



# Características socioeconómicas, medidas gubernamentales y resultados sanitarios de COVID-19

## *Socioeconomic characteristics, containment measures and health outcomes of COVID-19*

Tomás Gómez Rodríguez<sup>1</sup>, Arturo Martínez Camacho<sup>1</sup>,  
Humberto Ríos Bolívar<sup>2</sup> \*

<sup>1</sup>Universidad Autónoma del Estado de Hidalgo, México

<sup>2</sup>Instituto Politécnico Nacional, México

Recibido el 19 de julio de 2021; aceptado el 20 de septiembre de 2021

Disponible en Internet el: 21 de septiembre de 2021

### Resumen

Se analiza el impacto de las características socioeconómicas pre existentes a la pandemia, así como las medidas tomadas por los distintos gobiernos para reducir los efectos de la pandemia de COVID-19, con el fin de examinar su contribución al número de casos y decesos. Para analizar estas propuestas se emplean dos muestras. Ambas muestras se conforman con datos de 187 países organizados en forma transversal, el método de estimación es Mínimos Cuadrados Ordinarios. Los resultados muestran evidencia de que las variables PIB per cápita y gastos sanitarios (DE) tienen una relación positiva con los casos totales de COVID-19 por millón. Mientras que la variable pobreza extrema muestra evidencia de una relación negativa con respecto al número de casos y decesos totales por millón. Por otro lado, se encuentra evidencia de una relación positiva entre el número de decesos totales por millón (DM) y las variables índice de repuesta gubernamental (IRG) y gastos sanitarios.

---

\* Autor para correspondencia

Correo electrónico: [hrrios@ipn.mx](mailto:hrrios@ipn.mx) (H. Ríos Bolívar).

La revisión por pares es responsabilidad de la Universidad Nacional Autónoma de México.

<http://dx.doi.org/10.22201/fca.24488410e.2021.3485>

0186- 1042/© 2019 Universidad Nacional Autónoma de México, Facultad de Contaduría y Administración. Este es un artículo Open Access bajo la licencia CC BY-NC-SA (<https://creativecommons.org/licenses/by-nc-sa/4.0/>)

*Código JEL:* C31, E00, E66, H51, H12

*Palabras clave:* características socioeconómicas; resultados sanitarios; pobreza extrema; COVID-19; medidas de contención y mitigación

## **Abstract**

The impact of pre-pandemic socioeconomic characteristics, as well as the measures taken by different governments to reduce the effects of the COVID-19 pandemic, are analyzed in order to examine their contribution to the number of cases and deaths. Two samples are used to analyze these proposals. Both samples are made up of data from 187 countries organized in a cross-sectional manner, the estimation method is Ordinary Least Squares. The results show evidence that the variables GDP per capita and health expenditure (DE) have a positive relationship with the total cases of COVID-19 per million. While the extreme poverty variable shows evidence of a negative relationship with respect to the number of cases and total deaths per million. On the other hand, there is evidence of a positive relationship between the number of total deaths per million (DM) and the variables government response index (IRG) and health expenditures.

*JEL Code:* C31, E00, E66, H51, H12

*Keywords:* socioeconomic characteristics; health outcomes; extreme poverty; COVID-19; containment and mitigation measures

---

## **Introducción**

El primer caso de COVID-19 (una enfermedad infecciosa causada por el nuevo tipo de coronavirus SARS-CoV-2), se detectó en la ciudad de Wuhan en noviembre de 2019 (aunque no se conoce el origen exacto de la enfermedad, debido a que el virus puede haber estado en circulación en otros lugares antes de su detección en Wuhan). En poco tiempo esta enfermedad comenzó a extenderse por el resto de China, y varios meses después también se detectó un número creciente de casos en otros países. (Wu, 2021). Finalmente, el 11 de marzo de 2020 la Organización Mundial de la Salud declaró la existencia de una pandemia global provocada por el COVID-19. El 1 de abril de 2020 la Organización Mundial de la Salud reportó que se habían detectado aproximadamente 823 626 casos confirmados y 40 598 decesos alrededor del mundo (Chaudhry et al., 2020). Con la rápida propagación global del patógeno y las profundas alteraciones de la vida social, pronto quedó claro que el COVID-19 se ha convertido en la peor pandemia en más de un siglo (Wu, 2021).

Dada la escala y la gravedad sin precedentes del brote de COVID-19, es importante estudiar cuales podrían ser los determinantes a nivel macro del riesgo de enfermedades infecciosas (Morens y

Fauci, 2020). Por tanto, es importante identificar los predictores socioeconómicos y sanitarios para afinar las medidas sociales y económicas para una gestión eficaz de la pandemia (Wu, 2021).

Uno de estos factores puede ser el crecimiento de la concentración y de la conectividad urbana esto significa que una vez que los patógenos han infectado poblaciones humanas, estos patógenos se propagan más rápido y tienen más alcance que antes (Alirol et al., 2011). A medida que los centros urbanos alrededor del mundo se convirtieron en epicentros de transmisión de COVID-19, se volvió evidente la dificultad de mantener la distancia social y otras medidas de contención en áreas densamente pobladas.

Por otro lado, el crecimiento de la población urbana suele ir acompañada de la construcción de infraestructura de comunicación (vías férreas, carreteras, aeropuertos, etc.) a gran escala. Por tanto, los centros urbanos del mundo también se han convertido en nodos cruciales del comercio y de los viajes internacionales (Wu, 2021). Esta mayor conectividad por un lado ha facilitado el rápido crecimiento del comercio, pero, por otro lado, afecta la propagación del SARS-CoV-2 ya que esto podría estar asociada al desarrollo de las redes de comercio y viajes aumentado su alcance (Wu, 2021).

Por otro lado, durante la actual pandemia los gobiernos de todo el mundo han tomado medidas no farmacéuticas, han aplicado restricciones sociales y han prestado apoyo económico en diversos grados. Entre estas medidas se encuentran el cierre de escuelas y lugares de trabajo, las restricciones a los viajes internacionales y las políticas de análisis y seguimiento entre otras. Para que las políticas dirigidas por los gobiernos reduzcan significativamente el número de casos, así como el número de decesos en particular entre los grupos menos favorecidos, es necesario identificar y orientar los factores sociales, económicos y determinantes de la salud de la población. Ya que por ejemplo es menos probable que las personas que viven en condiciones socioeconómicas precarias observen la distancia social. Así mismo, Lou et al. (2020) y Wright et al. (2020) encuentran que el cumplimiento de las ordenes de mantenerse en casa durante la pandemia de COVID-19 varía significativamente cuando se considera el ingreso de las personas. Además de que observan que las personas con bajos ingresos están más expuestas al virus durante sus viajes al trabajo (Ashraf, 2020).

