

PATRONES DE MOVILIDAD EN TIEMPOS DE COVID-19: UN ENFOQUE CON *BIG DATA*Steffan Gómez-Campos¹, Mariana Cubero-Corella¹, María Fernanda Salas García¹,
Shu Wei Chou-Chen²¹*Programa Estado de la Nación, San José, Costa Rica.*²*Escuela de Estadística - Centro de Investigación en Matemática Pura y Aplicada, Universidad de Costa Rica, San José, Costa Rica.*✉ sgomez@estadonacion.or.cr

Enviado: 30/06/2022; Aceptado: 08/02/2023

DOI: <https://doi.org/10.15517/es.2023.55398>**Resumen**

La movilidad en Costa Rica es un tema complejo debido a la falta de ordenamiento territorial de la Gran Área Metropolitana (GAM). La crisis sanitaria global causada por la pandemia del COVID-19 cambió considerablemente los patrones de movilidad en el país a causa de restricciones vehiculares, y de actividades económicas, impuestas por el gobierno para contener los contagios del virus. Con el uso de las técnicas de *big data* y los datos de Waze, se analiza la congestión vial (como *proxy* de la movilidad de población) antes (2019) y durante la pandemia (marzo a diciembre de 2020). Además, se analiza la relación entre los flujos de movilidad de la población, junto con variables sociodemográficas, y los contagios de COVID-19. Los análisis realizados muestran que la movilidad de población cambió drásticamente con la pandemia, y que la movilidad y las variables sociodemográficas estudiadas están asociadas con la cantidad de contagios por COVID-19. Estos resultados sirven como una inspección del fenómeno ocurrido tan complejo, y también como un insumo para valorar la factibilidad de aplicar medidas sobre el tránsito en condiciones posteriores a la pandemia, con el fin de reducir los tiempos perdidos por la congestión, la contaminación y otras externalidades negativas que produce el fuerte embotellamiento en la GAM.

Palabras clave: Coronavirus; análisis espacial; time series; desarrollo humano; salud pública, navegación móvil, big data.

MOBILITY PATTERNS IN TIMES OF COVID-19 PANDEMIC: A BIG DATA
APPROACHSteffan Gómez-Campos¹, Mariana Cubero-Corella¹, María Fernanda Salas García¹,
Shu Wei Chou-Chen²¹*Programa Estado de la Nación, San José, Costa Rica.*²*Escuela de Estadística - Centro de Investigación en Matemática Pura y Aplicada, Universidad de Costa Rica, San José, Costa Rica.*✉ sgomez@estadonacion.or.cr

Submitted: 06/30/2022; Accepted: 02/08/2023

DOI: <https://doi.org/10.15517/es.2023.55398>**Abstract**

Mobility in Costa Rica is a complex issue due to the lack of urban planning in Gran Área Metropolitana (GAM). The global health crisis caused by the COVID-19 pandemic considerably changed mobility patterns in the country due to vehicle restrictions and economic activities imposed by the government to contain the spread of the virus. With the use of *big data* techniques and Waze data, road congestion (as a *proxy* of population mobility) is analyzed before (2019) and during the pandemic (March to December 2020). In addition, the relationship between population mobility flows, along with sociodemographic variables, and COVID-19 infections is analyzed. The analysis shows that population mobility changed drastically with the pandemic and that mobility and the sociodemographic variables studied are associated with the number of COVID-19 infections. These results serve as an inspection of the complex phenomenon that has occurred, and also as an input to assess the feasibility of applying traffic measures in post-pandemic conditions, in order to reduce time lost due to congestion, pollution, and other negative factors produced by the strong bottleneck in the GAM.

Keywords: Coronavirus; spatial analysis; time series; human development; public health, mobile navigation, big data.

1. Introducción

Costa Rica es un país pequeño, de 51,100 km^2 de extensión, dividido administrativamente en 7 provincias, 82 cantones y 485 distritos. El 65 % de los poco más de cinco millones de habitantes radica en la Gran Área Metropolitana (GAM) que se ubica en el centro geográfico del territorio. Ahí están las cabeceras de cuatro de las provincias: San José (la capital), Alajuela, Cartago y Heredia. Son las zonas más urbanas y densamente pobladas. También las de mayor desarrollo económico y mejores condiciones de vida. Hay diferencias sustanciales en los indicadores socioeconómicos entre las zonas de la GAM y el resto del país.

Los patrones de transporte y movilidad en Costa Rica ha sido objeto de estudio durante varios años, debido a la falta de ordenamiento territorial de la GAM y el crecimiento de las ciudades intermedias. Asimismo, se suman otros problemas de la población para moverse, debido a que la región es urbana, con densidad baja de población, distante y desconectado, con una gran apuesta por el vehículo particular, un sistema de transporte público poco eficiente y una red vial que no da abasto [1, 22].

La crisis sanitaria global causada por la pandemia del COVID-19 también afectó sustancialmente en el país. El 6 de marzo de 2020 se confirmó el primer caso de COVID-19 en el país. Al ser una enfermedad altamente contagiosa, a partir de ese momento comenzó una estrategia de medidas sanitarias y de control de la movilidad decretadas por el Gobierno para controlar los efectos de la pandemia. Entre ellas destacan el teletrabajo en buena parte del Estado y sector privado, el cierre obligatorio de templos y cultos religiosos, el cierre total de playas en todo el país, cierres temporales de comercios y restricciones vehiculares.

La presente investigación se centra en medir la relación que tuvieron las medidas sanitarias para el control de la pandemia, los cambios en los patrones de movilidad de las personas y algunas características sociodemográficas con los contagios a nivel local en el país.

La movilidad de personas es un fenómeno difícil de cuantificar. El caso de Costa Rica es un escenario propicio para realizar esta aproximación de la movilidad de personas, por medio de la congestión vial (variable *proxy*). Se cuenta con información de la aplicación Waze para un largo período de tiempo de enero de 2019 a setiembre de 2020¹. Además, estos datos están altamente correlacionados con otras medidas que han probado ser robustas para aproximar la movilidad de personas en medio de la pandemia, en especial los registros agregados por país que publica Google como parte de su proyecto “Community Mobility Reports”.

¹por medio de un convenio entre el Programa Estado de la Nación y el Ministerio de Obras Públicas y Transportes (MOPT).

Google registra datos agregados por país para lugares específicos. Por ejemplo, zonas de comercio y recreación, como teatros, cines, restaurantes y bares. También, tiene datos para medir cómo ha variado el desplazamiento de las personas en comercios de abastecimiento, como supermercados y farmacias. Además, cuenta con registros de las zonas de paradas de transporte público, entre otros. A diferencia de Google, los datos de Waze posibilitan, para el caso de Costa Rica, profundizar el análisis local (distrito o cantón) para determinar comportamientos específicos.

En la literatura se encuentra diversas aplicaciones de datos móviles para planificar obras viales para la toma de decisiones públicas [22, 25]. El uso de los datos mediante señales de geolocalización enviadas por la tecnología celular también ha sido un insumo en medio de la pandemia con el fin de medir la movilidad de la población y, por ende, tomar acciones para contener los contagios por COVID-19. Por ejemplo, la información de localización de *Twitter* es utilizado para aproximar la dinámica de movilidad de manera confiable [15].

Diversos estudios han demostrado que la información de datos móviles, recopilada durante los primeros meses, fue posible determinar que los patrones de desplazamiento de las personas variaron considerablemente. Para ello se utilizaron diferentes métodos de medición y estudio. En Estados Unidos se logró medir la efectividad del distanciamiento físico en las tasas de contagio [5]. En Italia, los sensores automáticos de conteo de autos en carreteras fueron usados para medir la movilidad y tratar de contener el virus [9]. En China se demostró que las medidas de prevención impuestas sobre la movilidad de las personas en Wuhan y las zonas circundantes influyeron sobre los patrones de esparcimiento del COVID-19 en el territorio [18]. Con información de Apple y de Google para 53 países también se encontró una relación entre la movilidad y el contagio. La movilidad explicó más del 85% de la variabilidad en la transmisión del virus [20].

Este breve repaso de estudios muestra la utilidad de evaluar la movilidad de personas usando distintas fuentes de información y su relación con los contagios por virus. Se puede encontrar otros estudios similares en esa creciente literatura [12, 3, 23]. Como lo indica el Imperial College de Londres [20], los datos de movilidad representan un importante *proxy* para medir el distanciamiento social.

Los análisis con datos de Google han sido un insumo central para los intentos públicos de controlar la pandemia. La empresa creó un sitio web específico para ese fin, donde actualiza sus reportes de movilidad por país². Sin embargo, tiene algunas limitaciones, en particular que son datos agregados. Es decir, no permiten ver el comportamiento local. Algo que con Waze sí se puede realizar para el caso de Costa Rica.

²Para más detalle, ver <https://www.google.com/covid19/mobility/>.

Un experimento efectuado en el Instituto de Seguridad en Aplicaciones Distribuidas (SVA, por su sigla en alemán), de la Universidad Técnica de Hamburgo, comprobó la posibilidad de geolocalización con alto nivel de precisión de los usuarios a partir de sus movimientos en carretera en ambas aplicaciones [16].

