

Análisis de la variabilidad de reportados de COVID-19 en tres semanas en relación con parámetros de movilidad

Analysis of the variability of reported COVID-19 over three weeks in relation to mobility parameters

Edgar López Pezoa¹  & Sebastián Alberto Grillo¹ 

¹Universidad Nacional de Asunción, Facultad de Ciencias Exactas y Naturales, Departamento de Matemática, San Lorenzo, Paraguay.

*Autor correspondiente: epezoa@facen.una.py.

Resumen: Determinar la relación de los patrones de movilidad sobre la evolución de la pandemia de COVID-19, tiene aplicación potencial en mejores políticas para controlar la pandemia. Google disponibiliza datos de movilidad de cada país donde se registran los cambios porcentuales promedios de la población sobre 6 categorías: 1) Espacios recreativos cerrados, 2) supermercados y farmacias, 3) estaciones de transporte, 4) parques y lugares abiertos, 5) lugares de trabajo y 6) zonas residenciales. Además, tenemos la serie de casos diarios reportados de COVID-19 a lo largo de la pandemia. En este trabajo aplicamos un suavizado semanal a todas las secuencias de tiempo y además calculamos un factor de variación entre el número de casos reportados en 21 días y el número de casos reportados actual. Después se aplica un (i) análisis de componentes principales con las series de movilidad etiquetadas según el factor de variación de reportados y (ii) un análisis de correlación entre las series de movilidad y el factor de variación de reportados. Los resultados sobre los datos de Argentina, Brasil, Canadá, Chile, Estados Unidos, India, México, Polonia, Rusia y Turquía, muestran que los datos de movilidad pueden ser más o menos determinantes dependiendo del país. Además, que las tendencias de movimiento en áreas residenciales están significativamente correlacionadas a la reducción de los casos reportados en la mayoría de los países, sin embargo, las correlaciones de las variables de movilidad pueden variar bastante de país en país.

Palabras clave: COVID-19, movilidad, análisis de correlación, análisis de componentes principales, series de tiempo.

Abstract: Determining the relationship of mobility patterns on the evolution of the COVID-19 pandemic has potential application in better policies to control the pandemic. Google makes available mobility data for each country where the average percentage changes of the population are recorded over 6 categories: 1) enclosed recreational spaces, 2) supermarkets and pharmacies, 3) transportation stations, 4) parks and open places, 5) workplaces and 6) residential areas. In addition we have the series of daily reported COVID-19 cases throughout the pandemic. In this paper we apply a weekly smoothing to all time sequences and further calculate a variation factor between the number of reported cases in 21 days and the current number of reported cases. We then apply a (i) principal component analysis with the mobility series labeled according to the reported variation factor and (ii) a correlation analysis between the mobility series and the reported variation factor. The results on data from Argentina, Brazil, Canada, Chile, India, Mexico, Poland, Russia, Turkey, and the United States show that mobility data can be more or less determinant depending on the country. In addition, trends of movement in residential areas are significantly correlated to the reduction of reported cases in most countries, however the correlations of mobility variables may vary quite a bit from country to country.

Key words: COVID-19, mobility, correlation analysis, principal component analysis, time series.

Introducción

Uno de los cambios más notorios que la pandemia de COVID-19 ha traído a las sociedades son las restricciones que han impactado a la movilidad de las personas. Siendo que aun con la disponibilidad de las vacunas pueden ocurrir saturaciones del sistema de salud que obliguen a tomar restricciones.

El estudio del efecto de la movilidad sobre la

pandemia de COVID-19 sigue dos problemáticas principales. Primero, está la forma en que la movilidad a larga distancia distribuye la pandemia entre distintos puntos geográficos (Kraemer *et al.*, 2020) y segundo, como la movilidad dentro de un entorno geográfico limitado influencia a la transmisión de casos (McGough *et al.*, 2020). Este proyecto se enfoca en la segunda problemática, donde varios

Recibido: 29/11/2021 Aceptado: 01/02/2022



2078-399X/2022 Facultad de Ciencias Exactas y Naturales - Universidad Nacional de Asunción, San Lorenzo, Paraguay. Este es un artículo de acceso abierto bajo la licencia CC BY 4.0 (<https://creativecommons.org/licenses/by/4.0/deed.es>).

estudios presentan que la pandemia estuvo asociada a importantes reducciones de movilidad (Warren & Skillman, 2020) y (Cot *et al.*, 2021), que a su vez implican un crecimiento sub-exponencial en el número de casos activos (Maier & Brockmann, 2020).

