

Estudio Académico

Desarrollo e Implementación de un Índice de Tráfico Basado en Google Maps: Un Análisis de la Congestión Vial en Santo Domingo, D.N.

Junio 2025

Desarrollo e Implementación de un Índice de Tráfico Basado en Google Maps: Un Análisis de la Congestión Vial en Santo Domingo, D.N.

*Luis Roberto Despradel Dargam
Carlos José Montero Gil*

Santo Domingo, República Dominicana
Junio 2025

Resumen

Este estudio presenta el desarrollo e implementación de un índice de tráfico para el Distrito Nacional de la República Dominicana, utilizando datos extraídos de Google Maps. La metodología empleada se inspira en el enfoque propuesto por Seong et al. (2023) y permite capturar la intensidad de la congestión vial mediante el análisis de imágenes georreferenciadas en intervalos de 30 minutos. El índice resultante fue validado a través de análisis descriptivos y modelos de regresión que revelan patrones coherentes con la realidad urbana: mayor congestión en días laborables, reducción en fines de semana y feriados, así como sensibilidad a variables climáticas y horarios pico. La herramienta desarrollada ofrece un insumo innovador para la medición y monitoreo del tráfico urbano dominicano, con potencial de aplicación en el diseño y evaluación de políticas públicas, incluyendo operativos de tránsito, intervenciones en infraestructura y análisis del impacto de eventos masivos. Este trabajo constituye la primera implementación de un sistema estandarizado de medición de congestión vial en el contexto dominicano y sienta las bases para investigaciones futuras orientadas a mejorar la movilidad urbana a través de decisiones informadas y sustentadas en evidencia empírica.

Palabras clave: Congestión vial; Índice de tráfico; Google Maps; Movilidad urbana; Santo Domingo; Políticas públicas; Análisis geoespacial; Recolección de datos automatizada.

1. Introducción

La congestión vial representa un desafío crítico para las ciudades en desarrollo, como Santo Domingo, República Dominicana, donde el crecimiento acelerado del parque vehicular y la expansión poblacional han superado la capacidad de la infraestructura existente. Este fenómeno no solo afecta la movilidad urbana, sino que también genera costos económicos significativos: estimaciones recientes sugieren que los costos directos de la congestión alcanzan aproximadamente el 1.1% del PIB, con un impacto indirecto adicional del 0.5% debido a la pérdida de productividad (Calatayud et al., 2021). A pesar de su relevancia, en el contexto dominicano no existen sistemas estandarizados de medición de la congestión vial accesibles al público, lo que limita la capacidad de diagnosticar el problema y diseñar intervenciones efectivas.

Inspirado en la metodología de Seong et al. (2023), este estudio desarrolla e implementa un índice de tráfico basado en datos de Google Maps para el Distrito Nacional. Entre el 1 de octubre de 2024 y el 15 de enero de 2025, se recolectaron datos cada 30 minutos, capturando variaciones temporales y espaciales con alta granularidad. Este índice permite cuantificar la intensidad y duración de la congestión, ofreciendo una herramienta innovadora para el análisis de patrones de tráfico y el diseño de políticas públicas. Como primera iniciativa de este tipo en la República Dominicana, este trabajo sienta las bases para una gestión de la movilidad urbana informada por evidencia empírica, con aplicaciones potenciales en operativos de tránsito, planificación de infraestructura y evaluación de eventos masivos. Este trabajo se limita a la creación y verificación del índice, para ser propuesto como herramienta de medición de diferentes posibles análisis.

2. Revisión de la Literatura

La congestión vial es un fenómeno urbano complejo que surge cuando la demanda de espacio en las vías supera su capacidad operativa, lo que resulta en una reducción significativa de la velocidad del tráfico y un incremento en los tiempos de desplazamiento (CEPAL, 2001). Este problema se manifiesta con especial intensidad en ciudades en desarrollo, donde el aumento exponencial del parque vehicular no ha sido acompañado por una planificación urbana adecuada ni por inversiones suficientes en infraestructura vial (Mena, 2017). Factores como la expansión urbana descontrolada, la concentración de actividades económicas en áreas específicas y la ausencia de una cultura vial consolidada entre los conductores agravan aún más esta situación. Más allá de sus implicaciones en la movilidad, la congestión genera costos económicos y sociales considerables, tales como pérdidas de productividad, mayor consumo de combustible, deterioro de la calidad del aire y un impacto negativo en el bienestar de la población (CEPAL, 2001; Downs, 2004). En este contexto, la generación de datos confiables y el diseño de políticas públicas basadas en evidencia se presentan como herramientas esenciales para comprender las causas estructurales de la congestión y desarrollar estrategias sostenibles de mitigación.

