

Original

Modelación de episodios críticos de contaminación por material particulado (PM10) en Santiago de Chile. Comparación de la eficiencia predictiva de los modelos paramétricos y no paramétricos

Sergio A. Alvarado^{a,b,c,d,*}, Claudio S. Silva^a y Dante D. Cáceres^{d,e}^a División de Bioestadística, Escuela de Salud Pública, Facultad de Medicina, Universidad de Chile, Santiago de Chile, Chile^b Facultad de Ciencias de la Salud, Universidad de Tarapacá, Arica, Chile^c Centro de Microdatos, Departamento de Economía, Facultad de Economía y Negocios, Universidad de Chile, Santiago de Chile, Chile^d Grups de Recerca d'Amèrica i Àfrica Llatines, Unitat de Bioestadística, Facultat de Medicina, Universitat Autònoma de Barcelona, Barcelona, España^e División de Epidemiología, Escuela de Salud Pública, Facultad de Medicina, Universidad de Chile, Santiago de Chile, Chile

INFORMACIÓN DEL ARTÍCULO

Historia del artículo:

Recibido el 10 de diciembre de 2009

Aceptado el 14 de julio de 2010

On-line el 20 de octubre de 2010

*Palabras clave:*Contaminación del aire
Concentraciones extremas
Modelos Gamma
Modelos MARS

RESUMEN

Objetivo: Evaluar la eficiencia predictiva de modelos estadísticos paramétricos y no paramétricos para predecir episodios críticos de contaminación por material particulado PM10 del día siguiente, que superen en Santiago de Chile la norma de calidad diaria. Una predicción adecuada de tales episodios permite a la autoridad decretar medidas restrictivas que aminoren la gravedad del episodio, y consecuentemente proteger la salud de la comunidad.

Método: Se trabajó con las concentraciones de material particulado PM10 registradas en una estación asociada a la red de monitorización de la calidad del aire MACAM-2, considerando 152 observaciones diarias de 14 variables, y con información meteorológica registrada durante los años 2001 a 2004. Se ajustaron modelos estadísticos paramétricos Gamma usando el paquete estadístico STATA v11, y no paramétricos usando una demo del software estadístico MARS v 2.0 distribuida por Salford-Systems.

Resultados: Ambos métodos de modelación presentan una alta correlación entre los valores observados y los predichos. Los modelos Gamma presentan mejores aciertos que MARS para las concentraciones de PM10 con valores $< 240 \mu\text{g}/\text{m}^3$ para el año 2001, y los modelos MARS presentan mejores aciertos para aquellas que exceden los $240 \mu\text{g}/\text{m}^3$ de PM10 para todos los años.

Conclusiones: Los modelos MARS son más eficientes para predecir episodios graves de alta contaminación por PM10 y posibilitan a la autoridad sanitaria adoptar restricciones preventivas que aminoren su efecto sobre la salud de la población. Esto se explicaría porque MARS corrige las variaciones de la serie a lo largo del tiempo, ajustando mejor la curva asociada a la concentración de PM10.

© 2009 SESPAS. Publicado por Elsevier España, S.L. Todos los derechos reservados.

Modeling critical episodes of air pollution by PM10 in Santiago, Chile. Comparison of the predictive efficiency of parametric and non-parametric statistical models

ABSTRACT

Objective: To evaluate the predictive efficiency of two statistical models (one parametric and the other non-parametric) to predict critical episodes of air pollution exceeding daily air quality standards in Santiago, Chile by using the next day PM10 maximum 24 h value. Accurate prediction of such episodes would allow restrictive measures to be applied by health authorities to reduce their seriousness and protect the community's health.

Methods: We used the PM10 concentrations registered by a station of the Air Quality Monitoring Network (152 daily observations of 14 variables) and meteorological information gathered from 2001 to 2004. To construct predictive models, we fitted a parametric Gamma model using STATA v11 software and a non-parametric MARS model by using a demo version of Salford-Systems.

Results: Both models showed a high correlation between observed and predicted values. However, the Gamma model predicted PM10 values below $240 \mu\text{g}/\text{m}^3$ more accurately than did MARS. The latter was more efficient in predicting PM10 values above $240 \mu\text{g}/\text{m}^3$ throughout the study period.

Conclusion: MARS models are more efficient in predicting extreme PM10 values and allow health authorities to adopt preventive methods to reduce the effects of these levels on the population's health. The reason for this greater accuracy may be that MARS models correct variations in the series over time, thus better fitting the curve associated with PM10 concentrations.

© 2009 SESPAS. Published by Elsevier España, S.L. All rights reserved.

*Keywords:*Air pollution
Extreme concentrations
Gamma models
MARS models

Introducción

Diversos estudios en todo el mundo han reportado los efectos de la contaminación del aire sobre la salud, especialmente la exposición a material particulado¹⁻⁶. En la actualidad, el foco de la

* Autor para correspondencia.

Correo electrónico: salvarado@med.uchile.cl (S.A. Alvarado).

investigación son los efectos agudos y a corto plazo, especialmente sobre la mortalidad y la morbilidad por causas cardiovasculares y respiratorias⁷⁻¹¹. Esto ha hecho que los países tomen una serie de medidas de gestión ambiental para controlar estas emisiones y, por otra parte, tratar de predecir tempranamente los episodios de alta contaminación del aire. Estas medidas han incluido un cambio sistemático a combustibles menos contaminantes, restricción diaria de la circulación a un determinado porcentaje de vehículos motorizados, cierre diario de algunas industrias, etc. Las causas que originan la contaminación son diversas, pero las actividades antropogénicas son las que más contribuyen al problema. Sin embargo, el grado de contaminación también está influenciado por otros factores, como el clima y la topografía. El clima influye de manera decisiva en la persistencia de los contaminantes atmosféricos; el viento, la temperatura y la radiación solar modifican de manera drástica la dispersión y el tipo de contaminantes que puede haber en un determinado momento; la topografía influye en el movimiento de las masas de aire y por lo tanto en la persistencia de la contaminación en una determinada zona geográfica. La combinación de todos estos factores determina finalmente la calidad del aire⁵.

