



GRADO EN ESTADÍSTICA

TRABAJO FIN DE GRADO

*Estimación de la demanda de
sistemas de movilidad urbana*

Manuel José Buendía Castiñeira

Sevilla, junio de 2020

Índice general

Agradecimientos	III
Resumen	V
Abstract	VI
Índice de Figuras	VII
Índice de Cuadros	IX
1. INTRODUCCIÓN	1
2. SITUACIÓN ACTUAL DE LA MOVILIDAD URBANA	3
2.1. Situación actual	3
2.2. Tendencias	6
3. LA REUBICACIÓN DE VEHÍCULOS	9
4. FUENTES PARA MATRICES ORIGEN DESTINO	11
4.1. Fuentes Tradicionales	11
4.1.1. El impulso de la Movilidad Sostenible	12
4.1.2. Desde Forecasting a Nowcasting	16
4.2. Nuevas fuentes	17
4.2.1. Telefonía Móvil	18
4.2.2. Tarjetas Inteligentes de Transporte	19
4.2.3. Tarjetas de crédito	20
4.2.4. Redes Sociales	20
4.2.5. Sistemas Operativos	22
4.2.6. Otras fuentes privadas	23
4.2.7. Conclusión sobre las nuevas fuentes	23
5. CLIENTES OBJETIVOS	25
5.1. Vehículos eléctricos compartidos	25
5.2. Peculiaridades del usuario de motocicleta	26
5.3. Estudios sobre scooter-sharing	27
5.3.1. Clusterización de clientes de escúteres compartidos	27
5.3.2. Factores de influencia en el uso de escúteres compartidos. Encuesta en España	30
5.3.2.1. En cuanto a las características socioeconómicas:	30
5.3.2.2. En cuanto a otras características:	32
5.3.2.3. Conclusión encuesta	33
6. APLICACIÓN PRÁCTICA SOBRE SEVILLA	35

6.1. Información disponible	35
6.2. Zonas óptimas para la disponibilidad de los escúteres en Sevilla.	36
7. CONCLUSIONES	41
Bibliografía	43

Agradecimientos

En primer lugar, no puedo menos que agradecer a mi profesor y tutor José Luis Pino sus directrices para llevar a término este trabajo.

En segundo lugar, quisiera aprovechar para tener un recuerdo para mi profesor de instituto, Miguel Caras, que me enseñó a disfrutar de las Matemáticas y a entender lo que era un buen profesor. Esto me lleva a recordar a todos aquellos profesores que aman su trabajo y durante esta época de pandemia han dedicado más esfuerzo del esperado a que sus alumnos siguieran aprendiendo. Y permitaseme extender este agradecimiento a esos buenos profesores que he encontrado en este Grado de Estadística, aquellos que no sólo saben mucho de Estadística sino que además saben transmitir su pasión y enseñarla.

Por último, sin duda lo más importante, el agradecimiento inacabable a mi familia, a May, mi compañera de vida y proyectos y a mis hijos Martina y Mauricio, no ya por este Trabajo sino por cada uno de los exámenes que tuve que hacer para llegar hasta aquí, esperando me disculpen los tiempos descuidados, el amor que no di, los cariños distraídos, mi estrés continuo, mis malas caras, mis quejas inoportunas, vuestras demandas que no vi... Para ellas y para él, mi más grande abrazo, mis más sinceras ‘gracias’ y mi más honesto ‘perdonadme’. En mi descargo, el esfuerzo de todos mereció la pena.

Resumen

El presente trabajo analiza la situación actual de fuentes de datos geográficas y estadísticas con las que podamos optimizar la distribución de escúteres eléctricos compartidos, centrándonos concretamente, como ejemplo urbano, en la ciudad de Sevilla. Para ello se comprueban los datos existentes oficiales y no oficiales que nos aporten información sobre movilidad de las personas en la ciudad de Sevilla, intentando encontrar matrices de Origen-Destino lo más actualizadas posibles, incluso analizando la posibilidad actual de obtener matrices O-D en tiempo real, dada la evolución de los sistemas de geolocalización y la recopilación de estos datos por parte de determinadas app.

También hemos buscado la información disponible de estudios y encuestas de demanda de este tipo de vehículos, tratando de definir las variables o parámetros que nos definan los perfiles de las personas más atraídas por utilizar estos medios de locomoción.

Finalmente, analizamos la información socioeconómica existente sobre personas en determinadas zonas geográficas, como las secciones censales, para poder cruzar los datos de estas secciones censales con los perfiles definidos y las matrices de Origen-Destino. Con todo ello, podemos elaborar un mapa de secciones censales en las que establecer la mayor y menor demanda.

Abstract

The following dissertation analyses the current status of geographic and statistical data sources that can be used to optimize the distribution in shared electrical scooters, focusing specifically, as an urban example, in the city of Sevilla.

For the purpose of the study, both existing official and unofficial geographical and statistical datasets that provide information on the movement of people across the city of Seville were checked. The objective was to try to find Origin-Destiny matrices that were as updated as possible, even analyzing the possibility of obtaining real-time O-D matrices, which would only be possible due to the recent evolution of geolocalisation systems and the gathering of this data by certain applications.

Information from other studies and demand surveys on this type of vehicle was also used, trying to define variables and parameters that define the profile of people that would be more attracted to use these means of transportation.

Finally, the existing socioeconomic information on people from specific geographic locations, like census tracts, was analyzed to try to cross data with census sections containing the defined profiles and Origin-Destiny matrices. With all data, a map of census sections with higher and lower demand could be created.

Índice de figuras

2.1. Gráfico escúteres por países	5
2.2. gráfico escúteres por ciudades	5
4.1. mapa Zonificación	13
4.2. gráfico Composición parque vehículos	14
4.3. gráfico evolución parque vehículos	14
4.4. Viajes generados y atraídos según macrozona	15
4.5. Matriz viajes generados-atraídos según macrozonas	16
4.6. Gráfico Esteban Moro	18
4.7. Gráfico Reparto Sistemas Operativos	22
5.1. Tabla resultados clusterización	28
5.2. Tridimensionales de clusters	29
5.3. Resultados encuesta en ciudades de España	31
6.1. mapa muving	40

Índice de cuadros

6.1. Prob. de usar escúter eléctrico según encuesta	36
---	----

Capítulo 1

INTRODUCCIÓN

En el último decenio se ha producido un cambio paradigmático en la movilidad urbana, donde el vehículo privado parece estar dando paso, de forma paulatina, a formas más ecológicas o menos contaminantes de desplazamiento, tanto con la transformación a energías limpias del transporte público convencional como con el surgimiento de nuevos modelos de transporte compartido que, básicamente, usan energía eléctrica (coches, motos, bicicletas, patinetes. . .) y que han visto incrementada su facilidad de desarrollo gracias al uso personal de smartphone con GPS por la práctica totalidad de la ciudadanía, lo que permite ubicar al usuario y facilitarle el medio de transporte adecuado.

Las empresas públicas o privadas que implementan las distintas fórmulas de movilidad urbana, necesitan realizar sus estudios analizando las posibles y más frecuentes ubicaciones de los ciudadanos que necesitan desplazarse, así como los posibles desplazamientos a realizar, utilizando aquello que se ha dado en llamar matrices de Origen-Destino. Sabemos que estos estudios implican complicados análisis de programación lineal, imposibles en muchos casos por los tamaños de las matrices a considerar, por lo que las soluciones se obtienen de forma heurística. Pero antes de embarcarse en estos dificultosos procesos, resulta indispensable disponer de unas matrices de Origen-Destino fiables, lo cual no es banal, pues unos datos exhaustivos y precisos de los desplazamientos urbanos en periodos horarios no es algo que pueda obtenerse directamente de organismos públicos y hacer un análisis de esta envergadura puede ser excesivamente costoso. No obstante, los avances en Sistemas de Información Geográfica (GIS) implementados por organismos públicos han incrementado notablemente la calidad y cantidad de información georreferenciada disponible en las web de las unidades estadísticas nacionales, autonómicas o locales.

El uso extendido prácticamente por la generalidad de la población de teléfonos móviles (con posibilidad de geolocalización por su operadora de Telecomunicaciones) o el de teléfonos inteligentes con GPS, que pueden comunicar su ubicación exacta a través de apps o redes sociales, nos abren también nuevas vías para poder estudiar la ubicación de los ciudadanos en distintas franjas horarias.

Con todo ello, en este trabajo intentamos recopilar y analizar todas las posibilidades actuales existentes hasta la fecha, para poder obtener estas matrices fiables de Origen-Destino. Dado que las posibilidades de información varían considerablemente entre países, autonomías y localidades, y dado que la información que nos interesa puede variar igualmente según el negocio a implementar, pues el target a estudiar para cada negocio es diferente, hemos decidido centrarnos en la implantación de un negocio de alquiler de

escúteres eléctricos con ubicación libre en la ciudad de Sevilla, con intención de optimizar las ubicaciones iniciales de estos escúteres.

Dado el vertiginoso avance de la tecnología, sobre todo en los últimos años en cuanto a posicionamiento, geolocalización, y ubicación de ciudadanos, así como la progresiva actualización y mejora de la información disponible en entidades públicas y privadas, y aunque nuestra intención es estar lo más actualizados posible, prevemos una vigencia muy corta de nuestras investigaciones después de la redacción de este TFG.

Capítulo 2

SITUACIÓN ACTUAL DE LA MOVILIDAD URBANA

2.1. Situación actual

Bien adentrados en el siglo XXI, la movilidad urbana sigue mayoritariamente apoyada en el automóvil particular. Si bien es cierto que la contaminación, el cambio climático, los atascos y la falta de aparcamiento han podido mermar el deseo de uso del vehículo propio como método de transporte urbano, la realidad es que la extensión de las ciudades (y el aumento de las distancias a recorrer) y la falta en muchos casos de alternativas reales, inclinan al usuario, que busca optimizar coste económico y tiempo de desplazamiento, hacia la comodidad de su vehículo propio (Banister 2008). Así, no parece en la actualidad un objetivo realista de la política urbana la eliminación de los atascos, pues si bien por una parte los usuarios presionan para minimizar los tiempos de desplazamiento, razones ambientales y de seguridad llevan a los gestores a buscar un nivel razonable de congestión (Lyons & Urry 2005), es decir, no es tanto minimizar el tiempo de viaje como conseguir un grado razonable de certeza, dicho de otra forma, que el tiempo estimado en llegar a destino sea fiable (Noland & Polak 2002).