Diversos estudios han abordado esta problemática desde enfoques metodológicos variados, ofreciendo perspectivas complementarias sobre sus causas y posibles soluciones. Downs (2004), por ejemplo, analiza cómo la congestión es un resultado inevitable del crecimiento económico y la urbanización, argumentando que las mejoras en la capacidad vial a menudo inducen una mayor demanda de uso (fenómeno conocido como "demanda inducida"), lo que limita la eficacia de las expansiones de infraestructura como solución a largo plazo. Por su parte, Cervero (2013) destaca la importancia de integrar el transporte público y la planificación urbana para reducir la

dependencia del automóvil privado, un factor crítico en contextos como Santo Domingo, donde el transporte colectivo enfrenta desafíos de cobertura y eficiencia. Asimismo, Böcker et al. (2013) exploran la influencia de variables climáticas en los patrones de movilidad, mostrando cómo la lluvia o las temperaturas extremas pueden exacerbar la congestión al alterar las preferencias de transporte de los ciudadanos.

En años recientes, el avance tecnológico ha permitido el desarrollo de herramientas innovadoras para medir y gestionar la congestión vial. El paquete *googletraffic*, creado por el Banco Mundial (2022), ha facilitado la recolección de datos a gran escala a partir de plataformas como Google Maps, aunque su aplicación enfrenta limitaciones como interrupciones por fallas técnicas o inconsistencias en la cobertura geográfica. Paralelamente, plataformas colaborativas como Waze for Cities han emergido como fuentes alternativas de información en tiempo real. En México, el Instituto Mexicano del Transporte (IMT) ha utilizado datos de Waze para analizar la accidentalidad vial y detectar puntos críticos de congestión en la Red Nacional de Caminos, demostrando el potencial de los datos crowdsourcing para generar estrategias de mitigación precisas (IMT, 2020; Vázquez Paulino et al., 2020). De manera similar, en Medellín, Gómez y Rodríguez (2021) documentan cómo la integración de datos de Waze con sensores locales ha optimizado la gestión operativa del tráfico, permitiendo emitir alertas en tiempo real y mejorar la respuesta ante emergencias viales. Sin embargo, estas iniciativas enfrentan barreras significativas: el acceso restringido a los datos de Waze, limitado a acuerdos con gobiernos o instituciones aprobadas, excluye a investigadores independientes y dificulta la construcción de series históricas de libre acceso.

En el contexto dominicano, la literatura sobre congestión vial es escasa, y los esfuerzos por cuantificar han sido fragmentados. Edelman (2019) señala que la gestión del entorno urbano en

Santo Domingo ha sido históricamente reactiva, con poca atención a la medición sistemática del tráfico o a la planificación basada en datos. Este vacío analítico contrasta con el enfoque de Seong et al. (2023), quienes proponen un índice de tráfico basado en Google Maps para evaluar la congestión en áreas metropolitanas de Estados Unidos, combinando análisis geoespaciales con métricas novedosas. Su metodología, adaptable a diferentes realidades urbanas, ofrece un marco prometedor para abordar las carencias locales y sirve como base conceptual para el presente estudio. En conjunto, estos antecedentes subrayan la necesidad de herramientas accesibles, escalables y contextualizadas que permitan no solo medir la congestión, sino también fundamentar intervenciones efectivas en ciudades como Santo Domingo.

Estos antecedentes destacan la necesidad de herramientas accesibles y escalables como el índice propuesto en este estudio.

3. Metodología

La metodología utilizada para crear el índice de tráfico se inspira en los pasos seguidos por Seong et al. (2023), ajustados a las capacidades y necesidades de este estudio. Las herramientas de recolección de datos utilizadas para este análisis fueron distintas a las de Seong et al, pero ambas utilizan la misma fuente de datos de Google Maps.


Para la creación del índice es necesario primero delimitar la zona de la cual calcularemos el tráfico. En este artículo solo nos enfocamos en el Distrito Nacional, pero la metodología puede ser aplicada para las demás ciudades del país. Dado al método de recolección de datos, el cual explicaremos a continuación, el índice también incluye algunos sectores de Santo Domingo Norte adyacentes al borde norte entre el distrito y la provincia de Santo Domingo.