La movilidad explica el 48% de la variabilidad de la transmisibilidad del virus, siendo que el resto corresponde posiblemente a variaciones del virus en sí y demás medidas sanitarias (Nouvellet *et al.*, 2021). Sin embargo, no todas las actividades implican los mismos efectos sobre la transmisibilidad, siendo que distintas combinaciones de actividades pueden producir efectos distintos. En ese sentido, un análisis de movilidad que discrimine según la categoría de movilidad ofrece una mejora potencial tanto en la predicción de una epidemia a corto plazo (Wang *et al.*, 2020), como para dar inferencias del efecto de la movilidad (Basellini *et al.*, 2021). En cuanto a modelos predictivos a corto plazo se han aplicado varios abordajes, como modelado con ecuaciones diferenciales parciales (Wang *et al.*, 2020) y ecuaciones diferenciales ordinarias (Linka *et al.*, 2021). Respecto a modelos que dan inferencias del efecto de la movilidad sobre la transmisibilidad, se han aplicado modelos lineales (Yilmazkuday, 2021), (Sampi Bravo & Jooste, 2020), (Linka *et al.*, 2021), (Dainton & Hay, 2021), modelos log-lineales (Noland, 2021), modelos markovianos (Arenas *et al.*, 2020), ecuaciones diferenciales ordinarias (Linka *et al.*, 2021), regresión de función sobre función (Cintia *et al.*, 2020) y análisis de correlación (Kajitani & Hatayama, 2021).

Este trabajo toma los datos de movilidad de Google que registra la variación de movimiento ordenado según las categorías de (i) tiendas y espacios de ocio, (ii) supermercados y farmacias, (iii) parques, (iv) estaciones de transporte, (v) lugares de trabajo y (vi) zonas residenciales (Aktay *et al.*, 2020). Cada uno de los valores registrados en estas categorías es promediado según la semana previa de modo a suavizar las variaciones periódicas semanales. Además, tomamos los datos de casos reportados diarios de COVID-19 y les aplicamos también un promediado según la semana previa. Finalmente, se dividen los casos promediados de reportados

en 3 semanas con los del día correspondiente, obteniendo una nueva serie temporal que representa un factor de variación de reportados en 3 semanas.

Usando en primer lugar las series de movilidad suavizadas y en segundo lugar la serie de factor de variación de reportados se aplican dos tipos de análisis: (i) un análisis de componentes principales de las series de movilidad, donde se toman los dos primeros componentes analizar que regiones del plano presentan días con un factor de variación de reportados mayor a 1 y cuáles días presentan un factor de variación de reportados menor a 1. (ii) Un análisis de correlación entre las variables de movilidad suavizadas y el factor de variación de reportados. Estos dos tipos de análisis se aplican sobre los datos disponibles de Argentina, Brasil, Canadá, Chile, Estados Unidos, India, México, Polonia, Rusia y Turquía.

El análisis de componentes principales arroja que la separación entre los días con factor de variación de reportados con valores mayores a 1 y menores a 1 varía de país en país, indicando que las variables de movilidad pueden ser más determinantes en ciertos países que otros. El análisis de correlación arroja que la variación de reportados tiende a estar negativamente correlacionada con la movilidad en zonas residenciales, mientras que tiende a valores positivos con las otras variables, para casos con 95% de confianza. Sin embargo, pueden darse excepciones en algunos países y el grado de correlación varía de país en país.

La estructura del trabajo es la siguiente, la Sección 2 detalla la metodología empleada junto al análisis de componentes principales y el análisis de correlación. La Sección 3 presenta los resultados obtenidos con los análisis. Finalmente, la Sección 4 resume los resultados.

Materiales y métodos

Los datos se han obtenido de manera gratuita de los Informes de Movilidad Local sobre el COVID-19 de Google, y están disponibles en su sitio web para todos los interesados. Así como lo indican en dicho sitio web: La finalidad de estos Informes de Movilidad Local es proporcionar información

valiosa sobre los cambios que se han producido en la movilidad de las personas como consecuencia de las políticas que se han establecido para combatir el COVID-19. Estos informes muestran las tendencias de movimiento a lo largo del tiempo ordenadas por zonas geográficas y clasificadas en diversas categorías de lugares, como tiendas y espacios de ocio, supermercados y farmacias, parques, estaciones de transporte, lugares de trabajo y zonas residenciales.

