

## Caracterización espacial de PM10 en la ciudad de Medellín mediante modelos geoestadísticos

Libardo Antonio  
Londoño Ciro  
Grupo GALA,  
Universidad de  
Antioquia, Medellín.  
libaranto@gmail.com

Julio Eduardo  
Cañón Barriga  
Grupo GALA,  
Universidad de  
Antioquia, Medellín.  
jecanon@udea.edu.co

Rubén Darío Villada  
Flórez  
Universidad de San  
Buenaventura seccional  
Medellín  
rdvillad@gmail.com

Lina Yohana López  
Ceballos  
Universidad de San  
Buenaventura seccional  
Medellín  
Yoha2785@gmail.com

(Tipo de Artículo: Investigación. Recibido el 20/04/2015. Aprobado el 27/07/2015)

**Resumen.** En este artículo se presenta un modelo geoestadístico para caracterizar espacialmente el comportamiento del contaminante PM10 en la ciudad de Medellín Colombia. Los datos se han tomado de nueve sitios de monitoreo en valor promedio mensual ( $\mu\text{g}/\text{m}^3$ ) durante el periodo enero 2003 a diciembre 2007. Se evaluaron diferentes modelos mediante pruebas de validación cruzada. El mejor modelo es el j-bessel. Se calculan los parámetros del modelo mediante pruebas ANOVA para agrupaciones trimestrales. Con Kriging ordinario y sistemas de información geográfica, se obtienen mapas de caracterización espacial del contaminante.

**Palabras clave.** Calidad del aire, material particulado, geoestadística

## Spatial characterization of pm10 in Medellín Colombia by geostatistical models

**Abstract.** In this article a geostatistical model is presented in order to spatially characterize the PM10 pollutant behavior in the city of Medellín, Colombia. The data has been taken from nine monitoring locations in monthly average value ( $\mu\text{g}/\text{m}^3$ ) for the period from January 2003 to December 2007. Different models were evaluated by cross-validation tests. The best model is a j-bessel. The model parameters are calculated using ANOVA tests for quarterly groupings. Maps of the pollutant's spatial characterization are obtained with ordinary Kriging and GIS.

**Keywords.** Air quality, particulate matter, geostatistics.

### 1. INTRODUCCIÓN

Los contaminantes atmosféricos tienen un efecto significativo sobre la salud de las personas en los centros urbanos [1] [2]. Recientemente se ha desarrollado una serie de investigaciones que usan las capacidades de visualización y análisis espacial de los Sistemas de Información Geográfica (SIG) para abordar problemas que van desde la interpolación espacial para la imputación de datos de concentración de contaminantes atmosféricos [3], hasta la representación de los patrones espaciales de los contaminantes del aire mediante funciones de análisis espacial [4] [5] [6] [7] [8].

En el caso del material particulado no se registran muchos estudios en comparación con otros contaminantes [3]. La concentración del material particulado está afectada por múltiples factores pero principalmente por los tipos de fuentes de emisión, las condiciones climáticas y topográficas, la densidad de

tráfico, la densidad poblacional y los usos del suelo [9] [10] [11][12].

Este artículo centra su atención en el material particulado de 10 micras de diámetro (PM10). El modelamiento de la concentración de PM10 reportado en diversos estudios se ha enfocado desde distintas perspectivas: análisis estadístico [13] [14], algoritmos de redes neuronales [15], de regresión adaptativos basados en funciones de suavizamiento (spline) [16], modelos gaussianos [17], modelos de usos del suelo (LUR) [18] y la geoestadística [3] [19].

En el presente artículo se usa la geoestadística para caracterizar espacialmente datos de concentración de PM10 en la ciudad de Medellín – Colombia durante el periodo enero de 2003 a diciembre de 2007. La geoestadística es muy eficiente, sin embargo, su uso está condicionado por la distribución estadística de los datos ya que éstos deben cumplir con el principio de estacionariedad, es decir, deben estar

normalmente distribuidos [20]. Adicionalmente se debe contar como mínimo con datos en 30 sitios de monitoreo [21].

Se cuenta con datos de concentración promedia mensual de PM10 en  $\mu\text{g}/\text{m}^3$  obtenida en mediciones realizadas en nueve sitios de monitoreo. Con estos datos se usa un algoritmo spline para densificar la muestra y obtener 50 datos por mes. Luego se hace un análisis estadístico exploratorio para validar el cumplimiento del principio de estacionariedad. Se hace un análisis estructural de los datos (variografía) mediante el estudio de nueve modelos teóricos de semivariograma (*spheric, gaussian, tetraspheric, pentaspheric, rational cuadratic, hole effect, j-bessel y k-bessel*) y luego se aplica el algoritmo del kriging ordinario.

Para determinar el modelo que mejor representa en cada mes el cambio de la varianza con la distancia, se realizan pruebas de validación cruzada usando la técnica "leave one out" [22] y se calculan los estadísticos de error ASE (*average standard error*), RMS (*root mean square-error*) y RMSS (*root mean square-error standardized*). Para cada mejor modelo se determinan sus parámetros: meseta (*partial sill*) en  $(\mu\text{g}/\text{m}^3)^2$ , alcance (*major range*) en km y discontinuidad al origen (*nugget*) en  $(\mu\text{g}/\text{m}^3)^2$ .