La predicción de los episodios graves de contaminación del aire en las grandes ciudades se ha transformado en una herramienta de gestión ambiental orientada a proteger la salud de la población, que permite a la autoridad sanitaria conocer, con cierta certeza, el probable grado de contaminación atmosférica que habrá en un determinado lapso de tiempo. Esta predicción se ha abordado mediante diversos modelos, combinando aproximaciones determinísticas y probabilísticas e incorporando diversos tipos de información¹²⁻¹⁷. La metodología actual y oficial de la Región Metropolitana de Santiago de Chile respecto al pronóstico de las concentraciones de material particulado PM10 se realiza con el Modelo Cassmassi, propuesto en 1999 por Joseph Cassmassi¹⁸, que aplica una regresión lineal múltiple y pronostica el valor máximo de la concentración promedio de 24 h de PM10 para el período de las 00 h a las 24 h del día siguiente. Este modelo incluye variables meteorológicas observadas, índices de condiciones meteorológicas observadas y pronosticadas, concentraciones de contaminantes observadas, índices de variaciones esperadas de emisiones y otros.

Para las concentraciones de PM10 se han usado en Chile diferentes métodos estadísticos para modelar concentraciones de contaminantes del aire, incluyendo series de tiempo¹⁹, redes neuronales^{20,21} y modelos de regresión adaptativos basados en funciones de suavizamiento (*spline*) llamadas *Multivariate Adaptive Regression Splines* (MARS)²². La eficiencia predictiva de estos modelos es variable y está estrechamente asociada al comportamiento y la evolución de los determinantes ambientales. Los modelos que utilizan la teoría de los valores extremos están siendo ampliamente usados para este fin, en especial en aquellos episodios que ocurren en periodos cortos de tiempo y presentan valores extremos o excedencias de los valores límite de alerta o emergencia establecidos por la autoridad^{23,24}.

El objetivo de este trabajo es comparar la eficiencia predictiva de los modelos multivariados Gamma y MARS para pronosticar el máximo de concentración de PM10 del día siguiente en Santiago de Chile en el periodo comprendido entre el 1 de abril y el 31 de agosto de los años 2001, 2002, 2003 y 2004.

Métodos

Fuentes de información

Se utilizaron las bases de datos de PM10 de la estación de monitorización Pudahuel de la red MACAM2-RM, de los años

2001, 2002, 2003 y 2004. Para cada año estudiado se seleccionaron las mediciones entre el 1 de abril y el 31 de agosto, que corresponde a la época del año con menor ventilación en la cuenca de Santiago. Se trabajó con el promedio móvil de 24 h. En caso de faltar datos, éstos se imputaron por los generados mediante un suavizamiento doble exponencial con un valor de coeficiente de suavización $\alpha=0.70$ (Anexo 1). Se trabajó con esta estación porque la mayor parte del año presenta los mayores índices de concentración de PM10. Además, es la que tiene mayor influencia en la toma de decisiones administrativas respecto a pronósticos de episodios graves del día siguiente. Por otra parte, producto de las medidas de gestión ambiental implementadas en el momento de declarar episodios graves de contaminación por PM10, se afecta el comportamiento de la serie de tiempo, generando valores de concentraciones menores que no reflejan la concentración real observada, por lo que penalizamos este efecto mediante una constante de corrección. En la práctica, esta constante viene dada por $\Delta C_i = \text{media}[CPM_{24,i-1} - CPM_{24,i}]$, en donde $CPM_{24,i-1}$ y $CPM_{24,i}$ corresponden a los promedios de concentración de PM10 el día antes y el día de la intervención, respectivamente, para cada mes del año del periodo de estudio. La distribución del número de episodios observados que superan los $240 \mu\text{g}/\text{m}^3$ para los años 2001, 2002, 2003 y 2004 corresponde a 4 (2,6%), 11 (7,2%), 5 (3,3%) y 2 (1,3%), respectivamente²⁵.

Procedimientos

Se usaron 152 observaciones multidimensionales compuestas por una variable respuesta PM10 y 13 variables predictoras. La modelación contempla retrasos de 1 y 2 días respecto a las variables de interés del día de mañana (N+1), que corresponde al día a modelar. Las variables predictoras del día de hoy (retraso de 1 día) se definieron como: promedio horario de concentración PM10 a las 0:00 h del día N (pm0), promedio horario de concentración PM10 a las 6:00 h del día N (pm6), promedio horario de concentración PM10 a las 12:00 h del día N (pm12) y promedio horario de concentración PM10 a las 18:00 h del día N (pm18). Las variables predictoras que incorporan retrasos de 2 días (N-1) son: máximo de concentración del promedio móvil 24 h de PM10 entre las 19:00 h del día N-1 y las 18:00 h del día N (pm10 h), máxima temperatura entre las 19:00 h del día N-1 y las 18:00 h del día N (mth), mínima humedad relativa entre las 19:00 h del día N-1 y las 18:00 h del día N (mhrh), temperatura máxima menos mínima entre las 19:00 h del día N-1 y las 18:00 h del día N (dth), y promedio de la velocidad del viento entre las 19:00 h del día N-1 y las 18:00 h del día N (vvh). Las variables predictoras del día de mañana (N+1) corresponden a: máxima temperatura del día N+1 (mtm), mínima humedad relativa del día N+1 (mhrm), temperatura máxima menos mínima del día N+1 (dtm) y promedio de la velocidad del viento del día N+1 (vvm). La respuesta en estudio es el máximo de concentración del promedio móvil de 24 h de PM10 del día N+1 (pm10 m). Los valores de las variables del día de mañana son pronósticos validados y entregados por la Dirección Meteorológica de Chile usando un modelo Mesoscale Modeling System (MM5), un modelo numérico que utiliza las ecuaciones de la física de la atmósfera para la predicción meteorológica en áreas limitadas²⁶.