Así se han considerado los mismos atributos que se presentan en los informes, los mismos son:

1. X_1 representa la categoría correspondiente a las tiendas y espacios de ocio;
2. X_2 representa la categoría correspondiente a los supermercados y farmacias;
3. X_3 representa la categoría correspondiente a los parques;
4. X_4 representa la categoría correspondiente a las estaciones de transporte;
5. X_5 representa la categoría correspondiente a los lugares de trabajo;
6. X_6 representa la categoría correspondiente a las zonas residenciales.

Los valores que pueden tomar cada uno de los atributos X_i se simbolizan mediante $x_{i,j}$; donde la i nos indica a cuál de los atributos corresponde el valor y la j nos indica el número, contando de manera corrida, del día al cual corresponde; siendo $j = 1$ el correspondiente al 01 de julio del 2020 y $j = 355$ para el 19 de junio del 2021. Es importante tener en cuenta que la variación de las $x_{i,j}$ es un número entero tal que $-100 \leq x_{i,j} \leq 100$.

Estos datos se han clasificado por países, y como ya se ha mencionado abarcan desde el 01 de julio del 2020 al 19 de junio del 2021, y para un mejor manejo de los mismos se han promediado entre los últimos siete días de tal manera que:

1. RR denota el promedio de los últimos siete días anteriores incluyendo al propio día del cambio porcentual desde la línea de base considerada para tiendas y espacios de ocio;

2. GP denota el promedio de los últimos siete días anteriores incluyendo al propio día del cambio porcentual desde la línea de base considerada para supermercados y farmacias;
3. P denota el promedio de los últimos siete días anteriores incluyendo al propio día del cambio porcentual desde la línea de base considerada para parques;
4. TS denota el promedio de los últimos siete días anteriores incluyendo al propio día del cambio porcentual desde la línea de base considerada para estaciones de transporte;
5. W denota el promedio de los últimos siete días anteriores incluyendo al propio día del cambio porcentual desde la línea de base considerada para lugares de trabajo;
6. R denota el promedio de los últimos siete días anteriores incluyendo al propio día del cambio porcentual desde la línea de base considerada para zonas residenciales.

Simbólicamente denotamos:

$$RR_j = \frac{\sum_{k=0}^6 x_{1,j+k}}{7}; \quad GP_j = \frac{\sum_{k=0}^6 x_{2,j+k}}{7};$$

$$P_j = \frac{\sum_{k=0}^6 x_{3,j+k}}{7}; \quad TS_j = \frac{\sum_{k=0}^6 x_{4,j+k}}{7};$$

$$W_j = \frac{\sum_{k=0}^6 x_{5,j+k}}{7}; \quad R_j = \frac{\sum_{k=0}^6 x_{6,j+k}}{7};$$

donde $0 \leq j \leq 349$.

Además se descargaron los datos epidemiológicos sobre la cantidad de test realizados y la de confirmados por países, los cuales se obtuvieron con el paquete COVID-19 que fue ejecutado en RStudio. Estos datos se seleccionaron de tal manera a coincidir con las fechas consideradas en los Informes de Movilidad Local. Para entender mejor, el paquete

instalado presenta la cantidad de confirmados desde el primer día acumulando día tras día los cantidad de casos confirmados, así se define $conf_j$ como la cantidad de nuevos confirmados en el día d_j en el país seleccionado.

De la misma se denotan las series de tiempo:

1. $conf_{1;j}$ como el promedio de confirmados de los últimos siete días anteriores incluyendo al propio día d_j de la cantidad de nuevos confirmados por día;
2. $conf_{3;j}$ como el promedio de casos reportados en la tercera semana contando a partir del día d_j considerado inicialmente.

Simbólicamente, tendremos:

$$conf_{1;j} = \frac{\sum_{k=0}^6 conf_{j+k}}{7};$$

$$conf_{3;j} = \frac{\sum_{k=0}^6 conf_{j+14+k}}{7};$$

donde $7 \leq j \leq 356$.

