

CONAMA 2020

CONGRESO NACIONAL DEL MEDIO AMBIENTE

**RELACIÓN ENTRE
CONTAMINANTES
ATMOSFÉRICOS, VARIABLES
METEOROLÓGICAS Y CASOS
DE COVID-19 EN CIUDADES
EUROPEAS**





Autor Principal: Ana Belén Vicente Fortea (Universidad Jaume I)

Otros autores: Somnath Chaudhuri (Universidad Jaume I); Pablo Juan Verdoy (Universidad Jaume I); Carlos Díaz Ávalos (Universidad Nacional Autónoma de México); Laura Serra Saurina (Universidad de Girona)

ÍNDICE

1. Título	2
2. Palabras Clave	2
3. Resumen	2
4. Introducción	3
4.1. Antecedente	3
4.2. Área de estudio	4
4.3. Datos	7
5. Metodología	11
6. Resultados	12
7. Discusión	16
8. Conclusiones	17
9. Bibliografía	18

1. TÍTULO

Relación entre contaminantes atmosféricos, variables meteorológicas y casos de covid-19 en ciudades europeas

2. PALABRAS CLAVE

COVID-19, PM₁₀, NO₂, variables meteorológicas

3. RESUMEN

La preocupación por conocer la relación entre los niveles de contaminación del aire y las muertes por enfermedades virales no es nueva. Algunos estudios encontraron que los pacientes con SARS, un virus respiratorio estrechamente relacionado con COVID-19, tenían un 84% más de probabilidades de morir si vivían en áreas con altos niveles de contaminación. Según el último informe de evaluación rápida del Centro Europeo para la Prevención y el Control de Enfermedades, Italia y España son los países más afectados de la Unión Europea por la pandemia COVID-19. A 31 de mayo de 2020, el número total de casos infectados por millón de habitantes de España es 5.120,95 y 3.848,11 para Italia. Este estudio se centra en las ciudades de Madrid, Barcelona, Milán y Roma durante el periodo anterior, durante y posterior del confinamiento. El objetivo de este trabajo es proporcionar un conocimiento más profundo que pueda ayudar a tomar decisiones futuras. Además, para ampliar la literatura existente, este estudio también incorpora variables meteorológicas que también pueden afectar la calidad del aire (PM₁₀ y NO₂) y está directamente relacionado con casos infectados con COVID-19. El estudio actual se ha llevado a cabo para identificar la relación entre los niveles de contaminación del aire con el valor esperado de las víctimas de COVID-19 y las covariables meteorológicas, utilizando un análisis jerárquico bayesiano. Como resultados se ha obtenido que todas estas variables son significativas respecto a la calidad del aire. La propuesta de este análisis bayesiano mejora las herramientas estadísticas que se han utilizado en este campo hasta ahora. Con su aplicación, podemos obtener avances importantes en los efectos de la salud y la calidad del aire en ambientes urbanos.

4. INTRODUCCIÓN

4.1. Antecedentes

La preocupación por conocer la relación entre los niveles de contaminación del aire y las muertes por enfermedades virales no es nueva. Un estudio de 2003 encontró que los pacientes con SARS, un virus respiratorio estrechamente relacionado con COVID-19, tenían un 84% más de probabilidades de morir si vivían en áreas con altos niveles de contaminación [1].

Sin embargo, aún no hay investigaciones concluyentes sobre la relación entre la contaminación atmosférica y la COVID-19, por lo que es un aspecto interesante a abordar ya que podría ser un elemento crucial para ayudar a mejorar la desescalada de la pandemia por esta enfermedad. En cualquier caso, los estudios existentes apuntan hacia una cierta relación entre ambas variables. En este sentido, un estudio sobre la calidad del aire en las provincias del norte de Italia de Lombardía y Emilia Romagna encontró una correlación entre las tasas de mortalidad por COVID-19 y los altos niveles de contaminación [2]. Los investigadores, al ver los resultados críticos de estas áreas geográficas, concluyeron que un alto nivel de contaminación debe considerarse como un factor adicional a la alta letalidad detectada. Otro estudio detectó que el Sars-CoV-2 (el virus que causa la COVID-19) incluso podría estar viajando en partículas PM₁₀ [3]. Se sugieren que el virus podría estar más disperso en partículas contaminantes del aire, aunque estos resultados deben tomarse con precaución y requieren más investigación, ya que todavía son resultados muy preliminares.

Además, otros estudios se centran en evolución de la concentración de dióxido de nitrógeno (NO₂). Uno de ellos revela que la exposición a largo plazo a este contaminante puede ser uno de los contribuyentes más importantes a la mortalidad causada por el virus COVID-19 en Italia, España, Francia y Alemania y quizás en todo el mundo [4].

Por otro lado, otros factores, como las condiciones meteorológicas, también pueden contribuir significativamente a cambios en los niveles de concentración de los contaminantes atmosféricos [5,6,7]. Por tanto, la relación entre estas dos variables es de especial interés por la correlación que existe entre ellas.

Por todo ello, ha crecido el interés por investigar si la contaminación del aire puede empeorar significativamente el brote de COVID-19 ya que predispone a las personas a infectarse con el virus [8]. Además, varios científicos sugieren que las partículas contaminantes del aire pueden actuar como vehículos para la transmisión viral.

El objetivo de este trabajo es arrojar luz sobre este tema que preocupa a la sociedad investigadora con el fin de aportar un conocimiento más profundo que pueda ayudar a tomar decisiones futuras. Además, para ampliar la literatura existente, se incorporan variables meteorológicas que puedan afectar la calidad del aire y que están directamente relacionadas con casos de infección por COVID-19 en ciudades europeas (Madrid, Barcelona, Milán y Roma). El estudio actual se ha realizado para identificar la relación entre los niveles de contaminación del aire con el valor esperado de las víctimas de COVID-19 y las covariables meteorológicas, utilizando un análisis bayesiano jerárquico. Estos nuevos hallazgos podrían tener un impacto significativo en las decisiones de los gobiernos en relación a relajar las restricciones aplicadas en la sociedad, ya que los resultados científicos sugieren que una mejora en la calidad del aire podría jugar un papel importante en la superación de la pandemia.

4.2 Área de estudio

Según un informe de evaluación rápida del Centro Europeo para la Prevención y el Control de Enfermedades, Italia y España son los países más afectados dentro de la Unión Europea por la pandemia de COVID-19 [9]. A 31 de mayo de 2020, el número total de casos infectados por millón de habitantes en España era de 5.120,95 y 3.848,11 en Italia. El número de muertos por millón de habitantes registrado en la misma fecha fue de 580,2 y 551,4 en España e Italia, respectivamente. Los datos muestran el gran impacto de la pandemia en estos dos países que tienen una diferencia significativa en la densidad de población, España 93,1 e Italia 205,9 [10]. Los registros detallados de la demografía y los casos de infección por COVID-19 para España e Italia se presentan en la tabla 1. Donde se observa que, pese a la gran diferencia de densidad poblacional citada, los casos de personas infectadas son similares. El porcentaje de personas mayores de 65 años en España para la muestra es del 19,65%, mientras que, para Italia, este porcentaje pasa a ser del 22,80%.

Tabla 1 Demografía y casos de infección a 31/05/20 por COVID-19

País	España	Italia
Habitantes	46.754.783	60.461.828
Densidad poblacional	93,105	205,859
Edad media	45,5	47,9
Camas hospitalarias (por mil habitantes)	2,97	3,18
Expectativa de vida	83,56	83,51
Infectados totales	239.429	232.664
Muertes totales	27.127	33.340
Infectados totales (por millón de habitantes)	5.120,95	3.848,11
Muertes totales (por millón de habitantes)	580,20	551,42

Este estudio se ha realizado en cuatro ciudades importantes de estos dos países, Milán y Roma de Italia, y Madrid y Barcelona de España. Estas ciudades registran el mayor número de muertes y casos confirmados del ataque fatal del virus [11]. Las figuras 1 y 2 representan la ubicación y el mapa de las cuatro ciudades de estudio de España e Italia, respectivamente.