Las autoridades de la Comisión Nacional del Medio Ambiente (CONAMA) han definido cuatro grados de concentraciones de PM10 con el fin de tomar decisiones administrativas en el momento de producirse episodios graves: bueno, 0-193 $\mu\text{g}/\text{m}^3$; alerta, 194-239 $\mu\text{g}/\text{m}^3$; preemergencia, 240-329 $\mu\text{g}/\text{m}^3$; y emergencia, > 330 $\mu\text{g}/\text{m}^3$ ²². Para nuestro estudio dicotomizamos la respuesta en dos clases: 1) pm10 m < 240 $\mu\text{g}/\text{m}^3$ y 2) pm10 m > 240 $\mu\text{g}/\text{m}^3$; es decir, «bueno o alerta» frente a «preemergencia o emergencia». El objetivo de la dicotomización es poder generar

tabulaciones cruzadas entre los valores observados de la variable respuesta y las predicciones, para poder evaluar la proporción de aciertos a las dos clases por parte de los modelos propuestos.

Construcción de los modelos Gamma y MARS

El ajuste de los modelos de un determinado año se validó con la información del año inmediatamente posterior; con ello se garantiza la independencia de los datos usados para su validación respecto a los usados en su construcción. Por tal motivo no se entregan predicciones para el modelo del año construido con información del año 2004, pues no se posee información del año 2005. Cada modelo fue estimado con los datos del periodo comprendido entre el 1 de abril y el 31 de agosto de un año, y se aplicó a los datos del año siguiente, para el mismo periodo, evaluando el ajuste de esas estimaciones en contraste con las observaciones reales correspondientes al segundo año. Ambos modelos se describen con detalle en el Anexo 2.

Regresión Gamma

Los modelos Gamma se usan en situaciones en que la variable posee valores mayores o iguales a cero. Originalmente se utilizaron para datos continuos, pero en la actualidad la familia de modelos lineales generalizados Gamma se utiliza para datos de recuento²⁷. En general, estos modelos consideran distintas maneras de cómo trabajar la variable respuesta, por ejemplo la exponenciación de la respuesta usando la transformación log-gamma²⁸.

Regresión Adaptativa Multivariada (MARS)

MARS es una metodología propuesta por Friedman²⁹ en el año 1991, que intenta construir un modelo de regresión no lineal basado en un producto de funciones llamado «base de suavizamiento» (*spline*). Estas funciones incorporan en su estructura los predictores, que entran en la modelación como parte de una función y no directamente como en la regresión clásica, y producen un modelo para la respuesta en estudio, que puede ser de tipo continua o binaria, que automáticamente selecciona las variables predictoras que aparecen en la ecuación final, las que se incorporan en las funciones llamadas «base de suavizamiento»^{30,32}.

En nuestro estudio, con el objetivo de comparar los modelos se consideraron los siguientes estadísticos: a) correlación lineal de Pearson entre el valor observado y el predicho, y b) proporción de error medio absoluto (*mpab*) entre el valor observado (*obs*) y el valor predicho (*pred*), dado por $mpab = \sum_{i=1}^n \{|(PM10_{obs} - PM10_{pred})| / (PM10_{obs})\} / n$, que equivale a evaluar los errores promedio cometidos por ambos modelos en las predicciones. Además, se consideró la proporción de aciertos en cada clase.

Se construyeron dos modelos MARS por año, uno con 20 funciones base y otro con 40, con el fin de comparar los ajustes de los modelos y las regiones seleccionadas para la predicción de la variable respuesta, lo que permite elegir el modelo que mejor ajusta la respuesta esperada incorporando particiones en el dominio de las variables predictoras³². En el caso de la regresión Gamma se trabajó usando la función de enlace logaritmo, con tres conjuntos de variables predictoras: el primero corresponde a todas las variables, el segundo sólo a variables de ayer y hoy, y el tercero a las variables pm0, pm6, pm18, dtm, dth y vvm. Este último conjunto explicaría mejor el comportamiento de las concentraciones de la variable respuesta, tal como ya han descrito otros autores²⁰.

Resultados

La tabla 1 muestra los estadísticos descriptivos de las variables incorporadas a la modelación final de concentraciones de PM10. Se puede ver que los máximos para los años 2001, 2002 y 2003 exceden el valor de 240 $\mu\text{g}/\text{m}^3$; para el año 2004 no se aprecia tal comportamiento.

La tabla 2 muestra los aciertos a la clase I y II por parte de los modelos Gamma y los aciertos a ambas clases por los modelos MARS. Las correlaciones son significativas para los tres tipos de modelo por año, pero los *mpab* se mantienen altos para todos los modelos salvo el de 40 funciones base de MARS del año 2002, en el cual se aprecia un 19% de error medio absoluto, al igual que en el modelo Gamma. En general, para los 3 años los modelos Gamma presentan mejores aciertos que MARS para las concentraciones de PM10 con valores < 240 $\mu\text{g}/\text{m}^3$, y los modelos MARS presentan mejores aciertos para aquellas que exceden los 240 $\mu\text{g}/\text{m}^3$ de PM10.

