

Comparando la detección y la divulgación de incidentes de tránsito en redes sociales: un enfoque inteligente basado en Twitter vs. Waze

Sebastián Vallejos¹, Brian Caimmi¹, Diego Gabriel Alonso¹, Luis Sebastián Berdun¹, Alvaro Soria¹

¹ ISISTAN-UNCPBA-CONICET, Facultad de Ciencias Exactas, Campus Universitario, Paraje Arroyo Seco, Tandil, Buenos Aires, Argentina
{sebastian.vallejos; brian.caimmi; diego.alonso; luis.berdun; alvaro.soria}@isistan.unicen.edu.ar

Abstract Nowadays, social networks have become in a communication medium widely used to disseminate any type of information. In particular, the shared information in social networks usually includes a considerable number of traffic incidents reports of specific cities. In light of this, specialized social networks have emerged for detecting and disseminating traffic incidents, differentiating from generic social networks in which a wide variety of topics are communicated. In this context, Twitter is a case in point of a generic social network in which its users often share information about traffic incidents, while Waze is a social network specialized in traffic. In this paper we present a comparative study between Waze and an intelligent approach that detects traffic incidents by analyzing publications shared in Twitter. The comparative study was carried out considering Ciudad Autónoma de Buenos Aires (CABA), Argentina, as the region of interest. The results of this work suggest that both social networks should be considered as complementary sources of information. This conclusion is based on the fact that the proportion of mutual detections, i.e. traffic incidents detected by both approaches, was considerably low since it did not exceed 6% of the cases. Moreover, the results do not show that any of the approaches tend to anticipate in time to the other one in the detection of traffic incidents.

Resumen Hoy en día, las redes sociales se han convertido en un medio de comunicación ampliamente utilizado para divulgar todo tipo de información. En particular, entre la información que es compartida se suelen incluir reportes de incidentes de tránsito de ciudades específicas. En vista de esto, aparte de las redes sociales genéricas en donde se comunican una amplia variedad de temas, han surgido redes sociales especializadas en la detección y divulgación de incidentes de tránsito. En este contexto, Twitter es un ejemplo de red social genérica en donde sus usuarios suelen informar incidentes de tránsito, mientras que Waze es una red social especializada en tránsito. En este artículo presentamos un estudio comparativo entre Waze y un enfoque inteligente que detecta incidentes de tránsito a partir del análisis de publicaciones compartidas en Twitter. El estudio comparativo fue realizado considerando a la Ciudad Autónoma de Buenos Aires (CABA), Argentina, como región de interés. Los resultados de este trabajo sugieren que ambos enfoques deberían ser considerados como fuentes de información complementarias. Esta conclusión se fundamenta en que la proporción de detecciones mutuas, es decir incidentes de tránsito detectados por ambos enfoques, resultó ser considerablemente baja no superando el 6% de los casos. Además, los resultados no evidencian que alguno de los enfoques tienda a anticipar temporalmente a su similar en la detección de incidentes.

Keywords: Traffic Incidents, Twitter, Waze, Machine Learning, Natural Language Processing.

Palabras clave: Incidentes de Tránsito, Twitter, Waze, Aprendizaje de Máquina, Procesamiento de Lenguaje Natural.

1 Introducción

Uno de los grandes problemas que afrontan las personas en las grandes ciudades es el planeamiento de los viajes urbanos. Estos viajes (por ejemplo, de la casa a la oficina y de vuelta a casa) suelen verse afectados por incidentes de tránsito como accidentes y cortes, convirtiéndolos en una actividad estresante. Para evitar inconvenientes, las personas comúnmente se informan sobre el estado del tránsito antes de iniciar un viaje. Años atrás, los principales medios para informarse sobre el tráfico eran la televisión y la radio. Sin embargo, recientemente las personas comenzaron a utilizar las redes sociales con este fin. Así, por ejemplo, cuando una persona atestigua un incidente de tránsito suele informarlo a través de las redes sociales.

A partir de este comportamiento, las redes sociales se convirtieron en una importante fuente de información sobre el estado del tráfico para una región determinada. En consecuencia, las redes sociales han inducido nuevos campos de investigación en donde se usa la información de estas redes como fuentes de información complementarias para actividades de planificación urbana [1].

En la literatura existe una variedad de trabajos que se centran en la clasificación de publicaciones de Twitter¹ para la detección de eventos relacionados al tránsito [2], [3], [4], [5]. En general, la clasificación de publicaciones de Twitter es llevada a cabo mediante la utilización de técnicas de Machine Learning. Sin embargo, si bien estos enfoques filtran publicaciones de Twitter relacionadas al tránsito, presentan la limitación de no interpretar automáticamente los incidentes de tránsito detectados.

En consecuencia, otros autores han propuesto diferentes enfoques que tienen por objetivo llevar a cabo la interpretación de incidentes de tránsito reportados vía redes sociales como Twitter o Facebook [6], [7], [8], [9]. No obstante, estos trabajos analizan ciertas cuentas predefinidas que suelen reportar los incidentes de tránsito utilizando sentencias claras y gramaticalmente correctas; facilitando así el proceso de interpretación de los incidentes. Es decir, que estos trabajos no consideran a cualquier nodo de la red como una fuente de información potencial, sino que se centran en nodos particulares y estructurados (generalmente entidades gubernamentales o de noticias).

También existen enfoques que primero identifican publicaciones de Twitter que reportan incidentes de tránsito y luego llevan a cabo un proceso de interpretación de incidentes de tránsito a partir de las publicaciones consideradas como relevantes [10], [11]. A pesar de que los procesos que se realizan en estos trabajos permiten obtener información que es de utilidad en el contexto de planificación urbana, la información obtenida no es representada en un mapa. Esta última consideración es de suma importancia para facilitar el planeamiento de viajes diarios en grandes ciudades. Asimismo, si bien los trabajos de la literatura mencionados analizan publicaciones provistas en redes sociales; hasta donde sabemos, no existe un enfoque que analice publicaciones que se encuentren escritas en español.

Además de las redes multipropósito como Twitter, surgieron nuevos tipos de redes sociales especializadas en tránsito. En este tipo de redes sociales, los usuarios pueden reportar incidentes de tránsito sobre un mapa, alertando así a otros usuarios. Como caso de ejemplo, se puede mencionar a Waze² que es considerada como la red social más popular dedicada exclusivamente al tránsito. Esta red social ha sido objeto de estudio en varios trabajos de la literatura [12], [13]. En [12] se utilizó la información divulgada en Waze para mejorar la seguridad en la vía pública mediante la identificación de ciertas zonas de una ciudad en donde frecuentemente ocurran accidentes. En [13] se comparó la información suministrada por Waze con información oficial provista por la municipalidad de Belo Horizonte, Brasil. En este último trabajo, se mostró que ambas fuentes de información eran complementarias dado que sólo compartían un 7% de los accidentes de tránsito.

En este punto, en las redes sociales existen dos fuentes de información distintas sobre el estado del tránsito: las redes sociales genéricas y las redes sociales especializadas en tráfico. Al tener dos fuentes de información surgen algunas incógnitas: ¿En qué fuente circula más información? ¿En cuál se informa antes sobre un incidente? Las redes sociales genéricas poseen más usuarios que las redes sociales especializadas en tránsito. Por esta razón, suelen manejar un volumen de información mucho más grande. Sin embargo, solo una pequeña parte de esta información está relacionada exclusivamente al tránsito. Entonces, ¿cuál de las alternativas es mejor para informarse del tránsito?

En este contexto, el presente trabajo intenta responder estas preguntas mediante un estudio comparativo entre una extensión de nuestro enfoque propuesto en [14] y Waze. El experimento consistió en monitorear incidentes de tránsito de la Ciudad Autónoma de Buenos Aires (Argentina) durante cinco días. Los incidentes detectados mediante el enfoque de [14] se compararon con los reportados en Waze. Los resultados obtenidos concluyen en

¹ <https://www.twitter.com/>

² <https://www.waze.com/>

que el enfoque propuesto y Waze deberían ser considerados complementarios. Por un lado, la proporción de detecciones mutuas, es decir incidentes de tránsito detectados por ambos enfoques, no superó el 6% de los casos. Esto indica que habitualmente los enfoques detectan distintos incidentes de tránsito. Por otro lado, los resultados obtenidos indican que existe un balance en cuanto a las veces y el promedio de tiempo en que los enfoques se anticipan al detectar los mismos incidentes.

El resto del artículo se organiza de la siguiente forma. La sección 2 presenta el enfoque que se aplica sobre Twitter. La sección 3 introduce los conceptos básicos de Waze. La sección 4 detalla el proceso del estudio comparativo, los resultados obtenidos y las lecciones aprendidas. Por último, la sección 5 presenta las conclusiones del trabajo y discute posibles trabajos futuros.

2 Enfoque Propuesto Basado en Twitter

El primer enfoque a comparar es una extensión de nuestro enfoque propuesto en [14]. El enfoque propuesto detectaba reportes de incidentes de tránsito a partir del análisis de publicaciones de la red social Twitter. Para realizar este trabajo fue necesario extender el enfoque, agregándole la capacidad de geolocalizar los incidentes detectados y ubicarlos sobre un mapa. En la figura 1 se muestra un esquema conceptual del enfoque. El flujo inicia con la captura de publicaciones compartidas en Twitter en tiempo real. En este punto, los usuarios de Twitter generan una gran cantidad de publicaciones por segundo. Por esta razón, el enfoque considera ciertas condiciones a la hora de capturar publicaciones. De esta forma, solo se capturan publicaciones que cumplan estas condiciones. Por ejemplo, publicaciones escritas en determinado idioma, y que contengan determinadas palabras.

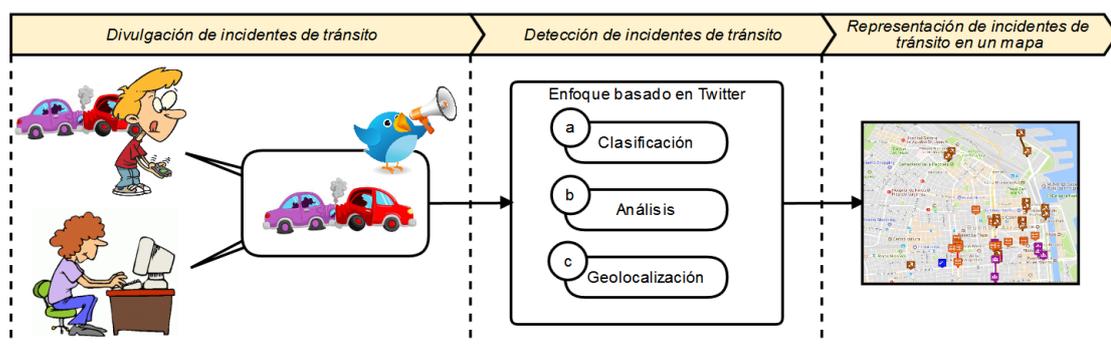


Figura 1. Enfoque propuesto para la detección de incidentes de tránsito a partir del análisis de publicaciones de Twitter.