No obstante, el enfoque actual para una movilidad sostenible requiere un cambio de paradigma, que como nos señala Banister (2008), se fundamenta en:

- 1) Realizar acciones para reducir la necesidad de viajar, lo que facilitan hoy en gran medida las TIC (facilitando el trabajo en casa, compras online, reduciendo envíos de documentación y ficheros...), si bien también es cierto que mientras algunas actividades se sustituyen, se generan otras nuevas, aunque parecen reducirse los viajes de larga distancia (Lyons & Kenyon 2003).
- 2) Medidas políticas en uso del suelo: reducción de la distancia. Esto engloba todo lo que se refiere a políticas urbanísticas, a través de ubicación de viviendas, reurbanización, diseño de espacios y rutas, desarrollo orientado al transporte público y por tanto de replantear las ciudades en un desarrollo sin automóviles. Sin embargo, este proceso es gradual y muy lento, siendo su implementación similar a la rotación del parque inmobiliario, estimado en un 2% anual (Banister & Hickman 2007).
- 3) Aumento de la eficiencia gracias a la innovación tecnológica: Diseño de motores más eficientes, combustibles alternativos y uso de fuentes de energías renovables.

Reducción de ruidos, restricciones de acceso a determinadas zonas urbanas a vehículos más contaminantes.

- 4) Medidas políticas, cambio modal: Esto implica medidas de promoción de transporte público, caminar y la movilidad en bicicleta, así como otros sistemas limpios (vehículos eléctricos), restringiendo el acceso, dificultando el estacionamiento, creando espacios más para las personas (Banister & Marshall 2000).

Las dos últimas acciones, junto con el avance tecnológico que lo permite, explican el auge en los últimos años de sistemas públicos y privados de compartición de vehículos eléctricos, desde coches (car-sharing), hasta bicicletas o patinetes, y por supuesto el que nos preocupa en este trabajo, que son los escúteres eléctricos compartidos (o moto-sharing). Métodos de desplazamiento que están intentando abrirse paso en una nueva era de movilidad, con una amplia oferta y abanico de opciones, y que están luchando contra el simbolismo del automóvil privado, durante muchos decenios el auténtico emblema de status quo, poder y seducción (Cass *et al.* 2005) y sobre el que se ha discutido mucho y existe amplia literatura, y aunque no es el propósito de este estudio, no dejaremos de señalar la unanimidad existente entre gobiernos y expertos sobre la necesidad de este cambio de paradigma, si bien no tanto sobre los plazos para implementar medidas (Banister 2003), debido por una parte a las dificultades de cambiar la aceptabilidad por parte de la población y por otra a las implicaciones económicas que puede suponer para la industria la reducción en ventas del vehículo propio convencional.

En cualquier caso, dentro de este cambio de modelo de movilidad, la implantación de los escúteres eléctricos en particular es un hecho en muchas ciudades del mundo, creciendo gradualmente de forma exponencial. Basándonos en el estudio “Global Scooter Sharing Market Report 2019” (Howe & Jakobsen 2019), podemos comprobar en la siguiente tabla la evolución del número de scooters disponibles, así como otros valores:

	2017	2018	2019
Número de escúteres	8.000	25.000	66.000
Ciudades con operadores	29	62	88
Operadores	26	38	54
Usuarios Registrados	350.000	1.800.000	4.800.000
Fabricantes de scooters		26	34

Así, podemos observar que el número de scooters entre las distintas operadoras ha llegado en 2019 a 66.000 scooters en las 88 ciudades en las que se ha implementado.

Curiosamente, observamos en este estudio que en 2019 la ratio de escúteres eléctricos compartidos ha pasado en el mercado global de escúteres compartidos de 96 % a 70 %. Esto es debido a la entrada del mercado indio, que ha comenzado implementando operadoras de compartición de escúteres con motores de combustión. En el resto del mundo, la ratio de escúteres eléctricos supone en 2019 el 99 % respecto al total.

Centrándonos en España, observamos que nuestro país ocupa el 2º lugar en número de escúteres disponibles en las ciudades, con 13.520 vehículos, seguido en Europa por Francia, a distancia con 8.200 escúteres (fig.2.1).

En cuanto a ciudades, las que disponen en la calle de más escúteres compartidos son Madrid (con 6.350) y París (con 6.300), seguido por Barcelona (4.600), existiendo 9




Figura 2.1: Gráfico escúteres por países




Figura 2.2: gráfico escúteres por ciudades

ciudades en España que disponen de empresas para compartir escúteres eléctricos (fig.2.2).

Podemos concluir que el mercado de los escúteres eléctricos compartidos es un sistema de movilidad que, aun con poco tiempo de rodaje, está ya bastante asentado en España. Si nos centramos en el caso de la ciudad de Sevilla, la información obtenida según noticias de la prensa local, nos indica que en la actualidad existen 2 empresas, teniendo constancia de la existencia al menos de 280 motos con la empresa Muving (https://sevilla.abc.es/sevilla/sevi-nueva-ofensiva-motos-electricas-sevilla-280-y-medio-201812030714_noticia.html), y otras 240 con la empresa Acciona (<https://www.acciona.com/es/salaprensa/noticias/2019/mayo/acciona-despliega-servicio-motos-el%C3%A9ctricas-compartidas-sevilla/>), aunque ABC habla ya, en noviembre de 2019 del millar de motos entre ambas https://sevilla.abc.es/sevilla/sevi-nuevas-formas-caminar-sevilla-diferencias-entre-patinetes-y-motos-electricas-201911100710_noticia.html

Si bien el modelo de ambas empresas es de ubicación libre, lógicamente la disponibilidad de recogida y aparcamiento de motos está limitada a una zona delimitada de la ciudad, que podemos comprobar en estos dos mapas, obtenidas de las web de cada una de las empresas. Se observa en ellos que si bien, a grandes rasgos, optan por las mismas zonas de la ciudad, probablemente por los estudios de mercado realizados, existen algunas pequeñas diferencias en sus delimitaciones.



2.2. Tendencias

Aparentemente, la tendencia es por un lado la absorción, fusión o asociación de empresas (en España Muving se ha fusionado con Ioscoot <https://www.expansion.com/empresas/>)

motor/2019/11/22/5dd832ff468aeb33618b4689.html), con la idea de conseguir potencial y volumen en un negocio en el que están entrando grandes empresas con mucho más soporte económico, de marketing y recursos, que en la competencia por conseguir clientes les puede suponer una gran ventaja.

Por otro lado, existe también la tendencia de crear flotas multimodales, dando a los clientes la posibilidad de usar otros medios como patinetes o bicicletas, o bien llegando a acuerdos de movilidad compartida con otros métodos de transporte, como autobuses urbanos e interurbanos, de forma que el cliente disponga cada vez más de facilidades para el desplazamiento sin necesitar el vehículo propio.

En el desarrollo del negocio del scooter eléctrico compartido, tras un remonte del mercado y asentamiento en Europa, hay indicadores claros de que países en desarrollo como India o Brasil, exploten con su oferta de vehículos compartidos en los dos próximos años, además del mercado estadounidense, asiático y australiano (Howe & Jakobsen 2019).

Capítulo 3

LA REUBICACIÓN DE VEHÍCULOS

Los primeros sistemas de compartición de vehículos han tenido tradicionalmente una configuración simétrica, es decir, los vehículos han de ser devueltos en el lugar de recogida, lo que implica que el usuario tenga que realizar el viaje de ida y vuelta. Los sistemas asimétricos permiten que el usuario pueda devolver el vehículo en cualquier otra estación o incluso libremente en cualquier zona dentro de la cobertura, en cuyo caso lo denominamos de ubicación libre o flotante.

Los operadores de compartición de coches (Car Sharing) han tenido que mejorar su eficiencia para competir con el transporte público y el propio transporte privado, y las redes asimétricas que permiten viajes unidireccionales pueden ser la forma más ventajosa y prometedora de sistema de usos compartidos de vehículos, tanto para clientes como para las propias empresas (Martin & Shaheen (2016), Shaheen *et al.* (2018)). Sin embargo, surge un problema con los sistemas asimétricos y es el desequilibrio de vehículos que puede producirse en determinadas estaciones o zonas debido a la concentración puntual de la demanda a determinadas horas o el desplazamiento a los mismos lugares. Esto provoca que en el caso de estaciones con un número de vehículos, el cliente pueda encontrarse que no tiene ninguno disponible, o bien que al pretender llegar con un vehículo a una estación se encuentre con que esta está completa y tiene que buscar otra estación, lo que provoca falta de servicio y gran insatisfacción en el cliente. En el caso de que el sistema sea de ubicación libre, el primer problema sigue existiendo (no encontrar vehículos por exceso de demanda) aunque el segundo no será un problema para el cliente, que siempre podrá soltar el vehículo en algún lugar autorizado cerca de su destino, por muchos que haya por aquella zona, pero se convierte en un problema para el operador, que debería proceder a redistribuir o devolver los vehículos acumulados a otras zonas. En los Car Sharing el problema es mayor que en vehículos más pequeños (bicicletas, patinetes, escúteres...), pues con estos pueden hacerse reubicaciones masivas con camiones de un sitio a otro, pero estos desequilibrios son los mayores problema a los que se enfrenta un operador de compartición de vehículos, donde el cliente requiere cada vez más flexibilidad y el Operador tiene que reaccionar con prontitud ante las demandas de los clientes y reubicar los vehículos entre los lugares donde existe exceso y los que exista escasez (Jorge & Homem de Almeida Correia 2013).

Ante las dificultades de encontrar solución para modelar este problema, denominado en

inglés “Vehicle Relocation Problem” (VReP), los investigadores han generado múltiples estudios en los que analizar los modelos apropiados para encontrar la forma óptima de reubicar vehículos, según las distintas configuraciones, dependiendo de la actividad diaria del operador, las distancias a recorrer, la cantidad de vehículos y otros.

Illgen & Höck (2018) realizan una revisión de todos los estudios existentes, casi todos para compartir vehículos en redes asimétricas con ubicaciones fijas, si bien se considera extrapolable a ubicaciones flotantes, simulando las diferentes zonas como si fueran estaciones fijas.

Muchas de las soluciones para resolver el VReP se basan en modelos de programación lineal mixta entera. Las dificultades en cuanto a dimensión y cálculos de estos problemas conllevan la necesidad de limitar en muchos casos el número de nodos con los que trabajar o imponer condiciones que generalmente la realidad no cumple, por razones computacionales (Nair & Miller-Hooks 2014). Otras opciones se basan en métodos como la formulación de modelos heurísticos o simulaciones para encontrar soluciones dentro de tiempos de computación que resulten prácticos (por ejemplo, Cepolina & Farina (2012)).

Los vehículos eléctricos tienen algunas características diferentes que han sido también tenidas en cuenta por algunos estudios, pues los rangos de funcionamiento y los tiempos de recarga pueden suponer una variable distinta a considerar, sin embargo los modelos resultantes han demostrado que existen pequeñas variaciones con los tradicionales (Li *et al.* 2016).

Con todo ello, concluimos que si bien existen importantes dificultades de cálculo para resolver el problema de programación lineal que nos encuentre la mejor forma de disponer los vehículos compartidos, hemos comprobado la existencia de multitud de estudios y fórmulas para resolver de la mejor manera posible esta dificultad. Sin embargo, para cualquiera de estos métodos es premisa básica disponer de unas fuentes de datos válidas, que nos generen unas matrices de origen-destino realistas.