La figura 1 muestra que las predicciones del modelo Gamma para altas concentraciones de PM10 se aleja más que lo predicho

Tabla 1
Medidas de posición y dispersión variables utilizadas en modelación de PM10

	2001			2002		
	Promedio (DE)	Mínimo	Máximo	Promedio (DE)	Mínimo	Máximo
pm10m	122,83 (58,4)	18,50	307,80	123,90 (67,2)	10,40	298,00
pm0	123,85 (106)	1,00	492,00	133,00 (126,6)	1,00	625,00
pm6	78,06 (57,9)	1,00	250,00	80,10 (56,9)	1,00	222,00
pm18	117,50 (83,5)	2,00	467,00	116,70 (83,6)	4,00	412,00
dtm	10,37 (5,3)	2,50	23,00	11,00 (5,1)	0,00	24,00
vvm	1,54 (0,48)	0,53	3,40	1,40 (0,4)	0,00	2,49
	2003			2004		
	Promedio (DE)	Mínimo	Máximo	Promedio (DE)	Mínimo	Máximo
pm10m	127,50 (50,50)	28,38	260,30	101,00 (43,10)	20,60	230,00
pm0	133,60 (101,40)	1,00	450,00	105,50 (88,30)	1,00	519,00
pm6	86,50 (55,20)	1,00	263,00	68,60 (42,30)	1,00	202,00
pm18	116,10 (72,10)	6,00	385,00	91,40 (59,20)	1,00	345,00
dtm	11,90 (5,03)	2,11	22,90	11,20 (5,02)	1,53	24,00
vvm	1,42 (0,40)	0,56	2,72	Sin datos	Sin datos	Sin datos

DE: desviación estándar; dtm: diferencia de temperatura del día de mañana; pm0, 6, 18: concentración de material particulado PM10 de la hora 0 del día anterior, de la hora 6 del día anterior y de la hora 18 del día anterior, respectivamente; pm10m: máximo de concentración de PM10 del día de mañana; vvm: velocidad del viento del día de mañana.

Tabla 2
Resultados de modelación MARS y Gamma

	2001 a 2002			2002 a 2003			2003 a 2004		
	Gamma	MARS 20 fb	MARS 40 fb	Gamma	MARS 20 fb	MARS 40 fb	Gamma	MARS 20 fb	MARS 40 fb
mpab (%)	38,00	39,00	32,00	19,00	29,00	19,00	28,00	25,00	25,00
Γ_{pearson}	0,83	0,88	0,74	0,82	0,81	0,86	0,78	0,82	0,82
Clase I (%)	98,00	67,00	44,40	99,00	0,00	100,00	99,00	100,00	99,00
Clase II (%)	50,00	99,30	95,40	12,50	98,00	97,00	0,00	0,00	0,00

fb: funciones base; mpab: proporción de error medio absoluto.

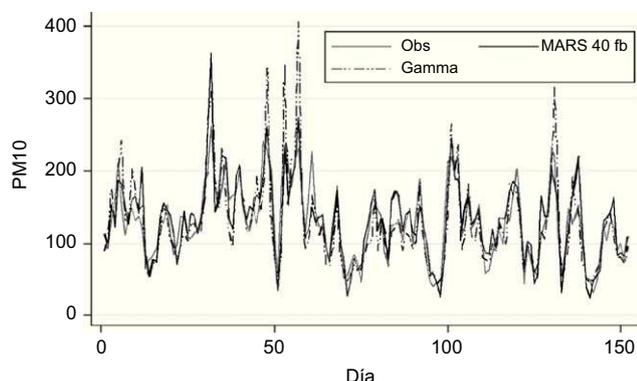


Figura 1. Valor observado de PM10 del año 2003 en la serie de tiempo de material particulado y ajustes del modelo del año 2002.

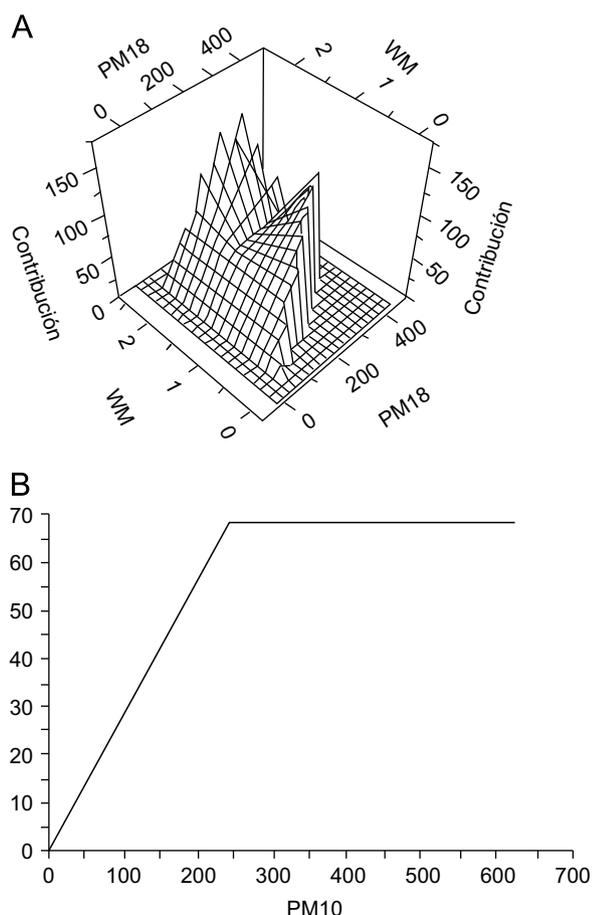


Figura 2. Superficies de interacción de funciones base de predictores seleccionados por MARS en el modelo de 40 funciones base del año 2002-2003 en (A) interacción entre pm18 y vvm (función base BF8) y (B) función base BF4.

por MARS, pero para valores $< 200 \mu\text{g}/\text{m}^3$ el modelo Gamma proporciona mejores predicciones.