Al capturar una publicación, el enfoque la analiza en busca de reportes de incidentes de tránsito. Este análisis consiste en tres etapas. En la primera etapa denominada 'clasificación' (a), el enfoque filtra y descarta aquellas publicaciones que no reporten incidentes de tránsito. Para esto, el enfoque primero clasifica cada publicación en 'relevante' o 'irrelevante' al tópico 'incidentes de tránsito' mediante tres clasificadores de texto: *Support Vector Machine* (SVM) [15], [16] empleando dos kernels distintos (Linear Kernel y RBF Kernel) y *Naive Bayes* [17], [18]. Luego, contando con las tres clasificaciones para cada publicación, el enfoque realiza el filtrado. El proceso de filtrado consiste en descartar sólo aquellas publicaciones que hayan sido clasificadas como 'irrelevante' por los tres clasificadores. Esta política de filtrado maximiza el *recall*, ya que minimiza las posibilidades de descartar publicaciones que reporten incidentes de tránsito a causa de una mala clasificación.

En la segunda etapa designada 'análisis' (b), el enfoque detecta los incidentes y las ubicaciones reportadas en la publicación. Primero, se reconocen las entidades nombradas en el texto de las publicaciones (como nombres de calles, nombres de barrios, tipos de incidentes, etc.). Esta no es una tarea sencilla de realizar ya que las publicaciones de Twitter son acotadas e informales. Por ejemplo, las palabras pueden estar incorrectamente capitalizadas, o tener faltantes de letras y tildes. Para enfrentar estos problemas, se define un listado con las entidades que se desean reconocer (por ejemplo, los nombres de calles y barrios de la ciudad que se está monitoreando). Al analizar una publicación, el enfoque busca estas entidades en el texto de la publicación mediante técnicas de *String Matching aproximado* [19]. Esta técnica permite encontrar similitud entre dos textos a pesar de que posean pequeñas discrepancias. De esta forma, el enfoque reconoce los nombres de calles y barrios en las publicaciones.

Una vez reconocidas las entidades, el enfoque las relaciona en ubicaciones e incidentes. Esto se logra a partir de reglas que relacionan las entidades reconocidas en el texto, según sus categorías y las palabras o conectores

lingüísticos que hay entre ellas. Por ejemplo, si se reconocen dos nombres de calles unidas por el conector lingüístico “y” se aplica la regla ‘Calle y Calle → Intersección’. Esta regla relaciona las dos calles en una intersección. Continuando con el ejemplo, la regla ‘Accidente en Intersección → Incidente’ reconoce un incidente de tránsito a partir de la ubicación reconocida en la regla anterior. De esta forma, las reglas relacionan gradualmente entidades simples (como nombres de calles), en ubicaciones y luego en incidentes de tránsito. Esta metodología permite adaptar el enfoque a la forma de escritura de los usuarios de Twitter de cada ciudad, simplemente agregando nuevas reglas o modificando las existentes.

Por último, en la tercera etapa denominada ‘geolocalización’ (c), el enfoque geolocaliza los incidentes detectados y los ubica visualmente sobre un mapa. Geolocalizar un incidente significa obtener las coordenadas geográficas de su ubicación. Por ejemplo, si se detecta un corte en el tramo de una calle comprendido entre otras dos calles, geolocalizar el corte consiste en obtener las coordenadas geográficas de los dos extremos del tramo. Para esto, el enfoque utiliza el servicio de geocodificación provisto por Google [20] que traduce direcciones textuales en coordenadas geográficas. Mediante este servicio, el enfoque traduce la descripción textual de la ubicación indicada en la publicación que reporta al incidente a coordenadas geográficas. Si la geocodificación es exitosa, el enfoque utiliza las coordenadas resultantes para ubicar el incidente sobre un mapa. En cambio, si la geocodificación falla por algún motivo como en el caso de que la ubicación no exista, el enfoque descarta la publicación.

Resumiendo, el enfoque es capaz de analizar las publicaciones compartidas en Twitter en tiempo real y ubicarlos sobre un mapa. Esto permite a los usuarios informarse de manera simple y rápida sobre el estado del tránsito de forma visual. Es posible que el enfoque identifique incidentes de tránsito en forma errónea y termine ubicando en el mapa accidentes o cortes inexistentes en la realidad. Esto puede ocurrir debido a algún error durante alguna de sus tres etapas. Un error en la etapa de clasificación (a) podría categorizar como relevante una publicación irrelevante; sin embargo, esto no resultaría en un incidente de tránsito erróneo representado en un mapa sino que solamente convendría en un gasto computacional innecesario durante las etapas de análisis y de geolocalización. En cambio, un error en la etapa de análisis (b) o de geolocalización (c) podrían concluir con un incidente falso por diferentes causas, como nombres de calles reconocidas incorrectamente, o un error de geolocalización que ubicara el incidente en una posición incorrecta en el mapa. En la experimentación del trabajo previo [14], un 0.91% de los incidentes detectados por el enfoque eran falsos, mientras que el 99.09% restante eran correctos. Actualmente, hay un prototipo online que materializa el enfoque. El prototipo (de acceso público en <http://intranet.isistan.unicen.edu.ar/>) se encuentra monitoreando la Ciudad Autónoma de Buenos Aires (CABA). En la página se pueden observar tanto los incidentes detectados a lo largo de la ciudad, como las publicaciones en las que se detectó cada uno de ellos. Con esta información, las personas pueden determinar qué camino tomar para que su movilidad en la ciudad no se vea afectada por los incidentes de tránsito.

3 Waze

En este trabajo, el enfoque presentado en la sección 2 se compara contra Waze. Waze es un sistema de navegación vehicular muy popular en la actualidad. Este sistema brinda a sus usuarios un servicio de planeamiento de rutas en tiempo real. Cuando un usuario necesita viajar desde un punto de la ciudad a otro, Waze busca una ruta que minimice el tiempo de viaje considerando el estado del tránsito en ese momento. Para conocer el estado del tránsito Waze se basa en la colaboración por parte de sus usuarios que son denominados wazers. Los wazers pueden colaborar aportando datos o información acerca del estado del tránsito. En la figura 2 se muestra un esquema conceptual sobre el sistema de colaboración empleado en Waze. Como se observa en la figura, existen dos tipos de colaboración: la colaboración activa (a) y la colaboración pasiva (b).

La colaboración activa (a) ocurre cuando un wazer reporta un incidente de tránsito. Los usuarios de Waze tienen la posibilidad de reportar los incidentes de tránsito que atestiguan. Al reportar un incidente en Waze, se debe indicar el tipo de incidente (accidente, corte, congestión, etc.) y su ubicación geográfica. Nótese que el usuario debe ser testigo del incidente al momento de reportarlo. Por esto, la ubicación del incidente que el usuario indica debe ser cercana a la ubicación del usuario que se determina por el GPS de su dispositivo móvil. Mediante este mecanismo, los usuarios de Waze comparten información acerca del estado del tránsito. Contando con esta información, Waze puede mejorar las estimaciones en los tiempos de viaje y sugerir mejores rutas a sus usuarios. De esta forma, Waze contribuye a formar comunidades de conductores locales que de manera conjunta realizan su aporte para mejorar la calidad de sus viajes diarios.

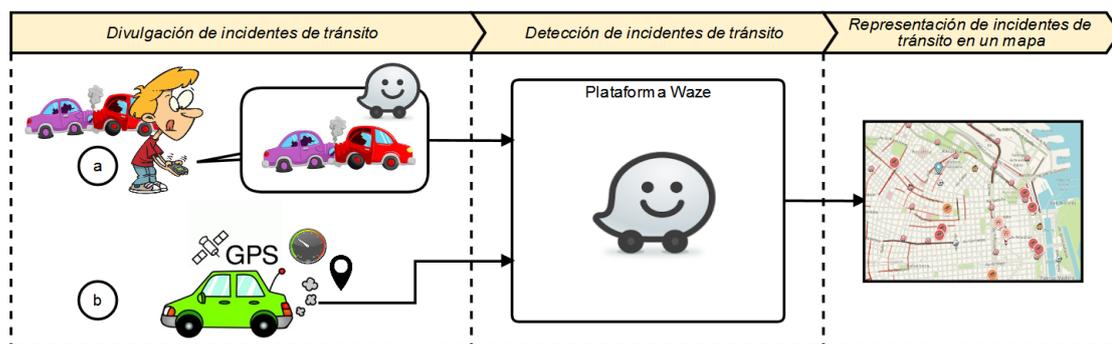


Figura 2. Sistema de colaboración de la red social Waze.

La colaboración pasiva (b) ocurre cuando un wazer conduce con la aplicación abierta en su dispositivo móvil. Waze recopila periódicamente datos a partir de los GPS que se encuentran en los dispositivos de sus usuarios como es el caso de los celulares inteligentes. Los datos recopilados proveen información de carácter útil sobre las condiciones de tránsito en diferentes áreas a todos sus usuarios. Por ejemplo, se pueden calcular las velocidades promedio a la que viajan los dispositivos. Esta información resulta útil para estimar duraciones de viajes (al igual que los incidentes reportados en la colaboración activa). Adicionalmente, Waze utiliza los datos recopilados mediante este mecanismo con diversos objetivos: como verificar errores en los mapas; conocer el sentido de las calles; mejorar la estructura vial; o conocer los giros permitidos.

Más allá de la creación de comunidades, Waze posee otras funciones sociales y de geo-gaming que complementan la aplicación. Una de ellas, consiste en un sistema de puntos y logros. Este sistema permite a los usuarios escalar en una jerarquía de rangos en base a la cantidad de incidentes que reportan o al uso pasivo de la aplicación. Escalar en esta jerarquía incentiva a los usuarios a colaborar, aportando más información acerca del estado del tránsito. Otro de los aspectos sociales más interesantes de Waze es su soporte multilinguaje y su interacción con redes sociales. Por ejemplo, un wazer puede visualizar a sus amigos wazers de otras redes sociales como Facebook o Twitter en su propio mapa. Estas funciones sociales fomentan la utilización de la aplicación y el crecimiento de la red social interna de Waze.

Resumiendo, el enfoque de Waze consiste en comunidades colaborativas de usuarios que comparten información útil respecto al tránsito. Esta información puede usarse tanto para mantener actualizados los mapas de la ciudad (colaboración pasiva) como para conocer los incidentes de tránsito que ocurren (colaboración activa). Dado que en este trabajo se busca comparar la información acerca de incidentes de tránsito que circula en cada red social, solo la colaboración activa de los wazers resulta de interés. De esta forma, los incidentes de tránsito reportados por los wazers se comparan con los incidentes que el enfoque presentado en la sección 2 detecta en las publicaciones de Twitter.

4 Estudio Comparativo

En esta sección se presenta el proceso llevado a cabo para comparar dos enfoques para la detección de incidentes de tránsito: el enfoque propuesto en este artículo que se basa en la red social Twitter y Waze. Este estudio comparativo focaliza dos criterios de comparación que persiguen diferentes objetivos.

El primer criterio de comparación tiene por objetivo analizar la cobertura de incidentes de tránsito detectados por ambos enfoques. De manera más específica, se desea determinar si el enfoque propuesto que se basa en la red social Twitter es capaz de detectar los mismos incidentes que son reportados en Waze. A su vez, mediante este criterio se puede estipular la proporción de incidentes de tránsito que solamente logran ser interpretados por alguno de los dos enfoques de manera individual. Dicho de otra manera, si el enfoque propuesto detecta incidentes de tránsito que Waze no identifica y viceversa.