Los datos fueron recolectados utilizando el paquete *googletraffic*, una herramienta en R desarrollada por el Banco Mundial (2022) la cual permite medir la congestión vehicular en áreas extensas utilizando datos de Google Maps. Esta solución facilita la recopilación y el análisis de información de tráfico para apoyar investigaciones de este tipo, diseño de políticas públicas y la gestión del transporte urbano. Utilizamos el mapa geopolítico del Distrito Nacional proporcionado por la Oficina Nacional de Estadísticas para delimitar con exactitud la zona a calcular. El paquete estadístico proporciona archivos PNG similares a los de la Figura 1, los cuales muestran el tráfico de la zona en tiempo real según data de Google Maps. Para poder medir el Distrito Nacional completo, el paquete entrega once archivos PNG de diferentes zonas. Es importante recalcar que para esta prueba de concepto, sólo se midieron las principales avenidas, pero la metodología se puede aplicar para todas las calles de la ciudad, como visto en la Figura 2 la cual une los once archivos obtenidos en un tiempo determinado.

Figura 1
Ejemplo de archivo PNG utilizado



Figura 2
Compilación de diferentes archivos con la máxima resolución posible



Las fotos obtenidas muestran cuatro tipos de colores indicando el nivel de tráfico en las calles: verde - 1, naranja - 2, rojo - 3, rojo vino - 4. Para cuantificar la cantidad de tráfico de la

zona delimitada por la foto, sumamos la cantidad de pixeles de cada color (N) y le asignamos un peso según el nivel de tráfico que representa. Para esto, utilizamos la fórmula:

$$\delta_{it} = 0.25N(naranja)_{it} + 0.5N(rojo)_{it} + 1.0N(rojoVino)_{it}$$

Donde δ_{it} es el nivel de tráfico en zona i en tiempo t .

La data fue capturada cada 30 minutos desde el 1.º de octubre 2024 hasta el 15 de enero 2025. No contamos con información en los periodos entre 12:00PM 26/10/2024 - 11:00AM 28/10/2024 y 4:00PM 02/12/2024 - 8:30AM 03/12/2024 dado a una falla eléctrica de nuestros sistemas. Estos períodos serán eliminados de los análisis econométricos.

El índice de tráfico T_t en el Distrito Nacional entonces es dado por la suma $\sum \delta_{it}$ del tráfico de las zonas i , para el tiempo t . Este índice entonces lo podemos ver cada 30 minutos, o agrupando por tiempos mayores utilizando el promedio del día, semana, o mes denominado por $\bar{T}_t$.

Todos los análisis a continuación fueron el resultado del agregado de los once archivos PNG del Distrito Nacional. Esta metodología también permite elegir sectores específicos como por ejemplo el polígono central, Piantini, entre otros. Aunque estas limitaciones a mayor granularidad están fuera del alcance de este artículo, contamos con archivos HTML con toda la información necesaria, para el periodo de recolección de datos, los cuales permiten calcular el índice en sectores específicos.

4. Resultados

En esta sección se presentan los hallazgos derivados del análisis del índice de tráfico desarrollado para el Distrito Nacional, divididos en dos partes fundamentales: primero, la construcción y descripción del índice para caracterizar el comportamiento natural del tráfico urbano; segundo, un análisis de regresión que explora las correlaciones entre el índice y posibles


determinantes de la congestión. Estos resultados buscan no solo validar la precisión de la herramienta propuesta, sino también evaluar su capacidad explicativa frente a factores temporales, climáticos y sociales, ofreciendo una base empírica para comprender la dinámica vial de Santo Domingo.

4.1. Creación del Índice

El índice de tráfico se construyó a partir de 5,057 observaciones del índice en intervalos de 30 minutos desde el 1ero de octubre 2024 hasta el 15 de enero 2025. La serie de tiempo cuenta con 106 días, incluyendo múltiples festivos, como por ejemplo el Día de la Constitución (feriado el 4 de noviembre) y Navidad (25 de diciembre). En el grafico 1 observamos la serie de tiempo, donde podemos empezar a ver la ciclicidad del tráfico en la ciudad. Al igual podemos ver las fechas anteriormente mencionadas donde experimentamos una falla eléctrica y no contamos información.

Gráfico 1


Índice de Tráfico Distrito Nacional - Cada 30 minutos



Para facilitar la interpretación, el índice se agrupó en diferentes escalas temporales —diaria, semanal y por hora— mediante promedios simples de las observaciones. Esta elección metodológica, en lugar de usar medianas, permite capturar eventos extremos, como picos de tráfico en horas específicas, que son cruciales para entender la dinámica urbana.

A continuación, se analiza el índice semanal para identificar las tendencias de congestión vehicular durante el período estudiado. Este se calculó como el promedio de todas las observaciones semanales. Los resultados, ilustrados en la gráfica 2, revelan un incremento progresivo del tráfico desde octubre hasta mediados de diciembre, seguido de una notable disminución a partir del 22 de diciembre de 2024, coincidiendo con el período festivo de Navidad. Esta caída se debe al periodo festivo comprendido entre la Navidad y el Día de Reyes, el cual muestra una saturación vial muy por debajo de la tendencia de las semanas anteriores. El poder ver este tipo de comportamiento lógico en el índice muestra la precisión en poder capturar la realidad del tráfico.