En referencia a las ciudades de estudio en España, Madrid tiene una superficie de 604,3 km². Es la capital de España y la tercera ciudad más poblada de la Unión Europea con una población estimada de 6,4 millones de personas. Su ubicación en el centro del país convierte a Madrid en el principal nudo de transporte dentro de la Península Ibérica [12]. La economía de la ciudad se basa en los sectores de servicios, construcción e industria. Según datos del Inventario de Emisiones Contaminantes en la Atmósfera de Madrid, el tráfico rodado es responsable de más del 50% de las emisiones de NO₂ y partículas contaminantes [13].

Relación entre contaminantes atmosféricos, variables meteorológicas y casos de COVID-19 en ciudades europeas



Figura 1: Situación ciudades españolas objeto de estudio

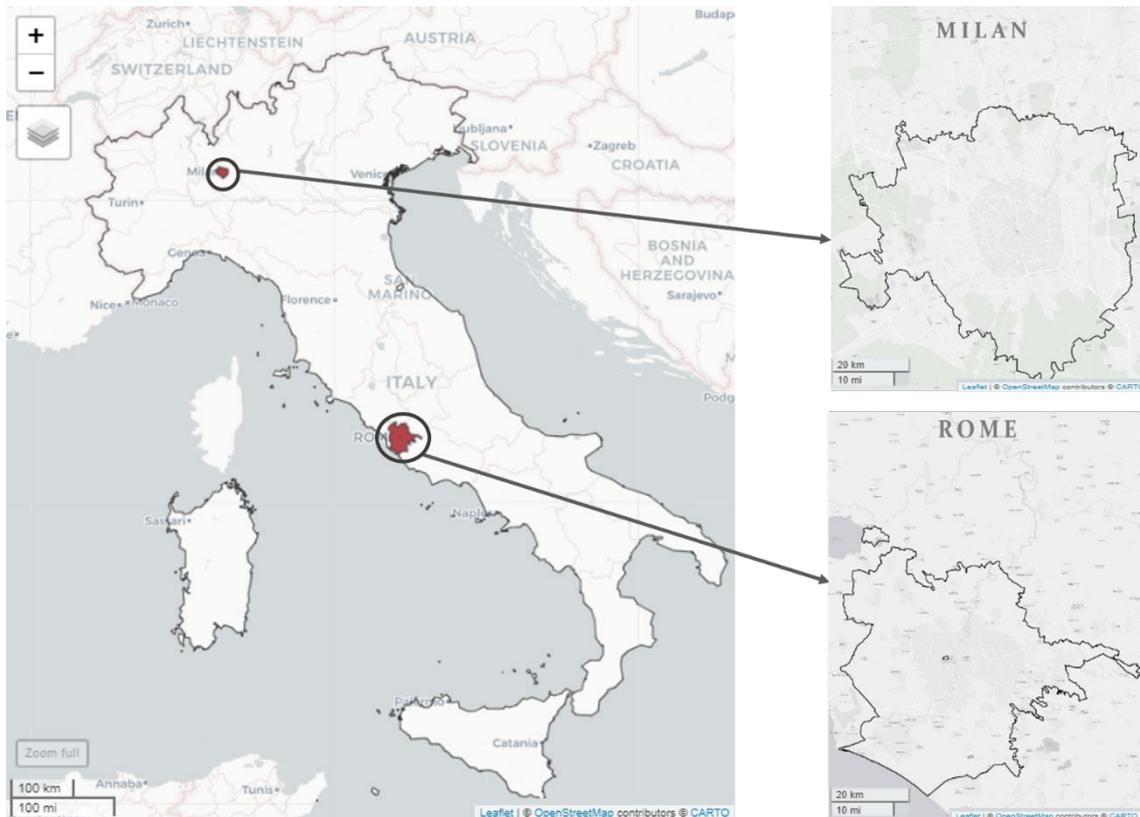


Figura 2: Situación ciudades italianas objeto de estudio

Por otro lado, Barcelona tiene una superficie de 101,9 Km², es otra ciudad muy poblada (alrededor de 5,6 millones de habitantes) de Europa. El área metropolitana de Barcelona está densamente industrializada y cuenta con varias vías principales utilizadas tanto para el

transporte local, nacional e internacional. Además, un aeropuerto con mucho tráfico se encuentra a solo unos kilómetros al sur y un puerto con mucho tráfico en la costa este de la ciudad. Los niveles diarios de contaminación en Barcelona superan el límite del 70% establecido por la Organización Mundial de la Salud (OMS). Esta contaminación proviene principalmente del tráfico, en particular de los vehículos diésel que generan el 60% de NO₂ y el 80% de partículas como PM₁₀ [14].

Roma, la capital de Italia y Milán, el centro financiero del país son las otras dos ciudades de estudiadas. Roma tiene una superficie de 1285 km² y es una de las ciudades más superpobladas de Europa (alrededor de 2,9 millones de habitantes). El mayor problema de esta ciudad es la falta de una red adecuada de transporte público. Por lo tanto, los habitantes usan principalmente automóviles que conducen en situaciones ocasionales de atasco de tráfico en las concurridas carreteras de la ciudad. Por tanto, las emisiones del tráfico son la fuente dominante de contaminantes atmosféricos en Roma. Además del tráfico, hay varias otras actividades contaminantes, como la calefacción doméstica [15].

Milán se encuentra en el valle del Po, que es la región más industrializada de Italia [16]. La ciudad protegida por los Alpes y el valle de los Apeninos tiene una superficie de 181,8 km² con más de 1,4 millones de habitantes en el área urbana. Milán tiene una de las tasas de propiedad de automóviles más altas de Europa. La movilidad general asciende a más de 5,3 millones de viajes por día entre la ciudad y el área metropolitana circundante. La ciudad se encuentra entre las grandes urbes europeas con las concentraciones atmosféricas de material particulado más altas, tanto en términos de nivel medio anual como de días de superación del límite de PM₁₀ de la Unión Europea de 50 µg/m³.

Los dos países estudiados, España (población de 46,9 millones) e Italia (población de 60,3 millones) comparten varias características como ciudadanos muy sociales con interacciones físicamente afectivas, ciudades densamente pobladas y porcentajes de personas mayores de 65 años significativos. Estos dos países de la región mediterránea son testigos del incremento de pacientes infectados con el nuevo coronavirus y representan un porcentaje considerable del total mundial de muertes por COVID-19. En ambos países, el primer caso infectado identificado se registró el 30 de enero de 2020. Más tarde, el 21 de febrero de 2020 se detectó un grupo de casos, comenzando con 16 casos confirmados en la región de Lombardía de Italia. Aun así, Italia tardó aproximadamente tres semanas en tomar la decisión de cerrar todos los negocios no esenciales y la prohibición nacional de desplazamientos innecesarios por parte de la población. Finalmente, el 9 de marzo de 2020, el gobierno de Italia impuso un confinamiento nacional.

Al mismo tiempo, en España a finales de febrero y principios de marzo, no hubo acciones contundentes ni toma de precauciones por el gobierno advirtiendo de la gravedad de la pandemia. La transmisión comunitaria comenzó a mediados de febrero y para el 13 de marzo se habían registrado casos confirmados de COVID 19 en casi todas las 52 provincias del país. Esto llevó a la implementación del de un confinamiento a nivel nacional el 14 de marzo de 2020.