El segundo criterio de comparación consistió en identificar experimentalmente cuál de los dos enfoques tiende a detectar incidentes de tránsito con mayor antelación. La antelación es una de las características más importantes de este tipo de enfoques. Si un enfoque divulga incidentes al poco tiempo de que ocurran, el enfoque tiende a ser de mayor utilidad para los usuarios finales que desean evitar cualquier obstáculo durante sus viajes interurbanos. Asimismo, mediante este criterio se puede determinar en cuál de las redes sociales involucradas (Twitter y Waze) se divulgan incidentes de tránsito con mayor anticipación.

El resto de la sección se estructura de la siguiente forma. La subsección 4.1 presenta el conjunto de datos utilizado en el estudio comparativo. La subsección 4.2 describe el pre-procesamiento que recibieron estos datos

para poder realizar la comparación. La subsección 4.3 detalla la descripción y los resultados del proceso comparativo considerando los dos criterios de comparación definidos. Finalmente, la subsección 4.4 presenta un apartado que discute los resultados obtenidos.

4.1 Recolección del Conjunto de Datos

El caso de estudio involucró como región de interés a la Ciudad Autónoma de Buenos Aires (CABA), Argentina. CABA posee la mayor cantidad de habitantes de Argentina y una de las de mayores densidades poblacionales de Sudamérica (14450 habitantes/km² en el año 2010) [21]. Esto da lugar a que CABA usualmente presente un tránsito complicado e incluso caótico. A modo de ejemplo, la ciudad se ubica en la posición 19 del ranking de ciudades con más congestión del mundo [22]. Por lo tanto, asumimos que la frecuencia de incidentes de tránsito que ocurren en esta región es alta, como también lo es la diversidad de usuarios que alertan sobre estos incidentes en las redes sociales Twitter y Waze.

El primer paso de la comparación comprendió la recolección de una muestra de publicaciones de Twitter y alertas de Waze. Para recolectar publicaciones de Twitter se utilizaron dos filtros sobre el flujo público de Twitter. El primer filtro se basa en una lista de palabras clave. Cuando el texto de una publicación presenta alguna de estas palabras la publicación pasa a formar parte del conjunto de datos. En este sentido, utilizamos una lista conformada por 65 palabras clave frecuentemente utilizadas en la jerga referida al tránsito. Palabras como 'tránsito', 'accidente' y 'cortes' son algunos ejemplos utilizados. El segundo filtro aplica una delimitación geoespacial en la que las publicaciones de Twitter que dispongan de las coordenadas geográficas del lugar en que se generó la publicación son consideradas en el conjunto de datos. En este caso, se conformó un cuadrante que delimitara a CABA. Los vértices del cuadrante se corresponden con las siguientes coordenadas: latitud máxima de -34.5329; latitud mínima de -34.7075; longitud máxima de -58.3031; longitud mínima de -58.5324. Se debe tener en cuenta que la API de Twitter utilizada para la recolección sólo provee una proporción del total de publicaciones de Twitter existentes. Específicamente, esta proporción oscila entre el 1% y el 40% de las publicaciones generadas en tiempo real [23], [24], [25]. Con respecto a la recolección de alertas de Waze se empleó un filtro de delimitación geoespacial. En este caso, se utilizó el mismo cuadrante utilizado en la recolección de publicaciones de Twitter. De esta forma, todas las alertas posicionadas dentro del cuadrante conformaron el conjunto de alertas de Waze.

La recolección de publicaciones de Twitter y de alertas de Waze se realizó durante un lapso de cinco días. El lapso comprendió tanto días laborales como días no laborales en donde controlamos que no existieran reportes programados de manifestaciones o cortes. Al asegurarnos que no existían reportes programados podemos suponer que la región de interés presentaba tránsito de carácter normal. Concretamente, la recolección de datos comenzó un viernes a las 11:00 horas y finalizó un martes a las 11:00 horas. Durante este lapso de tiempo de cinco días, se recolectaron 21075 publicaciones de Twitter y 15983 alertas de Waze.

4.2 Pre-procesamiento del Conjunto de Datos

Una vez que se tuvieron a disposición los conjuntos de publicaciones de Twitter y de alertas de Waze, se pre-procesaron estos conjuntos para adecuar los reportes de incidentes al contexto de la comparación. Para realizar este pre-procesamiento, se tuvieron en cuenta una serie de consideraciones. En primer lugar, el enfoque propuesto analizó el conjunto de publicaciones de Twitter (es decir, filtró las publicaciones relevantes al tránsito, las interpretó y las geolocalizó) para detectar los incidentes de tránsito presentes en esta colección. Para realizar el procesamiento, se aclara que se realizaron distintas evaluaciones empíricas con el fin de obtener distintas configuraciones posibles para el enfoque propuesto. Luego, se seleccionó la configuración óptima para realizar el estudio comparativo. En segundo lugar, el análisis comparativo se limitó a dos tipos de incidentes: accidente y cortes. Esto se debe a que ambos enfoques son capaces de detectar estos tipos de incidentes que suelen ser fácilmente localizables y que generalmente abarcan áreas reducidas. Por lo tanto, los incidentes de tránsito que no eran accidentes o cortes (por ejemplo, demoras y manifestaciones) no fueron tenidos en cuenta. En tercer lugar, en la comparación consideramos a cada fecha por separado para poder ver la variación de las detecciones en días laborales (viernes, sábado, lunes y martes) y días no laborales (domingo).

La tabla 1 presenta el número de incidentes (accidentes o cortes) detectados por cada uno de los enfoques a lo largo de los días en que tuvo lugar la recolección de datos. Cada uno de los días se detalla mediante su letra inicial. En esta tabla se puede observar que existe una gran disparidad en cuanto al número de incidentes que detectó cada enfoque. Por un lado, el enfoque propuesto basado en Twitter detectó 303 incidentes mientras que Waze reconoció 674 incidentes de tránsito. Estos primeros valores sugieren que Waze identifica más del doble de incidentes de tránsito que el enfoque propuesto. No obstante, al realizar un análisis detallado, no todos los incidentes se encontraban en las condiciones necesarias para realizar la comparación. Como primera

consideración, algunos incidentes detectados por el enfoque propuesto fueron geolocalizados por fuera del cuadrante delimitador de CABA. Como segunda consideración, era necesario que los incidentes tuvieran cierto grado de confianza. En efecto, un incidente presenta un grado aceptable de confianza si la fuente que lo reporta es considerada fiable por otros usuarios, o si varios usuarios reportan el mismo incidente. Sin embargo, no todos los incidentes involucrados cumplían con este requisito.

Tabla 1: Incidentes detectados por el enfoque propuesto y por la red social Waze.

Enfoque	Incidente	Día					Total
		V	S	D	L	M	
Enfoque Propuesto	Accidentes	21	22	15	42	13	113
	Cortes	42	27	24	55	42	190
	Total	63	49	39	97	55	303
Waze	Accidentes	139	97	50	95	35	416
	Cortes	74	54	19	79	32	258
	Total	213	151	69	174	67	674

Para continuar con el pre-procesamiento, se adecuaron los incidentes a la comparación mediante la utilización de dos criterios de aceptación. El primer criterio de aceptación establece que todos los incidentes detectados se encuentren localizados dentro de una misma región espacial. En consecuencia, todos los incidentes de tránsito detectados por el enfoque propuesto que fueran localizados fuera del cuadrante delimitador no se tuvieron en cuenta durante el resto del análisis comparativo. El segundo criterio de aceptación determina que los incidentes detectados deben presentar cierto grado de confianza para ser tenidos en cuenta. Por ejemplo, el hecho de que un incidente sea reportado por una única publicación de Twitter no tiene el mismo grado de confianza que el de un incidente reportado múltiples veces por distintos usuarios. Por lo tanto, los incidentes de tránsito detectados por el enfoque propuesto que estuvieran asociados a distintos reportes se mantuvieron para realizar la comparación, mientras que los que tuvieran asociada una única publicación fueron descartados. Algo similar se llevó a cabo con las alertas de Waze. Para este caso, los metadatos de las alertas de Waze ofrecen ciertos atributos que facilitan esta tarea. Uno de estos atributos se denomina *'Confidence'*. Este atributo determina en un rango [0; 10] el valor de confianza de la alerta de tránsito basándose en la reputación del usuario que la creó. Asimismo, otro atributo denominado *'nThumbsUp'* determina el número de validaciones positivas proporcionadas por otros usuarios que circularon cerca del incidente. Teniendo en cuenta estos dos atributos, cualquier alerta que tuviera al menos un valor mayor a cero para el atributo *'Confidence'* o *'nThumbsUp'* fue considerada para la comparación.

Tabla 2: Incidentes que satisfacen los criterios de aceptación para realizar la comparación.

Enfoque	Incidente	Día					Total
		V	S	D	L	M	
Enfoque Propuesto	Accidentes	15	20	12	28	5	80
	Cortes	36	23	20	46	39	164
	Total	51	43	32	74	44	244
Waze	Accidentes	77	53	19	42	14	205
	Cortes	74	54	19	79	32	258
	Total	151	107	38	121	46	463

La tabla 2 muestra el número de incidentes de tránsito detectados por cada enfoque al considerar a aquellos incidentes que hayan satisfecho los criterios de aceptación. A partir de esta tabla se puede ver que la cantidad de incidentes detectados por el enfoque propuesto pasó de 303 incidentes a 244 incidentes lo que indica una reducción del 19.47%). Además, la cantidad de incidentes detectados por Waze se redujo notablemente de 674 incidentes a 463 incidentes lo que expresa una reducción del 31.30%.

El siguiente paso del pre-procesamiento comprendió la eliminación de casos en donde existan repeticiones de incidentes. Una repetición de incidentes ocurre cuando existen al menos dos incidentes del mismo tipo con ubicaciones cercanas y tiempos de reportes similares, por lo que se los puede interpretar como el mismo incidente. A modo de ejemplo, la figura 3 muestra dos situaciones de incidentes repetidos por ambos enfoques: a la izquierda se muestran cuatro alertas de incidente detectadas por el enfoque propuesto; a la derecha se muestran tres alertas

de incidentes reportadas en Waze. Esta redundancia desvirtúa los resultados del estudio comparativo ya que puede inducir a que se consideren varios reportes de un mismo incidente como incidentes distintos, por lo que debe ser eliminada.

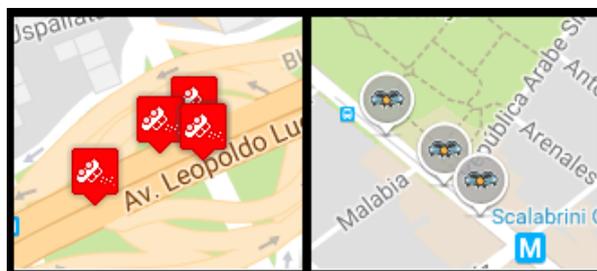


Figura 3. Ejemplos de repetición de incidentes.

