	ZMCM	VTOCOM	STOTC	PROMSO	SO2MOV
TACUBA	1.00	.72*	.76*	.66*	.46*	.75*	.84*	-.47*	.70*	.79*	.76*
TLALNE	.72*	1.00	.69*	.76*	.54*	.76*	.81*	-.61*	.74*	.85*	.67*
XALOST	.76*	.69*	1.00	.77*	.64*	.69*	.92*	-.40*	.53*	.91*	.88*
C_ESTR	.66*	.76*	.77*	1.00	.66*	.69*	.90*	-.41*	.63*	.91*	.71*
PEDREG	.46*	.54*	.64*	.66*	1.00	.51*	.75*	-.33*	.41*	.76*	.56*
MERCED	.75*	.76*	.69*	.69*	.51*	1.00	.82*	-.54*	.69*	.84*	.66*
ZMCM	.84*	.81*	.92*	.90*	.75*	.82*	1.00	-.49*	.69*	.98*	.85*
VTOCOM	-.47*	-.61*	-.40*	-.41*	-.33*	-.54*	-.49*	1.00	-.52*	-.52*	-.44*
STOTC	.70	.74*	.53*	.63*	.41*	.69*	.69*	-.52*	1.00	.69*	.63*
PROMSO2	.79*	.85*	.91*	.91*	.76*	.84*	.98*	-.52*	.69*	1.00	.83*
SO2MOV	.76*	.67*	.88*	.71*	.56*	.66*	.85*	-.44*	.63*	.83*	1.00

* Significativa

VTOCOM Venta de combustibles en la ZMCM

STOTC Emisiones totales de azufre por combustibles en la ZMCM.

PROMSO Concentraciones mensuales de SO₂ en la atmósfera de la ZMCM

SO2MOV Máximo promedio móvil mensual para la ZMCM

Glosario

- ACF autocorrelation**
Función: Es llamada función de autocorrelación al coeficiente de correlación entre Z_t y Z_{t+k} para el mismo proceso separado solo por una longitud de tiempo k . De modo que en un modelo $MA(q)$, las ACF 's determinan el valor de q .
- Análisis de Intervención:** Metodología desarrollada por Box y Tiao que permite identificar en un serie de tiempo los factores externos que la afectan y a los cuales se les conoce como intervenciones.
- AR (p) Autorregresive**
Model: Modelo autorregresivo de orden (p) y objeto de estudio de la Metodología de Box - Jenkins.
- ARMA(p,q)**
Autorregressive Moving Average Model: Modelo autorregresivo medias móviles de compuesto por un modelo autorregresivo de orden p [AR(p)] y un de medias móviles de orden q [MA(q)]. Este modelo es el objeto de estudio de la Metodología de Box - Jenkins.
- ARIMA(p,d,q)**
Autorregressive Integrated Moving Average Model: Modelo autorregresivo integrado de medias móviles compuesto por un modelo autorregresivo de orden p [AR(p)], d diferencias lineales y un modelo de medias móviles [MA(q)]. Este modelo es el objeto de estudio de la Metodología de Box - Jenkins.
- Concentraciones:** Condensación de algún contaminante en la atmósfera. Suele expresarse en dos tipos de unidades: partes por millón (ppm) y microgramos por metro cúbico ($\mu g/m^3$), según el tipo de contaminante.
- Emisiones:** Residuos químicos arrojados a la atmósfera por alguna fuente de emisión (chimeneas, vehículos, etc.).