Se hace un análisis de frecuencias con los modelos obtenidos en los 60 meses y se encuentra que el modelo más frecuente (modal) es el *j-bessel* (24 de 60 meses). Un análisis comparativo de los estadísticos de error de éste con respecto a los demás modelos, permite inferir que el *j-bessel* muestra buenos niveles de confiabilidad (> 80%) en los 36 meses restantes.

Finalmente se usan pruebas ANOVA para el análisis de los parámetros del modelo *j-bessel* agrupados trimestralmente, y se determinan los valores de parámetros que caracterizan espacialmente la concentración de PM10.

## 2. ÁREA DE ESTUDIO

Como caso de estudio se toma el área metropolitana del Valle de Aburra. La región se ubica en la parte sur-central del departamento de Antioquia, Colombia, ubicado entre los  $6.0^\circ - 6.5^\circ$  de Latitud y  $75.5^\circ$  de longitud (ver fig. 1). Tiene una superficie aproximada de  $1.152 \text{ km}^2$  con 60 km de largo y entre 10 y 20 km de ancho en su centro.

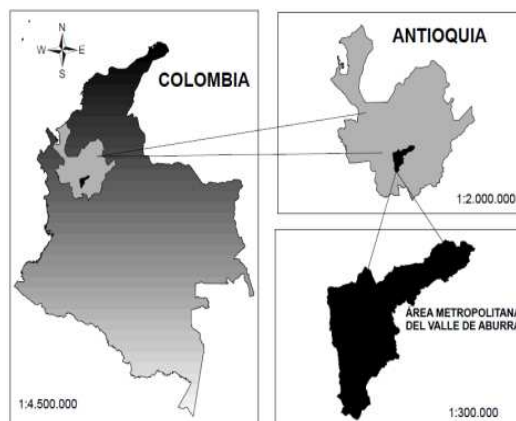


Fig. 1. Ubicación del área de estudio.

Se dispone de la concentración promedia mensual de PM10 en  $\mu\text{g}/\text{m}^3$  obtenida en mediciones realizadas en nueve sitios de monitoreo (ver tabla 1 y fig. 2) de la red de calidad del aire de la ciudad de Medellín (*RedAire*) entre enero de 2003 y diciembre de 2007 (*Geographic Coordinate System: GCS MAGNA. Projected Coordinate System: MAGNA Colombia Bogota, Projection Transverse Mercator*).

TABLA 1  
Sitios de monitoreo

Municipio	ID	Longitud	Latitud
Bello	0	836453,7118	1192238,514
Medellín	1	834627,2956	1183784,652
Itagüí	2	832448,9433	1176904,404
Envigado	3	835867,6199	1174759,704
Medellín	4	833574,6822	1178899,767
Medellín	5	834659,7652	1185469,715
Medellín	6	829832,1868	1181272,411
Medellín	7	831941,9630	1186047,249
Medellín	8	832459,7349	1182607,152




Fig. 2. Ubicación sitios de monitoreo

### 3. METODOLOGÍA

La metodología está implementada en las herramientas *Spatial Analyst*® y *Geostatistical Analyst*® del aplicativo *ArcMap*® de ESRI. Para poder aplicar las técnicas geoestadísticas se requieren por lo menos 30 datos, en consecuencia se densifica el muestreo utilizando un interpolador spline. El error de los datos interpolados es de 12,91 calculado a partir de la raíz del error cuadrático promedio (*RMS-root mean square-error*) [22] [23]. Se extrae la información del valor interpolado de PM10 en 41 sitios que corresponden con intersecciones entre vías principales (ver fig. 3).




Fig. 3. Ubicación sitios aleatorios.

Con el procedimiento anterior se dispone de 50 datos por mes. Con este conjunto de datos se hace un análisis exploratorio para validar el cumplimiento del principio de estacionariedad en cada mes. El proceso se muestra en la parte derecha de la fig. 4 [24].

Para los conjuntos de datos en donde el valor absoluto de coeficiente de sesgo (*skewness*) es mayor o igual a 0.5 se realizan transformaciones según los siguientes criterios [20]:

- Si  $0.5 < |CS| \leq 1$ , entonces se aplica una transformación raíz cuadrada.
- Si  $|CS| > 1$ , entonces se aplica una transformación logarítmica.