Para llevar a cabo el procedimiento de eliminación de incidentes repetidos, se analizaron los incidentes utilizando diferentes radios de distancia. Al usar varios radios se pueden agrupar los incidentes por cercanía. Para este caso, se variaron los radios de distancia entre las ubicaciones de los incidentes en 50, 100, 200 y 300 metros. Los radios abarcaron distancias relativamente cercanas (50 y 100 metros) inferiores al largo en metros de una cuadra en CABA para cuando se conoce con exactitud la ubicación de los incidentes. En cambio, se emplearon distancias más largas (200 y 300 metros) para soportar los casos donde existan reportes de un mismo incidente del que se conoce su zona y no su ubicación precisa.

Tabla 3: Distribuciones de incidentes al realizar la eliminación de incidentes repetidos.

Enfoque	Incidente	Radio [m]	Día					Total	Redundancia eliminada
			V	S	D	L	M		
Enfoque Propuesto	Accidentes	-	15	20	12	28	5	80	-
		50	14	12	10	25	5	66	17.50%
		100	13	12	10	23	5	63	21.25%
		200	12	12	10	22	5	61	23.75%
		300	12	11	10	21	5	59	26.25%
	Cortes	-	36	23	20	46	39	164	-
		50	34	23	20	42	33	152	7.31%
		100	32	22	20	42	33	149	9.14%
		200	28	15	18	30	24	115	29.87%
		300	28	14	15	28	20	105	35.97%
Waze	Accidentes	-	77	53	19	42	14	205	-
		50	60	44	17	37	12	170	17.07%
		100	50	38	16	34	12	150	26.82%
		200	47	34	15	32	11	139	32.19%
		300	41	32	15	32	11	131	36.09%
	Cortes	-	74	54	19	79	32	258	-
		50	33	33	16	45	19	146	43.41%
		100	33	32	14	42	18	139	46.12%
		200	29	26	8	33	16	112	56.58%
		300	28	22	8	30	15	103	60.07%

En la tabla 3 se puede apreciar el estado del conjunto de datos luego de aplicar la eliminación de incidentes repetidos. Se debe aclarar que el estado del conjunto de datos antes de la eliminación de repeticiones se detalla en negrita junto con un guion (‘-’) para la columna radio. A partir de esta tabla, se puede determinar que existen diferencias entre la cantidad de incidentes repetidos que procesan ambos enfoques. A medida que se aumenta el

valor del radio se disminuye las detecciones de ambos enfoques ya que se van eliminando repeticiones. Sin embargo, la disminución de repeticiones es más notoria en los cortes de Waze. Por ejemplo, considerando un radio de 50 metros la cantidad de cortes detectados por el enfoque propuesto se reduce de 164 a 152 (7.31%), mientras que en Waze se reduce de 258 a 146 (43.41%). Esto se debe a que Waze exige que un corte sea reportado por múltiples usuarios antes de considerarlo como válido. Hasta que esto no ocurra, los reportes de los usuarios se acumulan en el lugar, generando redundancia.

La figura 4 describe el promedio de reportes redundantes que tiene el conjunto de datos utilizados para cada uno de los enfoques. En el eje horizontal se observan los distintos radios considerados para el experimento (50, 100, 200 y 300 metros) mientras que en el eje vertical se detalla el promedio de reportes redundantes para cada radio utilizado. En la figura 4 se puede visualizar el hecho de que en todos los casos de radios el enfoque propuesto posee una menor cantidad de incidentes repetidos. Cuando se considera un radio de 50 y de 100 metros, la diferencia de la proporción de incidentes repetidos entre Waze y el enfoque propuesto llega al 21.09% y al 24.47%, respectivamente. Si se sigue aumentando el radio a 200 y 300 metros, la diferencia comienza a reducirse gradualmente llegando a 17.92% y 16.67%. Sin embargo, durante los experimentos, al utilizar radios mayores a 100 metros, se comenzaron a considerar incorrectamente alertas de distintos incidentes como alertas de un mismo incidente. Por lo cual no resulta conveniente superar los 100 metros de radio.

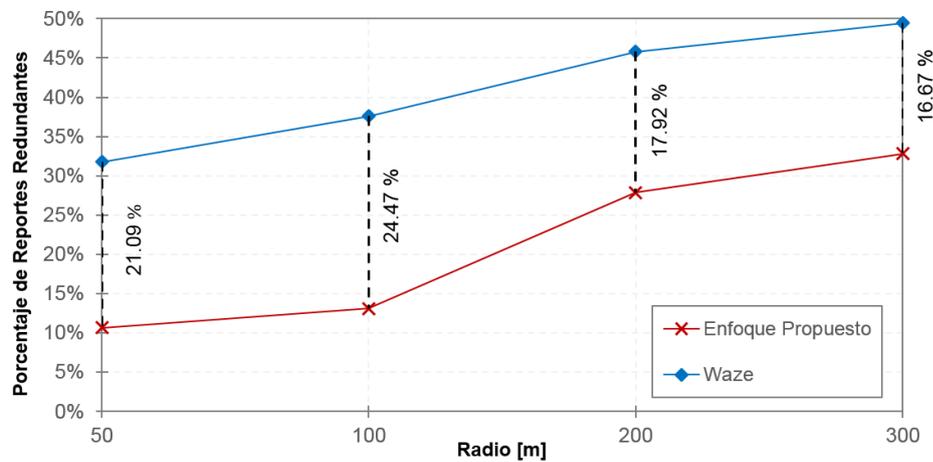


Figura 4. Porcentaje de reportes redundantes para el enfoque propuesto y para Waze al considerar distintos radios.

A partir de esos datos, podemos decir que el radio de 100 metros puede ser considerado como un punto de inflexión debido a que en radios más altos (200 y 300 metros) se tiende a agrupar una gran proporción de incidentes distintos como repeticiones. Por otro lado, dado que en CABA las cuadras tienen un largo de 100 metros, si se buscaran detecciones mutuas en un radio de 50 metros es posible que varios reportes de un mismo incidente de tránsito no se logren agrupar a pesar de encontrarse en la misma cuadra. Por esta razón, un radio de 100 metros sería el valor más adecuado para la comparación que se pretende llevar a cabo. La figura 5 muestra el resultado de eliminar la redundancia en los dos casos presentados en la figura 3. En ambas situaciones, se conserva únicamente la alerta que se reportó antes en el tiempo. De esta forma, en la comparación se contabiliza cada incidente una única vez, evitando distorsionar los resultados de la comparación debido a redundancia en los datos.

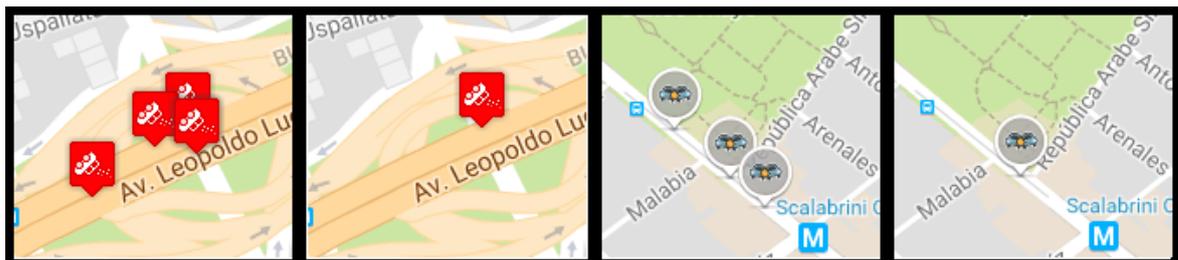


Figura 5. Resultado tras eliminar la redundancia mostrada en la figura 3.

4.3 Comparación de Incidentes Detectados

Una vez que se finalizó con el pre-procesamiento del conjunto de datos, se continuó con el primer criterio de comparación que se centra en analizar la cobertura de incidentes detectados por ambos enfoques. Por lo tanto, se llevó a cabo un análisis sobre el conjunto de incidentes sin repeticiones considerando separadamente los tipos de incidentes involucrados (es decir, accidentes y cortes) y un radio de 100 metros. Específicamente, el conjunto de incidentes utilizado se desprende de las filas de la tabla 3 en donde el radio fuera de 100 metros.

Con el objetivo de analizar el conjunto de reportes conseguidos y determinar la distribución de detecciones, se efectuaron los siguientes pasos. Primero, por cada tipo de incidente, se presentaron los incidentes detectados por cada enfoque de manera superpuesta en un mismo mapa de CABA. Luego, por cada incidente reconocido por el enfoque propuesto se calculó la distancia en metros hacia todos los incidentes reconocidos por Waze. Cuando la distancia hacia algún incidente reconocido por Waze fuera igual o menor al radio de 100 metros establecido, los incidentes fueron considerados como una detección mutua. Dicho de otra manera, en estos casos ambos enfoques detectaron el mismo incidente de tránsito. Por el contrario, los incidentes que no participaron de alguna detección mutua fueron considerados como detecciones individuales. Al finalizar, se hizo un recuento para determinar el número de detecciones propias del enfoque propuesto, el número de detecciones propias de Waze y el número de detecciones mutuas entre ambos enfoques.

La figura 6 muestra tres gráficos que detallan la distribución resultante de incidentes detectados por el enfoque propuesto y Waze considerando un radio de 100 metros. Por un lado, el gráfico de barras apiladas de la izquierda describe la cantidad de incidentes distinguiendo ciertos aspectos. El eje vertical se divide primero por el tipo de incidente (accidente o corte) y luego por la distribución por cada uno de los días considerados (V: viernes, S: sábado, D: domingo, L: lunes y M: martes). El eje horizontal denota la cantidad de incidentes por día discriminando por el tipo de detección que puede ser tanto individual (denotada con el nombre del enfoque correspondiente) o conjunta para el caso de las detecciones mutuas. Por otro lado, los gráficos de torta de la derecha indican el total de incidentes detectados para cada tipo de incidente considerando todas las fechas y la proporción correspondiente de detecciones totales.