Gráfico 2



El índice nos permite entender diferencias entre distintos momentos, pudiendo cuantificar, por ejemplo, los populares “tapones de diciembre”. El índice de tráfico para una semana promedio de noviembre fue de 35,636, mientras que para las primeras semanas de diciembre hasta el 20 fue de 40,808. Esto representa un 14.5% en incremento en la congestión vehicular en el Distrito Nacional entre noviembre y diciembre pre-Navidad. Similarmente, el flujo vehicular en las semanas entre Navidad y el Día de Reyes fue un 36% por debajo del promedio semanal de todas las semanas anteriores.

Para ver el índice diario, calculamos el promedio de todas las observaciones de ese día. En la gráfica 3 podemos observar lo marcadas que son las semanas, principalmente notables por un bajo índice en los fines de semana.

Gráfico 3




Un ejemplo de análisis sencillo que se puede realizar con este tipo de datos es examinar el impacto que tuvo el Viernes Negro (29/11/2024) en el tráfico del Distrito Nacional. Este análisis permite visualizar cómo los patrones de movilidad cambiaron durante este evento comercial

importante. Utilizando el viernes anterior como base, podemos calcular que el tráfico no fue afectado por este evento. Solo observamos un aumento de 0.2% en el índice.

En la gráfica 3 también podemos ir identificando la variabilidad de flujo de vehículos que hay por días de la semana. Para tener una mejor comprensión, calculamos el índice promedio por día de la semana eliminando días feriados de la data para eliminar sesgos en la inferencia a realizar. Esto puede ser observado en el gráfico 4.


Gráfico 4



A simple vista podemos notar que el lunes es el día laboral con menos tráfico mientras que el viernes es el de mayor. Podemos ver como el tráfico de los fines de semana es significativamente menor al de los días laborales. Es importante recalcar que esta gráfica no está tomando en cuenta varios factores correlacionados a la saturación vehicular como la precipitación, días de pago, eventos específicos, entre otros. Por esta razón, no estaremos calculando diferencias entre los días de la semana en esta parte del análisis. De todas maneras, visualizar promedios simples nos da una idea de la fluctuación del tráfico. Una posible solución para reducir la congestión promedio de una semana sería reducir solamente el tráfico de los viernes con diferentes políticas públicas que ayuden a mitigar la congestión.

En términos de horas del día, en la gráfica 5 podemos ver el promedio del índice por horas excluyendo los fines de semana. Como es de esperarse, son visibles las horas pico de entrada y salida del horario laboral 8:00 y 17:00, lo cual incrementa la confiabilidad del índice elaborado. La hora con mayor tráfico es a las 18:00 mientras que la mejor hora para el tráfico dentro del horario laboral es a las 11:00.

Gráfico 5



Con este índice es posible entender el flujo del tráfico para cada día de la semana. Esto nos puede ayudar a comprender las diferencias inter-diarias en el tráfico de la ciudad para así mejorar políticas públicas. En la gráfica 6 podemos observar el índice promedio hora por cada día de la semana laboral y en la gráfica 7 el promedio hora para días del fin de semana versus el promedio de un día laboral. Aquí se nota como el viernes posee un tráfico significativamente mayor en las horas que usualmente poseen un menor tráfico, 12:00 - 15:00. Al igual, podemos ver que el pico del tráfico del sábado es entre las 12:00 - 13:00, donde el tráfico es hasta mayor que un día laboral promedio. Mientras que el pico del domingo es a las 19:00, con un tráfico similar a un sábado.

Gráfico 6






Gráfico 7



El índice también permite ver el efecto que tiene un día feriado en el tráfico. Por ejemplo, calculamos el tráfico del lunes feriado del Día de la Constitución, movido para el 4 de noviembre. El tráfico para este día fue 65% por debajo del promedio de los demás lunes del mes de noviembre. En la gráfica 8 vemos que el tráfico de este día feriado fue muy similar a un domingo.

Gráfico 8



4.2. Correlaciones encontradas

Varios factores afectan la congestión vial de una ciudad, como el clima (Böcker et al., 2013), el precio del combustible (Goodwin et al., 2004), días de pago (Glaeser et al., 2008), entre otros. Para obtener buenas inferencias entre las observaciones del índice, es necesario controlar por diferentes covariables como las previamente mencionadas. Por esta razón, realizamos un análisis de regresiones para poder comprender la viabilidad del índice ante este tipo de análisis más robustos.