Debido a las razones antes mencionadas es importante identificar los predictores socioeconómicos y sanitarios para afinar las medidas sociales y económicas para una gestión eficaz de la pandemia actual, así como otras que puedan presentarse en el futuro (Javaheri, 2021). En este mismo sentido Braveman y Gottlieb (2014) argumentan que los factores socioeconómicos los cuales pueden incluir ingreso, riqueza, empleo y educación entre otros pueden ser los impulsores fundamentales de los resultados en materia de salud y resaltan la necesidad de seguir investigando el impacto de estos factores (Ashraf 2020).

Estudios previos sobre este tema han reportado que un mayor índice de mortalidad está asociado con factores como la riqueza, clases sociales y etnicidad de acuerdo a los trabajos de Gkiouleka et al 2018

y Bryan et al. 2020. Por otro lado, en el trabajo de Chen y Krieger (2020) se encuentra que los grupos de personas en desventaja tienen mayor riesgo de mortalidad por COVID-19 (Javaheri, 2021). Ejemplo de lo anterior es que, aunque el 14% de los habitantes de Inglaterra y Gales pertenecen a grupos étnicos asiáticos y minoritarios, alrededor del 35% de los pacientes con COVID-19 en estado crítico son miembros de estos grupos de acuerdo al trabajo de House et al. (2020). Esta disparidad no es exclusiva de la presente pandemia, de hecho, se reporta un mayor índice de mortalidad en países con extrema pobreza de acuerdo al trabajo de Murray et al. (2006). En otros estudios se relacionan los altos índices de mortalidad con factores como pobreza (Mamelund, 2006), desempleo (Grantz et al., 2016) y la clase obrera en países industrializados (Bengtsson et al., 2018) durante la pandemia de influenza de 1918. Durante la pandemia de H1N1, también se reportaron altos índices de mortalidad en grupos desfavorecidos de todo el mundo (Biggerstaff et al., 2014; Lowcock et al., 2012; Rutter et al., 2012; Charu et al. 2011).

Específicamente en este estudio se analiza el impacto de las características socioeconómicas pre existentes a la pandemia de los diferentes países como: gasto de salud, turismo, pobreza extrema, ingreso per cápita entre otros, en conjunción con las medidas tomadas por los distintos gobiernos para reducir los efectos de la pandemia de COVID-19, con el fin de examinar su contribución al número de casos y decesos (Javaheri, 2021). Por tanto, se examina si existe un nexo positivo entre las características socioeconómicas pre pandemia y los resultados sanitarios de la pandemia de COVID-19 (número de casos y decesos). Así mismo se estudia si las medidas de mitigación y contención exhiben una relación negativa con el número de casos y de decesos provocados por la pandemia de COVID-19.

Para analizar estas propuestas se emplean dos muestras. Ambas muestras se conforman con datos de 187 países organizados en forma transversal, el método de estimación es Mínimos Cuadrados Ordinarios. Las variables socioeconómicas utilizan datos pre pandemia. Mientras que los datos de las medidas de mitigación y contención se registran durante la pandemia, específicamente se usan datos al 28 de diciembre de 2020.

Por tanto, el presente estudio contribuye a la literatura reciente sobre la relación entre los resultados sanitarios provocados por la pandemia COVID-19 y las características socioeconómicas en conjunción con las medidas de mitigación y contención de tres maneras importantes: la primera es a través de una amplia base de datos conformada por 187 países. La segunda aportación consiste en utilizar datos actualizados hasta el 28 de diciembre de 2020. Y la última al combinar datos pre pandemia de las características socioeconómicas con datos de las medidas de contención y mitigación registrados durante la pandemia de COVID-19.

El resto del trabajo se divide en las siguientes secciones: en la sección revisión de la literatura se muestran los trabajos relacionados al estudio del nexo entre las características socioeconómicas pre pandemia y los resultados sanitarios de la pandemia de COVID-19, así mismo en esta sección se

consideran los trabajos que analizan la relación entre las medidas de contención y mitigación y los resultados sanitarios de la pandemia. En la sección datos se encuentran la descripción de las variables y sus estadísticas básicas; en la sección metodología se describen los métodos de estimación y los modelos a estimar. En la sección resultados, se presentan los hallazgos y análisis del modelo estimado. Por último, en las conclusiones se consignan las principales aportaciones del estudio.

## **Revisión de la literatura**

El surgimiento de la pandemia de COVID-19 ha dado origen a una rama de la literatura que estudia la relación entre los resultados sanitarios del COVID-19 y los factores socioeconómicos estos estudios en algunos casos también consideran el nexo entre las medidas sanitarias para la contención y mitigación de los efectos de la pandemia COVID-19. Algunos trabajos que estudian esta relación son los de: Javaheri (2020), Ashraf (2021), Wu (2021), Chaudhry et al. (2020), Stojkoski et al. (2020) y Nguimkeu y Tadjadjeu (2021)

En el trabajo de Javaheri (2020) se analiza si los factores socioeconómicos y sanitarios están correlacionados con el resultado de la pandemia de COVID-19. Los datos utilizados provienen de la Comisión COVID-19 de Lancet para los cinco países más afectados por la pandemia. El análisis se realiza mediante los modelos de regresión “ridge” y “extreme gradient boosting”. Los resultados del estudio sugieren que la demografía y las desventajas sociales se correlacionan con la mortalidad por millón de COVID-19. Por otro lado, en el trabajo de Ashraf (2021) se examina el impacto de las condiciones socioeconómicas en los resultados sanitarios por COVID-19. Así mismo se estudia el efecto de las medidas gubernamentales sobre las condiciones socioeconómicas y los resultados sanitarios por COVID-19. Los datos utilizados en este estudio consisten en 9529 observaciones diarias de 80 países en el período que abarca del 22 de enero al 20 de mayo de 2020. Los resultados del estudio muestran que las circunstancias socioeconómicas tienen una asociación negativa fuerte con los casos confirmados y los decesos por millones de personas infectadas por COVID-19. También se encuentra que las medidas estrictas de distanciamiento social y programas generosos de apoyo al ingreso ayudan a disminuir los casos y los decesos en países con condiciones socioeconómicas precarias.