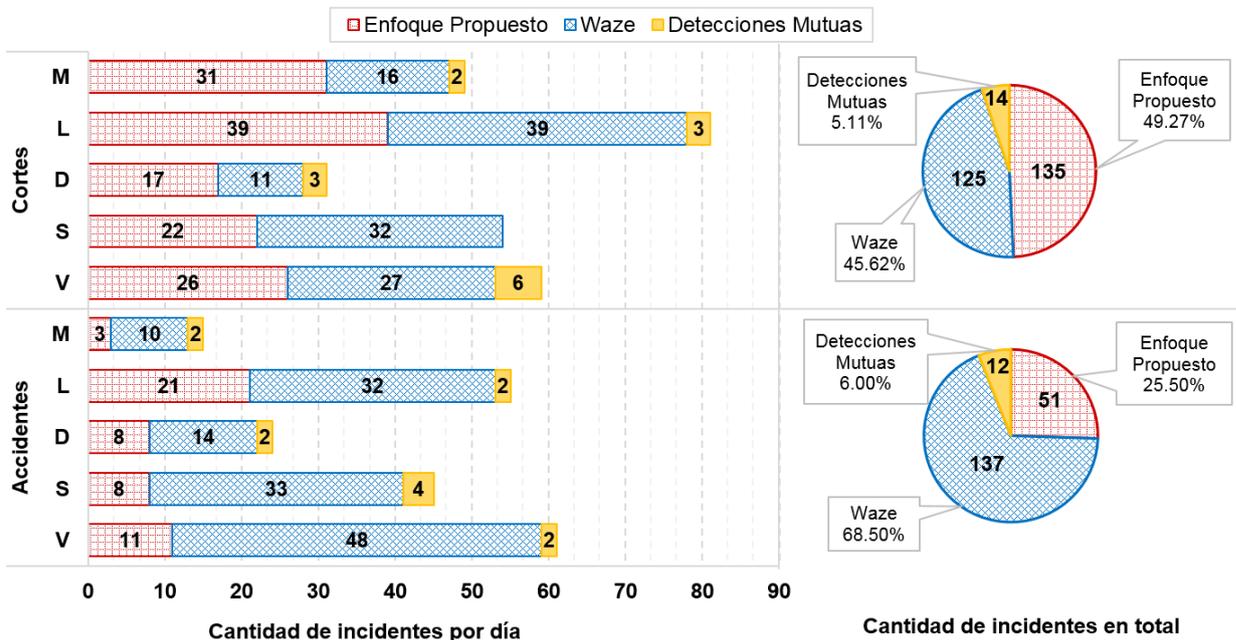


Figura 6. Distribución de incidentes detectados individualmente y mutuamente por el enfoque propuesto y Waze al considerar un radio de 100 metros.

Analizando la figura 6 se pueden establecer tres conclusiones. La primera conclusión es que la cantidad de incidentes detectados es mayor en los días laborales que en los no laborales. Al sumar las cantidades de detecciones totales por cada día se obtienen los siguientes valores: el viernes (V) se detectaron 120 incidentes, el sábado (S) 99, el domingo (D) 55, el lunes (L) 136 y el martes (M) 64. Se debe resaltar que el día domingo, que es

considerado como día no laboral, hubo la menor cantidad de detecciones. Esto puede deberse a que en estos días suele aliviarse el tránsito en CABA. En el caso del día martes hubo una cantidad menos de incidentes debido que sólo se detectaron incidentes hasta las 11:00 am. Salvando el caso del día martes, los días lunes, viernes y sábado (considerado día de trabajo de media jornada) tuvieron una mayor proporción de incidentes que el día domingo. De esta manera, se observa que los días laborales suelen tener una mayor cantidad de detecciones de incidentes de tránsito que un día no laboral.

La segunda conclusión es que Waze identificó una cantidad de accidentes considerablemente mayor que el enfoque propuesto. Como se observa en el diagrama de torta superior de la figura 6, ambos enfoques obtuvieron una proporción de cortes similares (49.27% para el enfoque propuesto y 45.62% para Waze). Sin embargo, los resultados fueron distintos para el caso de los accidentes. Específicamente, Waze logró una proporción de detecciones (68.5%) que duplica a la proporción conseguida por el enfoque propuesto (25.5%), como muestra el diagrama de torta inferior en la figura 6. Esto estaría indicando que los usuarios de Waze suelen reportar más accidentes que los usuarios de Twitter.

La tercera conclusión es que la cantidad de detecciones mutuas fue mucho más baja que la cantidad de incidentes detectados individualmente por cualquiera de los enfoques. Esto ocurrió con proporciones similares tanto para el caso de los accidentes (6%) como para el caso de los cortes (5.1%). A nuestro parecer, que existan pequeñas proporciones de detecciones mutuas induce a que los reportes de tránsito que circulan en Twitter y en Waze no suelen cubrir los mismos incidentes. Sin embargo, esto también puede deberse a que el radio de 100 metros es insuficiente en ciertas situaciones, específicamente en las autopistas. Por ejemplo, la figura 7 muestra reportes de incidentes en autopistas. La imagen de la izquierda muestra reportes de accidente detectados por el enfoque propuesto y la imagen de la derecha muestra reportes de accidente de Waze. En ambas imágenes se muestra cómo los usuarios reportan un mismo incidente en reiteradas ocasiones y a distancias mayores de 100 metros. Esto es porque, al tratarse de una vía rápida sin intersecciones, las personas suelen manipular la información acerca de su ubicación de manera menos precisa. Esta redundancia remanente en las autopistas afectan los resultados de la comparación. En la subsección 4.6 se profundiza sobre este problema de redundancia en las vías rápidas.

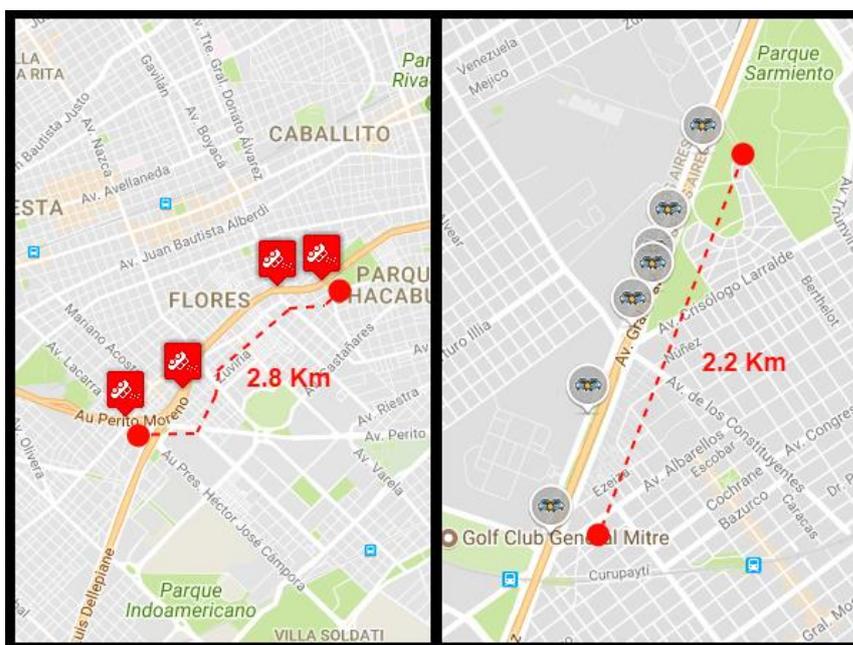


Figura 7. Redundancia de incidentes de tránsito ubicados en autopistas.

4.4 Comparación de los Tiempos de Reporte de los Incidentes que Ambos Enfoques Detectaron Mutuamente

A partir del conjunto de incidentes de tránsito detectados por ambos enfoques cuya distancia sea cercana (es decir, lo que denominamos detecciones mutuas), el siguiente paso en la comparación tiene por objetivo determinar qué enfoque identificó dichos incidentes con mayor antelación. Con tal motivo, la comparación se basó en contrastar los tiempos de reportes de los incidentes que forman el conjunto de detecciones mutuas. Para llevar a cabo esto,

para cada día se agruparon los incidentes involucrados en una detección mutua considerando un radio de 100 metros. Por cada caso de detección mutua, se determinó el enfoque que haya detectado al incidente involucrado con mayor anticipación y el lapso de tiempo existente hasta que el enfoque contrario detectara el mismo incidente. Cabe aclarar que estos lapsos de tiempo permiten determinar la diferencia de tiempo existente para que ambos enfoques se percaten de un mismo incidente. Tomando en cuenta estos lapsos de tiempo, se calculó el promedio de antelación total en horas, minutos y segundos, con el que cada enfoque anticipa al enfoque contrincante.

La tabla 4 detalla los resultados referidos a las antelaciones entre ambos enfoques. En la primera columna se especifica el tipo de incidente considerado. En la segunda se detalla el día involucrado. En la tercera columna se muestra la cantidad de antelaciones (es decir, la cantidad de veces que un enfoque identificó un incidente antes que su oponente). En la cuarta columna se presenta el promedio en horas, minutos y segundos, con el que un enfoque identifica un incidente antes que el otro enfoque. Se debe notar que una celda con guion significa que el enfoque involucrado no logró enterarse de ningún incidente antes que el otro enfoque para una fecha específica, por lo que no tiene asociado un promedio de antelación.

Si bien el número de datos utilizados en esta comparación es escaso debido al bajo número de detecciones mutuas entre ambos enfoques, de la tabla 4 se pueden extraer dos conclusiones preliminares. La primera conclusión es que la cantidad de veces que cada enfoque anticipa al otro en la detección de incidentes varía según el tipo del incidente que se esté considerando. En el caso de los accidentes, Waze tuvo una mayor cantidad de antelaciones que el enfoque propuesto en tres de los cinco días. Mientras que el enfoque propuesto superó en cantidad de antelaciones a Waze en una sola ocasión. Esto indicaría que Waze suele anticipar al enfoque propuesto en la detección de accidentes. En cambio, en el caso de los cortes, no se evidenció una diferencia significativa entre ambos enfoques. Concretamente, el enfoque propuesto tuvo 6 anticipaciones de cortes mientras que Waze tuvo 8. Por lo tanto, podemos afirmar que, a diferencia de los accidentes, ninguno de los dos enfoques suele anteponerse frente a su similar para el caso de la detección de cortes.

La segunda conclusión es que en el caso de los cortes, los tiempos promedio de antelación suelen ser mayores cuando el enfoque propuesto anticipa a su similar en comparación al caso contrario. Considerando los promedios de antelación totales, el tiempo promedio del enfoque propuesto (2:19:44 hs) duplica al tiempo de Waze (1:09:12 hs). Si se observan los datos de la tabla 4, se puede establecer que cuando el enfoque propuesto anticipa a Waze, lo suele hacer con tiempos de antelación considerablemente mayores. Por ejemplo, en el día viernes (V en la tabla 4), el enfoque propuesto detectó un corte con 5 horas de anticipación. En esta ocasión, el corte involucrado fue reportado vía Twitter alrededor de las 11:00 am, mientras que Waze identificó el mismo corte un poco antes de las 16:30 pm. Este mismo hecho de que cuando el enfoque propuesto anticipa a Waze lo hace con una diferencia de tiempo considerable no aplica para el caso de los accidentes. En este caso, la diferencia de promedios de antelación total (1:41:58 hs del enfoque propuesto frente a 0:41:55 hs de Waze) se debe principalmente al caso particular del día lunes (L en la tabla 4). Ese día, usuarios de Twitter reportaron dos accidentes durante la madrugada. Sin embargo, los wazers reportaron esos mismos accidentes varias horas después, cuando comenzaron a transitar por las zonas afectadas al iniciar sus jornadas laborales.

Tabla 4: Cantidad de antelaciones y promedio de antelaciones de ambos enfoques utilizando un radio de 100 metros.