Esta medida continuó durante más de 2 meses en ambos países. A mediados de mayo, con una tendencia a la disminución gradual del número de infectados y muertes, los gobiernos de ambos países comenzaron a levantar algunas restricciones y relajar el confinamiento con medidas de desescalada. En relación con la propagación del COVID-19 en las cuatro ciudades de estudio, es de destacar que, a 31 de mayo de 2020, Milán registró el mayor número de casos infectados 17.068,05 por millón de población seguida de Madrid (10.664,86) y Barcelona (8.095,43). Roma

registró menos casos de estas cuatro ciudades con 1.964,15 casos infectados por millón de población [10]. En la tabla 2 se presentan registros detallados de información sobre el área, la demografía y los casos infectados de las ciudades del estudio comentados.

Tabla 2 Demografía y casos por COVID-19 hasta 31/05/20 de las ciudades objeto de estudio

Ciudad*	Habitantes (millón)	Área (km ²)	Densidad poblacional (por km ²)	Caso totales confirmados	Casos totales confirmados (por millón Habitantes)
Madrid	6,642	604	5.400	70.836	10.664,86
Barcelona	5,575	102	16.000	45.132	8.095,43
Milán	1,352	182	2.783	23.076	17.068,05
Roma	2,730	1.285	2.232	5.643	1.964,15

*Datos de área Metropolitana

Aunque el confinamiento a nivel nacional, y una serie de recomendaciones médicas en los dos países, muestran mejores perspectivas, aún quedan grandes incertidumbres sobre la evolución futura de la pandemia y la eficacia de las estrategias de mitigación o contención de la misma [17].

4.3 Datos

Se han estudiado dos de los principales contaminantes atmosféricos como son el PM₁₀ y NO₂ como variables de respuesta al análisis realizado de la incidencia del número de casos de COVID-19. Además, se han considerado covariables con el fin de dar más precisión del análisis. Las covariables se dividen en dos grupos, uno relacionado con los parámetros meteorológicos (temperatura, ráfaga y velocidad del viento, presión, humedad y punto de rocío) y el segundo es el número de casos diarios de COVID-19 infectados.

El conjunto de datos de calidad del aire para las áreas de estudio se recopila de diferentes repositorios abiertos gubernamentales en línea. En el caso de Italia (tanto Roma como Milán), los datos de calidad del aire se recopilan de la Agenzia regionale per la protezione ambientale della Toscana (ARPAT) [18]. Para Madrid, se ha obtenido de Calidad del Aire en Madrid, Servicio de Protección de la Atmósfera [19] y la Agencia Europea de Medio Ambiente [20]. Para Barcelona, Medi Ambient, Generalitat de Catalunya [21] y Parc Vall d'Hebrón en Barcelona, Catalunya ofrece acceso abierto a los registros diarios de calidad del aire.

Los datos recopilados se muestran en las figuras de la 3 a la 6. Las Figuras 3 y 4 representan la variación temporal de la concentración de NO₂ y PM₁₀, en escala logarítmica para facilitar la modelización. Las fases de confinamiento para ambos países se ilustran con líneas verticales en los gráficos. En España, el confinamiento se impuso el 14 de marzo y continuó hasta el 9 de mayo de 2020 (resaltado en líneas verticales negras). Por otro lado, para Italia continuó por un período más prolongado a partir del 9 de marzo hasta el 18 de mayo de 2020 (representado en rojo). En la figura 4 se observa una reducción de la concentración de NO₂ durante la fase de confinamiento en las cuatro ciudades estudiadas. Mientras que la concentración diaria de PM₁₀ no muestra cambios sustanciales durante este período.

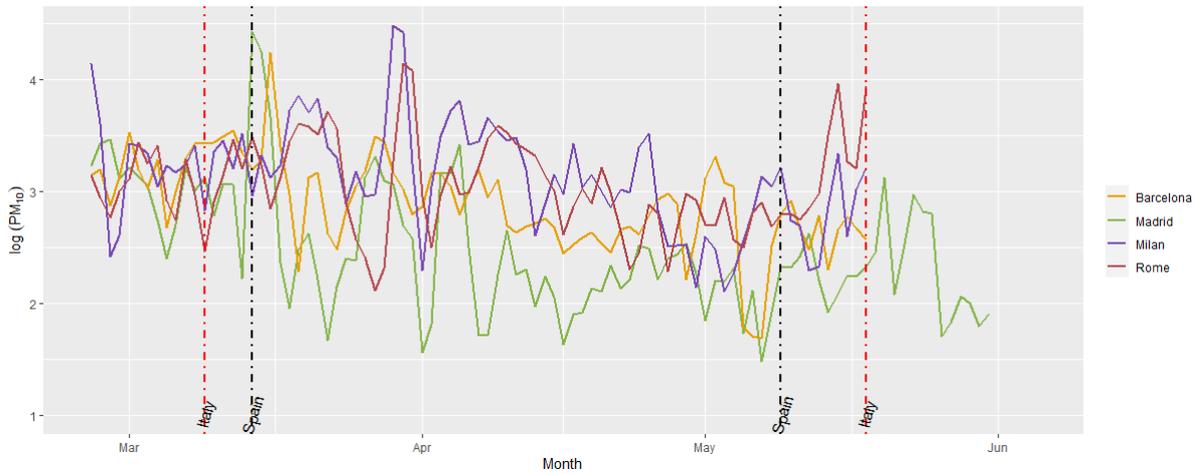


Figura 3: Variación temporal de log(PM₁₀)
(Líneas verticales: periodo confinamiento)

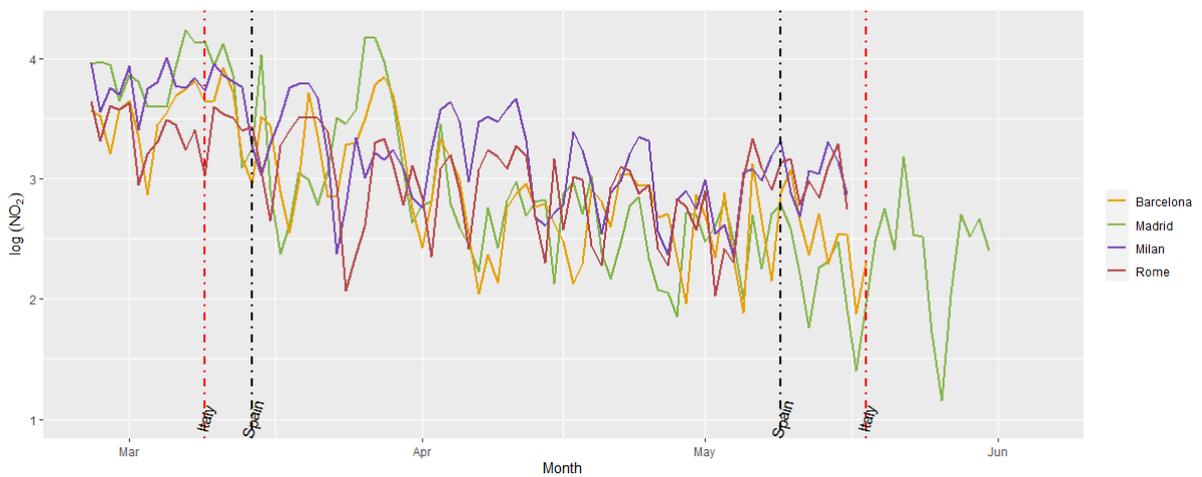


Figura 4: Variación temporal de log(NO₂)
(Líneas verticales: periodo confinamiento)

Por otro lado, las figuras 5 y 6 muestran la frecuencia de los contaminantes estudiados en cada ciudad.