Capítulo 4

FUENTES PARA MATRICES ORIGEN DESTINO

4.1. Fuentes Tradicionales

Desde que los municipios adquieren tamaños como para que el Ayuntamiento tenga una preocupación y responsabilidad por la óptima movilidad de sus habitantes y necesite aplicar la más elemental política de transporte, requerirá conocer cuáles son los patrones de movilidad de la población, y por tanto las matrices de Origen-Destino que la describen.

Para ello, tradicionalmente los municipios u organismos públicos han recurrido a estudios, generalmente costosos, basados principalmente en encuestas, con las que han estimado las necesidades de movilidad de los ciudadanos, sea por motivos laborales, de ocio o de otra índole, pensando principalmente en la reorganización óptima del tráfico y en los recorridos del transporte urbano. Estos primeros estudios comienzan en España en la década de los 80 y 90 (Módenes 2008), siendo ya en este siglo XXI cuando las mejoras en las metodologías nos llevan a disponer de estudios válidos. Uno de los primeros estudios fiables fue en el Censo del 2001 del Instituto Nacional de Estadística, donde se incluyeron cuatro preguntas sobre movilidad en el cuestionario individual. Teniendo en cuenta que el censo es sobre toda la población, los resultados dan una perspectiva muy importante sobre el transporte individual en los distintos municipios de España y da pie a importantes estudios posteriores.

También en 2000-2001 se realiza la Encuesta de Movilidad de las Personas Residentes en España (MOVILIA), encuesta que se repitió en una segunda oleada en 2006-2007. Estas encuestas sirvieron para centrar las encuestas futuras, delimitando su dimensión espacial (MOVILIA se realizó sobre toda la población española y sobre todo tipo de desplazamientos, incluidos los de larga distancia), así como para definir conceptos y aclarar elementos metodológicos. Otra encuesta con características temáticas muy similares a MOVILIA, pero a nivel internacional, fue ‘La Enquête Nationale Transports et Déplacements’, entre 2007-2008, realizada por L’Institut Nationale de la Statistique et des Études Économiques (INSEE), aunque incide en mayor medida en el uso de los transportes (Encuesta Sobre Movilidad Cotidiana en las Regiones Urbanas de Andalucía, 2011).

No podemos olvidar que también se han realizado diversas encuestas por diferentes organismos centradas en áreas metropolitanas. En Andalucía, por ejemplo, se realizó

la Encuesta Domiciliaria de la Bahía de Cádiz en 2005 y la Encuesta Domiciliaria de Movilidad en el Área Metropolitana de Sevilla de 2007. El coste de los estudios, básicamente con encuestas en grandes muestras de población, implica que sean generalmente estudios realizados ocasionalmente, lo que probablemente da buenas pautas a los Ayuntamientos para tomar medidas sobre la movilidad local, pero que no parecen demasiado útiles para el objetivo de este trabajo que sería obtener la estimación de una matriz diaria de Origen-Destino para hacer una óptima distribución de los escúteres de una empresa de compartición de vehículos.

Ya en el segundo decenio se realiza por el Instituto de Estadística y Cartografía de Andalucía la “Encuesta Social 2011, Movilidad en las regiones urbanas de Andalucía”. Esta encuesta, perfectamente documentada y publicada (García Paredes 2013), dispone de su ficha técnica en la que se especifica la población analizada, el marco muestral, la utilización de un muestreo estratificado trietápico, la afijación y, en suma, toda la información que te garantiza la fiabilidad de la encuesta. El resultado es una base de datos con 5.700 registros de personas y 17.000 registros sobre desplazamientos, que el IECA pone a disposición pública. Sin embargo, aunque la información puede resultarnos muy valiosa en nuestro estudio, para saber los motivos de desplazamiento, las distancias medias recorridas, según varias variables sociales o económicas, nos encontramos que la información obtenida y pública no indica en ningún caso las zonas, secciones censales o distritos desde los que parten hacia los que se mueven, es decir, no tenemos datos para obtener la matriz que buscamos de Origen-Destino en la ciudad de Sevilla.

4.1.1. El impulso de la Movilidad Sostenible

En el siglo XXI debido a la concienciación ecológica por el cambio climático y al auge de lo que en la segunda “Cumbre de la Tierra” (Rio de Janeiro, 1992) se definió como ‘desarrollo sostenible’, y que se basaba en tres pilares: Progreso económico, Justicia Social y preservación del medio ambiente, han proliferado políticas de sostenibilidad, promovidas en nuestro caso desde la propia Unión Europea. Para ello publicó en 2007 el libro verde, llamando a una nueva cultura de movilidad urbana, luego en 2009 publicó el Plan de Acción de Movilidad Urbana y en 2011 el libro blanco del transporte. Todos ellos sin imponer soluciones, pero proponiendo a las administraciones locales fórmulas para facilitar el cambio a una movilidad sostenible, en la que se reduzca la contaminación ambiental, la acústica, el consumo de energía, la congestión y la accesibilidad al transporte de todos los ciudadanos.

Siguiendo la misma dinámica, en España, el Instituto para la Diversificación y Ahorro de la Energía (IDAE) publica la “Guía Práctica para la Elaboración e Implantación de Planes de Movilidad Urbana Sostenible”, aconsejando a los municipios de más de 50.000 habitantes que siguieran sus recomendaciones. Posteriormente el gobierno aprobó la ley 2/2011 de Economía Sostenible, donde se fomenta la realización de Planes de Movilidad Sostenible por parte de las administraciones autonómicas y entidades locales.

Debido a todas estas recomendaciones, peticiones y requerimientos a la realización de los Planes de Movilidad Urbano Sostenible (PMUS), se ha conseguido que muchos ayuntamientos tengan aprobado en este último decenio o estén en ello, un PMUS. Para realizar un PMUS es indispensable tener un conocimiento importante de la movilidad de sus ciudadanos, lo que puede servir para tener datos actualizados.

En la ciudad de Sevilla, donde queremos centrar nuestro estudio, comprobamos que en enero de 2020 se ha presentado un diagnóstico del PMUS, que incluye un estudio de movilidad. Desgraciadamente el informe publicado no tiene ficha técnica, tan solo se indica que se ha realizado haciendo 47.000 encuestas telefónicas y “con datos recopilados de distintos servicios y administraciones”, por lo que desconocemos el método de obtención de los datos y por tanto la fiabilidad de estos. Tampoco tiene fecha del estudio, aunque gran parte de los datos son de 2016 y nos referencia la información sobre población a la existente a 1 de enero de 2017. Por tanto, deducimos que los datos son de movilidad en 2016.

Con independencia de que no tengamos ficha técnica, ni fecha, el estudio de movilidad nos parece una buena referencia, pues está conformado por el propio Ayuntamiento sevillano. La zonificación se ha realizado con criterios coherentes, para poder compatibilizarlo con informaciones socio-económicas ya existentes, de forma que se ha utilizado como unidad mínima las secciones censales de 2016, creando 140 zonas que constituirán la base espacial para el análisis de movilidad (fig.4.1).



Elaboración: Diagnóstico del PMUS. Ayuntamiento Sevilla

Figura 4.1: mapa Zonificación

Este tipo de estudios nos facilitan mucha información que será muy útil para nuestros estudios posteriores, como que exista una tasa de motorización de 679 vehículos por cada 1000 habitantes o la composición del parque de vehículos(fig.4.2)

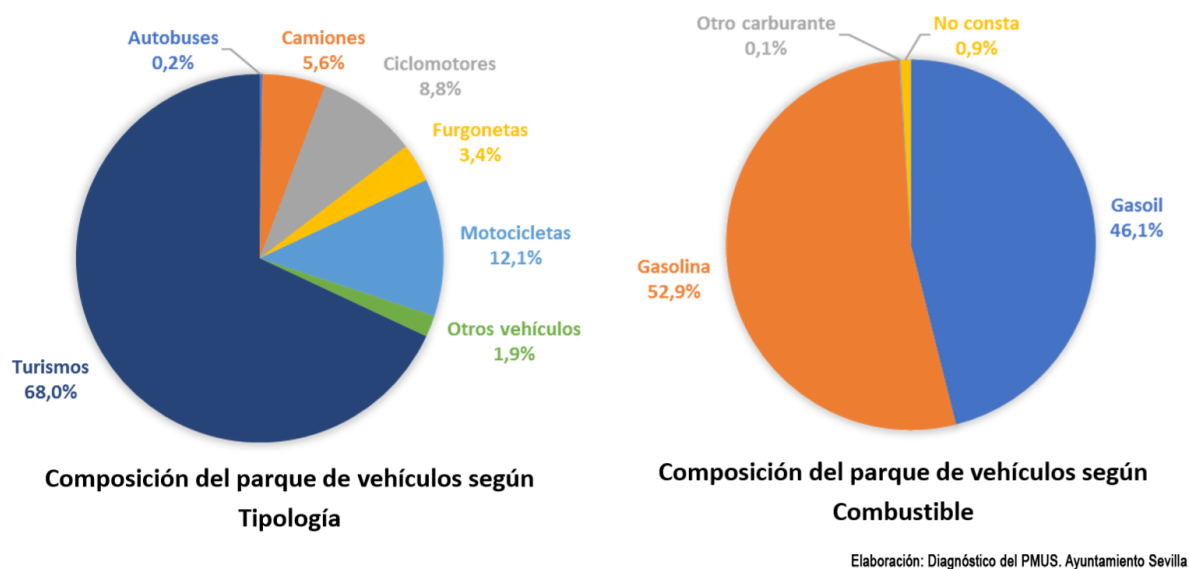


Figura 4.2: gráfico Composición parque vehículos

También nos da información sobre la evolución del parque de vehículos (fig.4.3):