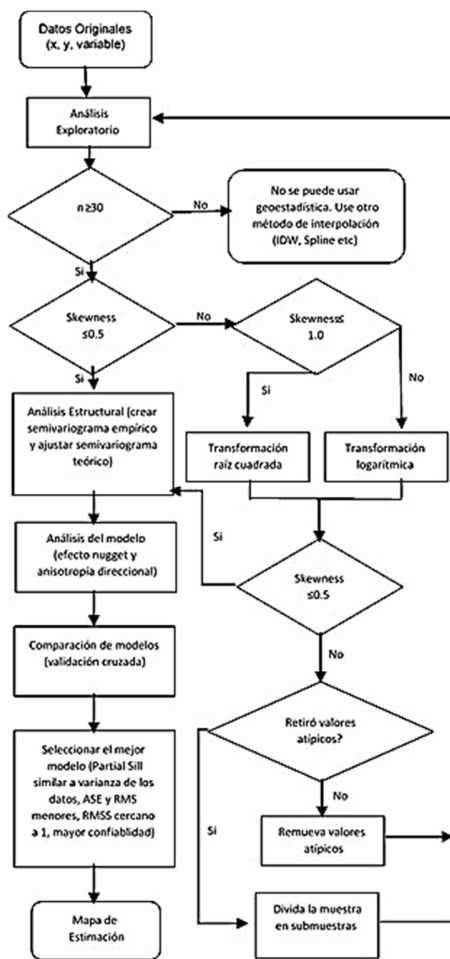


Fig. 4. Proceso análisis exploratorio y estructural [24].

Para los conjuntos de datos en los cuales las transformaciones anteriores no mejoran la estacionariedad, se realiza un análisis y detección de valores atípicos. Éstos se retiran de los datos y se realiza nuevamente el análisis exploratorio. Como se muestra en la parte inferior izquierda de la fig. 4, una vez determinado el conjunto de datos estacionarios en cada mes, se hace el análisis estructural de los datos construyendo primero el semivariograma experimental y luego ajustando un modelo de semivariograma teórico.

El siguiente paso es determinar cuál es el modelo teórico que mejor representa el cambio de la varianza con la distancia. Se prueban nueve modelos (*esférico, gaussiano, tetraesférico, pentaesférico, racional cuadrático*) se aplica el algoritmo de kriging ordinario. Mediante pruebas de validación cruzada usando la técnica “*leave one out*” [23]

y los siguientes criterios [25], se selecciona el mejor modelo teórico:

- Partial sill del modelo similar a la varianza ( $\sigma^2$ ) de los datos.
- El error estándar promedio entre el dato observado y el dato simulado (ASE-average standard error) debe ser pequeño.
- La raíz del error cuadrático promedio (RMS-root mean square-error) debe ser pequeño.
- La raíz del error cuadrático promedio estandarizado debe estar cerca de uno (RMSS-root mean square-error standardized).

Para los modelos obtenidos se calcula la Confiabilidad (\*) ( $100 - RMS$ ) y ésta se corrige por los efectos de la densificación de los datos mediante la ecuación (1).

$$C_c = \text{Confiabilidad} (*) * F_e (1).$$

En donde:

$$F_e = 1 - RMS_{spline} = 0,8709.$$

$$RMS_{spline} = 0,1291.$$

Seguidamente se hace un análisis de frecuencias con los mejores modelos obtenidos en los 60 meses para determinar el modelo más frecuente (modal). En la tabla 2 se muestran los resultados obtenidos de la frecuencia del modelo ( $F_A$ ) y los meses del año en donde se presenta. El modelo con mayor frecuencia es el *j-bessel* (24), seguido del *hole effect* (23).

TABLA 2. Frecuencias de mejores modelos.

Modelos	$F_A$	Meses 2003	Meses 2004
J-bessel	24	1, 3, 5, 6, 7, 9, 12	3, 5
Hole effect	23	2, 4, 8, 11	1, 2, 4, 6, 7, 10
Guassiano	4		
Exponencial	4		9, 11
Racional cuadrático	3	10	12
K-bessel	2		8

Modelos	Meses 2005	Meses 2006	Meses 2007
J-bessel	2, 4, 6, 8, 9, 12	1, 3, 9, 10, 11, 12	2, 3, 10
Hole effect	1, 3, 11	4, 5, 6, 7, 8	1, 4, 7, 11, 12
Guassiano	7, 10		5, 8
Exponencial	5		6
Racional cuadrático			9
K-bessel		2	

En la Tabla 3 se muestran los estadísticos de error de estimación promedio así:

- J-bessel: para los 24 meses modelados con j-bessel.
- Hole effect: para los 23 meses modelados con hole effect.
- J-bessel (1): para todos los 60 meses modelados con j-bessel.
- Hole effect (1): para los 23 meses que se modelaron con hole effect, modelados con j-bessel.
- J-Bessel (2): para los 24 meses que se modelaron con j-bessel. modelados con hole effect.
- Hole effect (2): para todos los 60 meses modelados con hole effect.

En la tabla 3 el número dentro del paréntesis es la desviación estándar promedio.

**TABLA 3**  
**Estadísticos de error de error de estimación promedio.**

	ASE	RMS	RMS S	Confiabilidad (*)	Cc
J-bessel	3,4 (1,8)	3,3 (1,8)	0,9 (0,1)	96,7 (1,8)	84, 2
Hole effect	3,1 (1,5)	3,1 (1,3)	0,9 (0,1)	96,9 (1,3)	84, 4
J-bessel (1)	3,6 (1,8)	3,5 (1,8)	1,0 (0,8)	96,5 (1,8)	84, 0
Hole effect (1)	4,5 (1,4)	6,1 (1,3)	1,2 (0,2)	93,9 (1,3)	81, 8
J-bessel (2)	3,5 (1,8)	3,3 (1,8)	0,8 (0,1)	96,7 (1,8)	84, 2
Hole effect (2)	3,8 (1,8)	3,7 (2,0)	1,2 (0,9)	96,3 (2,0)	83, 9

Usando pruebas ANOVA, se estudian los parámetros de los modelos *j-bessel* agrupados trimestralmente. Para ello se conforman los siguientes grupos en todos los años (Rango - Mes):

- (1 - 3): de enero a marzo.
- (3 - 6): de marzo a junio.
- (6 - 9): de junio a septiembre.
- (9 - 12): de septiembre a diciembre.