Por la forma de recolectar los datos de las aplicaciones de Waze y Google, existe evidencia de que ambas son un *proxy* satisfactorio para estimar la movilidad de las personas, por cuanto no se requiere calcular una ruta de viaje en automóvil para que se envíen los datos. Cada aparato celular se convierte en un sensor potencial de movimiento.

Para que los datos generados por estas plataformas sean robustos, se necesita alta penetración de tecnología celular, un fenómeno que también ocurre en Costa Rica. De acuerdo con un reciente informe de la Organización para la Cooperación y el Desarrollo Económicos (OCDE), el país es uno de los líderes de la región en penetración móvil, con suscripciones por cada cien habitantes mayores que el promedio de la OCDE y de América Latina [21]. La Sección 3.2 presenta un análisis empírico para ilustrar la similitud de patrones entre los datos de Waze y “Google Mobility Data” en Costa Rica.

El objetivo de esta investigación es analizar los efectos de la pandemia sobre el país con base en tres factores específicos: las medidas de restricción vehicular adoptadas por el Gobierno para combatir la pandemia, los flujos de movilidad de la población, y la asociación de estos con respecto a los nuevos contagios locales de COVID-19.

Los resultados obtenidos permiten crear herramientas que alimenten decisiones informadas en materia de transporte y movilidad durante la atención de la pandemia, en especial el control de la expansión del virus. Los resultados obtenidos también pueden constituirse en insumos para discusiones posteriores sobre la incidencia que pueden tener políticas concretas para minimizar el grado de congestión vial en el país.

A continuación, en la Sección 2 se exponen los fundamentos y las metodologías para lograr el objetivo planteado. En la Sección 3 se presentan los resultados obtenidos del análisis. Finalmente, las discusiones y conclusiones son dadas en la Sección 4.

2. Métodos y datos

Los análisis de esta investigación parten de una premisa: las medidas del Gobierno comprenden fases de restricción y apertura a lo largo del período analizado, y su cumplimiento incluye diversas medidas con alcance nacional, cantonal o distrital. Por consiguiente, los patrones de movilización de las personas se ven afectados, entre otros factores, por esas fases y su aplicación en el territorio con distintos niveles de alcance.

Los análisis propuestos en este artículo tienen una lógica secuencial de acuerdo con las siguientes cuatro preguntas de investigación:

1. ¿Cuáles cantones reportaron mayor congestión durante el 2019 y cómo varió esa congestión durante el 2020?
2. ¿Cuánto varió la congestión durante la pandemia de marzo a setiembre de 2020 con respecto a los patrones anteriores, dadas las medidas de restricción impuestas por el Gobierno y la autocontención de las personas a salir de sus casas?
3. ¿Modificarón los cambios registrados en la intensidad de la congestión vial también los patrones territoriales de movilidad?
4. ¿Están los cambios en la congestión vial, y otras variables sociodemográficas, relacionados con la cantidad de contagios por COVID-19 en el ámbito cantonal?

Con el fin de responder las preguntas planteadas, se propusieron las siguientes 4 metodologías:

1. Se construyó un *ranking* de congestión cantonal con los datos del 2019 y se comparó con lo ocurrido durante el 2020, con el fin de detectar cambios de patrones.
2. Se evaluaron múltiples indicadores de Waze como insumo, con distintos niveles de desagregación, para identificar la magnitud de los cambios en la movilidad antes y durante la pandemia.
3. Se trabajó con modelos de estadística espacial para determinar si la congestión vial cantonal, como medida de aproximación a la movilización de personas, mantiene (o alteró) los patrones territoriales de años anteriores durante los primeros siete meses del año 2020.
4. Se exploró la relación entre congestión vial y contagios, con datos de marzo a julio de 2020. Este fue el período crítico de manejo inicial de la pandemia y de aplicación de medidas sanitarias en el país.

2.1. Datos

La principal fuente de información empleada para aproximar los movimientos poblacionales en los ámbitos nacional y subnacional, consiste en los datos de congestión vial registrados por la aplicación de tránsito Waze, obtenida por convenio del Programa Estado de la Nación y el Ministerio de Obras Públicas y Transportes (MOPT).

Las variables sociodemográficas que fueron consideradas como variables independientes son:

- **Jamstotal**: promedio móvil de siete días de la cantidad de jams por día por cantón.
- **Fecha**: día del año.
- **DensidadPoblacion**: habitantes por km² de cada cantón.
- **SectorPrimario**: proporción de empleos formales en el sector primario (o agropecuario) por cantón.
- **Escolaridad2011**: porcentaje de la población con secundaria completa o más por cantón.
- **PorcPob_NoAsegurada**: porcentaje de la población sin seguro social de la Caja Costarricense de Seguro Social (CCSS).
- **PorcPob_Urbana**: porcentaje de la población que vive en zonas urbanas en el cantón.
- **Patentes_canton**: total de patentes registradas en cada cantón con datos.
- **Trabajadores_canton**: cantidad de personas que trabajan en empresas formales de ese cantón.
- **Mov_intercantonal**: porcentaje de personas ocupadas mayores de 15 años que trabajan en un cantón distinto de donde residen.

Las variables mencionadas son obtenidas de las bases de datos de Censo y Encuesta Nacional de Hogares (ENAHO) del Instituto Nacional de Estadística y Censos³, y Banco Central de Costa Rica⁴. Finalmente, los datos sobre contagios por COVID-19 son obtenidos del Ministerio de Salud (Minsa).

2.2. Proceso de construcción y actualización de la información de Waze con técnicas de *big data*

La base de datos de Waze consiste en información desagregada espacialmente hasta segmentos de carretera de cien metros, aproximadamente, y temporalmente cada diez minutos. Este es un proceso realizado por el equipo técnico del Programa Estado de la Nación (PEN).

La unidad de observación es la congestión, en adelante *jams* por segmentos de carretera para el período comprendido entre enero de 2019 y setiembre de 2020. La información de *jams* por segmento de carretera está ligada al distrito, cantón, y provincia respectiva, con captura de datos cada diez minutos. En total se tienen 255.831.318 de registros.

Para extraer, transformar y cargar los datos (pipeline de Extract Transform and Load, ETL por sus siglas en inglés), se aplicaron técnicas de *big data* y procesamiento en paralelo para acceder, resumir y analizar la información. Los archivos iniciales se extrajeron en for-

³<https://www.inec.cr/>

⁴<https://www.bccr.fi.cr/SitePages/Inicio.aspx>

mato JSON, luego se importaron a una base de datos Mongo para, posteriormente, realizar las transformaciones necesarias y la intersección con la red vial del país. El pipeline del ETL se realizó con el lenguaje de programación Python y el framework PySpark; y el de analítica, con el lenguaje de programación R y el paquete `sparklyr` [19] para análisis con procesamiento en paralelo. La base de datos contiene poco más 255 millones de registros.

Para el procesamiento, la visualización y el análisis de datos, se usaron múltiples paquetes: `cartogram` [17], `ggplot2` [26], `lubridate` [13], `maptools` [7], `mapview` [4], `purrr` [14], `rgdal` [6], `rgeos` [8], `stringr` [27], `tmap` [24] y `tidyverse` [28].

En resumen, la extracción de datos consiste en 3 pasos:

1. Extracción de todos los *jams* y sus atributos en formato JSON, a través de conexión con la API de Waze.
2. Segmentación de la red vial nacional y cantonal del país en trectos de cien metros, y asignación de un identificador único a cada segmento.
3. Intersección de la base de *jams* del paso 1 con la de segmentos de carretera del paso 2, para obtener un conteo de *jams* por cada segmento de las carreteras, junto con otras variables como velocidad promedio, tamaño y coordenadas espaciales.

Algunos casos de congestión pueden estar duplicados en la base de datos debido a que la toma de datos ocurre cada diez minutos desde la API de Waze. Este sobrerregistro no genera mayores alteraciones, por dos motivos: el análisis no se centra en el valor absoluto, sino en la tendencia y cambios comparativos en el tiempo y territorio para todos los casos; además, la temporalidad en la captura de datos es la misma durante todo el período de análisis, por lo cual el posible sobrerregistro es sistemático a lo largo de toda la base.

2.3. Métodos de análisis

Tomando en cuenta las preguntas de investigación planteadas al inicio de la Sección 2, se analizaron los datos de congestión vial por tiempo y espacio. Luego, para describir las variaciones de intensidad de la movilidad por cantón en el país, se divide el tiempo en tres momentos:

1. lo ocurrido durante todo el 2019,
2. entre enero y febrero de 2020, antes de la pandemia, y
3. en los meses durante la pandemia, específicamente de marzo a setiembre.

Además, se calculó el índice de Morán para identificar la existencia de conglomerados de cantones con alta intensidad de congestión vial en los meses antes y durante la pandemia. Para establecer estas relaciones se obtuvo el índice de Morán global, y una prueba de

hipótesis basada en simulaciones de Monte Carlo para confirmar que la relación espacial es significativa [10]. En los períodos donde la relación espacial es significativa, se ejecuta el índice local de Morán como medida local de asociación espacial (local indicators of spatial association, LISA, por su sigla en inglés) para determinar cuáles cantones conforman estos conglomerados.