Las regresiones se hicieron de tipo:

$$\log(T_{it}) = \alpha + \sum_{k=1}^K \beta_k X_{k,it} + \varepsilon_{it}$$

Donde $\log(T_{it})$ representa el logaritmo del índice de tráfico en el tiempo t ; α es el intercepto; $\sum_{k=1}^K \beta_k X_{k,it}$ representa la suma de los efectos de K variables explicativas $X_{k,it}$ donde cada variable k puede incluir variables como día de la semana, precipitaciones, temperatura, si es

feriado, hora del día, entre otros, según la especificación del modelo; cada β_k mide el efecto marginal de la variable correspondiente sobre el índice de tráfico; y ε_{it} es el término de error.

En la Tabla 1 se presentan diferentes especificaciones del modelo. Cada columna incorpora distintos subconjuntos de variables explicativas con el objetivo de evaluar su contribución marginal a la variabilidad del tráfico.

Para el análisis de regresión, se incorporaron variables climáticas como precipitación y temperatura, las cuales fueron obtenidas mediante la plataforma Visual Crossing Weather, la cual proporciona datos históricos y horarios con alta resolución temporal para ubicaciones geográficas específicas.

Tabla 1

$y = \log(t)$	Reg 1	Reg 2	Reg 3	Reg 4	Reg 5	Reg 6	Reg 7
R-squared	0.03	0.03	0.04	0.04	0.04	0.06	0.47
R-squared Adj.	0.03	0.03	0.04	0.04	0.04	0.06	0.47
const	9.99***	9.99***	10.03***	9.99***	10.01***	8.22***	8.27***
0.Lunes	-0.24***	-0.24***	-0.24***	-0.24***	-0.24***	-0.28***	-0.26***
1.Martes	0.02	0.02	0.04	0.04	0.05	0.08	0.08***
3.Jueves	0.07	0.07	0.07	0.08	0.07	0.07	0.08***
4.Viernes	0.19***	0.18***	0.18***	0.19***	0.19***	0.20***	0.18***
5.Sabado	-0.47***	-0.48***	-0.48***	-0.48***	-0.47***	-0.46***	-0.47***
6.Domingo	-0.54***	-0.54***	-0.54***	-0.53***	-0.53***	-0.53***	-0.54***
Navidad (D)			-0.29***	-0.27***	-0.27***	-0.46***	-0.38***
Feriado (D)		-0.69***	-0.51***	-0.49***	-0.50***	-0.40**	0.41***
Lluvia (D)				0.32***			
ln_R3H_precip					0.19***	0.35***	0.15***
ln_R3H_temp						0.45***	0.22***
Horas*							X

$n = 4,806$

$p < 0.01$ ***, $p < 0.05$ **, $p < 0.1$ *

Los modelos fueron construidos incrementando la cantidad de variables explicativas para así comprender la correlación entre ellas. La regresión base, Reg #1, es simplemente utilizando efectos fijos de los días de la semana excluyendo el miércoles, lo cual trae como resultado coeficientes comparados versus el tráfico de un miércoles promedio. Al introducir más variables,

podemos notar que estos coeficientes no cambian significativamente. En la regresión #2 incluimos una variable binaria de días feriados (Feriado (D)), en la regresión #3 una variable binaria para el periodo de Navidad entre 23/12/2024 y 08/01/2025 (Navidad (D)), en la regresión #4 una variable binaria sobre si la precipitación fue mayor a 0 (Lluvia (D)), en las regresiones #5 y #6 respectivamente incluimos el logaritmo del promedio de precipitación ($\ln_R3H_precip$) y temperatura en las últimas 3 horas ($\ln_R3H_temp$), y finalmente en la regresión 7 incluimos efectos fijos de las horas del día (Horas). El modelo de regresión más completo vendría siendo la regresión 7, la cual intenta reducir el error de variables omitidas en el modelo. Sin embargo, somos conscientes de que el tráfico es influenciado por diversas variables no contempladas en las especificaciones de los modelos presentados.

Utilizando la regresión #7 podemos observar varias correlaciones interesantes las cuales muestran la precisión del índice al mostrar conexiones lógicas entre variables explicativas y el tráfico de la ciudad. Empezando por los días de la semana, los resultados de los modelos #1 al #7 muestran un patrón claro de congestión creciente a lo largo de los días laborales. En comparación con el miércoles, el tráfico de los martes y jueves es estadísticamente significativos, pero si vemos como en un lunes promedio hay menos tráfico y en un viernes promedio más. Por ejemplo, en un viernes promedio el índice de tráfico es aproximadamente un 19.7% mayor que el miércoles, según la última especificación. Este hallazgo sugiere que el viernes concentra una mayor carga vehicular, posiblemente asociado al cierre de semana laboral, salidas de la ciudad o eventos sociales.