Se toman como variables los parámetros del modelo (*partial sill*, *major range* y *nugget*). Estas variables son independientes, cuantitativas y en escala de razón. Inicialmente se analiza si la distribución de las variables en los grupos es normal o no. Esto se hace mediante pruebas de hipótesis así:

- H0: las variables se distribuyen en los grupos normalmente. Se acepta si el nivel de significancia de la prueba es > 0.05.

- H1: las variables no se distribuyen en los grupos normalmente. Se rechaza cuando el nivel de significancia de la prueba es <= 0.05.

Se valida la normalidad mediante una prueba de Kolmogorov Smirnov de una muestra (para n > 50 datos). La prueba se hace mediante el software SPSS®. Según los valores del estadístico de la prueba (nivel de significancia. Sig. 2-tailed), se acepta normalidad para los datos de cada una de las variables. Los resultados se muestran en la tabla 4.

**TABLA 4.**  
**Resultados Prueba de normalidad KS.**

	Partial Sill	Major Range	Nugget
Parámetros normales	<i>m</i> 0,65	4,18	0,31
	<i>s</i> 0,33	1,65	0,25
Kolmogorov-Smirnov Z	0,57	0,78	1,11
Sig. 2-tailed	0,90	0,58	0,17

En la tabla 5 se muestra un análisis descriptivo de los grupos

**TABLA 5.**  
**Análisis descriptivo de los grupos.**

Variable	Rango Mes	Media	Desv. Est.
Partial Sill	1 - 3	0,72	0,30
	3 - 6	0,76	0,35
	6 - 9	0,62	0,34
	9 - 12	0,51	0,32
	Mean	0,65	0,33
Major Range	1 - 3	3,77	1,28
	3 - 6	3,84	1,22
	6 - 9	4,78	1,84
	9 - 12	4,32	2,05
	Mean	4,18	1,65
Nugget	1 - 3	0,23	0,20
	3 - 6	0,30	0,27
	6 - 9	0,31	0,23
	9 - 12	0,40	0,28
	Mean	0,31	0,25

Se probó la significancia de la media de cada una de las variables en los distintos grupos. Esto se hizo mediante pruebas de hipótesis así:

- H0: la media de la variable es igual en los grupos. Se acepta si el nivel de significancia de la prueba es > 0.05.

- H1: la media de la variable no es igual en los grupos. Se rechaza cuando el nivel de significancia de la prueba es  $\leq 0.05$ .

Se implementa una prueba ANOVA de una sola vía. Según los valores del estadístico de prueba (nivel de significancia Sig.), se acepta igualdad entre las medias de las variables en los diferentes grupos (trimestres). Los resultados para comparaciones entre grupos se muestran en la tabla 6.

**TABLA 6.**  
**Resultados prueba ANOVA de Medias.**

Variable	F	Sig.
Partial Sill	1,71	0,18
Major Range	1,23	0,31
Nugget	1,15	0,34

Se aplica también la prueba de homogeneidad de varianza de Levene. Según los valores del estadístico de prueba (nivel de significancia Sig.), se acepta que las varianzas son estadísticamente similares. Los resultados se muestran en la Tabla 7.

**TABLA 7.**  
**Resultados prueba Levene de homogeneidad de varianza.**

Variable	Levene Statistic	Sig.
Partial Sill	0,13	0,94
Major Range	1,08	0,37
Nugget	1,22	0,31

A continuación se hace una comparación de las medias por trimestre mediante una prueba de Tukey. Según los valores del estadístico de prueba (nivel de significancia Sig.), se acepta igualdad entre las medias de las variables en las diferentes comparaciones. Los resultados se muestran en la tabla 8.

**TABLA 8.**  
**Resultados prueba Tukey comparaciones intergrupales (1/2).**

Variable	(I) Rango Mes	(J) Rango Mes	Sig.
Partial Sill	1 - 3	3 - 6	0,99
		6 - 9	0,85
		9 - 12	0,32
	3 - 6	6 - 9	0,65
		9 - 12	0,18
		6 - 9	0,80
Major Range	1 - 3	3 - 6	1,00
		6 - 9	0,34
		9 - 12	0,79
	3 - 6	6 - 9	0,40
		9 - 12	0,85
		6 - 9	0,87

**TABLA 8.**  
**Resultados prueba Tukey comparaciones intergrupales (2/2).**

Nugget	1 - 3	3 - 6	0,84
		6 - 9	0,83
		9 - 12	0,26
	3 - 6	6 - 9	1,00
		9 - 12	0,74
		6 - 9	0,75

La ecuación (2) representa el modelo j-bessel [26], los parámetros *partial sill*, *major range* y *nugget* se pueden tomar de los valores medios de la tabla 5 para cada agrupación trimestral (*Rango Mes*).

$$\gamma(h, \theta) = \theta_n + \theta_s \left[ 1 - \frac{2^{\theta_d} \Gamma(\theta_d + 1)}{\phi} J_{\theta_d}(\phi) \right] \quad (2).$$

$$\phi = \Omega_{\theta_d} \frac{\|h\|}{\theta_r}$$

En donde:

$\theta_n$  = parámetro nugget.