Con estos términos definimos:

$$C_{3;j} = \frac{conf_{3;j}}{conf_{1;j}},$$

el cual también podemos llamar como factor de variación entre el número de casos reportados en 21 días y el número de casos reportados actual.

Por último se definen los valores:

$$B_{3;j} = \begin{cases} 0 & \text{si } C_{3;j} \leq 1; \\ 1 & \text{si } C_{3;j} > 1, \end{cases}$$

y

$$D_{3;j} = \ln(C_{3;j}).$$

Además se hizo el análisis de los componentes principales a partir de RR , GP , P , TS , W y R . De cada componente se obtuvo la proporción de la varianza y la proporción acumulativa para conocer la importancia de tales componentes. Finalmente, se realizó una gráfica tomando como ejes los dos primeros componentes principales, coloreando los

puntos según el valor de $B_{3;j}$.

Para poder hacer el análisis de correlación entre los valores, se utilizaron los $D_{3;j}$ y los mismos se relacionaron con los valores de las categorías RR , GP , P , TS , W y R de tal manera que se fueron seleccionando los que tenían p -valor menor a 0.05.

Resultados

En esta sección evaluamos lo obtenido con (i) la aplicación de análisis de componentes principales sobre las variables de movilidad suavizadas (RR , GP , P , TS , W y R), que además son etiquetadas según el factor de variación de reportados en 3 semanas, (ii) la aplicación de análisis de correlación entre las variables de movilidad suavizadas y el logaritmo natural del factor de variación de reportados en 3 semanas.

Análisis de Componentes Principales

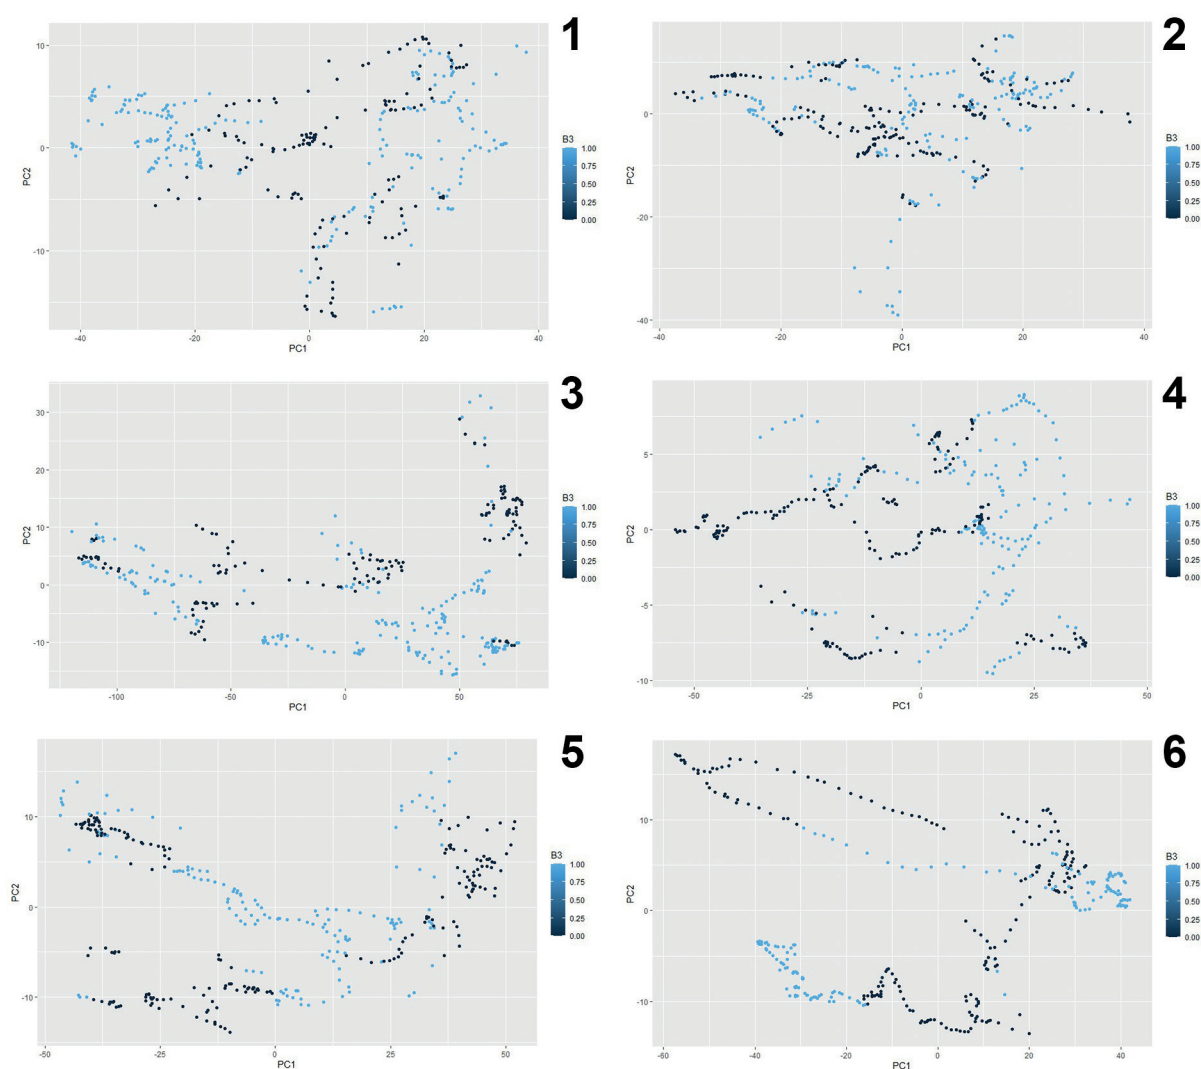
Según la Tabla 1 podemos observar que los primeros dos componentes principales sobre las 6 variables suavizadas de movilidad explican más del 90 por ciento de la varianza existente para dichas variables. Por lo tanto un gráfico que incorpore los dos primeros componentes como variables ofrece una buena aproximación de la estructura real de los datos.