El primer paso fue construir un modelo con el promedio mensual de congestiones durante el 2019, para determinar el estado “normal” del tránsito y las zonas que presentan alta congestión. Luego se ejecutó el mismo modelo para cada uno de los meses del 2020. De esta forma, se corroboró el comportamiento en el período previo al inicio de la pandemia, enero y febrero, así como la comparación posterior cuando se aplicaron las medidas de restricción. Se usan los datos mensuales como criterio de corte para tratar de aislar los efectos de las distintas medidas en este tiempo.

Cabe recordar que las regulaciones impuestas por el Poder Ejecutivo variaron en el tiempo, pero también en el nivel de afectación para cada cantón, con restricciones diferenciadas por distritos y zonas específicas como la GAM y la zona norte del país, por ejemplo. La evaluación por mes proporciona un panorama más preciso de lo ocurrido.

Finalmente, se analizó la relación entre variables sociodemográficas, congestión vial, como proxy de movilización, y la cantidad de contagios por cantón, por medio de la metodología descrita en la Sección 2.4.

2.4. Modelos de regresión para el análisis de movilidad y contagios por COVID-19

El análisis de regresión se realizó con información para el período de marzo a julio de 2020, período crítico en el manejo de la pandemia. Se utilizan dos modelos de regresión: lineal y binomial negativa, con doce combinaciones en total entre distintas configuraciones de los modelos para la calibración.

El uso de la regresión lineal sirvió para explorar las relaciones lineales principales entre las variables. Posteriormente, dada la naturaleza discreta de las variables casos nuevos y casos activos, así como a la violación de supuestos como la normalidad y homoscedasticidad, se considera también el modelo de Poisson, debido a que la variable respuesta se trata de conteos en un intervalo de espacio y tiempo, en este caso, días o semanas. Es común que este modelo presente problemas de sobredispersión producto de la suposición de igualdad de media y variancia. Una forma de relajar esta restricción es especificar un modelo de regresión binomial negativa para considerar la sobredispersión [11].

Los modelos incluyeron pruebas con distintos rezagos entre la medición de Waze y los datos de contagio del Minsa, por cuanto el virus tiene un período de incubación de entre ocho y quince días, aproximadamente.

Se probaron las variables (dependientes e independientes) y los parámetros para calibrar las doce combinaciones en los modelos de regresión. La selección del modelo con mejor ajuste, se usó el índice de información de Akaike (AIC) [2]. Para el modelo lineal, se utilizó el R^2 como medida de bondad de ajuste, mientras que para el caso de la regresión binomial negativa, se usó el pseudo R^2 de McFadden. Se escogieron los dos de mejor ajuste para ejecutar los análisis finales con la mejor combinación. Asimismo, se realizó el análisis con las siguientes consideraciones:

1. **Temporalidad:** los datos se agruparon por día, por semana y con un promedio móvil a siete días.
2. **Indicador COVID-19:** se usaron casos nuevos y también casos activos por día.
3. **Rezago:** utilizando el coeficiente de correlación de Pearson, se obtuvo la correlación entre los casos nuevos y los casos activos con los *jams* de Waze, con el fin de aproximar el nivel óptimo de días de rezago. Para casos nuevos se obtuvo una correlación máxima a los dieciséis días y para casos activos a los dieciocho días.

3. Resultados

3.1. Comparación en las zonas de mayor congestión vial antes y durante la pandemia

En primer lugar, se hizo un *ranking* de la congestión vial con los datos de Waze durante 2019 y 2020, con el fin de determinar los cambios relativos en la congestión antes y durante la pandemia, como una primera medición general de lo ocurrido. Para mayor información, se puede consultar una aplicación con indicadores cantonales llamada “Dcifra tu cantón”⁵ desarrollado por el Programa de Estado de la Nación.

La Figura 1 representa los movimientos en el ranking de mayor congestión en tres momentos: el 2019, entre enero y febrero de 2020, antes de la pandemia, y entre marzo y setiembre, durante la pandemia.

Un grupo de cantones presentaron la mayor cantidad de flujos de tránsito en el 2019 y se mantuvieron en las primeras posiciones durante el 2020, incluso en los meses de pandemia. En este grupo destacan San José, Alajuela y Desamparados, cantones con alta densidad de población, cabeceras de provincia o con alta concentración de conexiones de transporte público y flujo de trabajadores. También sobresale en los primeros lugares de congestión el cantón de Pococí en Limón, lo cual puede estar vinculado con la insuficiencia de la ruta 32, la vía principal de la GAM con la provincia de Limón, para abarcar el flujo vehicular

⁵www.dcifra.cr

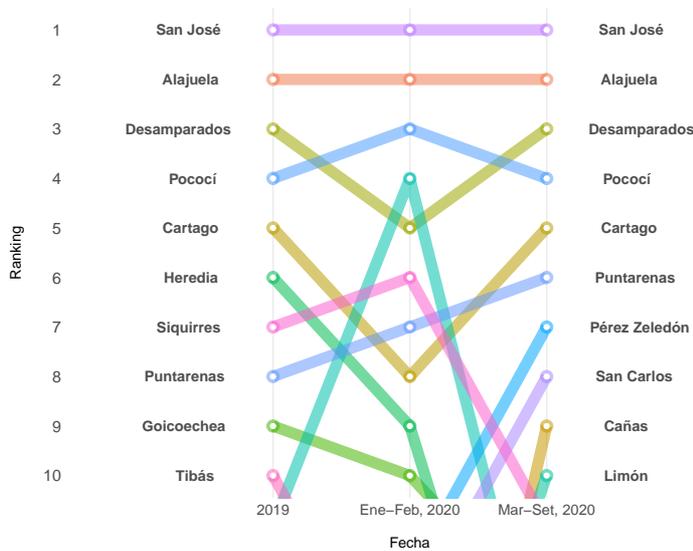


Figura 1: Cambios en el ranking de cantones con mayor congestión vial.

por esa zona, sumado a los trabajos de ampliación que han generado cierres y trabajos en la vía durante los meses que cubre el estudio.

Un segundo grupo de cantones tuvieron flujos regularmente altos en 2019, pero redujeron su importancia relativa durante el 2020, en particular con las medidas de restricción. Acá destacan el cantón central de Heredia, Goicoechea y Tibás. Los tres se ubicaron entre los diez con más congestión en 2019; sin embargo, durante el 2020, el flujo vehicular disminuyó de manera significativa al compararlo con otras zonas del país.

Por último, el tercer grupo es el de municipios que no estuvieron en las primeras posiciones durante el año 2019, pero sí aparecen con altos flujos en el 2020, en los meses de pandemia. En este caso se encuentran Pérez Zeledón, San Carlos, Cañas y Limón.

Lo ocurrido en estos cantones da una primera evidencia de las variaciones en la movilidad en período de pandemia. San José se mantuvo como el cantón con mayor congestión, pero se observó una reducción importante de la actividad cuando se comparan las condiciones de todo el 2019 con lo registrado entre marzo y setiembre de 2020, en período de pandemia. En promedio, la congestión se redujo un 66 % en este cantón.

La Figura 2 muestra, de acuerdo con la intensidad de los colores, el mapa con la reducción del tránsito en los dos momentos para el cantón central de San José. Nótese la disminución en el casco central y en la zona este. Se mantienen alto en las rutas de la General Cañas que

lo conectan con Alajuela y Heredia, el entronque con la vía de circunvalación a la altura del monumento del Agua en La Uruca y en general en toda la ruta 39 conocida como “la circunvalación”.

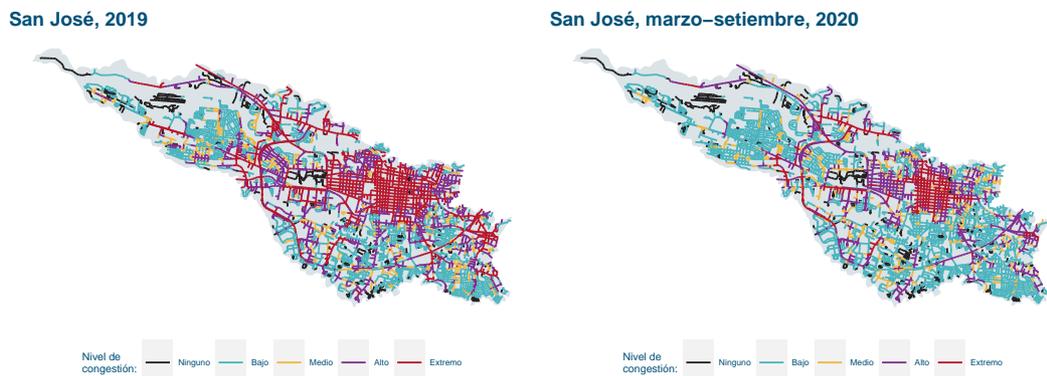


Figura 2: Cantidad de *jams* promedio por segmento en el cantón central de San José, según nivel de intensidad.