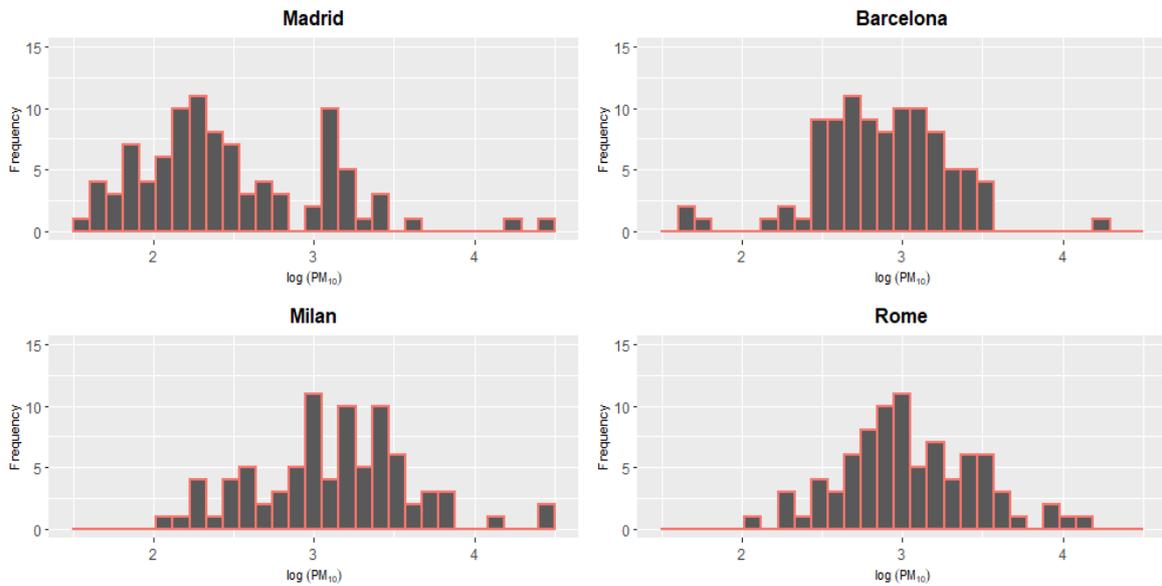


Figura 5: Histograma de log(PM₁₀)

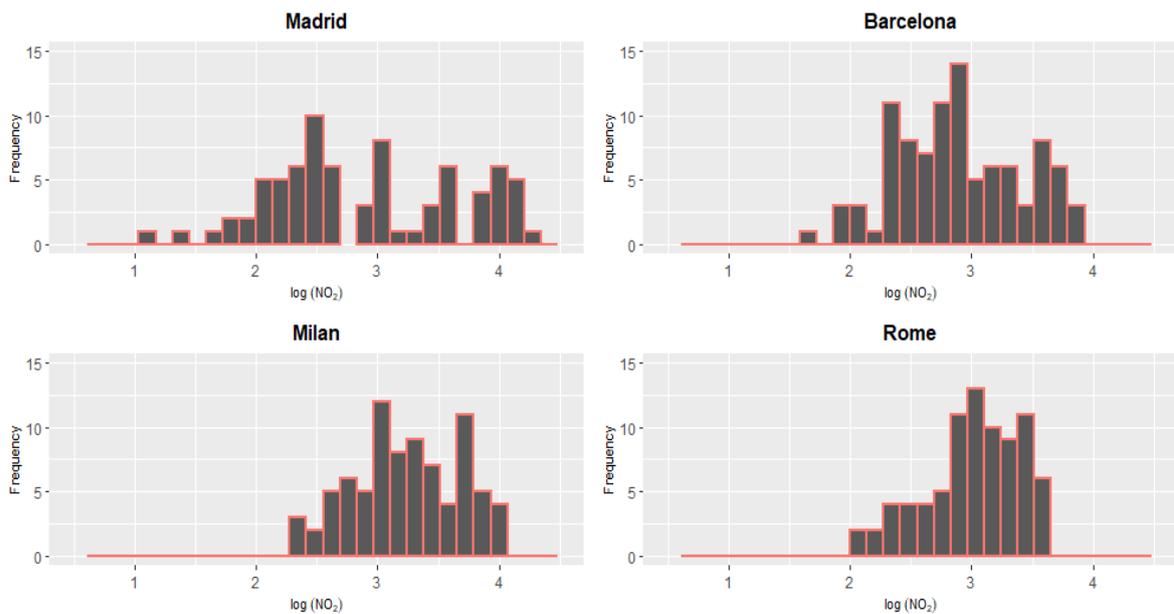


Figura 6: Histograma de log(NO₂)

Los datos meteorológicos de las cuatro ciudades estudiadas se han recuperado del portal abierto del proyecto World Air Quality Index (WAQI) [22]. El conjunto de datos al que se accede se basa en el promedio de varias estaciones en las cuatro ciudades. Proporciona registros diarios promedio de seis componentes climáticos como punto de rocío (en grados Celsius), humedad (en porcentaje), presión (en hPa), temperatura (en grados Celsius), ráfaga de viento (en kts) y velocidad del viento (en kts). Tanto la calidad del aire como el conjunto de datos meteorológicos son del 25 de febrero al 31 de mayo de 2020.

Los registros diarios totales de COVID-19 a nivel provincial en el caso de Italia están disponibles en el repositorio de GitHub [23]. Los registros de Milán y Roma se han obtenido de esta fuente. Los casos infectados diarios de COVID-19 para Barcelona y Madrid se han recuperado del repositorio abierto para casos agregados de COVID-19 que mantiene el Ministerio de Salud de España [24]. Excepto Barcelona, los datos de los casos infectados para las otras tres ciudades están disponibles del 25 de febrero al 31 de mayo de 2020. Las figuras 7 y 8 representan los casos de infección por COVID-19 diarios para Madrid y Barcelona de España y Milán y Roma de Italia. Para percibir el efecto de la contención sobre la propagación de la pandemia, se han representado las fases de confinamiento para ambos países (utilizando líneas verticales) en ambos gráficos.

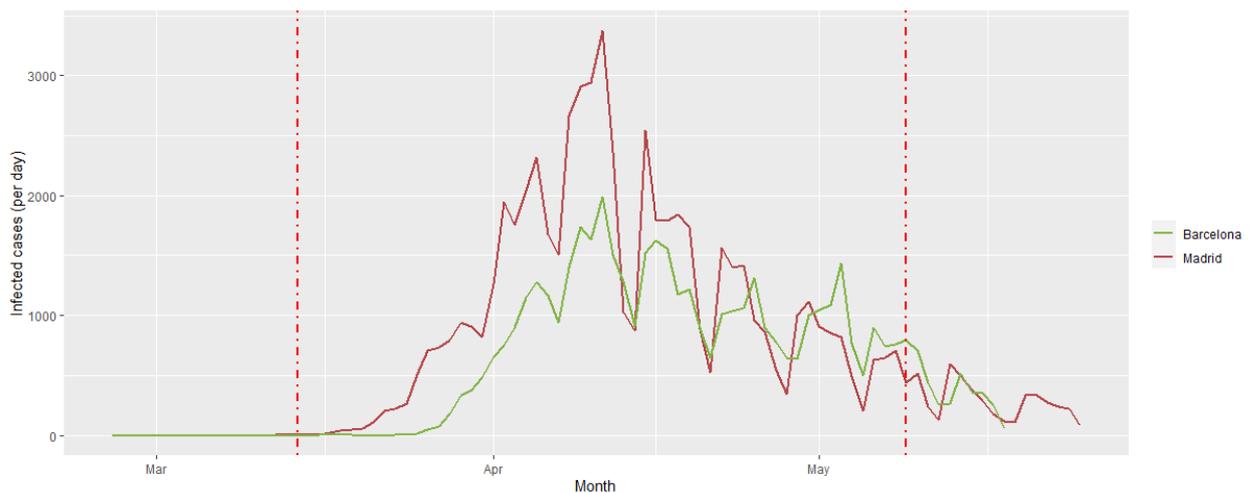


Figura 7: Número de casos diarios de COVID-19 en Madrid y Barcelona (España)
(Líneas verticales: periodo confinamiento)