Por otro lado, los fines de semana presentan una reducción significativa en la congestión. El sábado y el domingo muestran coeficientes negativos y significativos, siendo el domingo el día con menor tráfico (-42% respecto al miércoles). Esta caída en el tráfico es coherente con una menor actividad económica y laboral durante el fin de semana.

Las variables binarias de feriados y Navidad tienen un efecto negativo y estadísticamente significativo sobre el tráfico. En la especificación #6, se observa que los feriados están asociados con una reducción del tráfico del 33%, mientras que la Navidad está relacionada con una caída del 37% en el índice. Esto refuerza la idea de que, en fechas festivas, hay una disminución en los desplazamientos diarios habituales (laborales o escolares), lo cual alivia significativamente la congestión.

Las variables climáticas también resultan significativas en explicar el nivel de tráfico. El logaritmo de la precipitación promedio en las tres horas previas ($\ln_R3H_precip$) muestra una relación positiva y significativa, especialmente en la especificación 6. Esto indica que mayores niveles de lluvia están asociados con incrementos en el tráfico, posiblemente por reducción de velocidad, reducción de adherencia a la calzada, disminución de visibilidad o aumento del uso de vehículos privados. Asimismo, la temperatura ($\ln_R3H_temp$) tiene un efecto positivo y significativo. Un aumento en la temperatura está correlacionado con mayores niveles de congestión, lo cual podría reflejar cambios en patrones de movilidad (mayor uso de aire acondicionado, desplazamientos al aire libre o uso de vehículos en lugar de transporte público en condiciones de calor).

En la Tabla 2 podrán encontrar la inclusión de efectos fijos por hora (regresión #7) la cual permite capturar la variación intradía del tráfico. El tráfico comienza a incrementarse alrededor de las 6:00 a.m., alcanzando su punto máximo a las 6:00 p.m. El patrón observado evidencia las horas pico de entrada y salida laboral, reforzando la confiabilidad del índice en capturar la dinámica real del tráfico en la ciudad.

Finalmente, es importante notar que el poder explicativo del modelo (R^2) mejora sustancialmente al incluir todas las variables. Mientras las primeras especificaciones (#1 – #5)

tienen un R^2 ajustado de apenas 0.03–0.04, la especificación #7 alcanza un R^2 ajustado de 0.47, lo que indica que casi la mitad de la variabilidad en el logaritmo del índice de tráfico puede explicarse por los factores incluidos en el modelo.

Tabla 2

$y = \log(t)$	Reg 7
R-squared	0.47
R-squared Adj.	0.47
const	8.27***
0.Lunes	-0.26***
1.Martes	0.08***
3.Jueves	0.08***
4.Viernes	0.18***
5.Sabado	-0.47***
6.Domingo	-0.54***
Navidad (D)	-0.38***
Feriado (D)	0.41***
Lluvia (D)	
ln_R3H_precip	0.15***
ln_R3H_temp	0.22***
H1	-0.24***
H2	-0.45***
H3	-0.64***
H4	-0.79***
H5	-0.76***
H6	0.41***
H7	1.34***
H8	1.60***
H9	1.54***
H10	1.55***
H11	1.58***
H12	1.59***
H13	1.61***
H14	1.58***
H15	1.59***
H16	1.59***
H17	1.71***
H18	1.81***
H19	1.71***
H20	1.23***
H21	0.71***
H22	0.32***
H23	0.08

$n = 4,806$

$p < 0.01$ ***, $p < 0.05$ **, $p < 0.1$ *

5. Discusión

Los análisis realizados confirman que el índice de tráfico desarrollado en este estudio captura con precisión la dinámica de la congestión vial en el Distrito Nacional, reflejando patrones esperados como el aumento del tráfico en días laborables, su reducción durante fines de semana y feriados, y su sensibilidad a factores climáticos y eventos estacionales. Esta capacidad de respuesta lógica no sólo valida la calidad de los datos recolectados, sino que también posiciona al índice como una herramienta confiable para el diagnóstico de la movilidad urbana y la evaluación de políticas públicas en Santo Domingo. A continuación, se exploran diversas aplicaciones prácticas de esta métrica, con el objetivo de ilustrar su potencial para mitigar la congestión y mejorar la planificación vial en la ciudad.