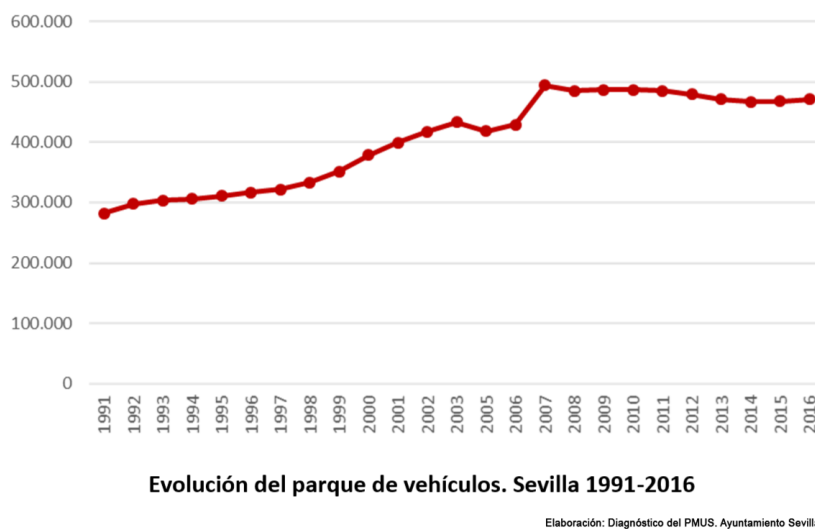


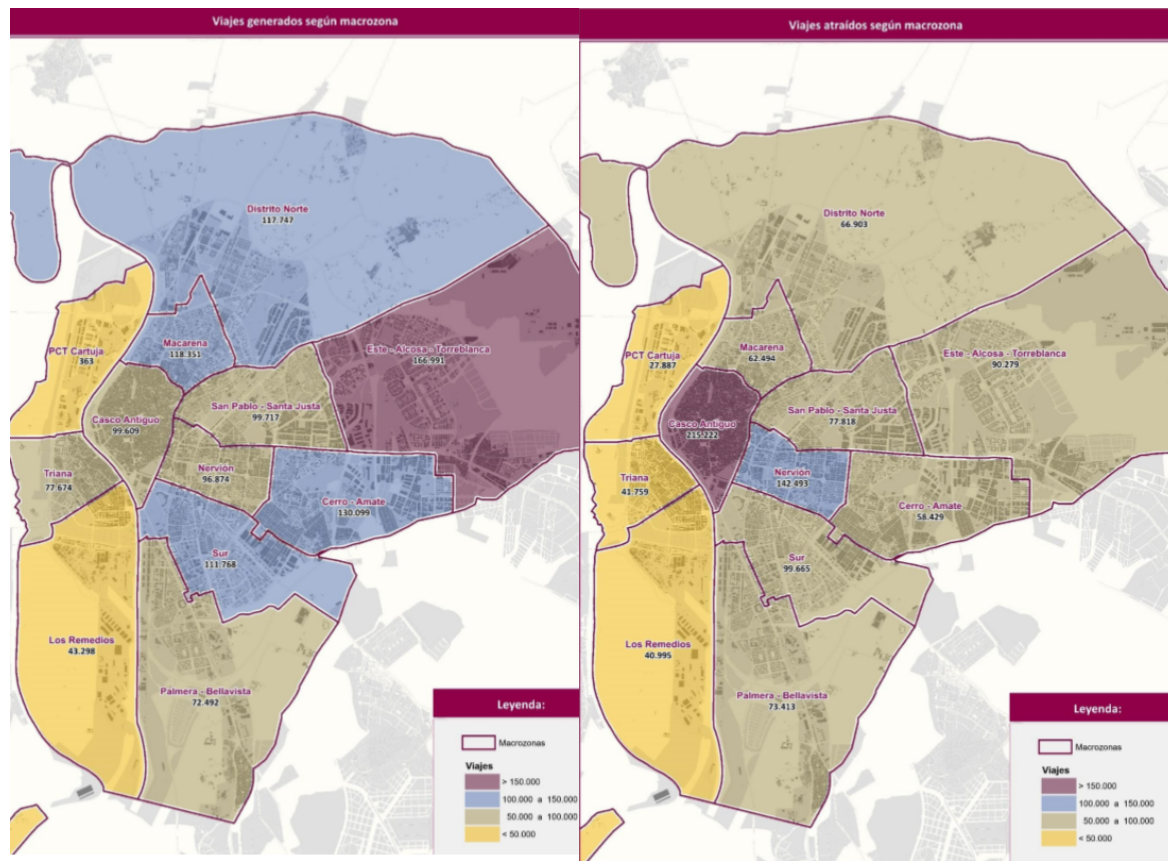
Figura 4.3: gráfico evolución parque vehículos

Así como otra mucha información global socio-económica, de producto interior bruto, empleo, industria, etcétera.

Lo más importante es que nos facilita la información de las zonas de atracción (polígonos empresariales, centros de enseñanza, zonas sanitarias, deportivas, comerciales...), pero, aunque nos relaciona en una tabla los existentes y nos pinta en mapas su localización, no nos da la información georreferenciada, lo que nos dificulta su utilización para nuestro objetivo.

A continuación se nos da información que nos puede ser de mucho interés, de forma global, con el número de viajes según motivo prioritario, la movilidad global por periodo horario y número de etapas del viaje, movilidad según horario y medio de transporte, según horario y motivo del viaje, distribución de la población según el número de viajes diarios, distribución según número de viajes diarios y grupos de edad, distribución de la población según número de viajes y sexo, distribución de viajes diarios, según grupos de edad y sexo, distribución del número de viajes según ocupación y grupo de edad, ocupados según sexo y número de viajes, y distribución según número de viajes, sexo y número de turismos. Sin embargo, toda esta información, como hemos indicado, es global, lo que puede servirnos, pero no es la información que buscamos y que nos sirva para realizar nuestras matrices de Origen-Destino.

En el apartado 2.5 del informe sí que empieza a desgranarnos la información detallada por zonas, aunque nos agrupa las secciones censales de las que hablaba en un principio, en 12 macrozonas. En primer lugar nos habla de zonas ‘generadoras’ de viajes y zonas ‘atractoras’, mostrándonos la población que se mueve desde unas zonas o que llega las otras(fig.4.4).



Elaboración: Diagnóstico del PMUS. Ayuntamiento Sevilla

Figura 4.4: Viajes generados y atraídos según macrozona

Y finalmente nos facilita la información que buscamos, que es una matriz de origen-destino, que aunque tiene el inconveniente de ser una foto fija estimada en 2016, y que se refiere a 13 macrozonas, no deja de ser una importante referencia como punto de partida para llegar a nuestro objetivo:(fig. 4.5)

		MACROZONA DE ATRACCIÓN													Total general
		1	2	3	4	5	6	7	8	9	10	11	12	99	
MACROZONA DE GENERACIÓN		Casco Antiguo	Macarena	Nervión	Cerro - Amate	Sur	Triana	Norte	San Pablo - Santa Justa	Este - Alcosa - Torreblanca	Palmera - Bellavista	Los Remedios	PCT Cartuja	Exterior	
1	Casco Antiguo	37.240	4.848	9.677	2.639	5.925	3.368	3.212	4.141	2.681	4.059	3.946	4.144	13.729	99.609
2	Macarena	30.967	21.661	7.847	2.425	6.185	3.215	9.732	10.638	4.270	3.688	3.486	2.904	11.334	118.351
3	Nervión	19.220	3.273	26.032	2.682	9.991	2.114	2.432	4.645	2.670	6.269	3.563	2.521	11.461	96.874
4	Cerro - Amate	15.316	3.239	25.541	29.678	7.903	2.812	5.008	6.824	7.497	4.823	4.390	2.410	14.659	130.099
5	Sur	18.839	2.230	14.408	5.467	31.756	3.061	1.211	6.096	2.707	9.202	3.587	2.342	10.863	111.768
6	Triana	14.798	1.721	8.932	1.254	5.214	16.351	1.387	1.151	2.088	3.770	7.556	1.956	11.495	77.674
7	Norte	20.514	11.804	4.924	4.417	6.201	1.736	32.418	10.119	5.034	2.963	1.468	2.658	13.491	117.747
8	San Pablo - Santa Justa	17.863	6.383	16.716	1.765	7.894	1.703	4.673	18.644	4.818	3.863	785	2.635	11.976	99.717
9	Este - Alcosa - Torreblanca	19.031	4.282	20.052	6.273	9.252	1.384	3.759	12.387	54.567	5.420	3.000	4.109	23.474	166.991
10	Palmera - Bellavista	11.098	2.263	3.911	1.237	7.938	1.796	2.185	2.556	1.361	23.367	2.466	668	11.647	72.492
11	Los Remedios	10.196	469	4.198	436	1.265	4.220	524	617	1.693	5.524	6.565	1.540	6.053	43.298
12	PCT Cartuja	0	189	174	0	0	0	0	0	0	0	0	0	0	363
99	Exterior	140	129	81	156	143	0	362	0	891	466	185	0	2.427	4.979
Total General		215.222	62.494	142.493	58.429	99.665	41.759	66.903	77.818	90.279	73.413	40.995	27.887	142.608	1.139.964

Elaboración: Diagnóstico del PMUS. Ayuntamiento Sevilla

Figura 4.5: Matriz viajes generados-atraídos según macrozonas

También vienen detallado, en sucesivas tablas, las matrices O-D por motivos de desplazamiento (Trabajo y Estudio) y las matrices O-D según medio de transporte utilizado (a pie, transporte público y vehículo privado).

Como conclusión, se confirma la valoración de Miralles-Guasch & Melo (2013), en el sentido de que las fuentes tradicionales son poco dinámicas, costosas y difíciles de mantener. También su escasa frecuencia implica diferencias en el tiempo y el espacio que conllevan bases de datos escuetas o incompletas.

4.1.2. Desde Forecasting a Nowcasting

Si bien la Matriz de O-D obtenida está realizada con encuestas de 2016, lo cual nos lleva a tener unos datos de hace 3 años, a que no tenemos una ficha técnica ni la transparencia sobre el estudio que nos garantice su fiabilidad y a que finalmente la matriz es sobre las 13 macrozonas y no sobre las 140 secciones censales planteadas en un principio (lo cual también nos crearía muchas más dificultades de cálculo), lo cierto es que es lo mejor conseguido con las fuentes tradicionales. Esto nos puede permitir conocer los movimientos genéricos de los ciudadanos de Sevilla y nos permitirá relacionar los movimientos entre macrozonas con las variables socioeconómicas conocidas de estas macrozonas, todo lo cual podrá servirnos para estimar pautas de movilidad futuras (forecasting).

Sin embargo, la gran evolución de las nuevas tecnologías y la evolución de los Sistemas de Información Geográfica (SIG), con el aumento de personas y cosas conectadas a la red, georreferenciadas y continuamente monitorizadas se produce una continua explosión de datos (Bosque-Sendra (2015); Gutiérrez-Puebla *et al.* (2016)), que nos abren la puerta a obtener datos más actualizados, incluso en tiempo real, lo que daría la posibilidad a las operadoras de implementar sistemas de reubicación inmediatos ('nowcasting'). Esto dependerá de que ciertamente tengamos la posibilidad de encontrar una fuente de datos que nos genere matrices de O-D según las horas de cada día, y algoritmos que fueran capaces

de resolver la oferta y demanda en cada zona de la ciudad en tiempo real. Asimismo, nos abren la vía de adquirir información o atributos de los que no disponíamos con las fuentes tradicionales, pudiendo por ejemplo obtener información inmediata sobre movilidad por actividades extraordinarias, como concentraciones, grandes eventos, festivales, conciertos. . . o incluso la movilidad de turistas (Osorio Arjona & García-Palomares 2017). Habríamos llegado entonces a la aplicación ideal para que el operador pudiera reubicar los vehículos o bien para ofrecer diferentes tarifas a los clientes por utilizar los vehículos en zonas de poca demanda para ir a sitios donde no existen vehículos y se prevé una demanda inmediata.

Analicemos la situación actual de estas nuevas fuentes.