En el trabajo de Wu (2021) se examina si la intensificación de los factores ambientales y socioeconómicos son los que impulsan el surgimiento de nuevas pandemias. El trabajo reseña como la conversión de los ecosistemas, el consumo de carne, la urbanización y la conectividad entre las ciudades y los países; pueden ayudar a explicar la dinámica de la pandemia COVID-19. Así mismo se investigan las políticas que pueden mitigar los riesgos originados por el virus SARS-CoV-2

Empleando datos de los 50 países con más casos de COVID-19 Chaudhry et al. (2020) realizan un análisis exploratorio a nivel país para investigar el impacto del tipo y el tiempo de implementación de las políticas y acciones de salud emprendidas en relación con la mortalidad por COVID-19 y los resultados sanitarios relacionados. La recolección de datos incluyó la acción del gobierno, el nivel de preparación nacional y los factores socioeconómicos específicos del país. Los resultados del estudio muestran que los cierres de frontera, los cierres totales y las pruebas generalizadas no se asociaron con la mortalidad derivada del COVID-19 por millón de personas. Sin embargo, también se encontró que los bajos niveles de preparación nacional, la escala en la realización de las pruebas para detectar COVID-19 y las características de la población se asociaron con un aumento de la carga de casos nacional y la mortalidad general.

Utilizando la técnica de promediado de modelos bayesianos y datos a nivel país Stojkoski et al. (2020) investigan si las características socioeconómicas, pueden explicar el resultado de la primera ola de la pandemia de COVID-19. Ellos obtienen el mapa de conjunto el cual actúa como un puente entre las investigaciones teóricas y las observaciones empíricas y ofrece una visión alternativa de la importancia conjunta de los determinantes socioeconómicos cuando se utilizan para desarrollar políticas destinadas a prevenir futuras crisis epidémicas.

Por último, en el trabajo de Nguimkeu y Tadadjeu (2021) analizan en que medida los factores demográficos y geográficos asociados a la enfermedad explican por qué la gravedad de la nueva pandemia de coronavirus se ha mantenido relativamente baja en el África subsahariana. Para analizar este tema emplean datos disponibles públicos organizados en sección transversal de 182 países de todo el mundo. Además, emplean un análisis de regresión que tiene en cuenta la posible notificación errónea de casos de COVID-19. Sus hallazgos muestran que la proporción de población mayor de 65 años, la densidad de población y la urbanización están significativamente asociadas de forma positiva con un alto número de casos infectados activos, mientras que la temperatura media registrada en el primer trimestre del año 2020 está asociada de forma negativa con este resultado de COVID-19.

Por tanto, el presente estudio se enfoca en el análisis de esta rama de la literatura. Para lo cual se emplean variables socioeconómicas a nivel país con datos pre pandemia que se clasifican de la siguiente manera: gastos en salud, movilidad, ingreso y actividad económica. Así mismo los datos se organizan en un marco transversal lo cual es lo más común en estudios epidemiológicos para analizar la prevalencia<sup>2</sup> de una enfermedad como en los trabajos de Guo et al. (2021), Sasaki et al. (2021) y Callinan et al. (2021). Además, se especifica un análisis de regresión múltiple en un marco lineal como en los trabajos de Nguimkeu y Tadadjeu (2021) y Varkey et al. (2020)

---

<sup>2</sup> La prevalencia es en la proporción de individuos de un grupo o una población que presentan una característica o evento determinado en un momento determinado.

## **Datos**

Para una gestión adecuada de la actual crisis sanitaria es fundamental identificar los factores que se asocian a los resultados sanitarios derivados de la pandemia COVID-19. Esto permitirá a las autoridades responsables prestar el apoyo necesario a las comunidades vulnerables que soportan una carga desproporcionada. Una de las principales limitaciones para determinar la fuente de esta disparidad es la dificultad para obtener datos a nivel de paciente en los que los registros de salud individual y los antecedentes socioeconómicos de los pacientes coincidan con la gravedad de la enfermedad y el resultado (Javaheri, 2021). Un segundo problema que se enfrenta en este tema es que los datos de las condiciones socioeconómicas de los países no tienen una frecuencia diaria.

Un enfoque alternativo para remediar parcialmente estas limitaciones es utilizar datos agregados por países del número de casos, mortalidad por COVID-19, características socioeconómicas pre pandemia y medidas de contención y mitigación adoptadas por los diferentes gobiernos.

Sobre la base de las crecientes pruebas y centrándose en la idea de que los antecedentes socioeconómicos y sanitarios están relacionados con los resultados sanitarios de la pandemia de COVID-19, este estudio: i) examina si existe un nexo positivo entre las características socioeconómicas pre pandemia y los resultados sanitarios de la pandemia de COVID-19 (número de casos y decesos); ii) así mismo se estudia si las medidas de mitigación y contención exhiben una relación negativa con el número de caso y de decesos provocados por la pandemia de COVID-19. El presente estudio pretende abordar estas cuestiones utilizando datos de 187 países organizados en sección transversal. Además, se clasifican las variables empleadas en dos tipos: el primer tipo de variables son socioeconómicas y sus datos son pre pandemia, el segundo tipo de variables son datos sobre las medidas de mitigación y contención adoptadas por los gobiernos y los registros se obtienen durante la pandemia. A su vez las variables socioeconómicas se pueden clasificar en gastos en salud: gastos sanitarios de las administraciones públicas como porcentaje del gasto de la administración pública (DE); movilidad de la población: turismo internacional (TI); ingreso: PIB per cápita por paridad de poder de compra (PIBpc) y pobreza extrema (PE) y actividad económica: crecimiento del PIB (GPIB). Los registros para las variables antes descritas provienen de bases de datos fiables como: la base de Indicadores de desarrollo elaborado por el Banco mundial 2020, Nuestro mundo en datos elaborado por Ritchie et al. (2021) y por último se utiliza la base Seguimiento de la respuesta del Gobierno COVID-19 de la universidad de Oxford (OxCGRT) realizada por Hale et al. (2021). En la tabla (1) se presentan el nombre, abreviatura, fuente, año y la unidad de medida de las variables socioeconómicas.