Glosario

Fuentes de emisión:	Existen dos tipos de fuentes de emisión: móviles y fijas. Las primeras se componen principalmente de las de transporte, y en las segundas encontramos: la producción de energía eléctrica, la incineración de residuos, el consumo de combustibles industriales y domésticos y los procesos industriales tales como el motor de combustión interna y la combustión de petróleo en caldera y hornos industriales
IMECA:	ÍNDICE METROPOLITANO DE CALIDAD DEL AIRE: Permite comparar las magnitudes de los diversos contaminantes en una escala homogénea ponderada a un valor de daño a la salud; en la cual 100 puntos IMECA corresponde al valor de la norma de cada uno de los contaminantes.
Intervención:	Las series son frecuentemente afectadas por ciertos eventos externos. A estos factores externos se les llama intervenciones. Estas son el objeto de estudio de la Metodología de Análisis de Intervención.
MA (q) Moving Average Model:	Modelo de medias móviles de orden (q) y el cual es el objeto de estudio de la Metodología de Box - Jenkins.
Microgramos por metro cubico $\mu\text{g}/\text{m}^3$:	Unidad utilizada para expresar la concentración de Partículas Suspensas en un volumen de Aire. La concentración de partículas se determina por la diferencia de peso de un filtro, después de la extracción de un volumen de aire conocido.
Medida o estrategia:	Acciones realizadas por la Industria Petrolera Mexicana para disminuir y controlar las emisiones de contaminantes a la atmósfera de la ZMCM.
Metodología de Box - Jenkins:	Metodología desarrollada por Box y Jenkins en 1976 cuyo objetivo es ajustar un modelo tipo ARIMA a una serie de tiempo dada.

- Número de caso:** Número asignado por la base de datos XMSO2_96 a cada registro mensual de SO_2 atmosférico en la ZMCM desde 1988 a principios de 1996.
- Óxidos de Azufre (SO_x):**
(Bióxido de azufre SO_2) Los óxidos de azufre atmosféricos (SO_x) son producidos por el proceso de combustión de los combustibles (gasóleo, diesel) con contenido de azufre (carbón y petróleo), durante el proceso de combustión son oxidados, formando como producto principal *bióxido de azufre* (SO_2). Estos compuestos son generalmente emitidos a la atmósfera en forma de bióxido de azufre (SO_2) y parcialmente como sulfitos (SO_3). EL SO_2 es oxidado a SO_3 en presencia de radiación solar dentro de un intervalo de tiempo de hasta dos días. El SO_3 es rápidamente absorbido tanto por el agua de lluvia como por las nubes para dar lugar a la formación de ácido sulfúrico (H_2SO_4) y con esto a la lluvia ácida.
- PACF *Partial autocorrelation Function*:** Es llamada Función de autocorrelación parcial a la gráfica de los coeficientes de autocorrelación parcial. De modo que, en un modelo AR(p), las PACF's determinan el valor de p.
- Partes por millón (ppm):** Es la unidad utilizada para expresar las concentraciones de contaminantes en la atmósfera, la utilizada aquí, expresa específicamente los gaseosos. Esta unidad es especificada por el Sistema Americano de Ingeniería (A.E.I.) adoptado por los E.U.A., el cual es una modificación del Sistema Británico.
- Promedio móvil de n horas:** Promedio aritmético de n datos anteriores al actual. Es utilizado para determinar la norma de algunos contaminantes, por ejemplo para el SO_2 la norma es de 0.13 ppm promedio móvil de 24 horas.

Glosario

RAMA:	Red Automática de Monitoreo Atmosférico del D.D.F.
Residuales:	Es la diferencia entre el valor real y el valor generado por el modelo.
Ruido Blanco:	Variable aleatoria independiente idénticamente distribuida con una función de distribución normal con media cero y varianza constante.
Serie de tiempo:	Es la colección de observaciones generadas en forma secuencial a través del tiempo. Y es solo una realización de un proceso aleatorio.
XMSO2_96:	Base de datos creada en el paquete STATISTICA y que contiene los registros mensuales desde principios de 1988 a marzo de 1996, de las concentraciones atmosféricas de SO ₂ para las 5 "grandes" estaciones de monitoreo y para la ZMCM.
ZMCM:	Zona Metropolitana de la Ciudad de México. Esta zona esta compuesta por las 16 delegaciones del Distrito Federal y 17 municipios conurbados del Estado de México