4.2. Nuevas fuentes

Hemos visto cómo en los dos últimos decenios la evolución de las TIC, las facilidades de conexión y el Internet de las cosas (IoT) nos han preparado para lo que algunos llaman la cuarta Revolución Industrial, o Revolución de la Información. Todo ello nos dispone la existencia de una especie de malla digital, sobre todo en las ciudades, que relaciona el mundo físico con el mundo virtual (Tascón & Coullaut 2017). El uso del Big Data, con un adecuado tratamiento y una utilización apropiada, nos enriquece el conocimiento de las ciudades, generando unas ciudades con un funcionamiento cada vez mejor planificadas y con más interacción social (Batty 2013), razón por lo que se han dado en llamar Smart Cities o ciudades inteligentes.

Con la web 3.0 surge la posibilidad de incluir la información georreferenciada de cuanta información existe, recopilándola en tiempo real y de forma continua, lo que abarata costes de recogida de mucha información antes impensable y por ende, aumenta enormemente las posibilidades, naciendo el concepto de Spatial Big Data.

Estos datos poseen tres características que de alguna forma definen su complejidad: volumen, velocidad y variedad (Clarke 2016). En relación a la movilidad, que es el tema que nos interesa, con Spatial Big Data podemos monitorizar localizaciones, obtener rendimientos, realizar telemetrías, además de poder disponer de atributos de los usuarios (Europe 2015).

Entre las nuevas fuentes de información utilizamos la clasificación realizada por Moro (2016) sobre los nuevos proveedores de datos. Según Moro, podemos distinguir actualmente 4 fuentes de información (fig.4.6):

1. Telefonía móvil
2. Tarjetas inteligentes de Transporte
3. Tarjetas de crédito
4. Redes Sociales

Según E.Moro, cada una de estas fuentes nos aporta un valor de la información obtenida, que curiosamente va en relación inversa a la frecuencia de la información, así, como nos indica en un gráfico, la telefonía móvil nos puede dar información de geolocalización frecuentemente, pero puede obtenerse poca información de las mismas, mientras que las tarjetas de crédito nos dan información muy valiosa (realización de compras), pero no es habitualmente frecuente.

Analizamos la situación actual y realidad de cada una de ellas.



Figura 4.6: Gráfico Esteban Moro

4.2.1. Telefonía Móvil

El teléfono móvil se ha convertido en un compañero ineludible para cualquier persona en todo el mundo, existiendo en España en 2019 un total de 54,44 millones de líneas suscritas (WeAreSocial 2019), lo cual supera en un 16 % a los 46,9 millones de españoles (Eurostat). Independientemente de las posibilidades que nos puede brindar el hecho de que el teléfono sea un Smartphone y por tanto tenga conexión a Internet y localización GPS, el simple hecho de tener un teléfono móvil básico ya nos da la posibilidad de que las operadoras de telefonía, puedan localizar a su usuario dentro de unas celdas definidas por sus antenas, con unos diámetros que pueden oscilar entre 100 y 3000 metros, lo que depende mucho del número de antenas cercanas, por lo que el error en las ciudades, donde hay muchas más antenas y más cercanas, suele ser pequeño. La técnica para su localización es la suma de la aplicación de varios métodos o algoritmos, entre los que podemos destacar la triangulación entre varias antenas, la fuerza de la señal del teléfono recibida en alguna de estas o el tiempo que tarda en llegar la señal (Sánchez *et al.* 2009).

El inconveniente de este Sistema es que, con todo, en algunas zonas, por la ausencia de antenas, la precisión de la localización puede ser demasiado escasa. Por otro lado, son datos que solo podrían obtener las Operadoras de Telefonía, que cuidan mucho de obtener datos de usuarios, porque pueden incurrir en infringir la Ley de Protección de Datos. No obstante, si los datos que la operadora da se limitan exclusivamente a datos de posicionamiento, de forma completamente anónima, se puede entender que no se incumple la ley. De hecho, en diciembre de 2019 el INE ha encargado a las 3 grandes operadoras en España un exhaustivo análisis de movilidad de la población del país, siempre garantizando el anonimato, lo cual no ha dejado de levantar una gran polémica (<https://www.eleconomista.es/economia/noticias/10170313/10/19/Es-legal-que-el-INE-rastree-nuestros-moviles-para-elaborar-sus-nuevas-estadisticas-.html>).

En este sentido resultan muy interesantes los estudios realizados tratando de encontrar, con la localización de móviles, métodos alternativos para establecer modelos del flujo del tráfico de vehículos. En este aspecto destaca el análisis realizado justamente en la ciudad de Sevilla, de Caceres *et al.* (2012).

En este trabajo se analiza la posibilidad de detectar el movimiento de vehículos cuyos usuarios están en una llamada telefónica, comprobando si cambian de celda durante esa llamada. Lo compararon con los métodos tradicionales con sensores utilizados por la DGT para comprobar su eficiencia y a priori se podía comprobar, como ya se había visto en varios estudios, que no había una correlación entre el tráfico medido entre uno y otro (dando coeficientes de correlación de 0'34), debido básicamente a que hay usuarios que llevan teléfonos de otras operadoras o teléfonos apagados o simplemente que las horas punta de mucho tráfico pueden ser horas inoportunas para realizar llamadas. Para resolverlo, han encontrado un método, que realiza una calibración utilizando el volumen recogido por detectores físicos, que luego pueden desaparecer. Con ello, encuentran un modelo que es bastante válido para monitorear la movilidad, aunque declaran que con algunos inconvenientes, como la dependencia de las Operadoras de telefonía o el tiempo de cálculo, que impide sea utilizado para un monitoreo en tiempo real. Sin embargo, concluyen algo que sí es de nuestro interés y es que su método puede ser tan eficiente para estimar matrices de Origen-Destino como un sistema de detectores o sensores.

4.2.2. Tarjetas Inteligentes de Transporte

En los últimos años se ha implementado en casi todos los medios de transporte públicos sistemas de pagos automatizados o Sistemas de Tarifas Automatizadas (AFC en inglés), con el uso de tarjetas inteligentes que han resuelto en gran medida las fórmulas de pago en el transporte, con la ventaja de poder usar estas tarjetas para diferentes medios de transporte, haciendo los viajes multimodales más simples. Estos sistemas AFC pueden servir igualmente para monitorizar los movimientos de la ciudadanía que utiliza los medios de transporte, y cómo no, para obtener matrices de Origen Destino. En la mayoría de los casos, estas matrices no pueden obtenerse de forma simple, puesto que la tarjeta se utiliza en la entrada al servicio (check-in), pero no en la salida (check-out), salvo en algunas ciudades que son la excepción. Por ello se utilizan distintos métodos, basados generalmente en un previsible encadenamiento de viajes, aunque hay otras fórmulas, con resultados diversos (Li *et al.* 2018).

El inconveniente de cualquiera de estos sistemas es que limita el análisis de movilidad a los ciudadanos que usan el transporte público, por lo que obtendríamos matrices de O-D en la que no estarían incluidos los ciudadanos que se desplazan en vehículo privado. Por otro lado, la información es propiedad de la compañía u organismo que gestione el Transporte Público, que no tiene por qué disponer esta información de forma pública. De igual forma, pueden existir diferentes empresas u organismos con diferentes tarjetas de transporte (como es el caso de Sevilla, con tarjetas diferentes para metro, autobús, y transporte interurbano), lo que complica la obtención de la información y el cruce de datos.

Con todo, los estudios realizados se encuentran siempre con la dificultad de verificar el modelo, lo que aparentemente solo han realizado la mitad de estos (Li *et al.* 2018). No obstante, existen estudios que, al trabajar con una única empresa han podido obtener muestras muy grandes, durante largos periodos, y sí han comprobado la confiabilidad de los resultados obtenidos, como es el caso de un estudio realizado sobre el área extraurbana de Turín, en Italia (Pronello *et al.* 2018).

4.2.3. Tarjetas de crédito

La localización por tarjetas de crédito no parece a priori un método para realizar las matrices de Origen-Destino que estamos buscando, dado que el uso que se hace en Sevilla de las tarjetas de crédito es únicamente para sacar dinero en entidades bancarias y consumo en tiendas y restaurantes. Decimos que no parece razonable porque buscamos matrices de movimientos diarios, y con este método descartaríamos movimientos que no fueran de consumo, como puede ser el desplazamiento diario al trabajo.

No obstante, no podemos rechazar el uso de tarjetas de crédito en otras zonas para obtener matrices de O-D válidas, pues no podemos obviar que hay lugares donde las tarjetas de créditos cumplen muchas más funciones, como puede ser en campus universitarios de EEUU, donde usan la misma tarjeta de crédito tanto para compras, como para acceder a instalaciones, servicios de bibliotecas, restaurantes e incluso en los autobuses del campus.

Todo ello conlleva que para una comunidad de este tipo, el análisis de la información que facilita una tarjeta de estas características puede tener una gran fiabilidad, como ocurre en el estudio de la movilidad realizado en el campus de la universidad de Buffalo con la denominada UB Card (Ebadi *et al.* 2017). En este estudio se realizan dos algoritmos para construir patrones de actividad-movilidad utilizando las transacciones con la tarjeta UB Card como única entrada. Como indicaba Moro, la ventaja de la tarjeta de crédito es la gran cantidad de información que se puede obtener (disponemos de información de todos sus accesos, movimientos y compras), si bien la frecuencia es menor. En este caso de la Universidad de Buffalo, este inconveniente desaparece en gran medida porque los estudiantes usan cotidianamente la tarjeta para todos sus servicios, con lo cual no cabe duda de que en estos casos se convierte en un método de gran utilidad para entender los patrones de los usuarios.

4.2.4. Redes Sociales

A la hora de analizar la movilidad de los ciudadanos y obtener una matriz de Origen-Destino, las nuevas fuentes vistas hasta ahora mejoran en muchos casos las antiguas, en cuanto a actualización, pero no dejan de tener límites de vigencia, costes, precisión o representatividad de la población. Así, hemos visto que algoritmos para obtener óptimas matrices de movimientos a partir del seguimiento de las llamadas de teléfonos móviles entre celdas requiere la colaboración con las operadoras de telefonía, la asimilación de las ‘celdas’ de telefonía con las zonas georreferenciadas en otras fuentes (para comparar datos socioeconómicos), y el no disponer de los datos en tiempo real. Las tarjetas inteligentes de transporte suponen la limitación del estudio a los ciudadanos que operan con esos medios de transporte, la colaboración con las entidades que los operan, y que sea una única operadora para recabar toda la información. En el caso de las tarjetas de crédito, salvo para casos excepcionales como el campus universitario de Buffalo, supone el registro solo de los movimientos que se refieren a consumo, obviando los desplazamientos familiares o de trabajo.