Tabla 1  
 Indicadores socioeconómicos

Nombre	Abreviatura	Fuente	Año	Unidad de medida
<b>Gastos en salud</b>				
Gastos sanitarios de las administraciones públicas como porcentaje del gasto total de la administración pública	DE	Organización Mundial de la salud	2018	%
<b>Movilidad</b>				
Turismo internacional	TI	Indicadores de Desarrollo Mundial	2019	Número de llegadas
<b>Ingreso</b>				
PIB per cápita por paridad de poder de compra	PIBpc	Indicadores de Desarrollo Mundial	2019	\$
Pobreza extrema	PE	Nuestro Mundo en datos	Se construye con el año más reciente disponible desde 2010	Porcentaje de la población que vive en la pobreza extrema
<b>Actividad económica</b>				
Crecimiento del PIB	GPIB	Indicadores de Desarrollo Mundial	2019	%

Fuente: Elaboración propia

Las variables se han seleccionado teniendo en cuenta su posible influencia en la aparición de enfermedades infecciosas. El gasto sanitario medido por las variables (DE) permiten analizar la preparación de un país con respecto al brote de COVID-19. Un mayor nivel de gasto en salud garantizaría a un país con una amplia infraestructura sanitaria, tanto física como de personal hacer frente al brote de manera más eficaz. La movilidad medida por la variable TI sirve como aproximación del desplazamiento de las personas fuera de los países. Los países con más viajes internacionales podrían haber recibido un gran número de casos de COVID-19 en la fase inicial de la pandemia y, en consecuencia, haberse enfrentado a brotes más graves posteriormente. El ingreso evaluado por las variables PIBpc y PE permiten examinar de manera aproximada el grado de cumplimiento de las medidas tomadas para evitar la expansión de la pandemia de COVID-19. Entre más alto sea el ingreso de las personas estas tendrán mayor posibilidad de cumplir con las medidas, si el ingreso es muy bajo las posibilidades son menores y por tanto aumenta el riesgo de contagio. La actividad económica se observa a través del crecimiento del PIB de cada país mayor actividad económica apuntaría a una mayor movilidad y concentración de las personas

mientras que menor crecimiento implicaría menor movilidad de las personas, así como menor concentración de las personas en oficinas.

Tabla 2  
Medidas de mitigación y contención

Nombre	Abreviatura	Fuente	Año	Unidad de medida
Índice de respuesta gubernamental	IRG	OxCGRT	2020	Número

Fuente: Elaboración propia

Por otro lado, para medir la respuesta de los gobiernos a la pandemia de COVID-19 se considera el índice de respuesta gubernamental (IRG). El índice de respuesta gubernamental se compone de los índices de restricción y del índice de contención sanitaria añadiendo dos indicadores adicionales, estos indicadores son el apoyo a los ingresos de la población por parte del gobierno y los programas de alivio de deuda para los hogares. El índice de rigor registra información sobre medidas de distanciamiento social y se calcula a partir de 8 indicadores los cuales incluyen: el cierre de escuelas, cierre del lugar de trabajo, cancelación de eventos públicos, restricciones a las reuniones, cierre del transporte público, requisitos de permanencia en el hogar, restricciones a la circulación interna y restricciones a viajar. Por otro lado, el índice de contención sanitaria se construye a partir de 3 indicadores los cuales son: campañas de concientización pública, la política de pruebas y el rastreo de contactos. Cada uno de los tres índices es una simple puntuación aditiva de los indicadores subyacentes, y se reajusta para variar de 0 a 100.

Los índices tienen fines comparativos y no deben ser interpretados como una calificación de la idoneidad o eficacia de la respuesta del país<sup>3</sup> a la pandemia de COVID-19 (Hale et al. 2020). Así mismo la base de datos OxCGRT es el origen de los datos para las variables que permiten cuantificar los resultados sanitarios provocados por la pandemia de COVID-19 estas variables son casos totales de COVID-19 por millón y decesos totales por millón causados por COVID-19. Los datos de las medidas de contención y mitigación, así como de los resultados sanitarios derivados de la pandemia COVID-19 fueron recopilados el 28 de diciembre de 2020.

---

<sup>3</sup> Más información sobre la composición de los índices: de rigor, contención sanitaria y de respuesta gubernamental se encuentra en el trabajo de Hale et al (2020) y en la página: [www.bsg.ox.ac.uk/covidtracker](http://www.bsg.ox.ac.uk/covidtracker).

Tabla 3  
 Resultados sanitarios de la pandemia COVID-19

Nombre	Abreviatura	Fuente	Año	Unidad de medida
Casos totales de COVID-19 por millón	CM	Nuestro Mundo en datos	2020	Número
Decesos totales por millón como resultado de la pandemia COVID-19	DM	Nuestro Mundo en datos	2020	Número

Fuente: Elaboración propia

Se analizan los resultados sanitarios a nivel de país durante la pandemia de COVID-19 con dos variables: casos confirmados por millón de personas y decesos por millón de personas para cada país. Los valores más altos de estas variables representan resultados sanitarios adversos (mayor número de casos y de decesos) y valores más bajos representan resultados sanitarios positivos (menor número de casos y de decesos). En las tablas 4, 5, y 6 se presentan las estadísticas descriptivas de las variables utilizadas en el estudio. Los países que componen las muestras A y B se pueden observar en tabla A1.

Tabla 4  
 Estadísticas descriptivas de los indicadores socioeconómicos

	DE	PIBpc	TI	PE	GPIB
Media	10.5	23 534.8	13 096 522	13.4	2.7
Máximo	27.8	129 451	166 009 000	77.6	18.7
Mínimo	1.8	784.9	12 000	0.1	-8.1
Desviación estándar	5.2	24 285.4	26 335 305.1	19.9	3.1
Observaciones	172	173	150	120	175

Fuente: Elaboración propia

Tabla 5  
 Estadísticas descriptivas de las medidas de mitigación y contención

	IRG
Media	55
Máximo	85.1
Mínimo	7.2
Desviación estándar	15.4
Observaciones	179

Fuente: Elaboración propia

Tabla 6  
Estadísticas descriptivas de los resultados sanitarios de la pandemia

	CM	DM
Media	16 016.3	309.9
Máximo	101 921.9	1 679.5
Mínimo	3.2	0.1
Desviación estándar	19 294.9	387.4
Observaciones	177	168

Fuente: Elaboración propia

Se realizó la prueba Jarque-Bera de normalidad de la distribución de los errores para las muestras A y B. Los resultados de la muestra A muestran que los errores se encuentran normalmente distribuidos. Por otro lado, los resultados de la muestra B presentan evidencia mixta.