Tipo de Incidente	Día	Antelaciones		Promedio de Antelación	
		Enfoque Propuesto	Waze	Enfoque Propuesto	Waze
Accidentes	V	1	1	0:13:41	0:22:19
	S	1	3	0:00:15	0:46:15
	D	0	2	-	0:29:17
	L	2	0	3:16:58	-
	M	0	2	-	0:57:53
	V+S+D+L+M	4	8	1:41:58	0:41:55
Cortes	V	1	5	5:12:04	1:33:13
	S	-	-	-	-
	D	3	0	2:16:54	-
	L	1	2	1:12:29	0:17:23
	M	1	1	0:43:05	0:52:51
	V+S+D+L+M	6	8	2:19:44	1:09:12

4.5 Resumen de los Resultados

A partir de la experimentación realizada, hemos comparado la cobertura de detecciones de incidentes de tránsito del enfoque inteligente propuesto que se basa en la red social Twitter y la misma cobertura lograda por Waze. No obstante, decidir qué enfoque alcanza una mayor cobertura no resulta ser una tarea trivial. Por lo tanto, consideramos dos criterios de comparación.

El primer criterio considera la cantidad de incidentes que los enfoques detectan tanto individualmente (incidentes solamente detectados por uno de los enfoques) como conjuntamente (incidentes detectados mutuamente por ambos enfoques). A partir de los resultados presentados en la subsección 4.3 se puede concluir que los enfoques deberían ser considerados complementarios en cuanto a la detección de incidentes. Si bien Waze detectó el doble de accidentes que el enfoque propuesto, muchas de estas detecciones eran repeticiones de incidentes que no pudieron ser eliminados utilizando el mecanismo basado en radios de distancia. A su vez, por lo percibido durante la experimentación, en muy pocos casos los enfoques identificaron mutuamente los mismos incidentes. Con esta evidencia se puede afirmar que las redes sociales Twitter y Waze no suelen divulgar los mismos incidentes de tránsito.

Por otro lado, el segundo criterio toma en cuenta el tiempo de antelación con el que los enfoques detectan los mismos incidentes. Los resultados ofrecidos en la subsección 4.4 determinaron que ninguno de los enfoques logró anticiparse siempre a su oponente. Waze tuvo una mayor cantidad de anticipaciones frente al enfoque propuesto. Este hecho fue notorio en el caso de los accidentes. Sin embargo, en el caso de los cortes la diferencia fue solamente de dos antelaciones. A pesar de este hecho, el promedio de tiempo de antelación logrado por el enfoque propuesto fue mucho mayor que el promedio de antelación conseguido por Waze para los dos tipos de incidentes considerados. A nuestro parecer, a partir de estas argumentaciones no es posible determinar acertadamente qué enfoque posee mayor anticipación al detectar incidentes de tránsito.

Otro punto interesante a discutir es que pudimos corroborar que los días laborales presentan una mayor proporción de detecciones de incidentes de tránsito que los días no laborales. Esto puede deberse tanto a que en los días no laborales no suele haber el mismo flujo de tránsito que en un día laboral como así al hecho de que también se reduce la cantidad de wazers activos. Hay que recordar que los wazers deben estar 'in situ' para poder reportar el incidente de tránsito.

En conclusión, el estudio comparativo llevado a cabo nos muestra que ninguno de los dos enfoques aventaja ampliamente a su contrincante. A nuestro juicio, los enfoques deberían ser considerados complementarios. La justificación a esto se basa en que ambos enfoques detectan una mayor cantidad de incidentes de forma individual que de forma conjunta. Esto es evidente en la figura 6 en donde las proporciones de detecciones mutuas no superaron el 6% de las detecciones. Si bien esta proporción de detecciones mutuas es baja, resultó ser similar a la proporción de 7% conseguida en el trabajo de [13]. Esto puede sugerir que todas las fuentes de información acerca del tránsito conocen sólo una pequeña porción de los incidentes que afectan el tráfico, por lo que es necesario considerar simultáneamente varias fuentes de información para tener una visión más certera del estado de tránsito. En cuanto a tiempo de antelación, Waze logró una mayor cantidad de anticipaciones, sin embargo, cuando el enfoque propuesto anticipa a Waze, lo hace con lapsos de tiempo considerablemente mayores.

4.6 Lecciones Aprendidas

El análisis de los resultados obtenidos sugieren que no existe un gran número de detecciones mutuas entre nuestro enfoque propuesto basado en Twitter y Waze. Este análisis nos hizo cuestionar la forma utilizada para identificar las detecciones mutuas. Si bien el radio de 100 metros especificado en la sección 4.3 resulta certero en lo que se refiere a las calles de la ciudad, cuando se habla de vías rápidas interurbanas o autopistas esta distancia parece ser inapropiada.

En una autopista, es muy factible que un usuario reporte mal la ubicación de un incidente. Esto se debe principalmente a dos cuestiones contrapuestas: congestionamientos o un alejamiento rápido del lugar del incidente debido a la velocidad de la vía. En primer lugar, un incidente de tránsito en una autopista a menudo genera grandes congestionamientos que producen largas filas de autos parados que alcanzan varios kilómetros. En el caso de que un usuario se vea afectado por un congestionamiento de este tipo, es posible que reporte el incidente informando su ubicación en el congestionamiento; lo que induce a la divulgación del incidente con una ubicación incorrecta que puede ser muy distante de la ubicación real del incidente. En segundo lugar, las autopistas son vías de tránsito rápido en donde los vehículos deben transitar a una velocidad que supere un límite de velocidad mínima. En consecuencia, si un usuario que transita por una autopista es testigo de un incidente de tránsito, para el momento en que termine de generar el reporte del incidente este usuario se habrá distanciado considerablemente de la ubicación real del incidente. Por lo tanto, en este caso también la ubicación reportada del incidente será incorrecta. Vale resaltar que estos tipos de reportes inexactos se pueden dar tanto en Waze como en Twitter. En

Waze, debido a que se toma la posición actual del usuario, mientras que en Twitter la inexactitud puede estar relacionada con la ubicación que reporte el usuario.

En vista de esto, se genera la pregunta de si el proceso de identificación de detecciones mutuas debería considerar diferentes contextos de vías de tránsito. Siendo más específicos, ahora intentaremos develar cómo afectan los diferentes contextos de calles y de autopistas al análisis realizado hasta este punto. Para llevar a cabo esto, dividimos el conjunto de incidentes disponibles en dos subconjuntos disjuntos: un subconjunto $C_{autopistas}$ de incidentes localizados en autopistas y un subconjunto C_{calles} de incidentes localizados en calles. De esta forma, $C_{autopistas}$ quedó constituido por 193 incidentes de tránsito mientras que C_{calles} quedó constituido por 514 incidentes de tránsito.

La tabla 5 muestra la distribución de incidentes teniendo en cuenta su tipo (accidente o corte), el tipo de enfoque que los detectó (enfoque propuesto o Waze) y el tipo de vía (calle o autopista) en el que se ubican. Esta tabla detalla que para el caso de los accidentes, el 66.25% (enfoque propuesto) y el 61.46% (Waze) se ubican en autopistas. En cambio, los cortes apenas constituyen el 6.10% (enfoque propuesto) y el 1.56% de los incidentes sobre autopistas. Resumiendo, los accidentes suelen ocurrir mayoritariamente en las autopistas de CABA y los cortes se manifiestan mayoritariamente en las calles de esta ciudad.

Tabla 5: Distribución del número de incidentes al considerar el tipo de incidente, el enfoque que lo detectó y el tipo de vía sobre el que se localizan.

Tipo de Incidente	Tipo de Enfoque	Tipo de vía	Cantidad de Incidentes	Proporción de Incidentes
Accidente	Enfoque Propuesto	Calles	27	33.75 %
		Autopistas	53	66.25 %
		Total	80	100 %
	Waze	Calles	79	38.53 %
		Autopistas	126	61.46 %
		Total	205	100 %
Cortes	Enfoque Propuesto	Calles	154	93.90 %
		Autopistas	10	6.10 %
		Total	164	100 %
	Waze	Calles	254	98.44 %
		Autopistas	4	1.56 %
		Total	258	100 %

A partir de esta diferencia en cuanto a la proporción de accidentes divulgados en autopistas y en calles, se profundizó el análisis para el caso de los accidentes en autopistas. Como se ha discutido previamente, emplear un radio de 100 metros para buscar detecciones mutuas en estos casos puede ser que no sea la mejor opción. Por lo tanto, repetimos el proceso de detecciones mutuas utilizando únicamente el subconjunto de accidentes del conjunto $C_{autopistas}$. En este punto, variamos el valor de radio desde un valor inicial de 100 metros hasta un valor final de 1000 metros, sumando 100 metros cada vez. A nuestro parecer, 1000 metros es una cota superior aceptable para buscar detecciones mutuas debido a que distancias superiores pueden permitir la identificación de una detección mutua en donde los incidentes sean distintos. Tomemos por ejemplo que un usuario transita por una autopista a velocidad mínima (en CABA son 50 km/h), este usuario recorre 1 kilómetro en 72 segundos; por lo tanto, luego de atestiguar un incidente podría demorar hasta 72 segundos para informar una ubicación cercana (menor a 1 kilómetro) al incidente real. Modificando este ejemplo, si un usuario transita a mayor velocidad dispondrá de menos tiempo para informar una ubicación cercana al incidente real.

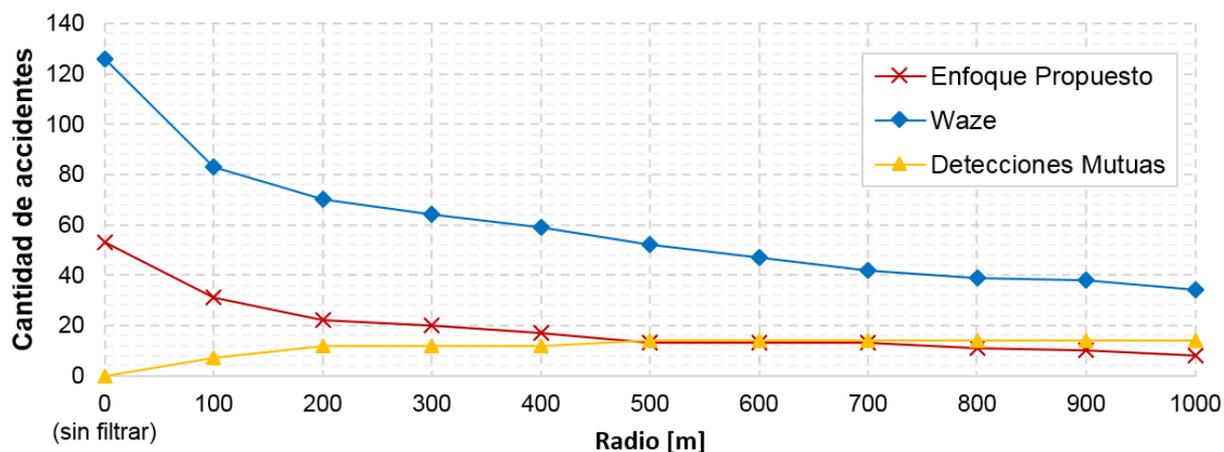


Figura 8. Proporción de detecciones mutuas e independientes por parte de ambos enfoques para el caso de accidentes en autopistas al variar el valor de radio utilizado en el proceso de detecciones mutuas.