Con la llegada de los teléfonos inteligentes o smartphones, con GPS incorporados en su gran mayoría y el acceso continuo a aplicaciones a las que el usuario permite conocer su ubicación geográfica, parece abrirse una fácil fuente de información para geolocalizar a los ciudadanos en cualquier lugar y momento. Sin embargo, para ello tendría que

existir una aplicación generalizada que todos los usuarios usaran y facilitarán permisos de geolocalización anónima a algún organismo, solo con afán de que este conociese los hábitos poblacionales de desplazamiento, y esto, hoy día, no sabemos de su existencia.

A pesar de todo, hay cientos de aplicaciones a las que el usuario les da autorización permitiendo su geolocalización. Entre las más importantes, por su uso generalizado, se encuentran varias redes sociales (Twitter, Foursquare, Facebook, Instagram. . .), en las que el usuario, en muchos casos, permite a su smartphone adjuntar coordenadas geográficas con su geolocalización. Esta información geolocalizada es bastante precisa, pues la da el GPS del celular. También existen otras aplicaciones que piden autorización para geolocalizarte, como la de Transportes Urbanos de la ciudad, la de cualquier uso de vehículos compartidos, las de taxi, Uber. . . Cualquier empresa que tiene esta información podría hacer un estudio de origen-destino, al menos de sus usuarios.

Entre las RRSS comentadas, analizamos Twitter por la facilidad que da a cualquier usuario a acceder a esta información de ubicaciones, tan solo solicitando un usuario de desarrollo, y que hemos comprobado que Twitter facilita en unos días, una vez comprobado que el usuario cumple las condiciones y compromisos exigidos. Este usuario permite, mediante la programación de determinadas API's, obtener de los Tweets las coordenadas georreferenciadas de la ubicación del usuario, siempre que el usuario haya permitido lanzar esta información. El problema radica precisamente en que haya un número suficiente de usuarios que emiten tweet y permiten compartir la información de ubicación. Si en la ciudad que queremos estudiar existiese un número muy alto de usuarios de esta red social, que sean activos y que además tengan permitida la transferencia de datos de ubicación, tendríamos de una potente herramienta como fuente de datos, no dependiente de ninguna empresa u organismo, gratuita, que no solo podría darnos matrices de Origen Destino, sino que, según la cantidad de tweet geolocalizados, podríamos hacer matrices continuamente, estimando patrones para cada día y hora. El inconveniente que vemos a priori sería el sesgo del tipo de población que puede escribir tweets georreferenciados o que, como hemos indicado, estos usuarios sean demasiado escasos respecto a la población estudiada.

Analizados los estudios realizados, encontramos casos de éxito, como el realizado en Kenia (Blanford 2015), en el que hicieron un seguimiento durante 10 meses (entre junio-2013 y marzo-2014) de los tweets habidos en todo el país, con un total de 28.335 usuarios únicos y 720.149 tweets (4.921 tweets diarios), lo que supone una muestra de usuarios de 1,2% de la población con teléfono móvil, lo que en el estudio consideran como datos 'suficientemente buenos'.

Este porcentaje de usuarios geolocalizados no se aleja mucho del estudio realizado por Cheng *et al.* (2010) que, aunque se hizo hace 10 años y un decenio es mucho tiempo en Redes Sociales, no encontramos estudios desde entonces que hayan comprobado algún cambio en este porcentaje. Sí sabemos que existe un porcentaje mucho mayor de tweets autoinformados sobre su ubicación, pero esto, además de ser poco fiable, porque las informaciones pueden ser falsas o inventadas (Hecht *et al.* 2011) sería en cualquier caso poco útil para nuestro análisis, ya que esas informaciones que suele meter el propio usuario de su ubicación suelen referirse, de ser ciertas, al municipio y no al barrio o distrito, por lo que en ningún caso serviría para poder realizar matrices de O-D dentro del municipio.

Dado que ese 1% de Tweet no es un dato que se considere suficiente, se han realizado también estudios para inferir las ubicaciones a partir de los metadatos (Ribeiro & Pappa

2017), algunos con resultados bastante buenos, pero que en el mejor de los casos nos da una precisión de 100 kms a la redonda, lo que nos descarta esos estudios para nuestro análisis de movilidad municipal.

4.2.5. Sistemas Operativos

Nos queda como último recurso la información que puede obtenerse por los propios Sistemas Operativos de los smartphones, que como podemos ver en esta gráfica de Statista (<https://www.statista.com/statistics/272307/market-share-forecast-for-smartphone-operating-systems/>) en 2023 está monopolizada por Alphabet (Android) y Apple.




Figura 4.7: Gráfico Reparto Sistemas Operativos

Ambos sistemas permiten que el usuario envíe a sus servidores sus datos de localización exacta, y aunque es una opción no habilitada por defecto, son muchos los usuarios que conceden su permiso porque esto les permite acceder a funcionalidades que considera interesantes. De esta forma, Alphabet (empresa matriz de Google) y Apple se supone que tienen una extensa información estadística sobre la movilidad de los usuarios que disponen de teléfonos con sus sistemas operativos. El problema es que hablamos de suposiciones porque Google y Apple no disponen de esta información de forma pública, y son poco transparentes a decir incluso si venden esa información. No obstante, en el momento en el que estamos escribiendo este trabajo, que es periodo de confinamiento debido a la pandemia de la COVID-19, tanto Apple como Google están facilitando unos informes de movilidad en las distintas regiones del mundo (<https://www.google.com/covid19/mobility/>), en el que muestran unos análisis en el que llegan al detalle de estimar la población que se desplaza a ‘comercios y ocio’, ‘tiendas de alimentación y farmacias’, ‘parques’, ‘estaciones de tránsito’, ‘lugares de trabajo’ y ‘casa’, lo que nos hace confirmar en gran medida que disponen de información más que precisa del movimiento de la población, información que si se dispusiera en algún momento de forma pública, nos permitiría sin duda realizar matrices de Origen-Destino con bastante calidad. Sin embargo, no hemos podido encontrar ninguna referencia para poder comprar esta información.

Andalusia

Retail & recreation

-68% compared to baseline



Grocery & pharmacy

-31% compared to baseline



Parks

-44% compared to baseline



Transit stations

-62% compared to baseline



Workplaces

-50% compared to baseline



Residential

+19% compared to baseline



4.2.6. Otras fuentes privadas

Además de las grandes multinacionales comentadas, siguen existiendo y creciendo otras empresas pequeñas y grandes que intentan introducirse en el segmento de la movilidad, en parte por el negocio en sí mismo de la movilidad, como hacen CityMapper o Moovit, que luchan por competir con Google Map en cuanto a dar al usuario la mejor información y opciones de transporte para desplazarse en la ciudad; o bien empresas que tratan de abrirse camino para un futuro de la movilidad urbana autónoma, en el que los vehículos autónomos necesitarán disponer de cuanta información sea posible. En esta línea trabajan empresas como Mobileye.

Hemos investigado si existe alguna otra empresa que venda datos sobre la movilidad de los usuarios, a partir de información obtenida de redes sociales o de su propia app y una opción empresarial que parece vender estos análisis, proveniente de sus propios usuarios y de otras fuentes, es Moovit: <https://moovit.com/es/maas-solutions-es/urban-mobility-analytics/>

4.2.7. Conclusión sobre las nuevas fuentes

La explosión tecnológica de los móviles inteligentes ha supuesto un cambio radical en las posibilidades de obtención de datos geolocalizados de los usuarios, aunque al día de hoy esta información es mayoritariamente privada y poco transparente, salvo la que puede obtenerse de Twitter, que no parece suficiente para realizar matrices de O-D en el interior de una ciudad. Necesitamos por tanto, si queremos trabajar con datos públicos, obtener la información de las encuestas realizadas por entidades locales para adaptarse a las exigencias de Desarrollo Sostenible, si bien estas nos facilitan una información

demasiado genérica. La otra opción sería ponerse en contacto con empresas privadas que puedan obtener datos de geolocalización de sus usuarios. En la información proporcionada públicamente, tenemos el inconveniente de que se obtienen de una encuesta realizada puntualmente, entre unas fechas que rápidamente van quedando anticuadas, y en la información privada, obtenida de los datos de geolocalización de los smartphone y tratadas en los big data de las grandes empresas, existe el inconveniente, en principio, de ser análisis estadísticos en los que se prescinde de lo particular, ignorando contextos, situaciones, meteorología, identidad social (género, etnia, clase social y económica) e introduciendo sesgos de desigualdad de acceso tecnológico (Schwanen 2016), por lo que es deseable un tratamiento eficiente de la información que dote a esta de cuanta información contextual sea posible.

Capítulo 5

CLIENTES OBJETIVOS

Una vez conocidas las fuentes que nos permitan obtener datos sobre la movilidad de los ciudadanos en una ciudad, nuestro siguiente paso consiste en encontrar cual es el perfil de cliente o dicho de otra forma, el público objetivo que puede estar interesado en utilizar este tipo de vehículos compartidos.

5.1. Vehículos eléctricos compartidos

Hemos comprobado la existencia de multitud de estudios para analizar el mercado de vehículos compartidos, desde coches, coches eléctricos hasta patinetes y bicicletas. La llegada de los vehículos compartidos supone un importante impacto en la movilidad urbana e influye positivamente en la planificación de las ciudades (Shaheen *et al.* 2015a), son vehículos que contribuyen a mejorar la calidad del aire, la accesibilidad, la habitabilidad y por ende, la calidad de vida, de forma que, en definitiva, facilitan a las ciudades un desarrollo sostenible y por tanto las instituciones públicas recogen regulaciones favorables para su adaptación.

Las ventajas del uso compartido son (Barth & Shaheen 2016):

- Provisión de una alternativa a la movilidad más flexible que el transporte público y más conveniente para la comunidad que el privado.
- Potencial para reducir costos de transporte de los usuarios y reducir estacionamientos.
- Mejora de la calidad del aire.
- Acceso y fomento del uso de modo de transporte más eficientes y respetuosos con el medio ambiente (junto con el tránsito ferroviario).

No obstante, los escúteres eléctricos tienen características diferentes de los vehículos de cuatro ruedas, así como de las bicicletas o patinetes eléctricos. El escúter es más accesible y puede llegar más cerca del destino, es más rápido en ciudad y por el contrario es más peligroso y más incómodo con frío, lluvia o calor que el automóvil y, por otra parte, al contrario que bicicletas y patinetes eléctricos, circula por vías urbanas, es más rápido y permite 2 viajeros.

5.2. Peculiaridades del usuario de motocicleta

El usuario de las motocicletas tiene peculiaridades que lo diferencian del resto y es importante conocer estas características que nos pueden servir de introducción para un usuario objetivo de escúter compartido.

Existe mucha literatura que analiza las decisiones que llevan a un usuario a una elección de medio de transporte específica, concluyendo que responden a multitud de factores, entre los que pueden destacarse algunos instrumentales y objetivos (tiempo de viaje, costes. . .) pero entre los que destacan con fuerza otros emocionales y no instrumentales, como el simbolismo, el posicionamiento social o la costumbre (Miralles-Guasch *et al.* 2014).