3.2. Análisis temporal de la congestión vial antes y durante la pandemia

A nivel nacional, la mayor congestión relativa se presentó durante los días viernes, y en la hora “pico” de la tarde, entre 4 p.m. y 7 p.m, que coincide con el fin de la jornada laboral y de clases en el sistema educativo público. Durante marzo y setiembre se mantuvo la hora pico de la tarde, aunque se movió al segmento entre 3 p.m. y 5 p.m. que concuerda con el límite de hora permitido para circular cuando se aplicaron las restricciones viales más fuertes.

Los niveles de intensidad son distintos entre enero-febrero y los meses posteriores, pero los datos evidencian que en general la pandemia, aunque redujo sustancialmente esa intensidad, no anuló por completo la movilidad de personas en esos dos momentos. La Figura 3 refleja ese comportamiento de manera comparada en el país.

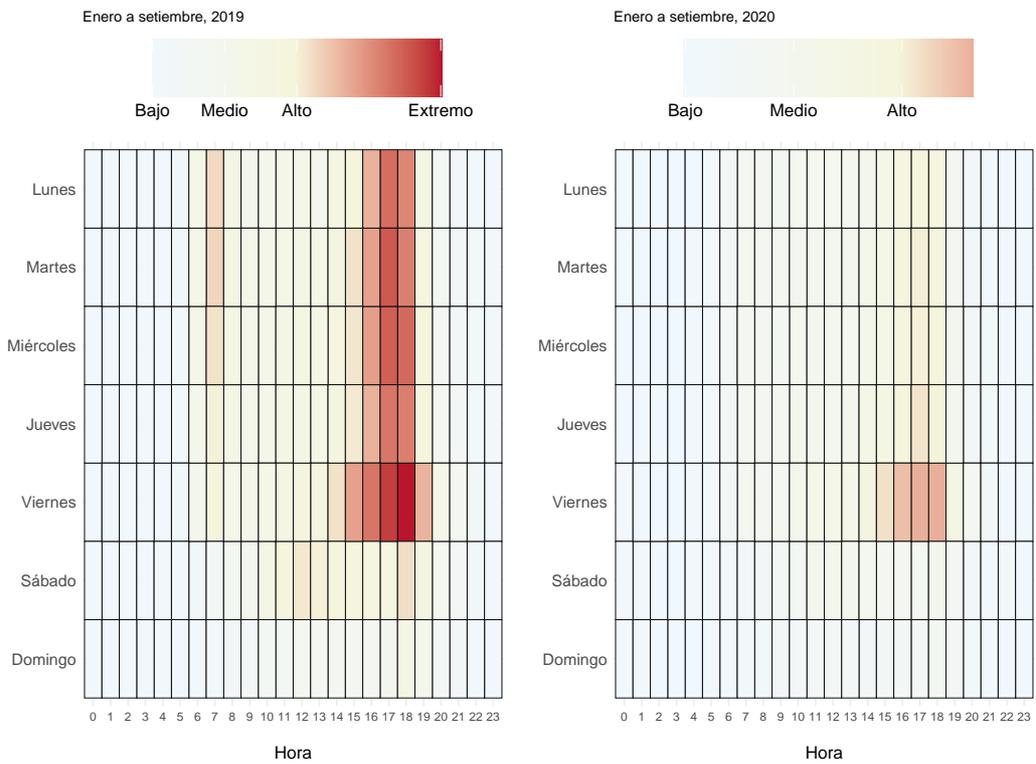


Figura 3: Nivel de congestión vial en Costa Rica, por día de la semana y hora.

El 12 de marzo el Gobierno comenzó una estrategia de medidas para controlar los efectos de la pandemia, entre ellas la medida de teletrabajo para el sector público. En esta fecha se observa una disminución importante de la congestión vial (ver Figura 4). Al mismo tiempo, se observa que el efecto estacional de los viernes se mantiene durante la pandemia. Cabe destacar que el único mes en el cual desaparece ese patrón por día de la semana es abril, que coincide con la Semana Santa, cuando se aplicó una fuerte restricción vehicular en todo el territorio nacional.

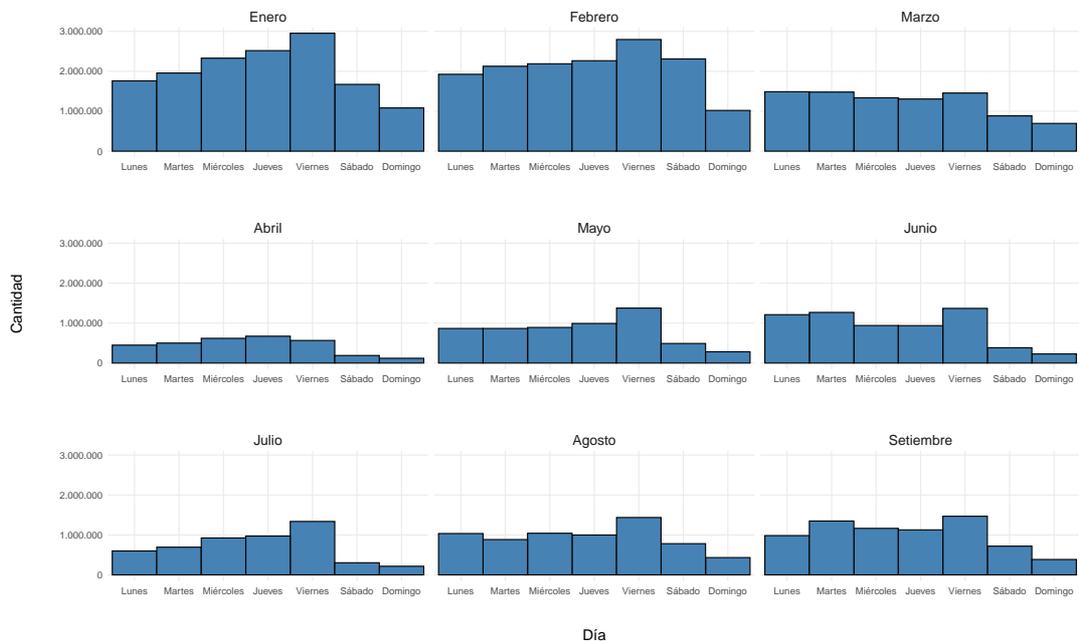


Figura 4: Congestión por día de la semana y mes en 2020.

El tiempo de atraso promedio es una manera de estimar momentos de alta congestión. En los puntos de mayor atasco se espera un incremento significativo de los tiempos promedio de viaje. Si se analiza el atraso promedio en segundos por hora del día y el mes, también se observan diferencias entre lo ocurrido antes y durante la pandemia. La Figura 5 muestra, por ejemplo, la hora “pico” de la mañana, entre 6 a.m. y 7 a.m. aproximadamente fue evidente en febrero debido al inicio del calendario escolar del Ministerio de Educación Pública (MEP). Se mantuvo en marzo y desapareció en abril de 2020. Por orden del Poder Ejecutivo, a partir del 17 de marzo se suspendieron las clases presenciales en centros educativos públicos y privados. En ambos casos se continuó con métodos de enseñanza a distancia.

De mayo a setiembre no se registraron flujos importantes de congestión en el segmento de hora de las mañanas.

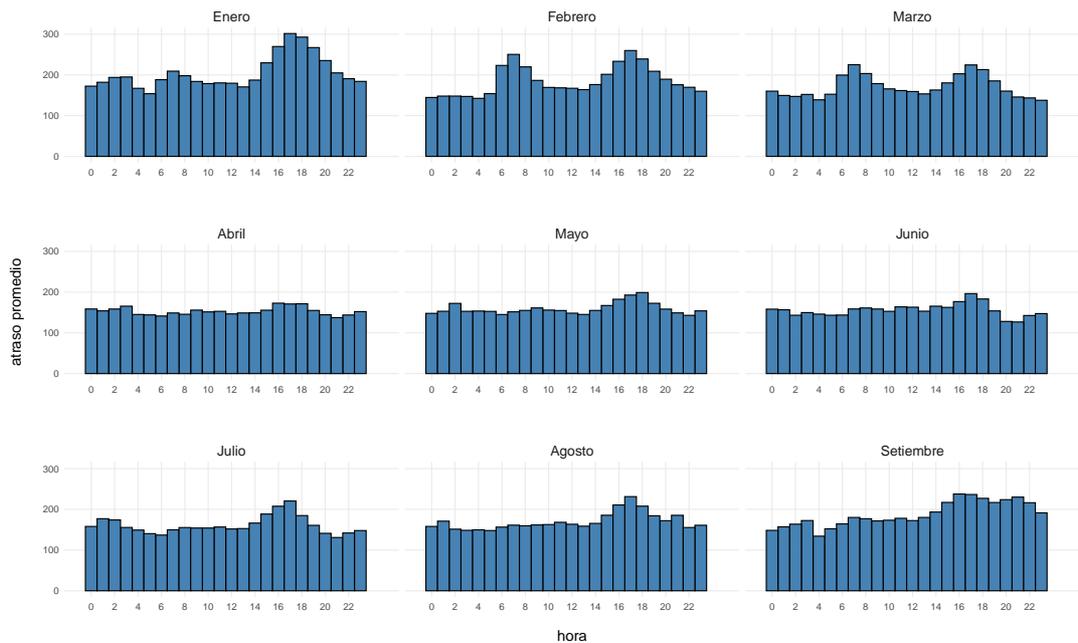


Figura 5: Atrazo promedio en segundos, por hora del día y mes. 2020 (promedio por segmento de carretera de 100 metros aproximadamente).