La figura 2, del modelo MARS de 40 funciones base del año 2002, muestra las relaciones de las interacciones de la función base $\max(0; \text{pm}18-137)$ y $\max(0; \text{vvm}-1,522)$ que generan la función base BF8, la cual representa una superficie de interacción (tabla 3) cuyo máximo alcanza $165 \mu\text{g}/\text{m}^3$. Esto indica que con valores superiores a $137 \mu\text{g}/\text{m}^3$ en las concentraciones de PM10 a las 18:00 h (pm18) y $> 1,522 \text{ m/s}$ en la velocidad del viento del día de mañana, el aporte a la concentración de PM10 del día de mañana por parte de la interacción se hace máximo en $165 \mu\text{g}/\text{m}^3$. Por su parte, también se observa que en la variable pm0 con concentraciones por encima de $240 \mu\text{g}/\text{m}^3$ el aporte máximo a la respuesta es de aproximadamente $70 \mu\text{g}/\text{m}^3$, lo cual representa el valor con el cual la función base BF4 contribuiría a la respuesta.

La tabla 3 muestra los modelos explícitos para los modelos MARS de 20 y 40 funciones base y los modelos Gamma para los años 2001, 2002 y 2003. La complejidad del modelo se aprecia en el número de funciones base incorporadas al modelo explícito; en este caso, el modelo del año 2002 posee nueve funciones base, de las cuales cinco corresponden a interacciones de funciones base univariadas, las funciones BF8 y BF9 corresponden a las interacciones de las funciones espejo respecto a la variable vvm y la correspondiente función base asociada a la variable pm18.

Discusión

La modelación MARS selecciona aquellas variables predictoras significativas y detecta posibles interacciones de ellas, generando modelos más flexibles desde el punto de vista de la interpretación. Ya que las interacciones siempre están restringidas a alguna subregión, éstas quedan expresadas algebraicamente mediante las funciones base, logrando de esta forma establecer un modelo parsimonioso que representa sin ningún tipo de transformación adicional la naturaleza propia de las variables que se están trabajando. Crea nodos o puntos de corte que actúan como valores umbral para cada variable predictor seleccionada, indicando el cambio que se genera en la contribución por parte de la función base a la respuesta en estudio.

Una vez seleccionado el modelo óptimo, MARS ajusta nuevamente el modelo para cada variable, de modo de determinar el impacto en la calidad del modelo al eliminar dicha variable; así se asigna un ranking relativo desde la variable más importante a la menos importante. De esta manera se definen variables de reemplazo o competidoras, con lo cual la metodología MARS permite tratar los valores perdidos o faltantes generando una función base exclusiva para aquellas variables que no poseen información, es decir, se genera una función base de imputación cuya finalidad es imputar el valor promedio de la variable predictor sin información.

Tal y como se ha podido determinar en el presente estudio, los modelos MARS resultaron similares en su eficiencia predictiva al cambiar el número de funciones base, independientemente del

Tabla 3
Modelos explícitos para MARS de 20 y 40 funciones base y Gamma para los años 2001, 2002 y 2003

Modelo año 2001		
MARS		
20 funciones base	BF1 = max(0; pm18 - 180) BF2 = max(0; 180 - pm18) BF3 = max(0; pm6 - 13) BF5 = max(0; dtm - 2,55)	BF7 = max(0; 1,307 - vvm) BF8 = max(0; vvm - 1,651)*BF1 BF10 = max(0; pm0 - 241)
pm10m = 113,337 + 0,232*BF1 - 0,493*BF2 + 0,244*BF3 + 2,374*BF5 + 152,930*BF7 + 1,860*BF8 - 0,007*BF15 + 2,594*BF19 + 0,001*BF20		
Gamma	pm10m = exp(4,15 + 0,00076*pm0 + 0,00223*pm6 + 0,00292*pm18 + 0,02504*dtm - 0,20295*vvm)	
Modelo año 2002		
MARS		
40 funciones base	BF1 = max(0; pm18 - 137) BF2 = max(0; 137 - pm18) BF4 = max(0; 240 - pm0) BF5 = max(0; dtm + 0,00000512)	BF7 = max(0; 1,307 - vvm)*BF5 BF8 = max(0; vvm - 1,522)*BF1 BF9 = max(0; 1,522 - vvm)*BF1 BF12 = max(0; vvm - 0,998)*BF5 BF24 = max(0; vvm - 0,867)*BF5
pm10m = 146,343 - 0,553*BF2 - 0,286*BF4 + 7,072*BF7 + 2,093*BF8 + 0,537*BF9 - 22,888*BF12 + 21,844*BF24		
Gamma	pm10m = exp(3,818 + 0,00118*pm0 + 0,002267*pm6 + 0,00298*pm18 + 0,035488*dtm - 0,149482*vvm)	
Modelo año 2003		
MARS		
20 funciones base	BF1 = max(0; pm18 - 71) BF2 = max(0; 71 - pm18) BF4 = max(0; 12 - pm6) BF6 = max(0; pm0 - 1,0)	BF10 = max(0; 30 - pm6)*BF6 BF11 = max(0; dtm - 2,108)*BF4 BF18 = max(0; dtm - 7,325)
pm10m = 75,758 + 0,378*BF1 - 0,712*BF2 + 0,172*BF6 - 0,019*BF10 + 0,488*BF11 + 2,815*BF18		
Gamma	pm10m = exp(3,885 + 0,00108*pm0 + 0,00107*pm6 + 0,0030047*pm18 + 0,02658*dtm)	

BF: funciones base; dtm: diferencia de temperatura del día de mañana; pm0, 6, 18: concentración de material particulado PM10 de la hora 0 del día anterior, de la hora 6 del día anterior y de la hora 18 del día anterior, respectivamente; pm10m: máximo de concentración de PM10 del día de mañana; vvm: velocidad del viento del día de mañana.

año para el cual se construyó el modelo y del año con que se validó. Partir el espacio asociado al rango de las variables predictoras no mejoró la calidad de las predicciones, y en ocasiones se vio que con una partición menos fina (menos subregiones) la metodología era más robusta que con una partición más fina. Esto podría explicarse por el hecho de que con el tiempo las series de PM10 muestran una tendencia descendente y variaciones en las concentraciones más bajas, por las medidas de intervención aplicadas³³.