## Metodología

Con los datos obtenidos se construyen dos muestras. Para ambas muestras se utilizan datos de 187 países organizados en forma transversal. De acuerdo a Sedgwick (2014) un estudio de tipo transversal es especialmente adecuado para estimar la prevalencia de un comportamiento o enfermedad en una población, la cual se mide con la variable casos totales de COVID-19 por millón. Los estudios de corte transversal son usuales en el área epidemiológica como en los trabajos de: Guo et al. (2021), Sasaki et al. (2021) y Callinan et al. (2021)

Además, se especifica un análisis de regresión múltiple en un marco lineal para analizar ambas muestras, específicamente se utiliza el método de Mínimos Cuadrados Ordinarios. El marco de la regresión lineal es la herramienta más sencilla para cuantificar la relación entre un resultado dado y un conjunto de posibles determinantes. Su ventaja radica en la inferencia analítica eficiente e insesgada de la fuerza de la relación lineal (Stojkoski et al. 2020). Como tal, se ha utilizado ampliamente en la modelización de los resultados de los fenómenos epidemiológicos.

La primera muestra analiza la relación entre el número de casos y las variables socioeconómicas pre pandemia en conjunción con las medidas de mitigación y contención de la pandemia de COVID-19 esta muestra se denomina muestra A. Para analizar esta muestra se utiliza como variable dependiente el número de casos totales de COVID-19 por millón, las variables independientes son las características socioeconómicas pre pandemia y las medidas de contención y mitigación. El modelo se expresa de la siguiente forma:

$$CM = DE + PIBpc + TI + PE + GPIB + IRG + u$$

(1)

Donde CM son los casos totales de COVID-19 por millón, DE son los gastos sanitarios de las administraciones públicas como porcentaje del gasto total de la administración pública, PIBpc es el PIB per cápita por paridad de poder de compra, TI es el turismo internacional, PE es la pobreza extrema, GPIB es el crecimiento del PIB, IRG es el índice de respuesta gubernamental y u es el término de error.

La muestra B examina la relación entre los decesos totales por millón causados por COVID-19 y las características socioeconómicas pre pandemia, así como las medidas de contención y mitigación empleadas por los distintos gobiernos El modelo se expresa de la siguiente forma:

$$DM = DE + PIBpc + TI + PE + GPIB + IRG + u \quad (2)$$

Donde DM es el número de decesos totales por millón como resultado de la pandemia COVID-19.

En las tablas A2 y A3 las cuales se encuentran en el apéndice se muestran la matriz de correlación la cual indica que no existen problemas de multicolinealidad. Por último, la investigación implica un análisis entre países, por tanto, la presencia de heterocedasticidad puede influir en los coeficientes. Para corregir la existencia de heterocedasticidad, se emplean errores estándar y covarianzas consistentes con la heterocedasticidad de White-Hinkley.

## Resultados

Se realizaron dos estimaciones una por cada muestra. Se empleó el método Mínimos Cuadros Ordinarios para realizar las estimaciones.

Tabla 7  
 Resultados para la muestra A

	Coefficiente	Error estándar	Estadístico-t	Probabilidad
<b>Indicadores socioeconómicos</b>				
DE	459.11*	269.96	1.70	0.09
PIBpc	0.32***	0.11	2.72	0.007
TI	.00003	.00006	0.51	0.60
PE	-145.37**	57.98	-2.50	0.014
GPIB	-175.61	289.17	-0.60	0.54
<b>Medidas de contención y mitigación</b>				
IRG	96.73	59.54	1.62	0.107
<b>Estadísticas</b>				
R cuadrado	0.44			
Estadístico	2.06			
<b>Durbin-Watson</b>				

Nota: \*\*\* estadísticamente significativo al 1%, \*\* estadísticamente significativo al 5% y \* estadísticamente al 10%.

Fuente: elaboración propia

La tabla 7 exhibe los resultados para la muestra A. Las variables DE y PIBpc son estadísticamente significativa al 10% y al 1% respectivamente. Un aumento de 1% en los gastos sanitarios de las administraciones públicas como porcentaje del gasto total de la administración pública representan un aumento de 459.11 casos totales de COVID-19 por millón. Por otro lado, un aumento de 1 dólar en la variable PIBpc representa un aumento de 0.32 casos de COVID-19 por millón de personas. Así mismo la variable PE es estadísticamente al 5%. Un aumento de 1% en esta variable significa una disminución de 145.37 en el número de casos de COVID-19. El resto de las variables en la muestra no son estadísticamente significativas.

Tabla 8  
 Resultados para la muestra B

	Coefficiente	Error estándar	Estadístico-t	Probabilidad
<b>Indicadores socioeconómicos</b>				
DE	17.47**	6.67	2.61	0.01
PIBpc	0.001	0.002	0.87	0.38
TI	.000002	.000001	1.34	0.18
PE	-3.62***	1.32	-2.74	0.007
GPIB	-13.70	11.11	-1.23	0.22
<b>Medidas de contención y mitigación</b>				
IRG	2.92**	1.35	2.15	0.03
<b>Estadísticas</b>				
R cuadrado	0.33			
Estadístico	1.97			
Durbin-Watson				

Fuente: elaboración propia

Los resultados para la muestra B se muestran en la tabla 2. En relación a las variables socioeconómicas se observa que la variable DE es estadísticamente significativa al 5%. Un aumento de 1% en la variable DE esta relacionado con un aumento de 17.47 decesos totales por millón causados por COVID-19. Por otro lado, la variable pobreza extrema es estadísticamente significativa al 5%. Un aumento de 1% en la variable PE indica una reducción de 3.62 en la variable decesos totales por millón como resultado de la pandemia COVID-19. Así mismo, Los resultados para las variables que analizan las medidas de contención y mitigación muestran que la variable IRG es estadísticamente significativa al 5%. Un aumento de una unidad en esta variable significa un aumento de 2.92 de la variable DM. El resto de las variables no son estadísticamente significativas.