$\theta_s$  = parámetro partial sill.

$\theta_r$  = parámetro major range.

$\theta_d$  = parámetro calculado con la herramienta *Geostatistical Analyst*®.

$\Gamma(\theta_d + 1)$  = función gamma.

$\Omega_{\theta_d}$  = valor calculado numéricamente sujeto a que  $\theta_s \geq 0$ ,  $\theta_r \geq 0$ ,  $\theta_d \geq 0$ ; con  $\gamma(\theta_r) = \theta_s$  y  $\gamma'(\theta_r) < 0$ .

$\|h\|$  = norma del vector de distancia.

$J_{\theta_d}(\phi)$  = función j-bessel.

#### 4. ANÁLISIS DE RESULTADOS

Una de las grandes dificultades para el estudio de variables ambientales está en las limitaciones con respecto a la cantidad de datos obtenidos en sitios de monitoreo en el tiempo pero sobre todo en el espacio. En este trabajo se usan algoritmos de interpolación tipo *spline* para remediar esta situación mediante la densificación de datos espaciales. Estos algoritmos fueron eficientes para el caso del material particulado y su confiabilidad de estimación fue similar a la reportada en la literatura en otros trabajos [3]. En el análisis estructural se analizaron para cada mes 9 modelos teóricos de semivariograma. En la mayoría de textos publicados se reportan resultados con modelos esféricos. De manera complementaria a lo reportado por la literatura

y con base en los criterios de validación cruzada, en este caso el modelo esférico no resultó ser eficiente.

La ventaja de un modelo geoestadístico con relación a otros interpoladores está en la información adicional obtenida sobre el máximo cambio de la varianza de los datos con la distancia (*partial sill*) y el alcance de la autocorrelación espacial de los mismos (*major range*). El modelo *j-bessel* tiene un *partial sill* y un *major range* promedio de  $0.65 (\mu\text{g}/\text{m}^3)^2$  y 4.18 km, con desviaciones estándar de 0.33 y 1.65 respectivamente. El primer valor está cercano a la varianza promedio de los datos con lo que se puede inferir que modela bien la variabilidad de los datos. El segundo valor tiene una desviación estándar no tan buena e indica el área de influencia de cada sitio de monitoreo. Esta información es bastante útil si se tiene en cuenta la naturaleza del sitio de monitoreo en función de lo que se quiere medir y la proximidad a la fuente de emisión, es decir, si el sitio de monitoreo es de punto crítico para mediciones de exposición directa o es de fondo para mediciones de exposiciones de largo plazo. En este caso se obtuvo como rango sensible de medición una distancia de 4 km entre el sitio de monitoreo y la fuente.

El análisis de frecuencia de los modelos obtenidos mostró que los modelos *j-bessel* y *hole effect* representaron el 78% de los meses estudiados siendo ligeramente más frecuente el *j-bessel* en 24 meses con respecto al *hole effect* en 23 meses.

Al estudiar el comportamiento del modelo *j-bessel* en los demás meses, se encontró que los criterios de validación cruzada eran buenos por lo que se optó por representar la concentración de PM10 en todo el periodo de estudio con dicho modelo, obteniendo en general una confiabilidad de estimación promedio corregida por efectos de la densificación de 84%.

Las pruebas de hipótesis se hicieron con agrupaciones mensuales de los parámetros del modelo, encontrándose también similitud en las medias de los parámetros.

Se evaluaron todos los 60 meses con el modelo *hole effect* y la confiabilidad de estimación promedio corregida por efectos de la densificación fue 83.9% que es ligeramente inferior a la del modelo *j-bessel*. Con los

parámetros del modelo *hole effect* agrupados mensual y trimestralmente, se hicieron pruebas de hipótesis para igualdad de medias. Los estadísticos de error mostraron que no existen diferencias significativas de este modelo con respecto al *j-bessel*. Por lo tanto, con el modelo *j-bessel* se pudo hacer una caracterización espacial de PM10 mediante kriging ordinario y los valores de los parámetros obtenidos de la columna 3 de la tabla 5. En las fig. 5 a 8 se muestran los resultados.