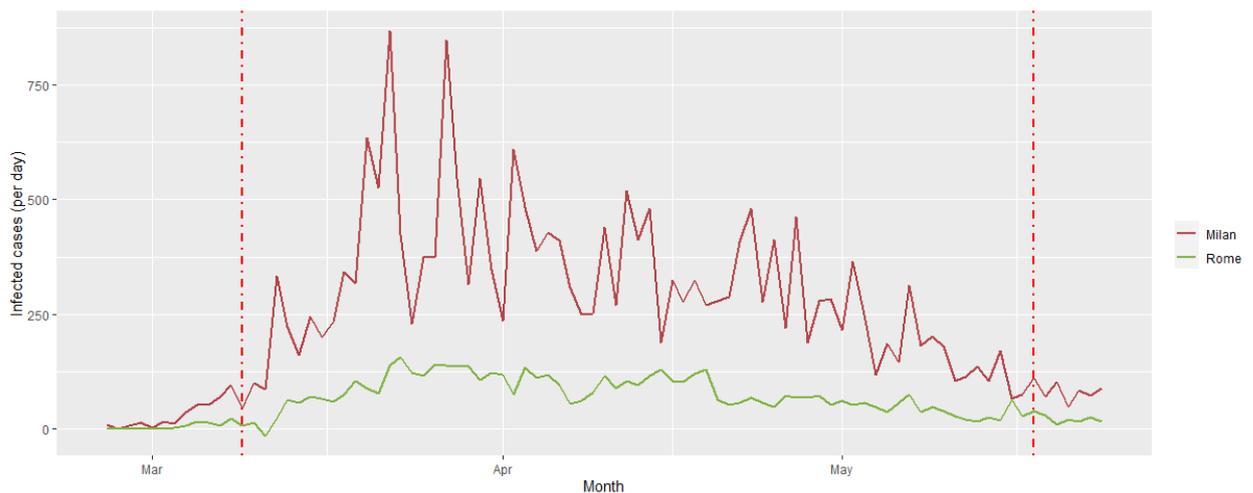


Figura 8: Número de casos diarios de COVID-19 en Roma y Milán (Italia)
(Líneas verticales: periodo confinamiento)

Todos los datos utilizados en el estudio se recopilan de fuentes sin restricciones de derechos de autor, patentes u otros mecanismos de control.

5. METODOLOGÍA

Los datos de series de tiempo utilizados en este estudio se agregaron sobre una base de tiempo diario, y se considera el problema de la predicción de los contaminantes de la contaminación del aire con el valor esperado de las víctimas de COVID-19 y las covariables meteorológicas, utilizando análisis bayesiano jerárquico. Los datos de los diferentes contaminantes del aire (PM₁₀, NO₂) están definidos en una dimensión, lo que da como resultado un proceso estocástico.

$$Y(t) \equiv \{y(t): t = 1, \dots, n\} \quad (1)$$

donde $\{t: t = 1, \dots, n\}$ es un conjunto de puntos o nodos de una cuadrícula unidimensional definida en el eje del tiempo. Los datos $y = \{y(t_1), \dots, y(t_n)\}$ representan un análogo de los datos agregados por área comúnmente usados en estadísticas espaciales.

Las variables de interés son los contaminantes del aire (PM₁₀, NO₂), $y_t = \text{Normal}(\mu_j, \sigma^2)$ y su asociación con un conjunto de covariables relacionadas con las variables meteorológicas y afectados por COVID-19. Para el tiempo t , el uso de la función de enlace canónico,

$$\eta_j = g(\mu_j) \quad (2)$$

relacionar la variable de respuesta con las covariables usando una relación lineal de la forma,

$$\eta_i = \beta_{0j} + \sum_{m=1}^M \beta_m z_{mj} + \sum_{l=1}^L f_l(v_{lj}) \quad (3)$$

donde β_{0j} es un escalar que representa la intersección, $\beta = (\beta_1, \dots, \beta_m)$ son los coeficientes que cuantifican el efecto de algunas covariables $z_j = (z_{1j}, \dots, z_{mj})$ sobre la respuesta, y $f = \{f_1(\cdot), \dots, f_L(\cdot)\}$ es una colección de funciones definidas en términos de un conjunto de covariables $v = (v_1, \dots, v_L)$, estructuradas. A partir de esta definición, variando la forma de las funciones $f_l(\cdot)$ se puede estimar diferentes tipos de modelos, desde regresión estándar y jerárquica, hasta modelos espaciales y espacio-temporales desarrollados en distintos trabajos ([25], [26], [27], [28] y [29]).

Usando las covariables disponibles, el modelo completo toma la forma

$$\eta_{it}(y_{it}) = \beta_0 + \beta_1 z_{temp} + \beta_2 z_{wind_g} + \beta_3 z_{pre} + \beta_4 z_{hum} + \beta_5 z_{wind_s} + \beta_6 z_{dew} + \beta_7 z_{affected-COVID-19} + u_i + \gamma_t \quad (4)$$

donde β_0 representa la intersección, tiempo t , $z_{(\alpha, t)}$ las covariables (temperatura, viento-g, velocidad del viento, presión, humedad, rocío y afectado por COVID-19), β_α los coeficientes asociados con las covariables, u_i la dependencia no estructurada y γ_t la dependencia temporal.

Las covariables se dividieron en un grupo G1, relacionado con las variables meteorológico (temperatura, viento-g, velocidad del viento, presión, humedad, punto de rocío) y los afectados por COVID-19. Para cada ciudad, se ajustaron seis modelos que combinaban covariables en G1 y afectados.

Estos modelos son comparados con el criterio de información de la desviación (DIC), el cual es un criterio de comparación bayesiano dado por:

$$DIC = D(\bar{\theta}) + 2p_D \quad (5)$$

donde $D(\bar{\theta})$ es la desviación evaluada en la media posterior y p_D es el número de parámetros efectivos que evalúa la complejidad del modelo.

Por otra parte, la validación cruzada (CPO), expresa la probabilidad posterior de las observaciones:

$$CPO = \pi(y_i^{obs} | y_{-i}) \quad (6)$$

Donde, y_{-i} es la observación y si eliminamos el elemento i . Esto facilita la validación cruzada y se calcula como $\left(-\left(\text{mean}(\log(CPO))\right)\right)$ (7).

Con ello, tanto DIC como $\left(-\left(\text{mean}(\log(CPO))\right)\right)$ sugieren un mejor modelo si disminuyen.

Los coeficientes utilizados son adimensionales.

6. RESULTADOS

La tabla 3 muestra los valores estadísticos obtenidos de los contaminantes atmosféricos considerados, los parámetros meteorológicos y los casos de COVID-19 infectados diariamente.

Tabla 3: Resumen de los valores estadísticos obtenidos diariamente.