Para el caso de la muestra A se encontró evidencia que apoya la hipótesis de un nexo positivo entre las variables socioeconómicas pre pandemia y el número de casos de COVID-19 en las variables DE y PIBpc. Lo anterior apunta a que los países con una mayor renta per cápita y que además realizan un mayor gasto en salud muestran registros más altos de casos de COVID-19. Esto se puede explicar debido

a que estos países realizan una mayor difusión de las pruebas, exhiben mayor transparencia en la notificación y tienen mejores sistemas nacionales de vigilancia. Otras posibles razones de la asociación positiva podrían ser la mayor accesibilidad a los viajes aéreos y a las vacaciones internacionales en los países más ricos, ya que los viajes son un importante factor que contribuye a la diseminación internacional del COVID-19 (Chaudhry et al. 2020). Sin embargo no encontramos evidencia que respalde esta premisa ya que la variable TI no es estadísticamente significativa.

En cuanto a la variable PE esta variable exhibe evidencia en contra de la existencia de un nexo positivo entre las variables socioeconómicas pre pandemia y el número de casos totales de COVID-19 por millón. En el trabajo Varkey et al. (2020) encuentran que la pobreza está relacionada con el número de casos por COVID-19 y consideran que podrían explicarse en términos del crecimiento económico ya que los países que muestran más actividad económica, están más afectados por los casos de COVID-19. Pero los resultados obtenidos en este estudio indican que no existe evidencia a favor de un nexo positivo entre la actividad económica medida por el crecimiento del PIB y los casos totales de COVID-19 por millón. Así mismo estos resultados concuerdan con el trabajo de Nguimkeu y Tadadjeu (2021) ya que encuentran que los países de la África subsahariana, los cuales son predominantemente pobres muestran un bajo número de casos de COVID-19 y estos resultados se mantienen aun cuando se considera que estos países no se están reportando la totalidad de los casos.

Los resultados de la muestra B indican que la variable DE exhibe evidencia a favor de la hipótesis que implica que las características socioeconómicas pre pandemia tienen un nexo positivo con el total de decesos por millón derivados de la pandemia de COVID-19. Por otro lado, la variable PE presenta evidencia en contra de la hipótesis anterior. Estos resultados concuerdan con los de la investigación de Javaheri (2021) donde encuentran que mientras que la India tiene el mayor número de personas en situación de pobreza extrema por millón y el menor número de camas de hospital, ha informado de una menor mortalidad por millón que el Reino Unido, que exhibe la menor pobreza extrema y el mayor número de camas de hospital.

Javaheri estima que lo anterior podría explicarse por qué el Reino Unido tienen una proporción mayor de personas de 65 años o más por millón. En los estudios de Javaheri (2021) y Nguimkeu y Tadadjeu (2021) aportan evidencia que apoyan esta noción. En la presente investigación esta variable no fue considerada.

Por último, la variable índice de respuesta gubernamental presenta evidencia a favor de una relación positiva entre las medidas de contención y mitigación y el total de decesos por millón derivados de la pandemia de COVID-19. Esta evidencia coincide con la encontrada en el trabajo de Chaudhry et al. (2020) ya que su análisis muestra que los cierres totales y las pruebas generalizadas de COVID-19 no se asociaron a una reducción del número de casos críticos ni de la mortalidad general.

Lo anterior podría ser explicado debido a que los datos obtenidos, son del 28 de diciembre de 2020, donde la curva epidemiológica individual de cada país no se encontraba todavía en la fase de "meseta" o de descenso. Así mismo este resultado podría reflejar el grado de incumplimiento de dichas medidas de contención y mitigación. Por ejemplo, en los Estados Unidos se han tenido problemas para hacer cumplir los cierres, y los ciudadanos de varios estados han protestado públicamente contra las medidas de salud pública para limitar la transmisión del COVID-19, y han fomentado una revuelta abierta (Chaudhry et al. 2020).

## **Conclusiones**

Se analizó la relación entre los resultados sanitarios de la pandemia COVID-19 y las condiciones socioeconómicas pre pandemia. Así mismo, se estudió el impacto de las medidas de contención y mitigación sobre los resultados sanitarios de la pandemia COVID-19. Para lo cual se utilizaron dos muestras, la muestra A y la muestra B. En la muestra A se emplea como variable dependiente los casos totales de COVID-19 por millón. Mientras que en la muestra B se emplea el total de decesos por millón derivados de la pandemia de COVID-19 como variable dependiente. Para ambas muestras se utilizan como variables independientes las características socioeconómicas pre pandemia y las medidas de contención y mitigación. Además, las dos muestras se construyen con datos para 187 países. Las estimaciones se realizaron empleando el método de Mínimos Cuadrados Ordinarios. Así mismo, para corregir la existencia de heterocedasticidad se emplean errores estándar y covarianzas consistentes con la heteroscedasticidad de White-Hinkley.

En la muestra A se encontró evidencia que apoya la hipótesis de un nexo positivo entre las variables socioeconómicas pre pandemia y el número de casos de COVID-19 en las variables DE y PIBpc. La variable PE exhibe evidencia en contra de un nexo positivo entre las variables socioeconómicas pre pandemia y el número de casos totales de COVID-19 por millón. Los resultados de la muestra B señalan que la variable DE exhibe evidencia a favor de la hipótesis que implica que las características socioeconómicas pre pandemia tienen un nexo positivo con el total de decesos por millón derivados de la pandemia de COVID-19. Y la variable PE presenta evidencia en contra de la hipótesis anterior.

La evidencia obtenida en la muestra A señala que los países con mayor renta per cápita y que realizan un gasto mayor en salud registran un mayor número de casos de COVID-19 resultados que concuerdan con los trabajos de Chaudhry et al. (2020) y Nguimkeu y Tadadjeu (2021). Los resultados se corroboran con la evidencia de la variable PE que indica que los países que exhiben mayor porcentaje de pobreza extrema están relacionados estadísticamente con menos casos de COVID-19.

Esto se puede explicar debido a que los países con mayor renta per cápita realizan una mayor difusión de las pruebas, exhiben mayor transparencia en la notificación y tienen mejores sistemas nacionales de vigilancia. Realizar este tipo de tareas es de suma importancia ya que permiten dimensionar la gravedad de la pandemia y por tanto reforzar el cumplimiento de las medidas de contención y mitigación o tomar medidas más estrictas. Así mismo los resultados de la muestra B muestran conclusiones similares para las variables PE y DE. Por otro lado, la evidencia para la variable IRG que evalúa las medidas de mitigación y contención sugieren una posible falta de cumplimiento de dichos preceptos por parte de las personas. Al exhibir una relación positiva con el total de decesos. Políticas que permitan elevar el grado de cumplimiento de estas medidas de contención y mitigación podrían reducir el número de decesos. Ejemplos de estas políticas pueden ser sistemas de vigilancia del cumplimiento de las medidas de contención y mitigación otro ejemplo de política es realizar la difusión masiva de dichas medidas y además incluir dentro de esta comunicación el combate a la información que no este soportada por evidencia científica. Las presentes conclusiones proponen vías para seguir debatiendo, investigando y explorando este tema. Una de estas vías es profundizar en el estudio del cumplimiento de las medidas de contención y mitigación adoptadas por los distintos gobiernos.