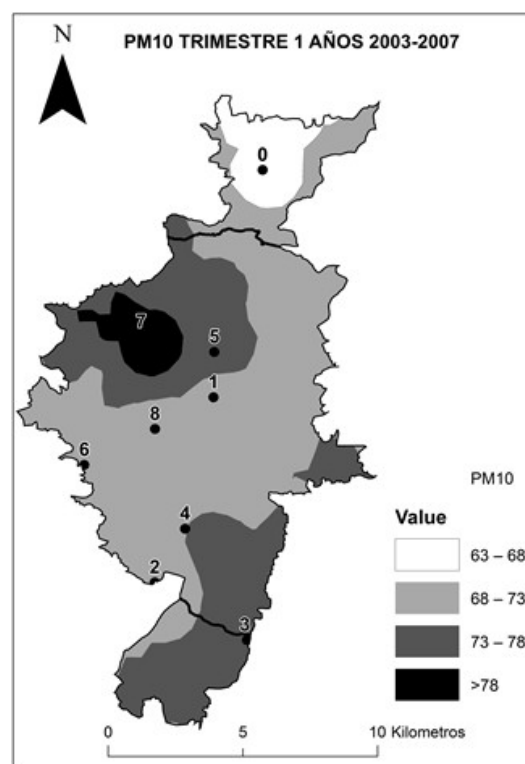


Fig. 5. Caracterización espacial de PM10 para el Rango Mes 1 - 3.

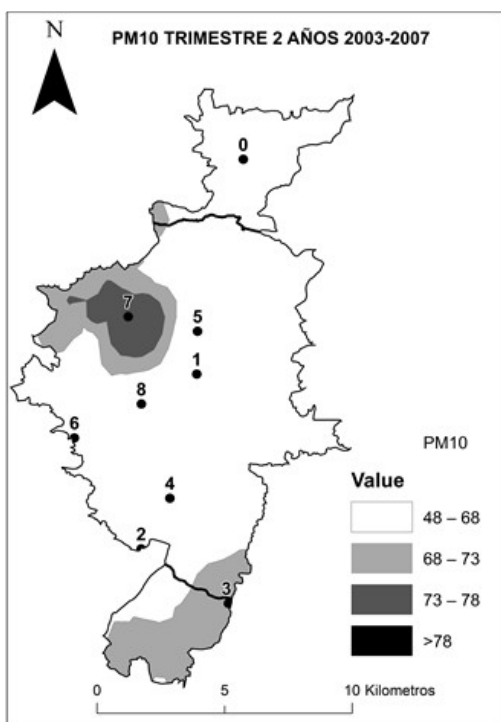


Fig. 6. Caracterización espacial de PM10 para el Rango Mes 3 - 6.

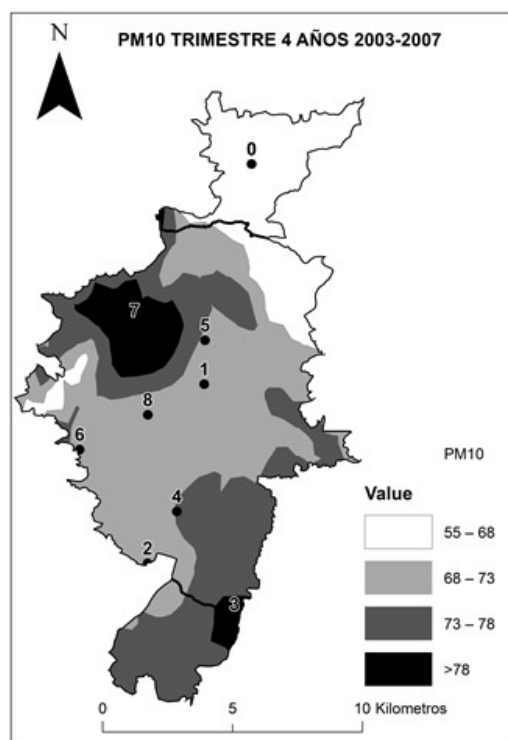


Fig. 8. Caracterización espacial de PM10 para el Rango Mes 9 - 12.

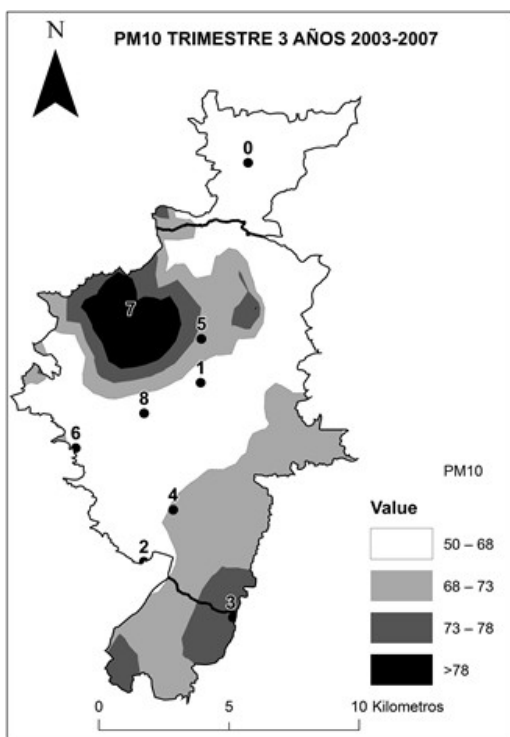


Fig. 7. Caracterización espacial de PM10 para el Rango Mes 6 - 9.