Tabla 1. Varianza acumulada de los dos primeros componentes principales de las variables de movilidad por país.

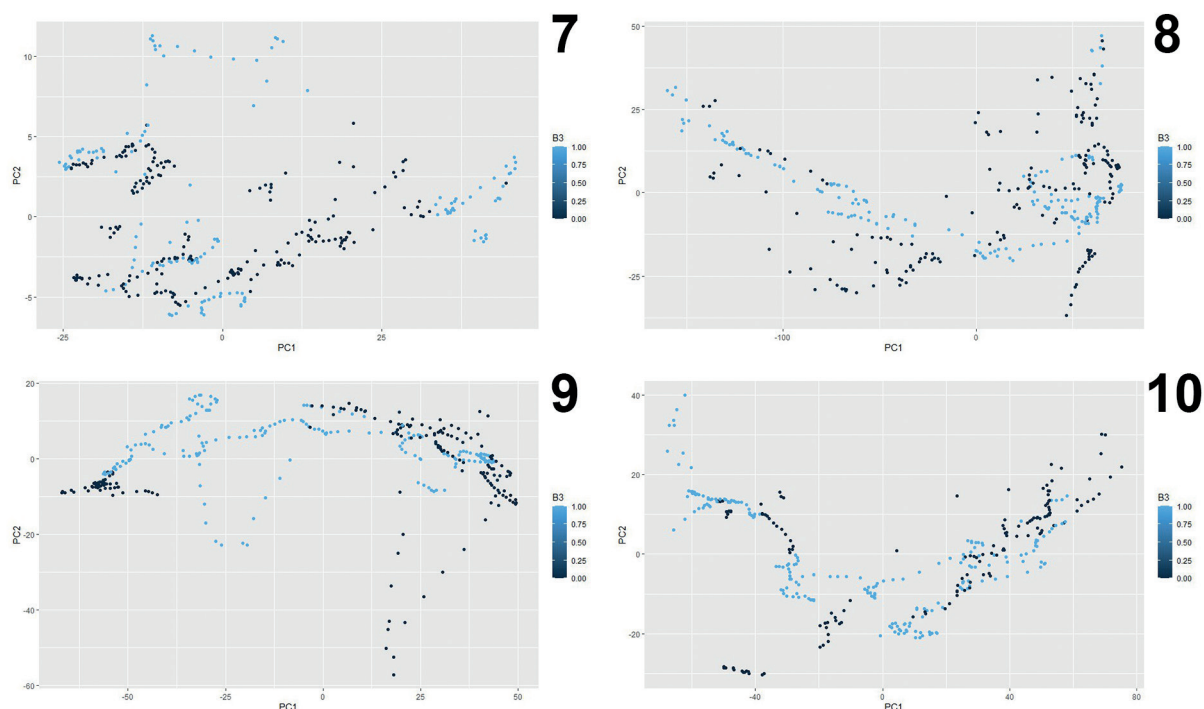
	Varianza acumulada de los dos primeros componentes principales
Argentina	0.96861
Brasil	0.9017
Canadá	0.99194
Chile	0.97498
Estados Unidos	0.98417
India	0.96998
México	0.96578
Polonia	0.9838
Rusia	0.98304
Turquía	0.9716