Si nos atuviéramos a los factores objetivos, las ventajas de conducir una motocicleta en grandes ciudades con condiciones climáticas favorables son enormes, pues se evita la congestión y se facilita el aparcamiento, lo que hace que los tiempos de desplazamiento no dependan tanto del tráfico existente (Espíe *et al.* 2013). En uno de los pocos estudios realizados en ciudades europeas comparando tiempos de desplazamiento, en concreto en París (Kopp 2011), se estimó en un 49 % la reducción de tiempos de viaje entre automóvil y motocicleta. Si a ello añadimos la mayor asequibilidad de la motocicleta, parecería obligada la elección de esta como medio de transporte preferente. Sin embargo, esto no es del todo cierto. Si bien es cierto que se ha demostrado, por ejemplo durante el periodo de crisis 2008- 2012, que mientras el mercado de automóviles descendía, el de motocicletas continuaba aumentando (Sobrinó & Monzón 2014), la motocicleta no es la mayoritariamente elegida por la población urbana para sus desplazamientos en vehículo privado (22 % en Barcelona), sino que sigue siendo el automóvil, probablemente porque el usuario sigue anteponiendo su comodidad y su seguridad, además de otros criterios menos objetivos.

Adentrándonos más en el usuario de la motocicleta, analizamos el estudio del usuario de motocicleta realizado en Barcelona (Marquet & Miralles-Guasch 2016), basadas en las encuestas EMEF 2004 y EMEF 2012, realizadas por el Departamento de Política Territorial y Obras Públicas del Gobierno de Cataluña y la Autoridad Metropolitana de Transporte de Barcelona. En este estudio se analiza el uso de la motocicleta en 2004 y 2012, y comprobamos que el usuario de motocicleta es mayoritariamente varón (un 68'8 %), aunque la tendencia es que las mujeres van aumentando su porcentaje de uso. El intervalo de edad de usuarios está entre 30 y 64 años (un 72,1 %). Comprobamos también que la elección de motocicleta como medio de transporte va relacionado con un mayor nivel de estudios reglados y también con que los desplazamientos no sean demasiado largos. No se encuentra relación alguna con el objetivo del desplazamiento.

Se deduce en el estudio que los propietarios de motocicleta no suelen usar transporte público ni automóvil, y viceversa, los usuarios de transporte público y automóvil no suelen plantearse la propiedad de una motocicleta.

Cabe destacar que entre la valoración de todos los usuarios por el medio de transporte que usan, la mayor puntuación la obtiene la motocicleta (con un 8,12), seguido del transporte público (7'09) y finalmente el coche (6'97). Por otra parte, los usuarios de motocicleta perciben más riesgo (5,45) que los de automóvil (3,7) y que los primeros, a mayor uso, menor riesgo perciben, aunque también podría interpretarse que a menor riesgo perciben, mayor uso.

Finalmente, cabe destacar por qué se prefiere usar la motocicleta al Transporte Público, concluyendo que es básicamente porque es más rápido (35'3%), más cómodo (23'3%) y más barato (14'6%). Por el contrario, el factor que lleva a los usuarios de automóvil a preferirlo al transporte público es que es más cómodo (28'8%) y más rápido (21'9%).

Nos encontramos por tanto con un medio de locomoción que satisface más a sus usuarios que el uso del automóvil a los automovilistas. Un medio de locomoción que es también seleccionado por criterios económicos. Y sin embargo, hay una gran parte de la población que no lo usa. Para nuestro estudio, sería importante averiguar el factor que determina a los usuarios a inclinarse mayoritariamente por el automóvil. Aunque podemos suponer que este factor es en gran medida el 'riesgo' (que los motoristas autovaloran muy superior a los automovilistas), en las encuestas de este análisis no se concluye si es ciertamente el 'riesgo', y echamos en falta preguntas a motoristas y automovilistas de la valoración de riesgo que les supone el otro vehículo, lo que podría darnos una orientación de si realmente los conductores de automóvil perciben mucho mayor riesgo en la motocicleta. Igualmente sería interesante conocer otras variables que pudieran influir en esa percepción de riesgo, como 'estado civil' o 'número de hijos'. Todo ello nos podría servir para encontrar cuales serían clientes potenciales de una moto de alquiler.

5.3. Estudios sobre scooter-sharing

Si bien la literatura sobre los nuevos sistemas de movilidad, como car-sharing o bicicletas compartidas (eléctricas o no) es amplia, los estudios y análisis sobre el caso concreto de los escúteres compartidos es mínima.

En 2012 nació la primera empresa de scooter-sharing en San Francisco, y como hemos visto, desde entonces las ofertas de esta modalidad de transporte no han dejado de crecer. La fórmula que se ha consolidado y que es ya habitualmente usada es que el usuario solo paga una tarifa de uso y el operador se encarga del combustible, el estacionamiento y el mantenimiento (Shaheen *et al.* 2015b).

Hemos visto que es preferible a las bicicletas eléctricas en ciudades con abundancia de cuevas, así como para distancias largas o para un viaje con prisas (Kafyeke 2017). Hemos comprobado que a día de hoy el 99% son de flotación libre (Howe & Jakobsen 2019).

5.3.1. Clusterización de clientes de escúteres compartidos

Hemos encontrado un muy interesante artículo de agrupación o clusterización de clientes realizado a partir de los datos suministrados por el proveedor de escúter eléctricos de una gran ciudad alemana (Degele *et al.* 2018). Dada la cantidad de datos existentes, los autores optaron por realizar una agrupación jerárquica de una muestra elegida al azar, para decidir el número de agrupaciones y finalmente realizar una partición k-media.

Se seleccionaron 5 variables para realizar la clusterización, que fueron 'número de viajes', 'edad', 'distancia recorrida', 'tiempo de uso' e 'ingresos por cliente'. Dado que se encontró una correlación entre 'distancia recorrida' y 'tiempo de uso', se eliminó esta última.

Para la agrupación jerárquica se utilizó la distancia euclídea y el enlace promedio con una muestra de 100 elementos y se comprobó que la agrupación óptima era de cuatro

grupos. Se procedió a continuación a realizar una agrupación tipo partición k-media para obtener 4 grupos. El número de registros para analizar obtenidos tras la depuración fueron 3513, lo que superaba ampliamente los 16 (24) necesarios para realizar 4 grupos. Como las variables trabajan con diferentes escalas y proveniencias se normalizaron los datos. Con todo ello, se obtuvieron los siguientes cluster (fig.5.1)

Cluster characteristics	Cluster 0	Cluster 1	Cluster 2	Cluster 3
Share of customers	4.41 %	23.63 %	58.24 %	13.72 %
Rentals per customer	52	7	9	1
Share of rides	23.99 %	17.97 %	56.34 %	1.70 %
Average age	34	48	28	35
Average time between rides	111 h (4.6 days)	601 h (25.0 days)	469 h (19.5 days)	2537 h (105.7 days)
Average distance	5.7 km	5.7 km	4.9 km	7.0 km
Share of revenue	41.46 %	16.17 %	41.19 %	1.18 %
Most common usage day	Wednesday	Friday	Saturday	Saturday

elaboración: Degele et al (2018)

Figura 5.1: Tabla resultados clusterización

En el mismo artículo nos representan en un gráfico tridimensional la situación de los cluster, por colores (fig.5.2)

El resultado del estudio se validó creando agrupaciones similares con otros proveedores con las mismas características en otras ciudades alemanas, comprobando que los porcentajes de la distribución por conglomerados eran muy similares.

La conclusión es que podemos clasificar los potenciales clientes en 4 grupos:

Primero tenemos un grupo denominado ‘cluster 0’, que podríamos denominar ‘usuarios potentes’ que son los usuarios que utilizan el escúter entre semana, por lo que puede suponerse que realizan desplazamientos de trabajo y otras citas. Tienen una media de edad de 34 años y son sin dudas los más interesantes para cualquier proveedor, dado que suponen el 4’41 % de los usuarios que generan el 41’46 % de los ingresos.

En segundo lugar por interés empresarial tenemos el denominado ‘cluster 2’ que es el de ‘usuarios ocasionales menores de 40’. Son usuarios jóvenes, que utilizan el escúter compartido ocasionalmente, generalmente los fines de semana, por lo que se relaciona con desplazamientos rápidos o imprevistos en momentos de ocio. Los ingresos que generan son pequeños, pero el grupo es muy amplio (un 58’24 % de los usuarios) y por tanto con ellos se consigue otro 41’19 % de los ingresos.

En tercer lugar el grupo ‘cluster 1’, o ‘usuarios ocasionales mayores de 40’ que tiene un perfil de uso muy parecido al ‘cluster 2’, pero en este caso para mayores de 40 años. El número de usos y distancias es ligeramente menor que el de los jóvenes, con diferencias poco significativas, utilizándolo también para desplazamientos ocasionales en fin de semana. Sin embargo el número de usuarios es menor (un 23’63 %), por lo que los ingresos que ocasionan bajan a un 16’17 %.

Finalmente tenemos el ‘cluster 3’ o ‘usuarios únicos’, que han utilizado el escúter una única vez, por lo que en principio no han generado prácticamente ingresos y su interés puede estar en su potencial para pasar a formar parte de alguno de los otros grupos.

Sin embargo, aunque el trabajo de Degele y otros nos realiza una valiosa clasificación del tipo de usuarios por características de edad y uso, nos encontramos aún para nuestro