Una aplicación interesante del índice sería evaluar la efectividad de los agentes de la Dirección General de Seguridad de Tránsito y Transporte Terrestre (Digesett) en la gestión del tráfico. Por ejemplo, se podría diseñar un experimento de tipo A/B en el que se compare la saturación vial en días con alta presencia de agentes en intersecciones clave (como las avenidas Winston Churchill o Abraham Lincoln) frente a días sin intervención significativa. Este enfoque permitiría cuantificar el impacto agregado de los agentes en la reducción de la congestión y determinar si su distribución estratégica en puntos críticos logra optimizar el flujo vehicular durante horas pico. Además, el experimento podría escalarse para identificar combinaciones óptimas de ubicaciones y horarios que maximicen su eficacia, proporcionando evidencia empírica para reestructurar los operativos de tránsito.

El índice también ofrece un marco robusto para analizar el impacto de mejoras en el transporte público, un componente esencial para reducir la dependencia del vehículo privado en Santo Domingo. Por ejemplo, podría emplearse para medir los efectos de nuevas rutas de

autobuses o del incremento en la frecuencia del Metro de Santo Domingo en zonas de alta congestión, como el polígono central. Un diseño cuasi-experimental, como el de diferencias en diferencias, permitiría comparar el índice antes y después de estas intervenciones, o entre áreas tratadas y no tratadas, revelando si tales medidas logran reducir significativamente los niveles de tráfico. Asimismo, la implementación de carriles exclusivos para transporte público podría evaluarse con esta herramienta, identificando su contribución a la descongestión y su efecto en los patrones de movilidad de los ciudadanos.

Otra área de aplicación relevante es el estudio de eventos masivos y su influencia en el comportamiento vial. Conciertos, desfiles o partidos deportivos en el Estadio Quisqueya, por ejemplo, generan picos de congestión localizados que afectan la dinámica urbana. El índice, con su gran frecuencia, podría utilizarse para cuantificar estos impactos y apoyar la planificación de desvíos, operativos de control o ajustes en el transporte público durante tales actividades. De manera similar, políticas como la introducción de horarios laborales escalonados por sector (por ejemplo, diferenciar los horarios de entrada entre el sector público y privado) podrían evaluarse midiendo si el índice refleja una distribución más uniforme de los picos de tráfico matutino y vespertino, contribuyendo a una movilidad más fluida.

Si se mantiene una recolección continua de datos, el índice también podría desempeñar un papel clave en la gestión de eventos no planificados, como apagones, inundaciones o bloqueos de vías. Al analizar la evolución del tráfico antes, durante y después de estos incidentes, sería posible estimar el tiempo de recuperación de la ciudad y detectar puntos vulnerables que requieran planes de contingencia específicos. Por ejemplo, un análisis post-inundación podría revelar si ciertas arterias, como la avenida Máximo Gómez, se convierten en cuellos de botella persistentes, orientando inversiones en drenaje o infraestructura resiliente. Esta capacidad de respuesta

dinámica fortalecería la preparación de Santo Domingo ante emergencias y optimizaría la asignación de recursos en situaciones críticas.

En un horizonte más amplio, el índice podría integrarse en un sistema de monitoreo en tiempo real, combinado con tecnologías como cámaras de tráfico o sensores IoT, para ofrecer una visión integral de la movilidad urbana. Esta plataforma permitiría identificar patrones recurrentes de congestión, detectar cuellos de botella en tiempo real y priorizar intervenciones en infraestructura (como ampliaciones de vías o construcción de pasos a desnivel) con base en datos objetivos. Además, su adaptabilidad a diferentes escalas espaciales —desde el Distrito Nacional hasta sectores específicos como Piantini— lo convierte en un recurso versátil para autoridades, investigadores y planificadores urbanos interesados en transformar la movilidad de Santo Domingo en un sistema más eficiente y sostenible.

6. Conclusión

Este estudio presenta la implementación de un índice de tráfico basado en datos abiertos de Google Maps, adaptado a las condiciones urbanas del Distrito Nacional. Inspirado en metodologías recientes y respaldado por herramientas desarrolladas por el Banco Mundial, el índice propuesto logra captar con precisión la variación espacio-temporal del tráfico en la ciudad, validado mediante análisis descriptivos y regresiones con variables climáticas, temporales y sociales.

Los resultados muestran que el índice propuesto responde lógicamente ante eventos esperados, como feriados, fines de semana, lluvias y horas pico. Además, su granularidad de 30 minutos permite una visualización detallada de los patrones diarios y semanales de congestión, lo

que lo convierte en una herramienta valiosa tanto para análisis descriptivos como para evaluaciones estadísticas más rigurosas.