Los datos de congestión de Waze además confirman que el inicio del año 2020 tuvo mayor congestión en enero y febrero que en el 2019, pero la pandemia y las medidas de restricción modificaron el comportamiento siguiente. La Figura 6 muestra las diferencias entre ambos años por mes y día de la semana, y como se indicó anteriormente, es clara la estacionalidad de la congestión: mayor movilidad los viernes. Nótese el cambio a partir de marzo del 2020 con respecto a lo sucedido en el 2019.

Para evaluar la reducción de la congestión de marzo a setiembre, en medio de la pandemia, con respecto a período previo, se estableció un promedio de congestión diaria considerando los datos de enero y febrero de 2020, para usarlos como base comparativa con lo ocurrido después.

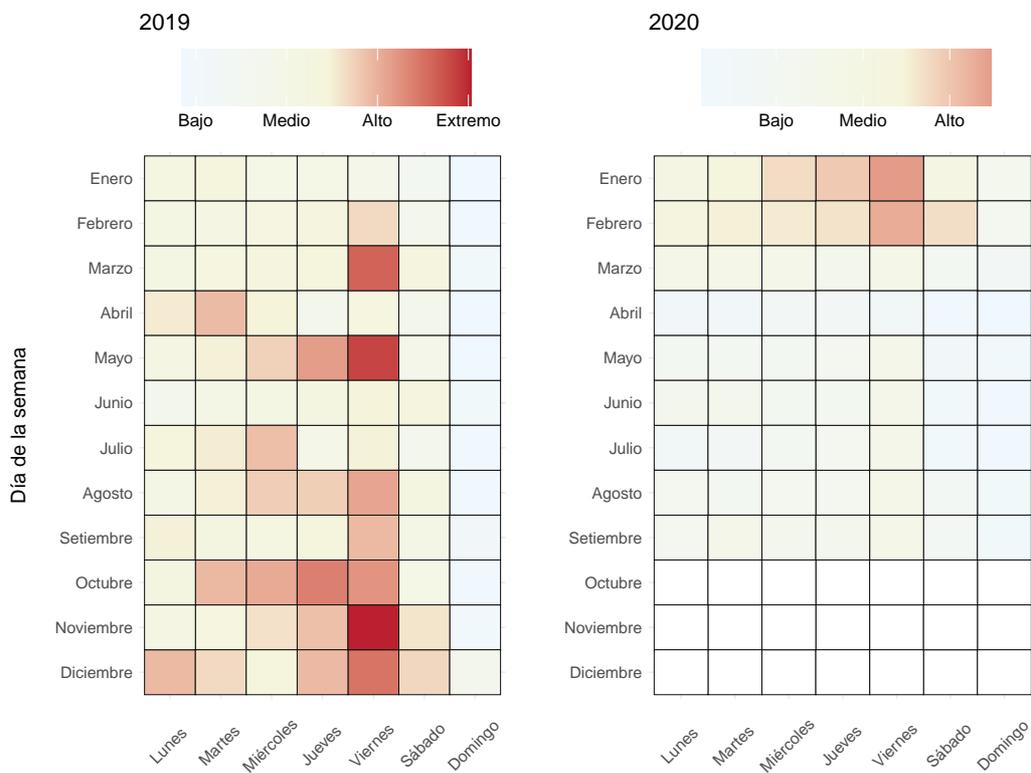


Figura 6: Nivel de la congestión vial por día de la semana y mes en Costa Rica durante 2019 y 2020.

La Figura 7 muestra que en Semana Santa la reducción de la movilidad de personas alcanzó un 90 %. Posteriormente, se flexibilizaron las medidas y la movilidad creció hasta un 40 %. No obstante, conforme crecieron los casos de contagio por COVID-19, el Poder Ejecutivo tomó nuevas acciones más estrictas. La más importante, hasta setiembre de 2020 que cubre este análisis, sucedió entre el 11 y el 19 de julio. En esas fechas se decretó un “cerco epidemiológico de la GAM”. Eso significó que todos los cantones de esta zona se catalogaron en alerta de emergencia naranja, es decir, estos cantones entraron a regir medidas más estrictas para la movilidad y la operación de comercios.

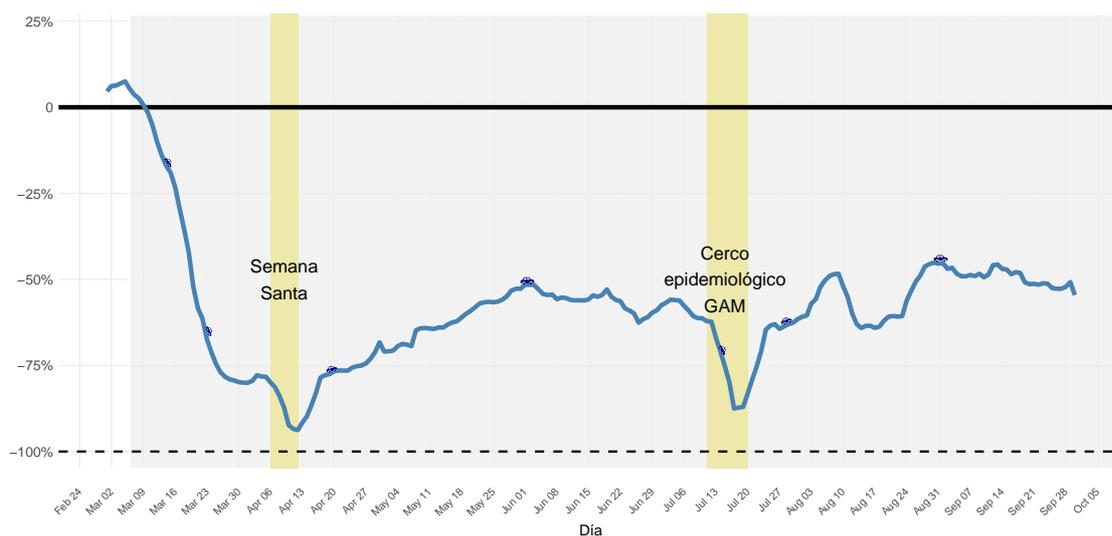


Figura 7: Cambio porcentual diario en la congestión vial con respecto a enero-febrero de 2020 (promedio móvil de siete días).

En suma, es evidente que las medidas restrictivas, junto a otros comportamientos de autocontención en medio de la pandemia, redujeron de manera significativa la movilidad de las personas.

De manera similar, la evidencia empírica respalda el grado de similitud entre los datos de movilidad de Google y los de congestión vial de Waze. Como ejercicio de validación, se unieron las dos series de datos con registros diarios entre el 17 de febrero y el 31 de julio de 2020 (166 días) y se correlacionaron para determinar cuán semejante son (Figura 8).

Por otra parte, la Figura 9 muestra que los datos de Google sobre movilidad de personas en Costa Rica durante la pandemia concuerdan el comportamiento, en término de tendencias, con los datos de Waze de la Figura 7. Esto evidencia que los datos de congestión vial funcionan como un *proxy* para medir la movilización de las personas. Además, cuenta con

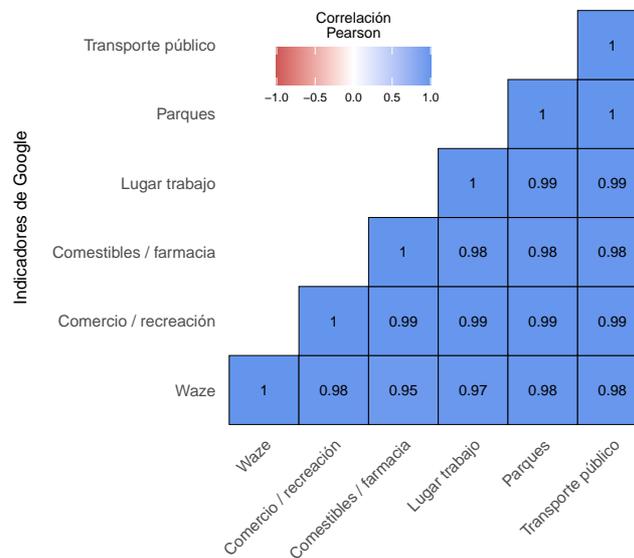


Figura 8: Correlación entre las mediciones de Waze sobre congestión vial e indicadores de Google sobre movilidad para Costa Rica

la ventaja de realizar un análisis local para determinar comportamientos por zonas.

3.3. Patrones territoriales antes y durante la pandemia

En esta sección, se llevó a cabo el análisis espacial antes y durante la pandemia para estudiar cambios en los patrones territoriales de desplazamiento de la población. El análisis parte la hipótesis que las restricciones dirigidas a reducir considerablemente el tránsito procuran evitar la diseminación del virus a lo largo del país.