Ciudad		Contaminante		Parámetros meteorológicos					Casos infectados	
		NO ₂	PM ₁₀	DEW	HR	P	T	WG		WS
Madrid	Min.	3,2	4,4	-2,0	38,0	1005,0	4,0	4,4	1,9	0,0
	Mediana	1,9	10,5	7,0	65,6	1014,0	12,8	9,2	3,5	488,0
	Media	22,7	14,4	6,5	65,8	1015,0	12,3	10,8	4,4	736,8
	Max.	69,2	83,3	12,0	92,0	1024,0	18,1	34,2	17,3	3374,0
Barcelona	Min.	5,2	5,4	1,0	55,5	998,2	8,4	3,1	1,1	0,0
	Mediana	17,6	17,8	8,5	76,7	1016,6	13,8	6,7	2,5	481,0
	Media	20,7	19,3	8,5	75,8	1016,3	13,6	8,1	2,9	567,4
	Max.	50,6	69,3	15,5	94,8	1027,0	17,2	18,8	7,0	1992,0
Milán	Min.	10,6	8,2	-11,0	24,9	998,5	5,0	1,5	0,7	0,0
	Mediana	25,5	23,6	3,0	56,8	1016,0	11,9	3,0	1,5	235,0
	Media	28,0	25,7	2,6	57,6	1016,1	11,8	4,3	1,9	254,1
	Max.	55,0	87,9	12,0	92,0	1028,7	18,1	13,3	5,1	868,0
Roma	Min.	7,6	8,3	-5,5	37,0	999,7	5,2	2,5	1,1	0,0
	Mediana	21,8	19,7	7,0	70,9	1012,5	13,2	5,9	2,5	58,0
	Media	21,9	23,0	6,3	69,7	1013,1	13,1	7,3	2,9	62,7
	Max.	37,9	63,0	14,5	93,0	1025,9	17,5	18,3	8,2	156,0

NO₂: µg/m³; PM₁₀: µg/m³; DEW: punto de rocío (°C); HR: Humedad relativa (%); P: presión (hPa); T: temperatura (°C); WG: Ráfaga de viento (kts); WS: Velocidad de viento (kts).

Las tablas de la 4 a la 7 presentan los resultados de los modelos jerárquicos según la expresión (4) para cada contaminante por ciudad. Se probaron 7 modelos. En estas tablas, las filas se refieren al número de modelo ajustado y las columnas a las covariables disponibles para su inclusión en los diferentes modelos. Las celdas blancas representan las covariables que se han incluido en cada modelo, mientras que las celdas grises son las que no están incluidas.

Tabla 4: Coeficientes adimensionales de los modelos (β_α) para Madrid

Modelo	Parámetros Meteorológicos						Afectados	Tiempo
	DEW	HR	P	T	WG	WS		
1- PM ₁₀							0.001	
2- PM ₁₀	-0.052	-0.008	0.001	0.125	0.117	-0.175		
3- PM ₁₀								
4- PM ₁₀	-0.089	0.000	-0.001	0.225	0.111	-0.101	0.000	
5- PM ₁₀							0.003	
6- PM ₁₀	0.040	-0.017	0.005	-0.012	0.162	-0.431		
7- PM ₁₀	0.036	-0.013	0.004	0.025	0.117	-0.348	0.001	
1 - NO ₂							0.002	
2 - NO ₂	-0.111	0.000	0.002	0.116	0.129	-0.226		
3 - NO ₂								
4 - NO ₂	-0.143	0.006	0.000	0.203	0.124	-0.162	0.000	
5 - NO ₂							0.004	
6 - NO ₂	0.038	-0.020	0.007	-0.102	0.163	-0.500		
7 - NO ₂	0.042	-0.015	0.006	-0.061	0.109	-0.403	0.001	

DEW: punto de rocío; HR: Humedad relativa; P: presión; T: temperatura; WG: Ráfaga de viento; WS: Velocidad de viento; Negrita significativo; Celda en Gris no aparece en el modelo.

Tabla 5: Coeficientes adimensionales de los modelos (β_α) para Barcelona

Modelo	Parámetros Meteorológicos						Afectados	Tiempo
	DEW	HR	P	T	DEW	H		
1- PM ₁₀							0.002	
2- PM ₁₀	0.044	-0.018	0.004	-0.027	-0.029	0.004		
3- PM ₁₀								
4- PM ₁₀	0.045	-0.020	0.004	-0.018	-0.037	0.022	0.000	
5- PM ₁₀							0.005	
6- PM ₁₀	0.015	-0.009	0.005	-0.074	0.027	-0.163		
7- PM ₁₀	-0.028	-0.002	0.002	0.103	0.014	-0.138	0.002	
1- NO ₂							0.002	
2- NO ₂	0.063	-0.019	0.006	-0.113	-0.142	0.148		
3- NO ₂								
4- NO ₂	0.062	-0.018	0.006	-0.117	-0.138	0.140	0.000	
5- NO ₂							0.005	
6- NO ₂	0.021	-0.007	0.007	-0.179	-0.044	-0.129		
7- NO ₂	-0.022	-0.001	0.004	-0.004	-0.057	-	0.002	
						0.0103		

DEW: punto de rocío; HR: Humedad relativa; P: presión; T: temperatura; WG: Ráfaga de viento; WS: Velocidad de viento; Negrita significativo; Celda en Gris no aparece en el modelo.

Por otro lado, los coeficientes significativos son los marcados en negrita. Como se puede observar, algunos modelos incluyen solo los casos afectados, otros el tiempo o las covariables meteorológicas, y el resto incluye una combinación de todas las covariables. Como el volumen de covariables es alto, solo se incluye en los modelos la combinación de algunas de ellas que son de interés porque el método INLA no permite la selección automática de variables.

Tabla 6: Coeficientes adimensionales de los modelos (β_α) para Milán.

Modelo	Parámetros Meteorológicos						Afectados	Tiempo
	DEW	HR	P	T	DEW	H		
1- PM ₁₀							0.008	
2- PM ₁₀	0.064	-0.011	0.004	-0.038	0.038	-0.234		
3- PM ₁₀								
4- PM ₁₀	-0.095	0.034	0.000	0.058	0.020	-0.209	0.004	
5- PM ₁₀							0.01	
6- PM ₁₀	0.180	-0.046	0.007	-0.066	0.088	-0.193		
7- PM ₁₀	0.210	-0.047	0.006	-0.094	0.000	0.159	0.003	
1- NO ₂							0.008	
2- NO ₂	-0.026	0.004	0.004	-0.021	0.020	-0.337		
3- NO ₂								
4- NO ₂	-0.168	0.044	0.000	0.064	0.004	-0.314	0.003	
5- NO ₂							0.01	
6- NO ₂	0.199	-0.064	0.009	-0.135	0.070	-0.165		
7- NO ₂	0.203	-0.058	0.008	-0.141	-0.016	0.157	0.002	

DEW: punto de rocío; HR: Humedad relativa; P: presión; T: temperatura; WG: Ráfaga de viento; WS: Velocidad de viento; Negrita significativo; Celda en Gris no aparece en el modelo.

Tabla 7: Coeficientes adimensionales de los modelos (β_α) para Roma.

Modelo	Parámetros Meteorológicos						Afectados	Tiempo
	DEW	HR	P	T	DEW	H		
1- PM ₁₀							0.032	
2- PM ₁₀	-0.029	0.009	0.001	0.090	0.171	-0.367		
3- PM ₁₀								
4- PM ₁₀	0.079	-0.005	0.001	0.010	0.159	-0.179	0.017	
5- PM ₁₀							0.045	
6- PM ₁₀	0.019	0.000	0.003	0.059	0.250	-0.561		
7- PM ₁₀	0.011	0.000	0.002	0.062	0.200	-0.402	0.011	
1- NO ₂								
2- NO ₂							0.031	
3- NO ₂	0.039	-0.001	0.004	-0.079	0.166	-0.428		
4- NO ₂								
5- NO ₂	0.117	-0.012	0.004	-0.138	0.158	-0.291	0.013	
6- NO ₂							0.038	
7- NO ₂	0.052	-0.013	0.005	-0.107	0.136	-0.383	0.012	

DEW: punto de rocío; HR: Humedad relativa; P: presión; T: temperatura; WG: Ráfaga de viento; WS: Velocidad de viento; Negrita significativo; Celda en Gris no aparece en el modelo.

Para poder discernir cuál es el modelo más apropiado se calculan los valores de DIC (expresión 5) y CPO (expresión 7) los valores obtenidos se presentan en las tablas 8 y 9 para cada modelo y ciudad. Son elementos de comparación sin unidades.