Más allá de su valor como insumo académico, el índice puede ser utilizado como herramienta de diagnóstico y monitoreo para el diseño de políticas públicas. Propuestas como operativos A/B con agentes de tránsito, evaluación de planes piloto de transporte público, o análisis del impacto de eventos extraordinarios podrían beneficiarse enormemente del uso sistemático de esta métrica. A futuro, su integración en sistemas de monitoreo urbano en tiempo real podría permitir la detección temprana de cuellos de botella y la priorización eficiente de inversiones viales.

No obstante, este trabajo también enfrenta limitaciones. El índice depende de la calidad y estabilidad de los datos proporcionados por Google Maps, los cuales pueden ser sensibles a variaciones en conectividad, y disponibilidad de datos. También se reconoce la ausencia de variables como incidentes viales, cambios en precios del combustible o volumen de transporte público, los cuales podrían mejorar el poder explicativo de los modelos propuestos.

A pesar de estas limitaciones, el presente estudio constituye un primer paso hacia una medición sistemática y basada en evidencia de la congestión vial en la República Dominicana. Futuros trabajos podrían explorar modelos predictivos, técnicas de aprendizaje automático, o expandir la cobertura espacial del índice hacia otras ciudades del país. Asimismo, la integración con datos de sensores, cámaras o redes de transporte público enriquecería su capacidad analítica. En definitiva, contar con una herramienta de medición como esta sienta las bases para el diseño de políticas de movilidad más inteligentes, sostenibles y orientadas a resultados.

7. Referencias bibliográficas

Banco Mundial. (2022). *Introducing googletraffic R package: A new tool to measure congestion across large spatial areas*.

Böcker, L., Dijst, M., & Prillwitz, J. (2013). Impact of everyday weather on individual daily travel behaviours. *Journal of Transport Geography*, 28, 32–39.

Calatayud, A., Sánchez González, S., Bedoya-Maya, F., Giraldez Zúñiga, F., & Márquez, J. M. (2021). *Congestión urbana en América Latina y el Caribe: Características, costos y mitigación*.

Cervero, R. (2013). *Transport infrastructure and global competitiveness*. World Bank.

Downs, A. (2004). *Traffic: Why it's getting worse, what can be done*. Brookings Institution Press.

Comisión Económica para América Latina y el Caribe (CEPAL). (2001). *Transporte urbano y pobreza: Reflexiones en torno a la movilidad en América Latina*. Santiago de Chile.

Edelman, D. J. (2019). *Managing the urban environment of Santo Domingo, the Dominican Republic*. Recuperado de <https://www.researchgate.net/publication/332042903>

Glaeser, E. L., Kahn, M. E., & Rappaport, J. (2008). Why do the poor live in cities? The role of public transportation. *Journal of Urban Economics*, 63(1), 1–24.

Gómez González, N., Casanova Zavala, W. A., Sarmiento Castellanos, I., & Mendoza Díaz, A. (2021). *Análisis de la Accidentalidad Vial Reportada por Waze*. Instituto Mexicano del Transporte.

Gómez, N. (2021). *Principales resultados del análisis de accidentalidad realizado utilizando datos del Waze*. Instituto Mexicano del Transporte.

Goodwin, P. B., Dargay, J., & Hanly, M. (2004). Elasticities of road traffic and fuel consumption with respect to price and income: A review. *Transport Reviews*, 24(3), 275–292.

Lu, J., Zhang, X., Xu, Z., Zhang, J., Wang, J., Mao, L., Jia, L., & Li, Z. (2020). Traffic index prediction and classification considering characteristics of time series based on autoregressive integrated moving average convolutional neural network model. *Sensors and Materials*, 32(11), 3955–3973. <https://doi.org/10.18494/SAM.2020.3058>

Mena, C. (2017). *Congestión vial en ciudades en vías de desarrollo*. Academia.edu.

Oficina Nacional de Estadísticas (ONE). (s.f.). *República Dominicana*. [Entidad gubernamental, sin fecha exacta de publicación].

Seong, J., Kim, Y., Goh, H., Kim, H., & Stanescu, A. (2023). Measuring traffic congestion with novel metrics: A case study of six U.S. metropolitan areas. *ISPRS International Journal of Geo-Information*, 12(3), 130. <https://doi.org/10.3390/ijgi12030130>

Vázquez Paulino, J. C., Morales Bautista, E. M., González Moreno, J. O., & Backhoff Pohls, M. Á. (2020). *Análisis geoespacial de tráfico en la RNC, utilizando datos colaborativos*. Instituto Mexicano del Transporte.

Visual Crossing Corporation. (2024). *Visual Crossing Weather Data Platform*.