El resultado promedio de la confiabilidad de estimación corregida trimestral (promedio de Cc de tabla 9) de los mapas de las fig. 5 a 8 fue de 83.8%. Éste valor es similar al valor promedio mensual reportado en la tabla 3 que fue de 84%, esto muestra coherencia en la confiabilidad de estimación de los mapas trimestrales.

**TABLA 9.**  
**Estadísticos de error promedios por trimestre.**

	Rango Mes			
	1 - 3	3 - 6	6 - 9	9 - 12
ASE	0,7	0,5	0,4	0,8
RMS	2,7	3,5	5,0	4,0
RMSS	3,0	5,1	10,0	4,1
Confiabilidad (%)	97,3	96,5	95,0	96,0
Cc	84,8	84,0	82,7	83,6

En cuanto a la caracterización espacial de PM10 se muestra similitud entre los trimestres 1 y 4, así como entre los trimestres 2 y 3. En general, en los 4 trimestres la máxima concentración está ubicada en la vecindad del sitio de monitoreo 7 al centro occidente y en el 3 al sur oriente del área de estudio. Como se puede ver en la fig. 2, en esas zonas existen microcuencas topográficas que pueden estar favoreciendo acumulaciones en la concentración del contaminante. Algo similar pasa en los trimestres 2 al 4 en la microcuenca



ubicada en el extremo centro occidental. En el centro del valle, en la línea formada por los sitios de monitoreo 1 y 4, se presenta menor contaminación con respecto a las zonas de las microcuencas mencionadas anteriormente.

Con estos mapas en futuros estudios se podrían construir mapas de excedencia que muestren zonas de la región de estudio en donde se superen los límites máximos permisibles de concentración de PM10 según la normativa de la resolución 610 de 2010 del ministerio de ambiente, vivienda y desarrollo territorial de Colombia (máximo promedio anual  $60 \mu\text{g}/\text{m}^3$ ). Los mapas muestran que en los trimestres 1 y 4 se supera en casi toda el área de estudio el valor umbral de máxima concentración lo cual podría generar problemas de salud pública.

Finalmente estos resultados podrían ser usados en estudios para la implementación de campañas de medición exploratorias que permitan compararlos con los obtenidos mediante observación directa.

## 5. CONCLUSIÓN

Se encontró un modelo geoestadístico (*j-bessel*) para caracterizar espacialmente el contaminante PM10 en la ciudad de Medellín, Colombia. Éste modelo tiene una confiabilidad de estimación promedia del 84% obtenida mediante pruebas de validación cruzada. Usando pruebas ANOVA se encontró similitud estadística entre los valores promedios de los parámetros del modelo en agrupaciones mensuales y trimestrales. Para las agrupaciones trimestrales se generaron mapas con kriging ordinario que muestran la distribución espacial de la concentración del contaminante en la ciudad. En los trimestres 1 y 4 los mapas muestran que la concentración del contaminante está por encima del límite máximo permisible en casi toda la ciudad y se ve una tendencia de los máximos valores de concentración a ubicarse en algunas microcuencas del valle. De igual manera se obtuvieron menores valores de concentración en la parte central del valle en la línea formada por los sitios de monitoreo 1 y 4. Estos resultados son útiles para la comprensión del comportamiento de esta sustancia en el territorio y la gestión ambiental de la calidad del aire de la ciudad. La aproximación al problema desarrollado mediante la implementación de sistemas de información geográfica, complementa otros estudios que

actualmente se adelantan en la ciudad con aproximaciones diferentes.