Tabla 8: Madrid - Barcelona. DIC - CPO (adimensional)

Modelo	DIC - Ma	CPO - Ma	DIC - Bar	CPO - Bar
1- PM ₁₀	413.79	2.1498	433.78	2.2519
2- PM ₁₀	384.05	1.9824	400.18	2.0559
3- PM ₁₀	453.46	2.3573	479.41	2.4917
4- PM ₁₀	384.15	1.9819	402.18	2.0625
5- PM ₁₀	143.46	1.4975	352.00	1.7938
6- PM ₁₀	-12.08	1.0120	341.58	1.7249
7- PM₁₀	59.60	0.9661	336.86	1.6978
1- NO ₂	441.03	1.0596	440.542	2.2887
2- NO ₂	411.32	2.1265	404.43	2.0786
3- NO ₂	482.38	2.5080	481.88	2.5048
4- NO ₂	412.30	2.1296	406.49	2.0852
5- NO ₂	241.08	1.6437	345.22	1.7546
6- NO ₂	-445.22	-1.4324	333.55	1.6818
7- NO₂	-434.54	-1.3699	328.14	1.6489

Tabla 9: Milán - Rome. DIC - CPO (adimensional)

Modelo	DIC - Mi	CPO - Mi	DIC - Ro	CPO - Ro
1- PM ₁₀	332.11	2.0010	330.49	1.9857
2- PM ₁₀	313.09	1.8567	325.70	1.9437
3- PM ₁₀	-382.79	-1.6044	-383.27	-1.6043
4- PM ₁₀	291.16	1.7446	305.15	1.8353
5- PM ₁₀	284.07	1.7433	139.95	1.2674
6- PM ₁₀	91.65	1.1643	-382.36	-1.4532
7- PM₁₀	9.01	1.0465	-377.96	-1.4030
1- NO ₂	341.46	2.1063	329.92	2.0313
2- NO ₂	313.04	1.9026	306.17	1.8743
3- NO ₂	-376.05	-1.6319	-376.42	-1.6331
4- NO ₂	298.40	1.8288	295.10	1.8201
5- NO ₂	257.91	1.7045	-373.79	-1.5320
6- NO ₂	-365.88	-1.3696	-365.15	-1.3374
7- NO₂	-363.36	-1.3733	-362.54	-1.2925

7. DISCUSIÓN

Considerando los valores estadísticos presentados en la tabla 3 y teniendo en cuenta que como se mencionó anteriormente, las cuatro ciudades analizadas son algunas de las ciudades europeas más afectadas por COVID-19, se observan diferencias significativas según los valores mostrados de los contaminantes atmosféricos y las variables meteorológicas.

En relación al NO_2 , las dos ciudades italianas tienen el valor mínimo más alto y, en particular, Milán es la que tiene la media más alta en comparación con las 4 ciudades analizadas. También es interesante observar la alta dispersión que presentan los datos de Madrid, con valores desde 3 hasta un máximo de 69. Este patrón se repite también para PM_{10} . Por lo que en general, las ciudades españolas tienen una mejor calidad de aire.

En cuanto a las variables meteorológicas, por un lado, no se observaron diferencias significativas en relación a la presión o la temperatura, aunque Barcelona destaca como la ciudad con mayor temperatura mínima. En cambio, en el caso de la humedad, Barcelona es la que tiene los valores más altos y Milán la más baja, ya sea observando los valores mínimos, máximos o el valor medio registrado. Estas diferencias están directamente relacionadas con los valores del punto de rocío. Barcelona es la ciudad con mayores valores de punto de rocío y Milán destaca por tener el valor mínimo más bajo, así como la media y mediana más bajas. En cuanto a la racha y la velocidad del viento, las ciudades españolas son las que presentan los valores más altos, aunque Madrid destaca por sus valores altos y Milán por sus valores bajos.

Finalmente, en cuanto a los casos infectados, se observa un claro gradiente negativo, siendo Madrid la ciudad con mayor número de casos, seguida de Barcelona, Milán y finalmente Roma, que es la que presenta el menor valor de casos. Además, cabe señalar que la media de Milán es la mitad que la de Barcelona y que la media de casos en Roma es una cuarta parte que, en Milán, por lo que las diferencias aquí son claras y bastante pronunciadas.

Por otro lado, teniendo en cuenta los valores de DIC y CPO (Tablas 8 y 9) en todas las ciudades, el modelo número 7 parece superar a todos los demás modelos diseñados y ejecutados en el estudio. El modelo 7 incluye todas las covariables, a saber, meteorológicas, número diario de pacientes afectados por COVID-19 y componente de tiempo informado en las Tablas 4, 5, 6 y 7. Los coeficientes significativos de las covariables incluidas se resaltan en negrita en las tablas mencionadas. Al comparar los coeficientes significativos en el modelo 7, se observa que los componentes meteorológicos en el caso de Barcelona no son importantes con respecto al mismo modelo de Madrid. En el modelo 7 de Madrid, la presión del punto de rocío, la temperatura, la ráfaga y la velocidad del viento son significativas para PM_{10} , mientras que la presión, la ráfaga y la velocidad del viento son significativas para el NO_2 . La velocidad del viento en ambos modelos está teniendo un efecto negativo en la concentración de PM_{10} y NO_2 .

En el caso del modelo 7 para Milán, el punto de rocío y la presión son positivamente significativos, mientras que la humedad tiene un efecto negativo tanto para PM_{10} como para NO_2 . Por otro lado, el modelo 7 para Roma tiene coeficiente positivo para la presión y ráfaga de viento, mientras que el coeficiente negativo para la velocidad del viento tanto en el caso del modelo PM_{10} como NO_2 . Pero en el caso del modelo NO_2 , el punto de rocío también tiene un efecto positivo. En general, los resultados del modelo de Roma son similares a los de Milán, los

datos afectados son más representativos en el modelo y muchos coeficientes de datos meteorológicos son significativos.

Cabe mencionar que, en todos los modelos, cuando se incluye la covariable que representa el número diario de pacientes infectados por COVID-19, son significativas en las cuatro ciudades de estudio para los modelos tanto de PM₁₀ como de NO₂. En general, la covariable afectada tiene coeficientes positivos en todos los modelos.

8. CONCLUSIONES

En este estudio, se aporta nueva información respecto a la literatura existente sobre la incidencia de COVID-19 en relación a la contaminación atmosférica y las variables meteorológicas, se aportan diferentes modelos estadísticos para este fin. Asimismo, se incorpora la variable tiempo (momentos antes y después de la pandemia). Este estudio se ha realizado en 4 ciudades, 2 de España y 2 de Italia, dos de los países europeos más afectados por el virus COVID-19.

Muchas investigaciones sobre COVID-19 han considerado variables meteorológicas, temperatura en la mayoría [30], o variables de contaminación [31], pero prácticamente no hay artículos que combinen estos dos tipos de variables al mismo tiempo, como se realiza en este estudio, y sobretodo con el uso de la metodología bayesiana.

Así, en este trabajo se consideran seis variables relacionadas con la meteorología y dos de la contaminación del aire que, combinadas en un mismo modelo, brindan mucha más información. Otro punto fuerte de nuestra investigación es el efecto temporal, no siempre presente en este tipo de estudios. Como se muestra en los distintos modelos, y sobretodo en los gráficos que muestran la variación temporal, este es un elemento a tener siempre en cuenta en todos los estudios de esta índole. Reforzando el estudio con la componente espacial, se consideran cuatro ciudades diferentes que permiten comparar y encontrar diferencias entre Italia y España.