En el caso de la estación de monitorización Pudahuel, ésta presentó cambios en las concentraciones anuales y mensuales de material particulado PM10 entre los años 1998 y 2004, básicamente debidos a la implementación de medidas de descontaminación global y de medidas extraordinarias los días de episodios graves, al uso del modelo de pronóstico de episodios graves y a los factores meteorológicos. Tales cambios influyen en el funcionamiento de los modelos y hacen que éstos no sean tan complejos en su estructura, puesto que la relación que se establece entre las variables predictoras no es tan complicada y ello se refleja en las funciones base construidas. A su vez, se observan diferencias de un año a otro, lo que podría estar influenciado por las condiciones meteorológicas particulares de cada año (año seco, fenómeno del niño u otros cambios climáticos). Otro factor a evaluar y que podría ser relevante es el aumento del parque automotriz en los últimos años.

Adicionalmente se han implementado diferentes métodos para modelar la concentración de material particulado en la región metropolitana de Santiago de Chile. Por ejemplo, Silva et al¹⁹, aplicando series de tiempo utilizando funciones de transferencia involucrando variables meteorológicas, describieron un 40% de

proporción media de error absoluto en la predicción de los episodios críticos. Por otra parte, Pérez et al²¹, usando redes neuronales con suavizamiento previo, hallaron aproximadamente un 30% de error medio absoluto en la predicción de los episodios graves²¹. Otros trabajos del mismo autor usando redes neuronales muestran mejores resultados que con una regresión lineal clásica²⁰. Por otra parte, Silva et al²² evaluaron dos aproximaciones metodológicas al problema de la predicción de la contaminación del aire por material particulado, y observaron que MARS proporcionó mejores predicciones que el análisis discriminante.

En el caso de las aplicaciones de los modelos a la estación de monitorización Pudahuel, las variables predictoras que mejor explican la respuesta serían las concentraciones concretas de PM10 (pm0, pm6 y pm18) y las variables meteorológicas (dtm y vvm), lo cual concuerda en el sentido de que MARS selecciona adecuadamente variables relacionadas con la persistencia de las condiciones de ventilación, las que tienen relación con la meteorología²².

Los métodos de predicción aplicados nos proporcionan modelos adecuados para estudiar la contaminación por material particulado. En general, la regresión Gamma fue inferior que MARS en cuanto a aciertos de la clase II, salvo en el modelo del año 2003 que predice para el año 2004, en el cual los aciertos en la clase II no fueron efectivos, por lo que MARS se presenta como una mejor herramienta de predicción de episodios de contaminación por encima de 240 µg/m³. Por otra parte, una ventaja del modelo Gamma es que en general hace mejores predicciones para la clase I (concentraciones de PM10 < 240 µg/m³); es decir, es sensible a valores de concentraciones de material particulado que

decretan calidad del aire buena o alerta, y ello vendría dado por el comportamiento de la variable de interés. Por ejemplo, para el año 2001, el producto de las medidas de intervención hace que la modelación Gamma ajuste mejor en ese año, ya que para años posteriores estas medidas han tenido un impacto moderado en los valores de la serie de PM10, haciendo menos eficientes estos modelos frente a los MARS, como acontece para los años 2002, 2003 y 2004.

Este trabajo básicamente apunta a que las modelaciones propuestas permitan detectar concentraciones por encima del valor umbral de $240 \mu\text{g}/\text{m}^3$, que es el que decreta la alerta epidemiológica en Santiago de Chile. Esta consideración haría de la modelación MARS una herramienta de mayor poder estadístico en comparación con un modelo de tipo Gamma. Este último punto concuerda con los resultados de otros autores, que muestran que MARS es más eficiente que otras técnicas^{22,34,35}. Esto podría explicarse por la aproximación de suavizamiento que usa esta metodología, que genera quiebres en la serie de tiempo de los predictores y ajusta localmente las funciones base en función de dichos quiebres o nodos.

Financiación

NIH/Fogarty Grant #D43TW 05746-02.

Contribuciones de autoría

S.A. Alvarado concibió el estudio y obtuvo la financiación, desarrolló los análisis estadísticos, redactó los apartados de métodos, resultados y discusión, y elaboró las gráficas. C.S. Silva preparó los datos primarios y los llevó al formato a usar para la modelación, redactó la parte de métodos junto al primer autor y ayudó en la redacción de la discusión. D.D. Cáceres escribió la introducción, revisó y colaboró en los análisis estadísticos y la edición de las tablas, y ayudó en la redacción de la discusión. S.A. Alvarado es el responsable del artículo.

Conflicto de intereses

Los autores declaran no tener ningún conflicto de intereses.

Agradecimientos

Los autores agradecen al Dr. Kyle Steeland, de la Emory University, sus comentarios al trabajo.

Anexo 1. Suavizamiento exponencial

Esta técnica usa una constante de suavizamiento: si la constante es cercana a 1 equivale a que dicha constante afecta mucho más al nuevo pronóstico, y al contrario, cuando dicha constante es cercana a 0 el nuevo pronóstico será muy parecido a la observación más antigua. Si se desea una respuesta rápida a los cambios de la variable se debe elegir una constante de suavizamiento mayor. La fórmula que relaciona el coeficiente y la serie de tiempo viene dada por $S_t^{[2]} = \alpha S_t + (1-\alpha)S_{t-1}^{[2]}$, donde $S_t = \alpha x_t + (1-\alpha)S_{t-1}$. Para generar dicho suavizamiento es necesario conocer los valores S_0 y S_t , y x_t corresponde a los valores de la serie original^{31,36}.