## Referencias

- Ashraf, B. N. (2020). Socioeconomic conditions, government interventions and health outcomes during COVID-19. *Covid Economics*, 37, 141-162.
- Bengtsson, T., Dribe, M., y Eriksson, B. (2018). Social Class and Excess Mortality in Sweden During the 1918 Influenza Pandemic. *American Journal of Epidemiology*, 187(12), 2568–2576. <https://doi.org/10.1093/aje/kwy151>
- Biggerstaff, M., Jhung, M. A., Reed, C., Garg, S., Balluz, L., Fry, A. M., y Finelli, L. (2013). Impact of medical and behavioural factors on influenza-like illness, healthcare-seeking, and antiviral treatment during the 2009 H1N1 pandemic: USA, 2009–2010. *Epidemiology and Infection*, 142(1), 114–125. <https://doi.org/10.1017/s0950268813000654>
- Bryan, M. S., Sun, J., Jagai, J., Horton, D. E., Montgomery, A., Sargis, R., y Argos, M. (2021). Coronavirus disease 2019 (COVID-19) mortality and neighborhood characteristics in Chicago. *Annals of epidemiology*, 56, 47-54. <https://doi.org/10.1016/j.annepidem.2020.10.011>
- Callinan, S., Mojica-Perez, Y., Wright, C. J. C., Livingston, M., Kuntsche, S., Laslett, A., ... Kuntsche, E. (2020). Purchasing, consumption, demographic and socioeconomic variables associated with shifts in alcohol consumption during the COVID-19 pandemic. *Drug and Alcohol Review*, 40(2), 183–191. <https://doi.org/10.1111/dar.13200>

- Charu, V., Chowell, G., Palacio Mejia, L. S., Echevarría-Zuno, S., Borja-Aburto, V. H., Simonsen, L. y Viboud, C. (2011). Mortality Burden of the A/H1N1 Pandemic in Mexico: A Comparison of Deaths and Years of Life Lost to Seasonal Influenza. *Clinical Infectious Diseases*, 53(10), 985–993. <https://doi.org/10.1093/cid/cir644>
- Chaudhry, R., Dranitsaris, G., Mubashir, T., Bartoszko, J., y Riazi, S. (2020). A country level analysis measuring the impact of government actions, country preparedness and socioeconomic factors on COVID-19 mortality and related health outcomes. *EclinicalMedicine*, 25, 100464. <https://doi.org/10.1016/j.eclinm.2020.100464>
- Chen, J. T., y Krieger, N. (2020). Revealing the Unequal Burden of COVID-19 by Income, Race/Ethnicity, and Household Crowding: US County Versus Zip Code Analyses. *Journal of Public Health Management and Practice*, 27(1), S43–S56. <https://doi.org/10.1097/phh.0000000000001263>
- Gkiouleka, A., Huijts, T., Beckfield, J., y Bambra, C. (2018). Understanding the micro and macro politics of health: Inequalities, intersectionality & institutions - A research agenda. *Social Science & Medicine*, 200, 92–98. <https://doi.org/10.1016/j.socscimed.2018.01.025>
- Grantz, K. H., Rane, M. S., Salje, H., Glass, G. E., Schachterle, S. E., y Cummings, D. A. T. (2016). Disparities in influenza mortality and transmission related to sociodemographic factors within Chicago in the pandemic of 1918. *Proceedings of the National Academy of Sciences*, 113(48), 13839–13844. <https://doi.org/10.1073/pnas.1612838113>
- Guo, Z., Zhao, S. Z., Guo, N., Wu, Y., Weng, X., Wong, J. Y.-H., ... Wang, M. P. (2021). Socioeconomic Disparities in eHealth Literacy and Preventive Behaviors During the COVID-19 Pandemic in Hong Kong: Cross-sectional Study. *Journal of Medical Internet Research*, 23(4), e24577. <https://doi.org/10.2196/24577>
- Hale, T., Angrist, N., Goldszmidt, R., Kira, B., Petherick, A., Phillips, T., ... y Tatlow, H. (2021). A global panel database of pandemic policies (Oxford COVID-19 Government Response Tracker). *Nature Human Behaviour*, 5(4), 529-538. Disponible en <https://www.bsg.ox.ac.uk/research/research-projects/covid-19-government-response-tracker#data>
- Hale, T., Petherick, A., Phillips, T. y Webster, S. (2020). Variation in government responses to COVID-19. *Blavatnik school of government working paper*, 31.
- House, N., Holborn, H., y Wc, L. (2020). ICNARC report on COVID-19 in critical care. *ICNARC*, 17, 1-26.
- Javaheri, B. (2021). The COVID-19 Pandemic: Socioeconomic and Health Disparities. <https://doi.org/10.20944/preprints202012.0599.v2>