Tomando como referencia los datos de 2019, es posible hallar patrones espaciales de la congestión ubicados, mayoritariamente, en zonas dentro de la GAM. Son focos de fuerte congestión que, además, tienen alta proporción de desplazamiento de personas de un cantón a otro para ir a trabajar, de acuerdo con la ENAHO y los datos del último censo de población del INEC. Al combinarse tales factores, muy probablemente ese conglomerado de cantones de la GAM con alta congestión se deba a flujos de tránsito intercantonales con afectación recíproca.

La Tabla 1 muestra el cambio de patrón de la correlación espacial, basado en la significancia estadística del índice de Morán global. Durante 2019 y los meses enero, febrero y marzo de 2020 se mantuvo el conglomerado de cantones con alto nivel de congestión, aunque con variaciones en la composición de ese grupo. A partir de abril desapareció el patrón

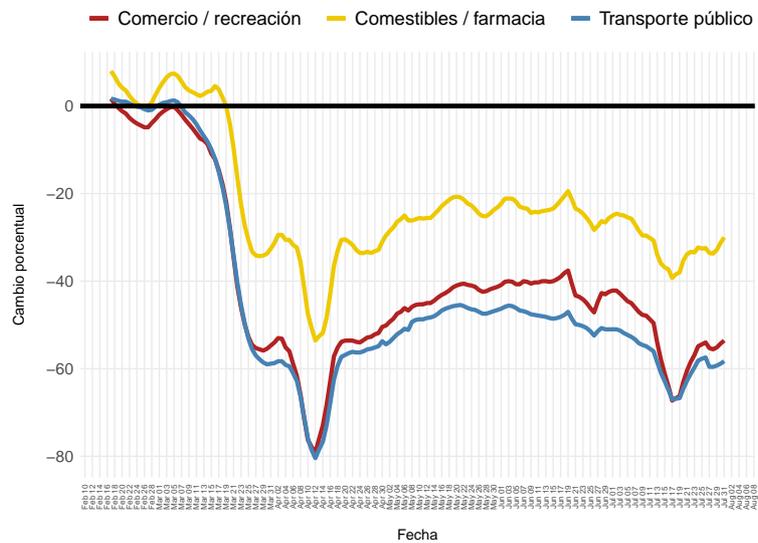


Figura 9: Cambios en la movilidad para Costa Rica con base en Google Mobility Data.

territorial de la congestión. En ninguno de los meses siguientes la relación espacial fue significativa.

Tabla 1: Significancia de la prueba de hipótesis sobre índice de Morán la congestión vial por mes

Período	p-value	
2019	0,01283	*
Enero de 2020	0,03736	*
Febrero de 2020	0,01135	*
Marzo de 2020	0,03555	*
Abril de 2020	0,17882	
Mayo de 2020	0,07974	
Junio de 2020	0,05204	
Julio de 2020	0,09841	
Agosto de 2020	0,28530	
Setiembre de 2020	0,22863	

* La prueba estadística es significativa si el p-value es menor de 0,05.

Cabe destacar que el mes de junio de 2020 la relación espacial no fue significativa por muy poco margen. Este período coincide con un período de apertura moderada y de aumento relativo de la movilidad de las personas que, por poco, vuelven a generar conglomerados de congestión en el territorio, según los análisis realizados. Concuerda, temporalmente, con el aumento relativo de casos de contagios en el país que, posteriormente, llevaron a las autoridades a decretar medidas de restricción más fuertes con el cerco epidemiológico en la GAM, a mediados de julio, para tratar de controlar las tasas crecientes de contagio.

Según los resultados del análisis de los datos del 2019, existe un único conglomerado significativo con ocho cantones que registraron alta congestión. Estas zonas presentaron una relación espacial significativa. En otras palabras, es ahí donde estaban los flujos viales más relevantes del país. Son seis casos de la provincia de San José: cantón central de San José, Desamparados, Goicoechea, Tibás, Montes de Oca y Curridabat, y otros dos de la provincia de Heredia: el cantón central y Santo Domingo. Todos estos municipios están ubicados en la GAM.

De acuerdo con los datos del Censo de Población del 2011, con actualización de proyecciones de población al 2020, en esos ocho cantones, en promedio, un 53 % de la población ocupada residente en ellos sale regularmente del cantón, pues su lugar de trabajo se ubica en otras zonas del país. Estos datos dan sustento a la tesis de que los municipios con mayor congestión comparten características demográficas y presiones viales que generan afectaciones mutuas. El problema radica en que esos flujos intercantonales pueden provocar riesgos crecientes, en medio de la pandemia, de esparcimiento del virus, sobre todo si eso ocurre infringiendo las medidas de distanciamiento físico.

La Figura 10 se observa que durante el 2019 y los primeros tres meses del 2020 los cantones donde hubo conglomerados de alta congestión son, en su mayoría, los mismos: casi todos dentro de la GAM, con excepción de Siquirres. Son lugares con altas densidades de población, en su mayoría cantones con una alta proporción de personas que trabajan en zonas vecinas y requieren desplazarse para ello.

Estos resultados evidencian que, en términos generales, la restricción disminuyó la intensidad de la congestión, pero también modificó los patrones de movilización de personas en todo el país. En ese sentido, las restricciones cumplieron su objetivo: reducir el desplazamiento de la gente en el territorio.

3.4. Factores asociados al comportamiento social en pandemia

En esta sección se presentan los resultados del análisis de regresión para estudiar la asociación entre la congestión vial, como un *proxy* de la movilidad de personas, y otras variables sociodemográficas cantonales, con la cantidad de contagios por COVID-19 en Costa Rica.

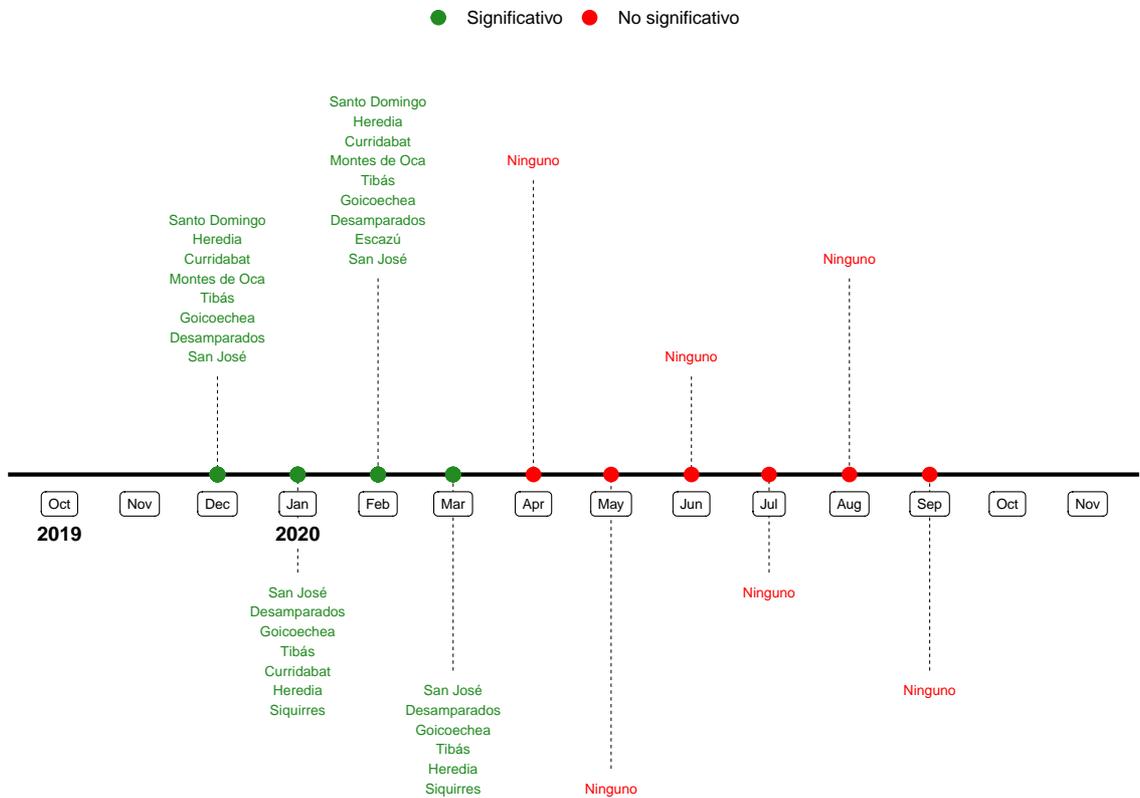


Figura 10: Cantones que forman parte del conglomerado de alta congestión, por mes (índice de Morán global y local)

La Tabla 2 presenta las diferentes combinaciones realizadas de los 12 modelos para calibrar el análisis. Los dos modelos seleccionados por su mejor ajuste, entre las doce combinaciones de parámetros utilizados, fueron el modelo lineal, con el promedio móvil de casos nuevos de COVID-19 por día, con dieciséis días de rezago, y en la regresión binomial negativa con el promedio móvil de casos nuevos de COVID-19 por día con dieciséis días de rezago. Es decir, en ambos procedimientos se validaron las mismas agregaciones de medición para la variable dependiente y los días de rezago.