## 6. REFERENCIAS

- [1]. N. Hamm, A. Finley, M. Schaap and A. Stein, "A spatially varying coefficient model for mapping PM10 air quality at the European scale," *Atmospheric Environment*, Vol. 102, pp. 393-405, 2015.
- [2]. Z. Sun, X. An, Y. Tao and Q. Hou, "Assessment of population exposure to PM10 for respiratory disease in Lanzhou (China) and its health-related economic costs based on GIS," *BMC Public Health*, Vol. 13, No 1, pp. 891-900, 2013.
- [3]. J. Li and D. Heap, "A. Spatial interpolation methods applied in the environmental sciences: A review," *Environmental Modelling & Software*, Vol. 53, pp. 173-189, 2014.
- [4]. S. Young, J. Tullis and J. Cothren, "A remote sensing and GIS-assisted landscape epidemiology approach to West Nile virus," *Applied Geography*, No 45, pp. 241-249, 2013.
- [5]. M. J. Bechle, D. B. Millet and J. D. Marshall, "Remote sensing of exposure to NO2: satellite versus ground based measurement in a large urban area," *Atmospheric Environment*, Vol. 69, pp. 345-353, 2013.
- [6]. J. Lorenzo, G. Aviles, J. Mondejar and M. Vargas, "A spatio-temporal geostatistical approach to predicting pollution levels: The case of mono-nitrogen oxides in Madrid," *Computers, Environment and Urban Systems*, No 37, pp. 95-106, 2013.
- [7]. M. Rooney, R. Arku, K. Dionisio, C. Paciorek, A. Friedman, H. Carmichael, Z. Zhou, A. Hughes, J. Vallarino, S. Agyei-Mensah, J. Spengler and M. Ezzati, "Spatial and temporal patterns of particulate matter sources and pollution in four communities in Accra, Ghana," *Science of the Total Environment*, Vol. 435-436, pp 107-114, 2012.
- [8]. D. Rojas-Avellaneda, "Spatial interpolation techniques for estimating levels of pollutant concentrations in the atmosphere," *Rev. mex. is*, Vol.53, No.6, pp.447-454, 2007.
- [9]. H. Merbitz, S. Fritz and C. Schneider, "Mobile measurements and regression modeling of the spatial particulate matter variability in an urban area," *Sci. Total Environ*, Vol. 438, pp. 389-403, 2012.
- [10]. G. Hoek, K. Meliefste, J. Cyrys, M. Lewné, T. Bellander, M. Brauer and B. Brunekreef, "Spatial variability of fine particle concentrations in three European areas," *Atmospheric Environment*, Vol. 36, No 25, pp. 4077-4088, 2002.
- [11]. G. Righini, A. Cappelletti, C. Cremona, A. Piersanti, L. Vitali and L. Ciancarella, "GIS based assessment of the spatial representativeness of air quality monitoring stations using pollutant emissions data," *Atmospheric Environment*, No 97, pp. 121-129, 2014.
- [12]. D. Dominick, H. Juahir, M. Latif, S. Zain and A. Aris, "Spatial assessment of air quality patterns in Malaysia using multivariate analysis," *Atmospheric Environment*, No 60, pp. 172-181, 2012.
- [13]. E. Gramsch, F. Cereceda-Balic, P Oyola and D. Von Baer, "Examination of pollution trends in Santiago de Chile with cluster analysis of PM10 and ozone data," *Atmospheric Environment*, Vol. 40, No 28, pp. 5464-5475, 2006.

- [14]. C. Silva, L. Firinguetti, and A. Trier, "Contaminación ambiental por partículas en suspensión: Modelamiento estadístico," *Actas XXI Jornadas Nacionales de Estadística*. Concepción, Chile, 1994.
- [15]. P. Pérez and J. Reyes, "Prediction of maximum of 24h average of PM10 concentrations 30h in advance in Santiago, Chile," *Atmospheric Environment*, Vol. 36, pp. 4555-4561, 2002.
- [16]. C. Silva, P. Pérez and A. Trier, "Statistical modelling and prediction of atmospheric pollution by particulate matter: two nonparametric approaches," *Environmetrics*, Vol. 12, pp. 147-159, 2001.
- [17]. J. Huertas, M. Huertas, S. Izquierdo and E. Gonzales, "Air quality impact assessment of multiple open pit coal mines in northern Colombia," *Journal of Environmental Management*, Vol. 93, No 1, pp. 121-129, 2012.
- [18]. E. Dons, M. Van Poppe, L. Panis, S. De Prins, P. Berghmans, G. Koppen and C. Matheeußen, "Land use regression models as a tool for short, medium and long term exposure to traffic related air pollution," *Science of the total Environment*, Vol. 476-477, pp. 378-386, 2014.
- [19]. M. Beauchamp, L. Malherbe and C. De Fouquet, "A pragmatic approach to estimate the number of days in exceedance of PM10 limit value," *Atmospheric Environment*, Vol. 111, pp. Pages 79-93, 2015.
- [20]. R. Webster and M. Oliver, *Geostatistics for Environmental Scientists*. England: John Wiley & Sons Ltd, 2007, p. 19-20.
- [21]. R. Bilonik, "A. Risk qualified maps of hydrogen ion concentration for the New York state area for 1966 – 1978," *Atmospheric Environment*, Vol. 17, pp. 2513-2524, 1983.
- [22]. L. Londoño and J. Cañón, "Imputation of spatial air quality data using gis-spline and the index of agreement in sparse urban monitoring networks," *Revista Facultad de Ingeniería Universidad de Antioquia*, No. 76, to be published, 2015.
- [23]. A. Pollice, and G. Jona Lasinio, "Two Approaches to Imputation and Adjustment of Air Quality Data from a Composite Monitoring Network," *Journal of Data Science*, Vol. 7, pp. 43-59, 2009.
- [24]. M. Quiroz, D. Martínez, H. Massone, L. Londoño and C. Dapeña, "Spatial distribution of electrical conductivity and stable isotopes in groundwater in large catchments: a geostatistical approach in the Quequén Grande River catchment, Argentina," *Isotopes in Environmental and Health Studies*, Jul. 2015. [Online]. Available: <http://dx.doi.org/10.1080/10256016.2015.1056740>.
- [25]. I. Villada and L. Londoño, "Aplicación de métodos geoestadísticos para la caracterización de la calidad química de un depósito de material calcáreo," *Revista Boletín Ciencias de la Tierra*, No. 35, pp. 15-23, 2014.
- [26]. K. Johnston, J. Verhoef, K. Krivoruchko and N. Lucas, *ArcGIS Geostatistical Analyst Tutorial*. USA: ESRI, 2003, pp. 256-258.