Los gráficos de las Figuras 1-10, obtenidos respectivamente de Argentina, Brasil, Canadá, Chile, Estados Unidos, India, México, Polonia, Rusia y Turquía, resultan del análisis de componentes principales para cada país donde tomamos al primer componente como eje de abscisas y el segundo componente como eje de ordenadas. Los puntos celestes representan días para los cuales el factor de variación de reportados en 3 semanas es mayor a 1, mientras que los puntos azul oscuro representan días en que el factor de variación de reportados en 3 semanas es menor a 1

1. Visualmente observamos que países como EEUU, la India o Rusia presentan agrupaciones más o menos homogéneas para cada clase, mientras que países como Brasil o Polonia parecen presentar una mayor superposición de clases. Para ningún país se nota que alguna dirección del plano tienda a dar ventaja a alguna clase, siendo que ambas clases tienden a encontrarse para valores bastante extremos tanto del primer componente como del segundo. Por lo que no se vislumbra ninguna curva simple que separe fácilmente los datos en todos los países.



Figuras 1-6. Visualizaciones a partir de análisis de componentes principales, correspondientes a diferentes países. 1) Argentina. 2) Brasil. 3) Canadá. 4) Chile. 5) Estados Unidos. 6) India.



Figuras 7-10. Visualizaciones a partir de análisis de componentes principales, correspondientes a diferentes países. 7) México. 8) Polonia. 9) Rusia. 10) Turquía.

Análisis de Correlación

Las correlaciones entre el logaritmo natural del factor de variación de reportados en 3 semanas y las variables *RR*, *GP*, *P*, *TS*, *W* y *R*; también muestra

diferencias notorias entre los países analizados. La Tabla 2 muestra valores con un valor *p* menor a 0.05 en negrita resaltando resultados significativos con un 95% de confianza. Argentina muestra una

Tabla 2. Tabla de correlaciones entre los países seleccionados y las variables suavizadas de movilidad, donde los resultados con un 95% de confianza se resaltan en negrita.

País	RR	GP	P	TS	W	R
Argentina	0.03422	0.09562	-0.10224	0.03192	-0.05908	-0.00232
Brasil	0.08026	0.08462	0.19857	0.09491	-0.16413	-0.11181
Canadá	0.31208	-0.13797	-0.02354	0.43087	0.13821	-0.26979
Chile	0.47898	0.41445	0.51501	0.44796	0.31973	-0.57305
Estados Unidos	-0.11295	-0.03982	0.03504	-0.06001	-0.21759	0.10696
India	0.29108	0.47291	0.23179	0.35550	0.43701	-0.46507
México	0.15251	0.14422	0.23424	0.16891	0.03659	0.08750
Polonia	0.07721	-0.29487	-0.04455	0.09438	0.07172	-0.15816
Rusia	0.46932	0.45646	0.28488	0.58028	0.12518	-0.37380
Turquía	0.20946	0.07842	0.08508	0.23143	0.33762	-0.23411

correlación insignificante, mientras que Chile, India y Rusia presentan correlaciones significativas para todas las variables de movilidad. La variable residencia R tiende a tener una correlación negativa entre los casos significativos, aunque puede haber excepciones como EEUU. Las demás variables tienden a valores positivos cuando son significativas, aunque en menor medida la variable supermercados y farmacias GP que es negativa para Canadá y Polonia, o la variable lugares de trabajo W que es negativa para Brasil y EEUU.