La figura 8 ilustra cómo varía la proporción de detecciones mutuas y detecciones independientes de cada enfoque a medida que se aumenta el valor de radio para el caso de los accidentes en autopistas. En el eje horizontal de esta figura se muestra el valor de radio en metros considerado que va desde 0 (sin proceso de eliminación de duplicados) hasta 1000; mientras que el eje vertical indica la cantidad de accidentes detectados. Las cantidades de accidentes se describen utilizando cruces rojas para el caso del enfoque propuesto, rombos azules para el caso de Waze y triángulos amarillos para el caso de las detecciones mutuas. A partir de esta figura, se puede decir que la cantidad de detecciones independientes de ambos enfoques disminuye a medida que el valor de radio es mayor. Contrariamente, la cantidad de detecciones mutuas aumenta a medida que el valor de radio es mayor. No obstante, la cantidad de detecciones mutuas se mantiene igual desde los 500 metros hasta los 1000 metros mientras que las detecciones independientes de ambos enfoques continúan disminuyendo en este rango. Por lo tanto, aumentar el valor de radio permite identificar una mayor cantidad de detecciones mutuas a la vez que se disminuye la cantidad de incidentes repetidos sobre autopistas.

Aumentar el valor del radio utilizado para la identificación de detecciones mutuas en autopistas pareciera una consideración favorable. Sin embargo, seleccionar un valor de radio óptimo para llevar a cabo esta tarea es sumamente subjetivo ya que no existe un valor de radio óptimo. Por ejemplo, la figura 9 muestra tres mapas con la distribución de detecciones mutuas (marcadores amarillos) e independientes (identificados con los marcadores indicados en la leyenda de la figura) en cuanto a accidentes en una de las autopistas de CABA el día sábado. El mapa A ilustra la distribución de accidentes original (sin eliminar reportes redundantes ni intentando identificar detecciones mutuas). El mapa B presenta la distribución de identificaciones utilizando un valor de radio de 100 metros. El mapa C muestra dos identificaciones mutuas que se originaron al usar un valor de radio de 1000 metros. Analizando los mapas, se puede decir que al utilizar un radio de 100 metros (mapa B) se mantiene una gran cantidad de incidentes sin asociar como una detección mutua; pero al utilizar un valor de radio de 1000 metros (mapa C) los incidentes terminan siendo asociados correctamente y se disminuyen la cantidad de detecciones independientes en esta sección de autopista. Se debe notar que en el mapa C los incidentes no se asocian como detecciones mutuas debido a sus diferencias horarias que sobrepasan las 4 horas establecidas en el proceso de comparación.

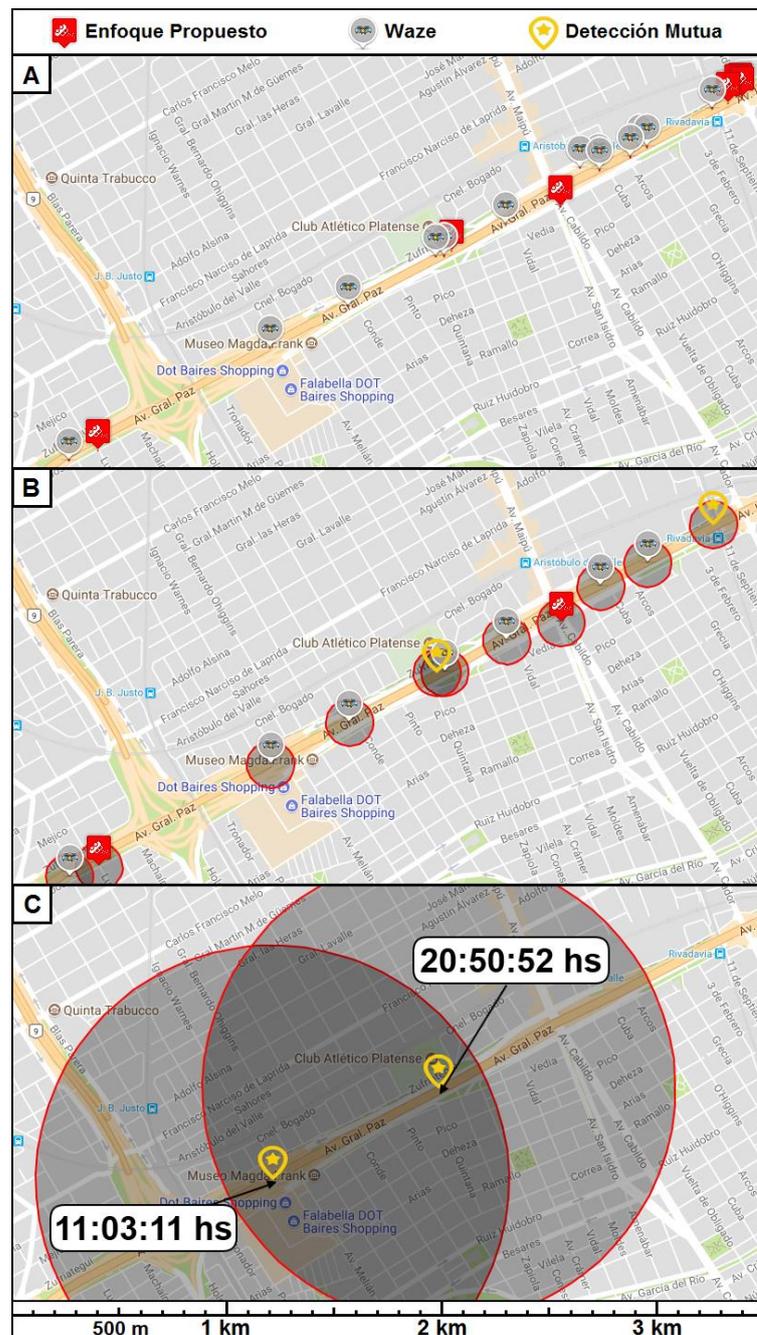


Figura 9. Mapas de distribución de detecciones mutuas considerando diferentes radios: (a) 0 metros (contexto original), (b) 100 metros y (c) 1000 metros.

En el caso presentado en la figura 9 se ve cómo aumentar el valor del radio para llevar a cabo la identificación de detecciones mutuas en autopistas favorece el proceso. Sin embargo, aumentar el valor de radio no siempre es favorable. La figura 10 exhibe un caso particular de accidentes ubicados en otra autopista luego de aplicar el proceso de identificación de detecciones mutuas. Los marcadores blancos se corresponden con las detecciones por parte de Waze y el marcado rojo se corresponde con una detección del enfoque propuesto basado en Twitter. En este caso, si se aumenta el valor de radio de 1000 metros a un valor mayor pueden ocurrir dos cosas. Por un lado, que el incidente A se asocie con el incidente C como una detección mutua, hecho que sería correcto ya que la diferencia horaria entre estos dos incidentes es menor a 4 horas y se ubican sobre la misma autopista. Por otro lado, que el incidente A se asocie con el incidente B como una detección mutua ya que la diferencia horaria entre

estos dos incidentes es menor a 4 horas. Esto último sería incorrecto ya que los incidentes fueron reportados en diferentes autopistas. En conclusión, el hecho de aumentar el valor de radio puede mejorar el proceso de identificación de detecciones mutuas a la vez que puede ser contraproducente.

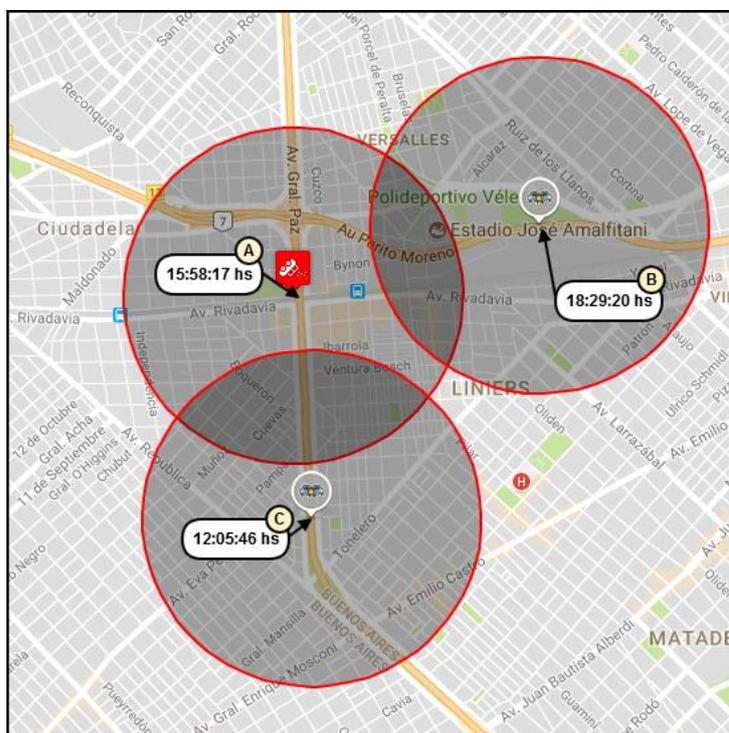


Figura 10. Dificultades de seleccionar un valor de radio para llevar a cabo el proceso de identificación de detecciones mutuas en autopistas.

Luego de llevar a cabo esta pequeña discusión, se pueden resumir ciertas lecciones aprendidas. En primer lugar, la identificación de detecciones mutuas en autopistas tiene una complejidad mayor que el mismo proceso aplicado a calles debido a que las ubicaciones de los reportes de un mismo incidente suelen ser más dispersas. En segundo lugar, si bien una alternativa para mejorar la identificación de detecciones mutuas comprende el aumento del valor del radio utilizado en este proceso, no es posible determinar hasta qué punto conviene aumentar este valor. Esto se debe a que a medida que se aumenta el valor del radio, también se aumenta la posibilidad de considerar distintos incidentes ubicados en autopistas como uno mismo. Asimismo, hemos observado que utilizando un valor de radio alto (1000 metros) permite identificar una mayor proporción de detecciones mutuas a la vez que se disminuye la cantidad de detecciones independientes de ambos enfoques. Sin embargo, siguen existiendo casos en que reportes de un mismo incidente no son identificados como detecciones mutuas debido a la gran distancia que existe entre sus ubicaciones. En tercer y último lugar, el hecho de aumentar el valor de radio induce a que se deba modificar el proceso de identificación de detecciones mutuas ya que es necesario separar el conjunto de incidentes ubicados en autopistas de los ubicados en calles.

5 Conclusión

En este trabajo presentamos un estudio comparativo entre dos enfoques orientados a la detección y divulgación de incidentes de tránsito. El primer enfoque analiza publicaciones de la red social Twitter mediante técnicas de *Machine Learning* y *Procesamiento de Lenguaje Natural* para identificar incidentes de tránsito. Sin embargo, al ser una red social genérica, las publicaciones compartidas involucran cualquier tema de interés y sólo una pequeña porción se corresponde al tránsito. El segundo enfoque es la red social Waze que se especializa en la divulgación del estado del tránsito. A diferencia de Twitter, Waze solamente contiene información referida al tránsito. El estudio comparativo que involucró a estos dos enfoques se basó en analizar por un lado la cobertura en cuanto a incidentes de tránsito detectados y por otro lado el grado de antelación de las detecciones.