- Lou, J., Shen, X., y Niemeier, D. (2020). Are stay-at-home orders more difficult to follow for low-income groups? *Journal of Transport Geography*, 89, 102894.
- Lowcock, E. C., Rosella, L. C., Foisy, J., McGeer, A., y Crowcroft, N. (2012). The social determinants of health and pandemic H1N1 2009 influenza severity. *American journal of public health*, 102(8), e51-e58.
- Mamelund, S.-E. (2006). A socially neutral disease? Individual social class, household wealth and mortality from Spanish influenza in two socially contrasting parishes in Kristiania 1918–19. *Social Science & Medicine*, 62(4), 923–940. <https://doi.org/10.1016/j.socscimed.2005.06.051>
- Morens, D. M., y Fauci, A. S. (2020). Emerging Pandemic Diseases: How We Got to COVID-19. *Cell*, 183(3), 837. <https://doi.org/10.1016/j.cell.2020.10.022>
- Murray, C. J., Lopez, A. D., Chin, B., Feehan, D., y Hill, K. H. (2006). Estimation of potential global pandemic influenza mortality on the basis of vital registry data from the 1918–20 pandemic: a quantitative analysis. *The Lancet*, 368(9554), 2211–2218. [https://doi.org/10.1016/s0140-6736\(06\)69895-4](https://doi.org/10.1016/s0140-6736(06)69895-4)
- Ritchie, H., Ortiz-Ospina, E., Beltekian, D., Mathieu, E., Hasell, J., Macdonald, B., ... y Roser, M. (2020). Coronavirus pandemic (COVID-19). *Our World in Data*. Disponible en <https://ourworldindata.org/coronavirus>
- Rutter, P. D., Mytton, O. T., Mak, M., y Donaldson, L. J. (2012). Socio-economic disparities in mortality due to pandemic influenza in England. *International Journal of Public Health*, 57(4), 745–750. <https://doi.org/10.1007/s00038-012-0337-1>
- Sasaki, S., Sato, A., Tanabe, Y., Matsuoka, S., Adachi, A., Kayano, T., Watanabe, T. (2021). Associations between Socioeconomic Status, Social Participation, and Physical Activity in Older People during the COVID-19 Pandemic: A Cross-Sectional Study in a Northern Japanese City. *International Journal of Environmental Research and Public Health*, 18(4), 1477. <https://doi.org/10.3390/ijerph18041477>
- Sedgwick, P. (2014). Cross sectional studies: advantages and disadvantages. *BMJ*, 348(mar26 2), g2276–g2276. <https://doi.org/10.1136/bmj.g2276>
- Stojkoski, V., Utkovski, Z., Jolakoski, P., Tevdovski, D., y Kocarev, L. (2020). The Socio-Economic Determinants of the Coronavirus Disease (COVID-19) Pandemic. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3576037>
- Wright, A. L., Sonin, K., Driscoll, J., y Wilson, J. (2020). Poverty and economic dislocation reduce compliance with COVID-19 shelter-in-place protocols. *Journal of Economic Behavior & Organization*, 180, 544–554. <https://doi.org/10.1016/j.jebo.2020.10.008>

Wu, T. (2021). The socioeconomic and environmental drivers of the COVID-19 pandemic: A review. *Ambio*, 50(4), 822–833. <https://doi.org/10.1007/s13280-020-01497-4>

## Anexo

Tabla A1  
 Lista de países

País					
Afganistán	Camboya	Gambia	Laos	Nueva Zelanda	Sri Lanka
Albania	Camerún	Georgia	Lesoto	Omán	Sudáfrica
Alemania	Canadá	Ghana	Letonia	Países Bajos	Sudán
Andorra	Chad	Grecia	Líbano	Pakistán	Sudán del Sur
Angola	Chile	Groenlandia	Liberia	Panamá	Suecia
Antigua y Barbuda	China	Guam	Libia	Papúa Nueva Guinea	Suiza
Arabia Saudita	Chipre	Guatemala	Lituania	Paraguay	Surinam
Argelia	Colombia	Guinea	Luxemburgo	Perú	Tailandia
Argentina	Comoros	Guinea Ecuatorial	Macao	Polonia	Tanzania
Armenia	Costa de Marfil	Guyana	Macedonia del Norte	Portugal	Tayikistán
Australia	Costa Rica	Haití	Madagascar	Puerto Rico	Timor-Leste
Austria	Croacia	Honduras	Malasia	Qatar	Togo
Azerbaiyán	Cuba	Hong Kong	Malawi	Reino Unido	Tonga
Bahamas	Dinamarca	Hungría	Maldivas	República Árabe de Egipto	Trinidad y Tobago
Bahréin	Djibouti	India	Mali	República Árabe Siria	Túnez
Bangladesh	Dominica	Indonesia	Malta	República Centroafricana	Turkmenistán
Barbados	Ecuador	Irak	Marruecos	República Checa	Turquía
Bélgica	El Salvador	Iran	Mauricio	República de Corea	Ucrania
Belize	Emiratos Árabes Unidos	Irlanda	Mauritania	República del Congo	Uganda
Benin	Eritrea	Islandia	México	República Democrática del Congo	Uruguay
Bermuda	Eslovenia	Islas Faroe	Moldavia	República Dominicana	Uzbekistan
Bielorrusia	España	Islas Salomón	Mónaco	República Eslovaca	Vanuatu
Bolivia	Estados Unidos	Israel	Mongolia	República Kirguiza	Venezuela
Bosnia y Herzegovina	Estonia	Italia	Montenegro	Ruanda	Vietnam
Botsuana	Eswatini	Jamaica	Mozambique	Rumania	Yemen
Brasil	Etiopía	Japón	Myanmar	San Marino	Zambia
Brunéi	Federación Rusa	Jordán	Namibia	Senegal	Zimbabwe
Bulgaria	Fiji	Kazajstán	Nepal	Serbia	
Burkina Faso	Filipinas	Kenia	Nicaragua	Seychelles	
Burundi	Finlandia	Kiribati	Niger	Sierra Leona	
Bután	Francia	Kosovo	Nigeria	Singapur	
Cabo Verde	Gabon	Kuwait	Noruega	Somalia	

Fuente: Elaboración propia

Tabla A2

Matriz de correlación de la muestra A

	CM	TI	DE	PE	IRG	PIBpc	GPIB
CM	1	0.26	0.49	-0.44	0.44	0.61	-0.17
TI	0.26	1	0.18	-0.24	0.32	0.28	-0.07
DE	0.49	0.18	1	-0.48	0.19	0.51	-0.39
PE	-0.44	-0.24	-0.48	1	-0.44	-0.48	0.31
IRG	0.44	0.32	0.19	-0.44	1	0.44	-0.07
PIBpc	0.61	0.28	0.51	-0.48	0.44	1	-0.13
GPIB	-0.17	-0.07	-0.39	0.31	-0.07	-0.13	1

Fuente: Elaboración propia

Tabla A3

Matriz de correlación de la muestra B

	DM	TI	DE	PIBpc	GPIB	PE	IRG
DM	1	0.31	0.45	0.40	-0.24	-0.41	0.36
TI	0.31	1	0.15	0.27	-0.04	-0.24	0.32
DE	0.45	0.15	1	0.49	-0.37	-0.48	0.16
PIBpc	0.40	0.27	0.49	1	-0.10	-0.47	0.44
GPIB	-0.24	-0.04	-0.37	-0.10	1	0.31	-0.03
PE	-0.41	-0.24	-0.48	-0.47	0.31	1	-0.43
IRG	0.36	0.32	0.16	0.44	-0.03	-0.43	1

Fuente: Elaboración propia