En cualquier caso, se han estimado distintos modelos para ver el efecto de cada una de las variables explicativas consideradas. Primero se ha estimado un modelo en el que solo se han incluido variables meteorológicas, luego otro con solo variables de contaminación, otro en el que se combinaron las dos, otro en el que se incluyó el tiempo y todos estos para cada una de las 4 ciudades de estudio. En total 24 modelos que nos han permitido sacar conclusiones concretas y determinar qué variables inciden en el número de casos de COVID-19. Nuestros resultados llevan a la conclusión de que existe una asociación débil pero significativa entre el número de víctimas de COVID-19 con dichas variables. Se hace necesario el uso del mayor número de componentes que den variación al estudio, y todo ello con variación temporal markoviana, es decir, teniendo en cuenta los momentos previos. Solo el efecto espacial es un elemento no incluido en el estudio, ya que se han analizado las ciudades por separado. Todo ello, en resumen, hace que el trabajo aporte la novedad de la modelización de elementos contaminantes con la inclusión no solo de variables meteorológicas y afectados por COVID-19 por separado, sino todas juntas y además con la inclusión del efecto modelado del tiempo.

9. BIBLIOGRAFIA

- [1] Cui, Y., Zhang, Z. F., Froines, J., Zhao, J., Wang, H., Yu, S. Z., Detels, R. 2003. Air pollution and case fatality of SARS in the People's Republic of China: an ecologic study. *Environmental Health*, 2 (1), 15.
- [2] Conticini, E., Frediani, B., Caro, D. 2020. Can atmospheric pollution be considered a co-factor in extremely high level of SARS-CoV-2 lethality in Northern Italy?. *Environmental pollution*, 261, 114465.
- [3] Setti, L., Passarini, F., De Gennaro, G., Baribieri, P., Perrone, M. G., Borelli, M., ... & Ruscio, M. 2020. SARS-Cov-2 RNA Found on Particulate Matter of Bergamo in Northern Italy: First Preliminary Evidence. *Environmental Research* 188, 109754.
- [4] Ogen, Y. 2020. Assessing nitrogen dioxide (NO₂) levels as a contributing factor to the coronavirus (COVID-19) fatality rate. *Science of the Total Environment*. 726, 138605.
- [5] Vicente, A.B., Jordán, M.M., Sanfeliu, T., Sánchez, A., Ma D., Esteban M^º D. 2012 Air pollution prediction models of particles, As, Cd, Ni and Pb in a highly industrialized area in Castellón (NE, Spain) *Environmental Earth Science* 66, 879-888.
- [6] Li, X., Liu, W., Chen, Z., Zeng, G., Hu., Ch., León, T., Liang, J., Huang, G., Gao, Z., Li, Z., Yan, W., He, X., Lai, M., He, Y. 2015. The application of semicircular-buffer-based land use regression models incorporation wind direction in predicting quarterly NO₂ and PM₁₀ concentrations. *Atmospheric Environment* 10, 18-24.
- [7] Plocoste, T., Calif., R., Euphrasie-Clotilde, L., Brute., F.N. 2020. Investigation of local correlations between particulate matter (PM₁₀) and air temperature in the Caribbean using Ensemble Empirical Mode Decomposition. *Atmospheric Pollution Research* 11 (10) 1692-1704.
- [8] Contini, D. y Costabile, F. 2020. Does Air Pollution Influence COVID-19 Outbreaks? *Atmosphere* 11(4), 377.
- [9] ECDC. (2020). Search | European Centre for Disease Prevention and Control. Retrieved May 19, 2020, from <https://www.ecdc.europa.eu/en/search?s=reproduction+number>
- [10] INbase (2020) <https://www.ine.es/dyngs/INEbase/>
- [11] EuroMOMO. (2020). EUROMOMO. Retrieved May 21, 2020, from <https://www.euromomo.eu/>
- [12] Cuevas, C.A., Notario, A., Adame, J.A., Hilboll, A., Richter, A., Burrows, J.P., Saiz-López, A. 2014. Evolution of NO₂ levels in Spain from 1996 to 2012. *Nature Scientific Reports* 4, 5887
- [13] Gómez-Losada, A., Santos, F.M., Gibert, K., Pires, J.C.M. 2019. A data science approach for spatiotemporal modelling of low and resident air pollution in Madrid (Spain): Implications for epidemiological studies. *Computers, Environment and Urban Systems* 75, 1-11.

- [14] Pey, J., Alastuey, A., Querol, X., Rodríguez, S. 2010. Monitoring of sources and atmospheric processes controlling air quality in an urban Mediterranean environment. *Atmospheric Environment* 44, 4879-4890.
- [15] Battista G., Vollaro, R. d L. 2017. Correlation between air pollution and weather data in urban areas: Assessment of the city of Rome (Italy) as spatially and temporally independent regarding pollutants. *Atmospheric Environment* 2017, 240-247.
- [16] Marcazzan, G.M., Ceriani, M., Valli, G.V., Vecchi, R. 2003. Source apportionment of PM₁₀ and PM_{2.5} in Milan (Italy) using receptor modelling. *The Science of the Total Environment* 317, 137-147.
- [17] Lopez, L. R., y Rodo, X. 2020. A modified SEIR model to predict the COVID-19 outbreak in Spain: simulating control scenarios and multi-scale epidemics. MedRxiv, 2020.03.27.20045005. <https://doi.org/10.1101/2020.03.27.20045005>
- [18] Agenzia Regionale per la Protezione Ambientale della Toscana. <http://www.arpat.toscana.it>. Accessed 26 April 2020.
- [19] Madrid, Servicio de Protección de la Atmósfera. <http://www.mambiente.madrid.es/opencms/opencms/calaire>. Accessed 26 April 2020.
- [20] Agencia Europea de Medio Ambiente. <https://www.eea.europa.eu>. Accessed 26 April 2020.
- [21] Informació, tràmits i serveis de la Generalitat de Catalunya. <http://web.gencat.cat/ca/inici>. Accessed 26 April 2020.
- [22] World Air Quality Index project. <https://aqicn.org>. Accessed 26 April 2020. Ministry of Health, Consumption and Social Welfare, Spain. <https://www.mscbs.gob.es>. Accessed 26 April 2020.
- [23] COVID-19 Italia - Monitoraggio Situazione. <https://github.com/pcm-dpc/COVID-19>. Accessed 26 April 2020.
- [24] Situation of COVID-19 in Spain, Ministry of Health, Consumption and Social Welfare. <https://covid19.isciii.es>. Accessed 26 April 2020.
- [25] Briz-Redón, Á., & Serrano-Aroca, Á. A spatio-temporal analysis for exploring the effect of temperature on COVID-19 early evolution in Spain. *Science of The Total Environment*. (2020). 138811.
- [26] Illian, J. B., Sørbye, S. H., & Rue, H. A toolbox for fitting complex spatial point process models using integrated nested Laplace approximation (INLA). *The Annals of Applied Statistics*. (2012). 1499-1530.
- [27] R-INLA project. <http://www.r-inla.org/home>. Accessed 17 April 2020
- [28] Rue, H., & Held, L. *Gaussian Markov random fields: theory and applications*. CRC press. (2005).

- [29] Rue, H., Martino, S., & Chopin, N. Approximate Bayesian inference for latent Gaussian models by using integrated nested Laplace approximations. *Journal of the royal statistical society: Series b (statistical methodology)*. (2009). 71(2), 319-392.
- [30]Oliveiros, B., Caramelo, L., Ferreira, N. C., & Caramelo, F. Role of temperature and humidity in the modulation of the doubling time of COVID-19 cases. *medRxiv*. (2020).
- [31]Conticini, E., Frediani, B., & Caro, D. Can atmospheric pollution be considered a co-factor in extremely high level of SARS-CoV-2 lethality in Northern Italy?. *Environmental Pollution*. (2020). 114465.