Conclusiones

Al estudiar la relación entre movilidad y transmisibilidad del COVID-19 evaluamos más prudente presentar resultados como factores relacionados, en vez de separar entre variables independientes y dependientes. Esto es debido a que variaciones de la transmisibilidad pueden motivar restricciones de la movilidad y al mismo tiempo se aplican restricciones a la movilidad para influir en la transmisibilidad. Mantenemos esta prudencia aunque el factor de variación de transmisibilidad registre un fenómeno que ocurra después de los valores medidos de movilidad. Además, en este análisis no se aplicó ningún test de causalidad, por lo que evitamos hablar de causa-efecto y preferimos hablar de patrones.

Una de las principales dificultades a la hora de analizar la movilidad, es que existen factores de la pandemia de COVID-19 que van cambiando a lo largo del tiempo, pudiendo modificar la dinámica ya existente. Por ejemplo, al inicio de la pandemia de COVID-19 no se sabía demasiado de tratamientos ni era tan común el uso de mascarillas, mientras que en etapas posteriores ya existen campañas de vacunación masiva. En ese sentido, el efecto progresivo de las vacunas tendría un efecto sobre el valor de nuestro factor de variación de reportados.

Los análisis aplicados dan sustento a políticas sanitarias comúnmente aplicadas contra el COVID-19. El alto porcentaje de varianza acumulada por los dos primeros componentes del análisis de componentes principales muestra que a pesar de tener 6 dimensiones, la dinámica de movilidad puede ser visualizada en un plano sin truncar demasiado

su geometría. Sin embargo, la superposición de clases observada en el análisis de componentes principales para varios países refuerza la evidencia de que la movilidad en sí misma no es suficiente para determinar variaciones en la transmisibilidad del COVID-19 en un plazo de 3 semanas. Además el análisis de correlación muestra que mayor tiempo de permanencia en áreas residenciales es un patrón relacionado a la reducción de la transmisibilidad en 3 semanas puede variar bastante de país en país.

Agradecimientos

Al Rectorado de la Universidad Nacional de Asunción por financiar este trabajo en el marco del Proyecto “Identificación de patrones de movilidad durante la pandemia de COVID-19 y su incidencia en el número de reproducción, usando minería de datos”.

Contribución de los autores

Los autores contribuyeron de igual manera en la elaboración de este artículo.

Conflictos de interés

Los autores declaran no tener conflictos de interés.

Literatura citada

- Aktay, A., Bavadekar, S., Cossoul, G., Davis, J., Desfontaines, D., Fabrikant, A., Gabrilovich, E., Gadepalli, K., Gipson B., Guevara, M., Kamath, C., Kansal, M., Lange, A., Mandayam, C., Oplinger, A., Pluntke, C., Roessler, T., Schlosberg, A., Shekel, T., Vispute, S., Vu, M., Wellenius, G., Williams, B. & Wilson, R.J. (2020). Google COVID-19 Community Mobility Reports: anonymization process description (version 1.1). *arXiv*, 2004.04145: 1–6.
- Arenas, A., Cota, W., Gómez-Gardeñes, J., Gómez, S., Granell, C., Matamalas, J.T., Soriano-Paños, D. & Steinegger, B. (2020). Derivation of the effective reproduction number R for COVID-19 in relation to mobility restrictions and confinement. *medRxiv*, 2020.04.06.20054320: 1–24.