A partir de este estudio comparativo, se obtuvieron resultados alentadores que indican que los enfoques deberían ser considerados complementarios. Esto se debe a que los enfoques no suelen identificar los mismos incidentes a la vez, sino que cada uno habitualmente detecta incidentes que el otro enfoque no. Además, divisamos que ninguno de los enfoques tiene un mayor grado de anticipación que el otro. Finalmente, percibimos que luego de eliminar incidentes repetidos (es decir, reportes de igual tipo con ubicación y tiempo similares), Waze sigue presentando una gran cantidad de incidentes que pueden ser considerados redundantes. Sin embargo, hay que tener en cuenta que la redundancia no sólo depende de la red social, sino de los tipos de incidentes. Por ejemplo, los resultados empíricos determinan que Twitter presenta más redundancia en accidentes que en cortes. Asimismo, es necesario notar que la API de Twitter utilizada no garantiza la entrega del 100% de las publicaciones en tiempo real. En consecuencia, es posible que se omitan publicaciones que podrían informar incidentes de tránsito. A pesar de esta limitación, el enfoque propuesto nos brinda resultados competitivos con los arrojados por Waze, lo que resalta la potencialidad de nuestro enfoque.

Con la evidencia empírica de que ambos enfoques deberían ser considerados complementarios, se planean continuar con diferentes líneas de investigación en este campo. En primer lugar, a partir de la evaluación preliminar se pudo concluir que los enfoques no suelen identificar los mismos incidentes, por lo que resultaría interesante poder combinar la información que brinda cada enfoque de manera separada. Al desarrollar un nuevo enfoque que combine los reportes de incidentes de varias fuentes de información se podría mejorar la cobertura de detecciones de incidentes. De esta forma, los usuarios finales percibirían incidentes de tránsito que no se les revelarían si solamente dependieran de uno de estos enfoques. En segundo lugar, si este tipo de análisis se ejecuta continuamente en tiempo real, podría servir como método de validación de incidentes. En otras palabras, esto permitiría verificar que realmente los incidentes de tránsito hayan ocurrido.

Por otro lado, estamos trabajando para repetir la comparación variando tres aspectos. El primer aspecto es la forma en que se realiza el proceso de identificación de detecciones mutuas ya que considerar un radio de 100 metros puede resultar controversial, especialmente en el caso de autopistas. En la subsección 4.5.1 se discutió que separar el conjunto de incidentes según su ubicación (calles o autopistas) y realizar la comparación usando radios mayores a 100 metros mejora el proceso de identificación de detecciones mutuas, pero también se concluyó que esto puede ser contraproducente. En consecuencia, creemos que esta división del conjunto de incidentes según su ubicación es necesaria y proponemos aplicar un procedimiento más sofisticado sobre el conjunto de incidentes en autopistas. Este procedimiento comprende la división de las autopistas propias a la región de interés en tramos para identificar detecciones mutuas en cada uno de estos segmentos individuales. El segundo aspecto es que el enfoque basado en la red social Twitter puede detectar incidentes de tránsito de forma errónea. Si bien en un trabajo previo [14], el número de detecciones erróneas fue menor al 1%, esto podría impactar en los resultados de la comparación. Por esta razón, sería necesaria una evaluación manual durante el pre-procesamiento para eliminar los incidentes detectados erróneamente por el enfoque. Por último, el tercer aspecto es la cantidad de datos utilizados. El experimento abarcó 5 días y se limitó a una región determinada de CABA. Repitiendo el experimento considerando una ventana de tiempo mayor y un área más grande, se podría analizar varios aspectos como: los rangos horarios en donde los reportes suelen generarse con mayor frecuencia; las zonas de CABA en donde es habitual que ocurran incidentes de tránsito; e incluso las variaciones que sufre el curso normal del tránsito cuando ocurren eventos especiales como paros o movilizaciones multitudinarias.

Referencias

- [1] Frias-Martinez, V. & Frias-Martinez, E., "Spectral clustering for sensing urban land use using Twitter activity", *Engineering Applications of Artificial Intelligence*, Elsevier, 2014, 35, 237-245. doi: [10.1016/j.engappai.2014.06.019](https://doi.org/10.1016/j.engappai.2014.06.019)
- [2] Carvalho, S. F. L. d. & others, "Real-time sensing of traffic information in twitter messages", *Proceedings of the 4th Workshop on Artificial Transportation Systems and Simulation (ATSS) at IEEE International Conference on Intelligent Transportation Systems (ITSC) 2010*, 2010.
- [3] Schulz, A.; Ristoski, P. & Paulheim, H., "I see a car crash: Real-time detection of small scale incidents in microblogs", *Extended Semantic Web Conference*, 2013, 22-33. doi: [10.1007/978-3-642-41242-4_3](https://doi.org/10.1007/978-3-642-41242-4_3)
- [4] D'Andrea, E.; Ducange, P.; Lazzerini, B. & Marcelloni, F., "Real-time detection of traffic from twitter stream analysis", *IEEE Transactions on Intelligent Transportation Systems*, IEEE, 2015, 16, 2269-2283. doi: [10.1109/TITS.2015.2404431](https://doi.org/10.1109/TITS.2015.2404431)

- [5] Kuflik, T.; Minkov, E.; Nocera, S.; Grant-Muller, S.; Gal-Tzur, A. & Shoor, I., “Automating a framework to extract and analyse transport related social media content: The potential and the challenges”, *Transportation Research Part C: Emerging Technologies*, Elsevier, 2017, 77, 275-291. doi: [10.1016/j.trc.2017.02.003](https://doi.org/10.1016/j.trc.2017.02.003)
- [6] Endarnoto, S. K.; Pradipta, S.; Nugroho, A. S. & Purnama, J., “Traffic condition information extraction & visualization from social media twitter for android mobile application”, *Electrical Engineering and Informatics (ICEEI)*, 2011, 1-4. doi: [10.1109/ICEEI.2011.6021743](https://doi.org/10.1109/ICEEI.2011.6021743)
- [7] Kosala, R.; Adi, E. & others, “Harvesting real time traffic information from Twitter”, *Procedia Engineering*, Elsevier, 2012, 50, 1-11. doi: [10.1016/j.proeng.2012.10.001](https://doi.org/10.1016/j.proeng.2012.10.001)
- [8] Anantharam, P.; Barnaghi, P.; Thirunarayan, K. & Sheth, A., “Extracting city traffic events from social streams”, *ACM Transactions on Intelligent Systems and Technology (TIST)*, ACM, 2015, 6, 43. doi: [10.1145/2717317](https://doi.org/10.1145/2717317)
- [9] Albuquerque, F. C.; Casanova, M. A.; Lopes, H.; Redlich, L. R.; de Macedo, J. A. F.; Lemos, M.; de Carvalho, M. T. M. & Renso, C., “A methodology for traffic-related Twitter messages interpretation”, *Computers in Industry*, Elsevier, 2016, 78, 57-69. doi: [10.1016/j.compind.2015.10.005](https://doi.org/10.1016/j.compind.2015.10.005)
- [10] Wanichayapong, N.; Pruthipunyaskul, W.; Pattara-Atikom, W. & Chaovalit, P., “Social-based traffic information extraction and classification”, *Intelligent Transport Systems (ITS) Telecommunications (ITST)*, 2011 11th Int. Conf., 2011, 107-112. doi: [10.1109/ITST.2011.6060036](https://doi.org/10.1109/ITST.2011.6060036)
- [11] Gu, Y.; Qian, Z. S. & Chen, F., “From Twitter to detector: Real-time traffic incident detection using social media data”, *Transportation Research Part C: Emerging Technologies*, Elsevier, 2016, 67, 321-342. doi: [10.1016/j.trc.2016.02.011](https://doi.org/10.1016/j.trc.2016.02.011)
- [12] Fire, M., Kagan, D., Puzis, R., Rokach, L., & Elovici, Y. (2012, November). “Data mining opportunities in geosocial networks for improving road safety”. In *IEEE 27th Convention of Electrical & Electronics Engineers in Israel (IEEEI)*, 2012. doi: [10.1109/IEEEI.2012.6377049](https://doi.org/10.1109/IEEEI.2012.6377049)
- [13] dos Santos, S. R., Davis Jr, C. A., & Smarzarro, R. (2017). “Analyzing Traffic Accidents based on the Integration of Official and Crowdsourced Data”. *Journal of Information and Data Management*, 8(1), 67.
- [14] Caimmi, B.; Vallejos, S.; Berdun, L.; Soria, Á.; Amandi, A. & Campo, M., "Detección de incidentes de tránsito en Twitter", *Biennial Congress of Argentina (ARGENCON)*, 2016 IEEE, 2016, 1-6. doi: [10.1109/ARGENCON.2016.7585327](https://doi.org/10.1109/ARGENCON.2016.7585327)
- [15] Cortes, C. & Vapnik, V., “Support-vector networks”, *Machine learning*, Springer, 1995, 20, 273-297. doi: [10.1023/A:1022627411411](https://doi.org/10.1023/A:1022627411411)
- [16] Vapnik, V., “The nature of statistical learning theory”, *Springer Science & Business Media*, 2013. doi: [10.1007/978-1-4757-3264-1](https://doi.org/10.1007/978-1-4757-3264-1)
- [17] John, G. H. & Langley, P., “Estimating continuous distributions in Bayesian classifiers”, *Proceedings of the Eleventh conference on Uncertainty in artificial intelligence*, 1995, 338-345.
- [18] Schütze, H., “Introduction to Information Retrieval”, *Proceedings of the international communication of association for computing machinery conference*, 2008.
- [19] Z. Yang, J. Yu, M. Kitsuregawa, Fast Algorithms for Top-k Approximate String Matching, in: *Association for the Advancement of Artificial Intelligence (AAAI) Conference on Artificial Intelligence*, 2010.
- [20] “The Google Maps Geocoding API”, “<https://developers.google.com/maps/documentation/geocoding/intro>”, 2016, [Accedido: 7 de Abril 2017]
- [21] "Buenos Aires", Es.wikipedia.org, 2017, [Online], Disponible: “https://es.wikipedia.org/wiki/Buenos_Aires”, [Accedido: 7 de Abril de 2017].
- [22] "TomTom Traffic Index – Measuring Congestion Worldwide (Buenos Aires)", 2017, [Online], Disponible: “https://www.tomtom.com/en_gb/trafficindex/city/buenos-aires”, [Accedido: 7 de Abril 2017].
- [23] "Twitter Firehose vs. Twitter API: What's the difference and why should you care? - BrightPlanet", BrightPlanet, 2017, [Online], Disponible: “<https://brightplanet.com/2013/06/twitter-firehose-vs-twitter-api-whats-the-difference-and-why-should-you-care/>”, [Accedido: 10 de Abril de 2017].

- [24] Bifet, A., Holmes, G., Pfahringer, B., & Gavalda, R., “Detecting Sentiment Change in Twitter Streaming Data”. In the *2nd Workshop on Applications of Pattern Analysis (WAPA)*, (pp. 5-11), October 2011.
- [25] Riquelme, F., & González-Cantergiani, P. “Measuring user influence on Twitter: A survey”. *Information processing & management*, 2016, 52(5), 949-975. doi: [10.1016/j.ipm.2016.04.003](https://doi.org/10.1016/j.ipm.2016.04.003)