Tabla 2: Las especificaciones y la bondad de ajuste de modelos de regresión ajustados

Modelo ^a	Temporalidad de datos ^b	Indicador COVID-19	Días de rezago	R^2 ^c
Lineal	Diario	Casos nuevos	16	0,36
Lineal	Diario	Casos activos	18	0,34
Lineal	Semanal	Casos nuevos	16	0,39
Lineal	Semanal	Casos activos	18	0,32
Lineal	PM_7	Casos nuevos	16	0,41
Lineal	PM_7	Casos activos	18	0,34
BN	Diario	Casos nuevos	16	0,21
BN	Diario	Casos activos	18	0,17
BN	Semanal	Casos nuevos	16	0,20
BN	Semanal	Casos activos	18	0,11
BN	PM_7	Casos nuevos	16	0,30
BN	PM_7	Casos activos	18	0,18

^a BN: Binomial negativa.

^b PM_7 : Promedio móvil de 7 días

^c R^2 -ajustado es calculado para modelos lineales y Pseudo- R^2 McFadden es calculado para modelos binomiales negativos y no son comparables.

La Tabla 3 presenta las estimaciones de los dos modelos de regresión (lineal y binomial negativa). Se puede observar, por ejemplo, que la estimación del coeficiente de **Jamstotal** es positiva y significa que en zonas donde hay una alta congestión, también hay un alto nivel de contagio del virus.

Los resultados de ambos modelos muestran evidencia empírica suficiente para apoyar la afirmación de que existe una asociación positiva entre la congestión vial (*proxy* de la movilidad de personas), y los casos de COVID-19 por cantón. Se registran altos niveles de congestión vial en zonas que también presentan altos niveles de contagio del virus en términos generales.

Asimismo, se encuentran asociaciones positivas entre los casos nuevos de COVID-19 y otras covariables como la densidad de población, el porcentaje de población no asegurada por la CCSS, el total de patentes de empresas registradas en el cantón, el porcentaje de personas que laboran en cantones diferentes de donde residen y la fecha.

Tabla 3: Estimación de los modelos de regresión lineal y binomial negativa

	Modelo de regresión ^a			
	Lineal		Binomial negativa	
Intercepto	-1573.12 (50.19)	***	-802.35 (9.91)	***
Jamstotal	0.84 (0.16)	***	0.12 (0.02)	***
Fecha	0.09 (0.00)	***	0.04 (0.00)	***
DensidadPoblacion	1.67 (0.14)	***	0.14 (0.02)	***
SectorPrimario	-1.40 (0.19)	***	-0.22 (0.03)	***
Escolaridad2011	-3.78 (0.23)	***	-0.02 (0.03)	
PorcPob_NoAsegurada	0.41 (0.11)	***	0.49 (0.02)	***
PorcPob_Urbana	-0.23 (0.18)		0.17 (0.03)	***
Patentes_canton	1.11 (0.20)	***	0.53 (0.03)	***
Trabajadores_canton	4.36 (0.19)	***	-0.11 (0.02)	***
Mov_intercantonal	2.09 (0.17)	***	0.4 (0.03)	***
AIC	63817.39		23728.91	
BIC	63902.67		23814.19	
deviancia	622243.64		8042.41	

^a Todos los predictores continuos son estandarizados.

*** p < 0,001; ** p < 0,01, * p < 0,05.

La hipótesis es que varias de esas variables tienden a dificultar el cumplimiento estricto de las medidas de distanciamiento. Mayor movilidad de personas, desde zonas con muchos trabajadores que deben trasladarse a otros cantones a laborar, así como municipios receptores que además tienen alta densidad de población y de parque empresarial instalado, pueden potenciar el acercamiento físico de las personas y crear condiciones más propicias para el contagio masivo. A eso se suman personas sin seguro de la CCSS que, generalmente, se desempeñan en el sector informal de la economía con condiciones más vulnerables, para quienes el distanciamiento social o el teletrabajo es más difícil de cumplir.

Es importante subrayar que las relaciones arriba descritas no expresan causalidad, sino asociación. Dan información sobre fenómenos que pueden ser relevantes para entender comportamientos y condiciones sociales en medio de la pandemia y tomar decisiones basadas en ello.

Otras covariables fueron detectadas con asociación negativa. Tal es el caso del sector primario: localidades donde hay más producción agropecuaria tienden a ser zonas con menor nivel de contagios por COVID-19. Lo central es entender las dinámicas sociales en estas regiones, para comprender las razones por las cuales esos fenómenos se presentan en conjunto. Una hipótesis es que son lugares con menor densidad poblacional y, por ende, donde es más fácil cumplir las recomendaciones de distanciamiento físico recomendadas por los expertos en salud para aminorar el contagio.

Por último, se exploraron territorialmente los cantones donde estas relaciones son más consistentes. Los resultados del modelo de regresión binomial negativa indican que la relación entre congestión vial y casos de COVID-19 es estadísticamente significativa en 44 de los 82 cantones (Figura 11), con un nivel de significancia del 5%. Esos cantones, organizados por provincia, son los siguientes:

- San José (8): Escazú, Aserrí, Mora, Santa Ana, Alajuelita, Tibás, Montes de Oca y Curridabat.
- Alajuela (9): cantón central, Atenas, Naranjo, Orotina, Zarcero, Valverde Vega, Los Chiles, Guatuso y Río Cuarto.
- Cartago (5): cantón central, La Unión, Turrialba, Oreamuno y El Guarco.
- Heredia (6): Santo Domingo, San Rafael, San Isidro, Belén, San Pablo y Sarapiquí.
- Guanacaste (5): Liberia, Nicoya, Bagaces, Carrillo y Cañas.
- Puntarenas (7): cantón central, Esparza, Montes de Oro, Osa, Quepos, Parrita y Corredores.
- Limón (4): Siquirres, Talamanca, Matina y Guácimo.

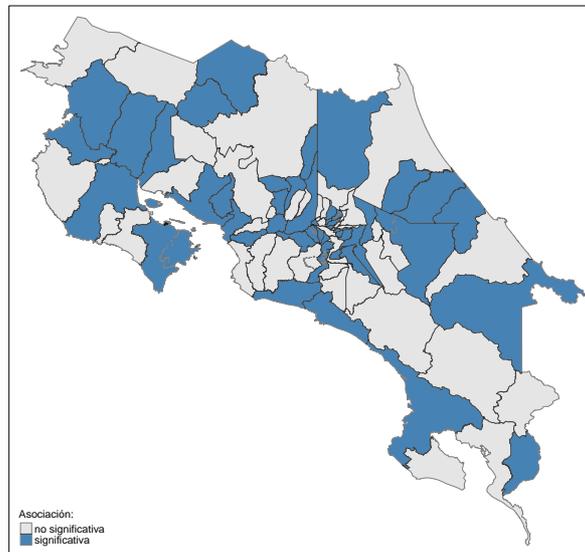


Figura 11: Cantones con asociación significativa entre congestión vial y casos de COVID-19.

En los cantones donde esa relación no fue significativa, se necesitan otras estrategias para calibrar los modelos y las variables. Como parte de los hallazgos, se detectaron anomalías en las colas de la distribución de los datos que requieren mayor estudio. Tal es el caso del cantón central de San José. Tiene momentos de pocos contagios con mucha congestión y, viceversa, muchos contagios con poca congestión. No son la regla, pero constituyen casos extremos que impiden la precisión del modelo. Además, este cantón se ve influenciado por otras variables difíciles de captar en el análisis sin un preprocesamiento específico. Por ejemplo: es la capital del país, es una zona más de paso y menos de residencia de las personas. Parte de su alta congestión se explica por los flujos viales desde o hacia zonas aledañas que concentran parques empresariales y zonas residenciales. También concentra una buena parte de las instituciones públicas, que en pandemia adoptaron modalidades de teletrabajo. En estos casos los valores de congestión vial exigen un tratamiento más exhaustivo.

En otros casos se encontraron indicios de estacionalidad en los datos. Por lo tanto, se optó por “suavizar” la serie de datos con promedios móviles, para reducir la influencia estacional de algunas variables. De ese modo, los modelos mostraron un mejor ajuste. Sin embargo, se deben utilizar otros procedimientos para precisar la magnitud de esas influencias o “ruidos” propios de los datos, y recalibrar los modelos. Eso es parte de la agenda pendiente de investigación en el tema abordado por este capítulo.

4. Conclusiones

La recomendación de las autoridades de salud para limitar el contagio del virus es reducir el contacto físico al máximo. En un escenario ideal, sin movilización de personas y aislamiento completo, el virus reduciría sustancialmente su capacidad de esparcimiento y letalidad.

En la práctica, ese escenario ideal es poco probable. Por ello es clave entender el flujo de personas que se movilizan en medio de la pandemia y a dónde. La relación de estas y otras variables sobre los casos de contagios locales también puede ser un insumo esencial para monitorear la situación en el tiempo.