- Basellini, U., Alburez-Gutierrez, D., Del Fava, E., Fava, E., Perrotta, D., Bonetti, M., Camarda, C.G. & Zagheni, E. (2021). Linking excess mortality to Google mobility data during the COVID-19 pandemic in England and Wales. *SSM - Population Health*, 14(100799): 1–18.
- Cintia, P., Pappalardo, L., Rinzivillo, S., Fadda, D., Boschi, T., Giannotti, F., Chiaromonte, F., Bonato, P., Fabbri, F., Penone, F., Savarese, M., Calabrese, F., Guzzetta, G., Riccardo, F., Marziano, V., Poletti, P., Trentini, F., Bella, A., Andrianou, X., Del Manso, M., Fabiani, M., Bellino, S., Boros, S., Urdiales, A.M., Vescio, M.F., Brusaferrero, S., Rezza, G., Pezzotti, P., Ajelli, M., Merler, S., Vineis, P. & Pedreschi, D. (2020). The relationship between human mobility and viral transmissibility during the COVID-19 epidemics in Italy. *arXiv preprint arXiv*, 2006.03141: 1–37.
- Cot, C., Cacciapaglia, G. & Sannino, F. (2021). Mining Google and Apple mobility data: Temporal anatomy for COVID-19 social distancing. *Scientific reports*, 11(4150): 1–8.
- Dainton, C. & Hay, A. (2021). Quantifying The Relationship Between Lockdowns, Mobility, and Effective Reproduction Number (R_t) During The COVID-19 Pandemic in The Greater Toronto Area. *BMC Public Health*, 21(1658): 1–8.
- Kajitani, Y. & Hatayama, M. (2021). Explaining the effective reproduction number of COVID-19 through mobility and enterprise statistics: Evidence from the first wave in Japan. *Plos one*, 16(3)e0247186: 1–12.
- Kraemer, M.U.G., Yang, C.-H., Gutierrez, B., Wu, C.-H., Klein, B., Pigott, D.M., Open COVID-19 Data Working Group, du Plessis, L., Faria, N.R., Li, R., Hanage, W.P., Brownstein, J.S., Layan, M., Vespignani, A., Tian, H., Dye, C., Pybus, O.G. & Scarpino, S.V. (2020). The effect of human mobility and control measures on the COVID-19 epidemic in China. *Science*, 368(6490): 493–497.
- Linka, K., Goriely, A. & Kuhl, E. (2021). Global and local mobility as a barometer for COVID-19 dynamics. *Biomech Model Mechanobiol*, 20(2): 651–669.
- Linka, K., Peirlinck, M. & Kuhl, E. (2020). The reproduction number of COVID-19 and its correlation with public health interventions. *Computational Mechanics*, 66: 1035–1050.
- Maier, B. & Brockmann, D. (2020). Effective containment explains subexponential growth in recent confirmed COVID-19 cases in China. *Science*, 368(6492): 742–746.
- McGough, S., Gan, R., Tibshirani, R. & Meyer, A.-M. (2020). Modeling COVID-19 mortality in the US: Community context and mobility matter. *medRxiv*, 2020.06.18.20134122: 1–11.
- Noland, R. (2021). Mobility and the effective reproduction rate of COVID-19. *Journal of Transport & Health*, 20(101016): 1–9.
- Nouvellet, P., Bhatia, S., Cori, A., Ainslie, K.E.C., Baguelin, M., Bhatt, S., Boonyasiri, A., Brazeau, N.F., Cattarino, L., Cooper, L.V., Coupland, H., Cucunuba, Z.M., Cuomo-Dannenburg, G., Dighe, A., Djaafara, B.A., Dorigatti, I., Eales, O.D., Elmsland, S.L., Nascimento, F.F., FitzJohn, R.G., Gaythorpe, K.A.M., Geidelberg, L., Green, W.D., Hamlet, A., Hauck, K., Hinsley, W., Imai, N., Jeffrey, B., Knock, E., Laydon, D.J., Lees, J.A., Mangal, T., Mellan, T.A., Nedjati-Gilani, G., Parag, K.V., Pons-Salort, M., Ragonnet-Cronin, M., Riley, S., Unwin, H.J.T., Verity, R., Vollmer, M.A.C., Volz, E., Walker, P.G.T., Walters, C.E., Wang, H., Watson, O.J., Whittaker, C., Whittles, L.K., Xi, X., Ferguson, N.M. & Donnelly, C.A. (2021). Reduction in mobility and COVID-19 transmission. *Nature Communications*, 12(1090): 1–9.
- Sampi Bravo, J. & Jooste, C. (2020). Nowcasting economic activity in times of COVID-19: An approximation from the Google Community Mobility Report. *World Bank*

- Policy Research Working Paper*, 9247: iii + 21 pp.
- Wang, L., Ben, X., Adiga, A., Sadilek, A., Tendulkar, A., Venkatramanan, S., Vullikanti, A., Aggarwal, G., Talekar, A., Chen, J., Lewis, B., Swarup, S., Kapoor, A., Tambe, M. & Marathe, M. (2020). Using Mobility Data to Understand and Forecast COVID-19 Dynamics. *medRxiv*, 2020.12.13.20248129: 1–5.
- Warren, M., & Skillman, S. (2020). Mobility changes in response to COVID-19. *arXiv*, 2003.14228: 1–6.
- Yilmazkuday, H. (2021). Stay-at-home works to fight against COVID-19: International evidence from Google mobility data. *Journal of Human Behavior in the Social Environment*, 31(1-4): 210–220.