Anexo 2. Construcción de los modelos

Modelo Gamma

La función de densidad de probabilidad para la función gamma generalizada viene dada por $f(y; \kappa, \mu, \sigma) = (\gamma^\gamma / (\sigma \gamma \sqrt{\gamma} \Gamma(\gamma))) e^{(z\sqrt{\gamma}-u)}$; $y \geq 0$, en donde $\gamma = |\kappa|^{-2}$, $z = \text{sign}(\kappa) \times \{(\ln(y)-\mu)/\sigma\}$ y $u = \gamma \exp(|\kappa|z)$. El parámetro μ es igual a $x^t \beta$, donde x es la matriz de predictores que incluye al intercepto y β es el vector de coeficientes. Para la distribución generalizada Gamma, el valor esperado condicional en x viene dado por: $E(y/x) = \exp[x\hat{\beta} + (\hat{\sigma}/\hat{\kappa})\ln(\hat{\kappa}^2) + \ln(\Gamma\{(1/\hat{\kappa}^2) + (\hat{\sigma}/\hat{\kappa})\}) - \ln(\Gamma(1/\hat{\kappa}^2))]$, donde $\hat{\sigma}$ tiene la siguiente expresión $\hat{\sigma} = (1/n) \sum_i \exp(\alpha_0 + \alpha_1 \ln(f(x_i)))$, si $\ln(\sigma)$ es parametrizado como $\alpha_0 + \alpha_1 \ln(f(x))$.

Puesto que se requiere expresar las estimaciones y los resultados en la escala original de medición, se trabaja con la exponenciación del modelo usando la transformación log-gamma $\mu = E(Y) = \exp(x^t \beta)$, y así aseguramos que la transformación no afecte a las interpretaciones en lo que se refiere directamente a la escala de medida original²⁸.

Modelo MARS

1) Modelo para un predictor

La metodología MARS propuesta por Friedman²⁹ selecciona K nodos de la variable predictora x , denotados por t_k , $k = 1, \dots, K$, los cuales podrían corresponder a cada una de las observaciones de la variable, y luego se definen $K+1$ regiones sobre el rango de x , en donde se asocia a cada nodo la función de suavizamiento lineal, generando una familia de funciones base de la forma:

$$B_K^{(q)}(x) = \begin{cases} x^j & j = 0, \dots, q \\ (x-t_k)_+^q & k = 1, \dots, K \end{cases}$$

en donde $(x-t_k)_+^q$ se conoce como función de truncamiento. Para la aproximación de orden q se estima la función $\hat{f}_q(x) = \sum_{k=0}^{K+q} a_k B_k^{(q)}(x)$; generalmente, el orden de suavizamiento que se tome debe ser ≤ 3 , para que la función y sus $q-1$ derivadas sean continuas. Esta restricción y el uso de polinomios en cada subregión producen funciones suavizadas y ajustadas.

2) Generalización con p predictores

Para el vector de predictores $x = (x_1, x_2, \dots, x_p)$, la función de suavizamiento se define de forma análoga al caso univariado. En este caso, el espacio R^p se divide en un conjunto de regiones disjuntas y dentro de cada región se ajusta un polinomio de p variables.

Para $p > 2$ se consideran regiones disjuntas que definen la aproximación de suavizamiento como productos tensores de intervalos disjuntos en cada una de las variables delineadas por la ubicación del nodo. Así, ubicando K_j nodos en cada variable produce un producto de K_j+1 regiones, $j = 1, \dots, p$.

Un conjunto de funciones base que generan el espacio de las funciones de suavizamiento sobre todo el conjunto de regiones es el producto tensorial de las correspondientes basales de suavizamiento unidimensionales asociadas con la ubicación de los nodos en cada variable dada por:

$$\hat{f}_q(x) = \sum_{k_1=0}^{K_1+q} \dots \sum_{k_p=0}^{K_p+q} a_{k_1, \dots, k_p} \prod_{j=1}^p B_{k_j}^{(q)}(x_j)$$

La selección de las funciones base consiste en elegir un buen conjunto de regiones para definir la aproximación de suavizamiento adecuada al problema; MARS genera funciones base mediante un

proceso de tipo paso a paso. Se inicia con una constante en el modelo y luego comienza la búsqueda de una combinación variable-nodo que mejora el modelo. La mejora se mide en parte por el cambio en la suma de errores cuadráticos (MSE). Se agregan sucesivamente funciones base para reducir el MSE.

Con objeto de evaluar este modelo, Friedman propone usar el estadístico *Generalized Cross Validation*,

$$GCV = \frac{\sum_{i=1}^N (y_i - \hat{f}_q(x_i))^2}{N} \bigg/ \left(1 - \frac{C(M)}{N}\right)^2,$$

con $C(M) = 1 + \text{traza}(B(B^T B)^{-1} B^T)$, donde B es la matriz de diseño, el numerador es la falta de ajuste sobre los datos de entrenamiento y el denominador es un término penalizado que refleja la complejidad del modelo.