Se usaron los datos de Waze como fuente de información para estimar la movilidad de las personas en tiempo real en el territorio nacional porque mantienen una alta correlación con las mediciones de Google, utilizadas en otras latitudes como un proxy válido de movilidad de personas, pero también porque con Waze se tienen microdatos para evaluar territorios específicos, tema que no es posible examinar con los datos de Google.

Los análisis realizados generaron información para atender empíricamente las preguntas de investigación planteadas en la Sección 2. La evidencia muestra que la pandemia modificó las zonas de mayor congestión en el país. Las restricciones sobre el tránsito y el cierre de comercios en el país ocasionaron reducciones considerables en los flujos de personas en todo el territorio, junto a otros aspectos, como la posible autocontención individual a salir de las casas de habitación. Estas reducciones no fueron constantes en el tiempo, pues las restricciones impuestas por el Gobierno variaron a lo largo del 2020.

Los resultados del análisis también muestran que, similar a estudios realizados en otros países, las mediciones de congestión vial (*proxy* de la movilidad de personas) junto a otras variables sociodemográficas, están relacionadas con la cantidad de contagios por COVID-19, según cantón. En efecto, modelos de regresión con información local muestran factores sociales vinculados a mayores casos de contagio del virus. Esos factores tienen en común que podrían generar riesgos tangibles sobre el cumplimiento de las medidas de distanciamiento físico para reducir la propagación del virus.

En suma, los análisis muestran que las medidas de restricción sanitaria impuestas por el gobierno cumplieron su objetivo de minimizar la movilidad de población de forma sustancial y que estos están relacionados con las tasas de contagio. Además, los resultados obtenidos proporcionan una inspección de los patrones de la movilidad vial antes y durante la pandemia. Esta información permite plantear mejores estrategias para el ordenamiento vial y desarrollo urbano en el país. Finalmente, permite preparar el país para futuras pandemias.

Cabe destacar que, como limitación del estudio, estas medidas de restricción para reducir la movilidad tuvieron consecuencias sociales, económicas y psicológicas que no fueron con-

templadas en este estudio, ya que requieren otras fuentes de información como encuestas a personas trabajadoras o empresas privadas del país.

Por último, la agenda futura de investigación requiere evaluar los patrones de movilidad de las personas en relación con otras fases de medidas sanitarias impuestas en el país, con el fin de generar recomendaciones más específicas para la contención del COVID-19. Asimismo, es necesario explorar otras posibles fuentes de información y otros métodos estadísticos, para contrastar los hallazgos con diversos enfoques y continuar con la precisión de las mediciones utilizadas, con el propósito de mejorar el ajuste de los modelos.

Referencias

- [1] Jonathan Agüero. *Patrones de movilidad en transporte público en la Gran Área Metropolitana de Costa Rica: desafíos e impactos*. Inf. téc. San José, Costa Rica.: Programa Estado de la Nación, 2021. URL: <http://hdl.handle.net/20.500.12337/8234>.
- [2] Hirotogu Akaike. «Information Theory and an Extension of the Maximum Likelihood Principle». En: *International Symposium on Information Theory*. Ed. por B.N. Petrov y F. Csaki. 1973, págs. 267-281.
- [3] Fernando Alvarez, David Argente y Francesco Lippi. «A Simple Planning Problem for COVID-19 Lockdown». En: Working Paper Series 26981 (abr. de 2020). DOI: [10.3386/w26981](https://doi.org/10.3386/w26981).
- [4] Tim Appelhans et al. *mapview: Interactive Viewing of Spatial Data in R*. R package version 2.11.0. 2022. URL: <https://CRAN.R-project.org/package=mapview>.
- [5] Hamada Badr et al. «Association between mobility patterns and COVID-19 transmission in the USA: a mathematical modelling study». En: *The Lancet Infectious Diseases* 20 (2020), págs. 1247-54. DOI: [10.1016/S1473-3099\(20\)30553-3](https://doi.org/10.1016/S1473-3099(20)30553-3).
- [6] Roger Bivand, Tim Keitt y Barry Rowlingson. *rgdal: Bindings for the 'Geospatial' Data Abstraction Library*. R package version 1.5-32. 2022. URL: <https://CRAN.R-project.org/package=rgdal>.
- [7] Roger Bivand y Nicholas Lewin-Koh. *maptools: Tools for Handling Spatial Objects*. R package version 1.1-4. 2022. URL: <https://CRAN.R-project.org/package=maptools>.
- [8] Roger Bivand y Colin Rundel. *rgeos: Interface to Geometry Engine - Open Source ('GEOS')*. R package version 0.5-9. 2021. URL: <https://CRAN.R-project.org/package=rgeos>.

- [9] Armando Cartenì, Luigi Di Francesco y Maria Martino. «How mobility habits influenced the spread of the COVID-19 pandemic: Results from the Italian case study». En: *Science of The Total Environment* 741 (2020), pág. 140489. DOI: [10.1016/j.scitotenv.2020.140489](https://doi.org/10.1016/j.scitotenv.2020.140489).
- [10] A. D. Cliff y J. K. Ord. *Spatial Processes: Models & Applications*. Pion, 1981.
- [11] Annette Dobson y Adrian Barnett. *An Introduction to Generalized Linear Models*. Chapman y Hall/CRC, 2018.
- [12] Yaqing Fang, Yiting Nie y Marshare Penny. «Transmission dynamics of the COVID-19 outbreak and effectiveness of government interventions: A data-driven analysis». En: *Journal of Medical Virology* 92.6 (2020), págs. 645-659. DOI: [10.1002/jmv.25750](https://doi.org/10.1002/jmv.25750).
- [13] Garrett Golemund y Hadley Wickham. «Dates and Times Made Easy with lubridate». En: *Journal of Statistical Software* 40.3 (2011), págs. 1-25. DOI: [10.18637/jss.v040.i03](https://doi.org/10.18637/jss.v040.i03).
- [14] Lionel Henry y Hadley Wickham. *purrr: Functional Programming Tools*. R package version 0.3.4. 2020. URL: <https://CRAN.R-project.org/package=purrr>.
- [15] Xiao Huang et al. «Twitter reveals human mobility dynamics during the COVID-19 pandemic». En: *PLoS ONE* 15(11) (2020). DOI: [10.1371/journal.pone.0241957](https://doi.org/10.1371/journal.pone.0241957).
- [16] Tobias Jeske. «Floating car data from smartphones: What google and waze know about you and how hackers can control traffic». En: *Proc. of the BlackHat Europe*. 2013, págs. 1-12.
- [17] Sebastian Jeworutzki. *cartogram: Create Cartograms with R*. R package version 0.2.2. 2020. URL: <https://CRAN.R-project.org/package=cartogram>.
- [18] Moritz Kraemer et al. «The effect of human mobility and control measures on the COVID-19 epidemic in China». En: *Science* 368.6490 (2020), págs. 493-497. DOI: [10.1126/science.abb4218](https://doi.org/10.1126/science.abb4218).
- [19] Javier Luraschi et al. *sparklyr: R Interface to Apache Spark*. R package version 1.7.7. 2022. URL: <https://CRAN.R-project.org/package=sparklyr>.
- [20] Pierre Nouvellet et al. «Reduction in mobility and COVID-19 transmission». En: *Nature Communications* 12.1 (feb. de 2021), pág. 1090. ISSN: 2041-1723. DOI: [10.1038/s41467-021-21358-2](https://doi.org/10.1038/s41467-021-21358-2).
- [21] OECD. *Estudios Económicos de la OCDE: Costa Rica 2020*. 2020. 148 págs. DOI: [10.1787/84cbb575-es](https://doi.org/10.1787/84cbb575-es).
- [22] Leonardo Sánchez. *Patrones de crecimiento urbano y sus impactos sobre la movilidad*. Inf. téc. San José, Costa Rica.: Programa Estado de la Nación, 2019. URL: <https://hdl.handle.net/20.500.12337/7817>.

- [23] Yayan Satyakti. «Do Human Restriction Mobility Policy in Indonesia Effectively Reduce the Spread of COVID-19». En: *SSRN Electronic Journal* (2020), pág. 101911. DOI: [10.2139/ssrn.3654553](https://doi.org/10.2139/ssrn.3654553).
- [24] Martijn Tennekes. «tmap: Thematic Maps in R». En: *Journal of Statistical Software* 84.6 (2018), págs. 1-39. DOI: [10.18637/jss.v084.i06](https://doi.org/10.18637/jss.v084.i06).
- [25] Anthony Townsend. «Re-programming mobility: How the tech industry is driving us towards a crisis in transportation planning». En: *Cities on the Move, New Cities Foundation, Geneva* (2012).
- [26] Hadley Wickham. *ggplot2: Elegant Graphics for Data Analysis*. Springer-Verlag New York, 2016. ISBN: 978-3-319-24277-4. URL: <https://ggplot2.tidyverse.org>.
- [27] Hadley Wickham. *stringr: Simple, Consistent Wrappers for Common String Operations*. R package version 1.4.0. 2019. URL: <https://CRAN.R-project.org/package=stringr>.
- [28] Hadley Wickham et al. «Welcome to the tidyverse». En: *Journal of Open Source Software* 4.43 (2019), pág. 1686. DOI: [10.21105/joss.01686](https://doi.org/10.21105/joss.01686).