Bibliografía

- Desqueyroux H, Momas I. Air pollution and health: a synthesis of longitudinal panel studies published from 1987 to 1998. *Rev Epidemiol Sante Publique*. 1999;47:361–75.
- Dockery DW, Schwartz J, Spengler JD. Air pollution and daily mortality: associations with particulates and acid aerosols. *Environ Res*. 1992;59:362–73.
- Roemer W, Hoek G, Brunekreef B, et al. PM10 elemental composition and acute respiratory health effects in European children (PEACE project). *Pollution Effects on Asthmatic Children in Europe*. *Eur Respir J*. 2000;15:553–9.
- Rosales-Castillo JA, Torres-Meza VM, Olaiz-Fernández G, et al. Acute effects of air pollution on health: evidence from epidemiological studies. *Salud Publica Mex*. 2001;43:544–55.
- Sanhueza P, Vargas C, Jiménez J. Daily mortality in Santiago and its relationship with air pollution. *Rev Med Chil*. 1999;127:235–42.
- Wordley J, Walters S, Ayres JG. Short term variations in hospital admissions and mortality and particulate air pollution. *Occup Environ Med*. 1997;54:108–16.
- Janke K, Propper C, Henderson J. Do current levels of air pollution kill? The impact of air pollution on population mortality in England. *Health Econ*. 2009;18:1031–55.
- Biggeri A, Bellini P, Terracini B. Meta-analysis of the Italian studies on short-term effects of air pollution – MISA 1996–2002. *Epidemiol Prev*. 2004;28(Suppl):4–100.
- Sánchez-Carrillo CI, Cerón-Mireles P, Rojas-Martínez MR, et al. Surveillance of acute health effects of air pollution in Mexico City. *Epidemiology*. 2003;14:536–44.
- Staniswalis JG, Yang H, Li WW, et al. Using a continuous time lag to determine the associations between ambient PM2.5 hourly levels and daily mortality. *J Air Waste Manag Assoc*. 2009;59:1173–85.
- Pascal L. Short-term health effects of air pollution on mortality. *Rev Mal Respir*. 2009;26:207–19.
- Gokhale S, Khare M. A theoretical framework for episodic-urban air quality management plan (e-UAQMP). *Atmospheric Environment*. 2007;41:7887–94.
- Kurt A, Gulbagci B, Karaca F, et al. An online air pollution forecasting system using neural networks. *Environ Int*. 2008;34:592–8.
- McKendry IG. Evaluation of artificial neural networks for fine particulate pollution (PM10 and PM2.5) forecasting. *J Air Waste Manag Assoc*. 2002;52:1096–101.
- Meenakshi P, Saseetharan MK. Urban air pollution forecasting with respect to SPM using time series neural networks modelling approach—a case study in Coimbatore City. *J Environ Sci Eng*. 2004;46:92–101.
- Scott GM, Diab RD. Forecasting air pollution potential: a synoptic climatological approach. *J Air Waste Manag Assoc*. 2000;50:1831–42.
- Tobias A, Scotto MG. Prediction of extreme ozone levels in Barcelona, Spain. *Environ Monit Assess*. 2005;100:23–32.
- Morales R. Contaminación atmosférica urbana. Episodios críticos de contaminación ambiental en la ciudad de Santiago. Editorial Universitaria; 2006.
- Silva C, Firinguetti L, Trier A. Contaminación ambiental por partículas en suspensión: modelamiento estadístico. *Actas XXI Jornadas Nacionales de Estadística*. Concepción; 1994.
- Pérez P, Reyes J. Prediction of maximum of 24-h average of PM10 concentrations 30 h in advance in Santiago, Chile. *Atmospheric Environment*. 2002;36:4555–61.
- Pérez P, Trier A, Silva C, et al. Prediction of atmospheric pollution by particulate matter using a neural network. *Conf. on Neural Inf. Proc*. Dunedin, New Zealand: Springer-Verlag; 1998.
- Silva C, Pérez P, Trier A. Statistical modelling and prediction of atmospheric pollution by particulate material: two nonparametric approaches. *Environmetrics*. 2001;12:147–59.
- Sharma P, Khare M, Chakrabarti SP. Application of extreme value theory for predicting violations of air quality standards for an urban road intersection. *Transportation Research*. 1999(Part D4):201–16.
- Thompson M, Reynolds R, Cox L, et al. A review of statistical methods for the meteorological adjustment of tropospheric ozone. *Atmospheric Environment*. 2001;35:617–30.
- SEREMI. Estadísticas de episodios críticos. En: Ministerial SR, editor. *Información Ambiental*, vol. 2010. Región Metropolitana: Gobierno de Chile; 2008.
- MM5. MM5 Community Model. Vol. 2010. Pennsylvania State University/National Center for Atmospheric Research Numerical Model 2008.
- Hardin J, Hilbe J. *Generalized linear models and extensions*. USA: College Station Texas; 2001.
- McCullagh P, Nelder J. *Generalized linear models*. London, UK: Chapman Hall; 1989.
- Friedman J. Multivariate adaptive regression splines. *The Annals of Statistics*. 1991;19:1–141.
- Lewis PAW, Stevens JG. Nonlinear modeling of time series using multivariate adaptive regression splines (MARS). *J Am Statist Assoc*. 1991;86:416.
- Montgomery DC, Johnson LA, Gardiner JS. *Forecasting and time series analysis*. New York: McGraw-Hill; 1990.
- MARS. User guide. Salfords-Systems 2001. *Multivariate Adaptive Regression Splines* Vol. 2010; 2001.
- CONAMA. Evolución de la calidad del aire en Santiago, 1997 a 2004. *Comisión Nacional del Medio Ambiente*. Vol. 2010; 2006.
- De Veaux R, Psychogios D, Ungar L. A comparison of two nonparametric estimation schemes: MARS and neural networks. *Computers Chemical Engineering*. 1993;17:819–37.
- Steinberg D. An alternative to neural nets: multivariate adaptive regression splines (MARS). *PC AI's*. 2001;15:38.
- Stata Corp. *Stata: Release 11. Statistical Software*. College Station (TX): StataCorp LP; 2009.