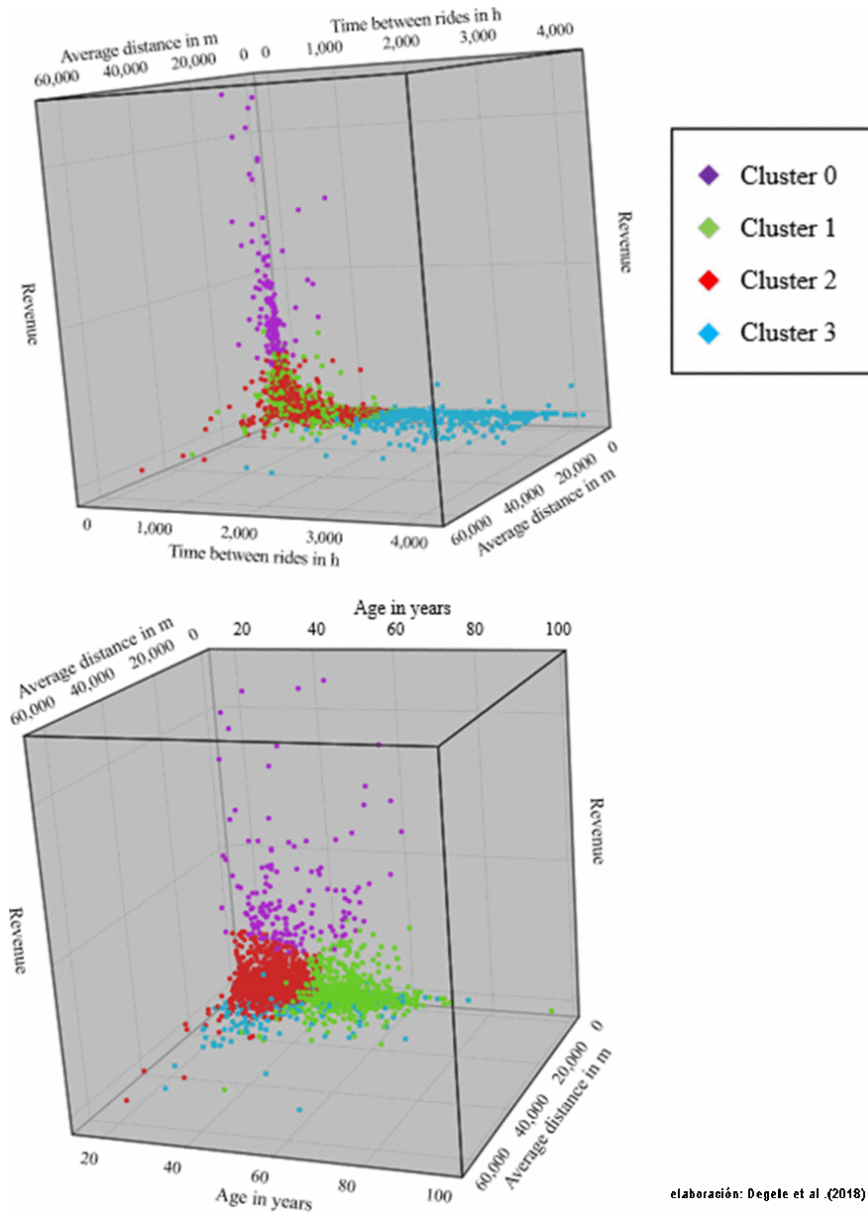


Figura 5.2: Tridimensionales de clusters

trabajo con una descripción de clientes potenciales demasiado escasa, pues no considera factores socioeconómicos, de comportamiento o de motivos de viaje, y por tanto no es suficiente para nuestro estudio en el que pretendemos relacionarlos con zonas geográficas de la ciudad.

5.3.2. Factores de influencia en el uso de escúteres compartidos. Encuesta en España

En enero de 2020 se ha publicado un artículo que definitivamente se adentra en el estudio que necesitamos (Gomez & Sobrino 2020). Este estudio realiza una encuesta que, según ellos mismos indican, “fue especialmente diseñada para (...) identificar los factores explicativos que influyen en la adopción del uso compartido de scooters”.

En ella se indaga sobre cuatro aspectos principales a personas que utilizan y no utilizan los escúteres eléctricos compartidos:

- a) Información socioeconómica y demográfica general
- b) Movilidad y variables relacionadas con el viaje.
- c) Actitudes y preferencias personales
- d) Percepciones y uso de servicios de uso compartido de scooter

La encuesta se distribuye y contesta de forma online, obteniendo 430 respuestas válidas.

Este método de encuesta da muchas facilidades para el investigador, pero nos genera dudas respecto al sesgo de la muestra, que en este caso podemos comprobar que es notorio, así por ejemplo se encuesta a un 67 % de personas de género masculino (según INE en Sevilla hay un 47'44 % de varones), casi un 30 % no tiene ingresos propios, el 83 % tiene estudios universitarios y un 71'8 % tiene entre 18 y 34 años (en INE hay un 22'40 % de población entre 18 y 34 años en la provincia de Sevilla). Es decir, la encuesta parece haberse movido básicamente por ambientes universitarios, probablemente en carreras de mayor presencia masculina, como estudios de Ingeniería, pero no parece una muestra muy representativa de la población urbana en general.

No obstante, el perjuicio de este sesgo podría ser que determinados sectores de la población no estuvieran representados o tuvieran un tamaño muestral demasiado pequeño, pero dado que el sesgo coincide con el que en los estudios anteriores hemos supuesto como clientes potenciales (jóvenes, varones, perfil profesional y universitario), y dado que no utilizamos los resultados de la encuesta, sino que el estudio se centra en crear un modelo logit ordenado generalizado para encontrar los factores que determinan la frecuencia de uso de los escúteres eléctricos compartidos, consideramos que puede ser perfectamente útil para nuestro trabajo.

El modelo viene definido en la Tabla 10 del estudio (que adjuntamos en fig.5.3), de donde analizando las variables que resulta significativas, podemos extraer las siguientes conclusiones:

5.3.2.1. En cuanto a las características socioeconómicas:

Es importante discernir, porque se han diferenciado en la encuesta, entre ‘usuarios ocasionales’ (cierta probabilidad de coger el escúter en fines de semana, momentos de ocio) y ‘usuarios frecuentes’ (uso más o menos habitual en días laborables).

Users' adoption of scooter-sharing systems in Spanish cities: modelling results.

Variables		Occasional users (threshold 1)			Frequent users (threshold 2)		
		Coeff.	Std. Error	p-Value	Coeff.	Std. error	p-Value
Socioeconomic characteristics	Age (base case: under 26)						
	From 26 to 34	0.318	0.559	0.569	2.740	0.880	0.002
	From 35 to 49	-0.036	0.811	0.965	-	-	-
	Above 49	-2.433	1.244	0.051	2.558	1.740	0.142
	Occupancy (base case: student)						
	Employee	-2.114	0.876	0.016	-	-	-
	Part-time employee and student	-1.314	0.735	0.074	-5.401	1.235	0.000
	Other	-0.453	1.339	0.735	-	-	-
	Education (base case: non-university)						
	University	0.976	0.688	0.156	3.701	1.260	0.003
	Monthly Income (base case: below 1000 Euro)						
	From 1000 to 2000 Euro	0.058	0.752	0.939	-3.564	1.367	0.009
	Above 2000 Euro	0.959	0.982	0.329	-3.899	1.371	0.004
	Dependent from family income	-1.274	0.721	0.077	-6.420	1.375	0.000
	Household structure (base case: alone)						
	Sharing household	2.504	1.082	0.021	-	-	-
	Family without children	1.766	11.000	0.109	-	-	-
	Family with children below 25	1.514	1.127	0.179	-	-	-
	Family with children above 26	-13.196	834.392	0.987	-	-	-
Car ownership (base case: no vehicle)							
One or more vehicles	2.787	0.691	0.000	-	-	-	
Travel-related attributes	Driving moto (base case: no)						
	Yes	1.795	0.517	0.001	-	-	-
	Weekend daily trips (base case: < 2)						
	From 2 to 3	1.067	0.520	0.040	-3.890	1.013	0.000
	Above 3	0.651	0.579	0.261	-	-	-
	Ever used carsharing (base case: no)						
	Yes	0.790	0.390	0.043	-	-	-
	Trip frequency in private car (base case: rarely)						
	From once to twice per week	-0.206	0.614	0.737	-3.715	1.038	0.000
	More than twice per week	-0.870	0.597	0.145	-	-	-
	Never	1.992	0.632	0.002	1.476	0.970	0.128
	Trip frequency in private moto (base case: rarely)						
	From once to twice per week	-1.559	0.928	0.093	4.435	1.329	0.001
	More than twice per week	-0.927	0.707	0.190	-	-	-
	Never	1.979	0.532	0.000	-0.344	0.780	0.659
	Trip frequency in public transport (base case: rarely)						
	From once to twice per week	-0.211	0.594	0.722	-	-	-
	More than twice per week	-0.985	0.596	0.098	-	-	-
	Never	0.955	1.122	0.394	-	-	-
	Trip frequency on foot (base case: rarely)						
	From once to twice per week	-0.843	0.664	0.204	2.548	1.001	0.011
	More than twice per week	-1.349	0.610	0.027	1.449	0.986	0.142
	Never	-5.328	2.035	0.009	-	-	-
	Trip frequency in taxi (base case: rarely)						
	From once to twice per week	1.006	0.621	0.105	-	-	-
	More than twice per week	0.419	0.739	0.571	-	-	-
	Never	1.054	0.498	0.034	-	-	-
Trip frequency in bike-sharing (base case: rarely)							
From once to twice per week	0.683	0.909	0.453	-	-	-	
More than twice per week	2.684	1.099	0.015	-0.109	1.024	0.915	
Never	-0.151	0.511	0.767	-	-	-	
Personal attitudes & preferences	Share bank account info	0.638	0.189	0.001	-	-	-
	Environment	0.032	0.177	0.856	1.722	0.345	0.000
	Luggage	-0.220	0.166	0.184	-	-	-
Constant							
No. obs	335						
Log-Likelihood at convergence	-134.161						
Log-Likelihood restricted	-283.445						
Mc Fadden's Pseudo R ²	0.507						

Figura 5.3: Resultados encuesta en ciudades de España

1º) La edad:

Puede decirse que por encima de 49 años hay mucha menos probabilidad de usar el escúter de forma ocasional que con la edad base, que es menos de 26.

También podemos asegurar que el rango de edad entre 26 y 35 años tiene mucha mayor probabilidad que los menores de 26 de usar frecuentemente el ciclomotor.

2º) Ocupación:

Los que declaran ser ‘empleados’ tienen menos probabilidad de usar ocasionalmente el escúter que los estudiantes. Y aquellos que se declaran ‘empleados y estudiantes a tiempo parcial’ podríamos asegurar que la probabilidad de usar la moto frecuentemente es inexistente.

3º) Educación

Según el nivel de estudios, no se detectan diferencias significativas en cuanto al uso ocasional, pero sí es bastante determinante en el uso frecuente, donde tener estudios universitarios supone multiplicar la probabilidad por 40.

4º) Ingresos

No se detectan diferencias significativas para el uso ocasional del moto-sharing, pero sí es un factor de importancia para el uso frecuente, donde curiosamente el uso mayor sería por parte de los que ganan menos de 1000 euros, pero a partir de ahí, cuanto más ganan, la probabilidad de ser viajeros frecuentes se va reduciendo. Aunque el rango que disminuye más la probabilidad es el de las personas que no tienen ingresos propios y dependen del familiar.

5º) Estructura del hogar

En cuanto a la composición familiar sólo hay un valor que pueda darse como significativo, y es la respuesta “dos o más personas compartiendo una vivienda privada”, que multiplica por 12 la probabilidad de usar el escúter compartido ocasionalmente respecto a los que viven solos.

6º) Vehículos

También es muy significativo, para el uso ocasional, el disponer ya de algún vehículo privado. Es muchísimo más probable que la persona que usa ocasionalmente un escúter compartido sea alguien que ya tiene algún vehículo, que la que no lo tiene.

5.3.2.2. En cuanto a otras características:

Respecto al resto de atributos analizados, vemos que un factor importante que incrementa la probabilidad de probar el moto-sharing es haber conducido antes ciclomotor o motocicleta, y en menor medida, haber hecho uso antes de alquiler de coche compartido, aunque en nuestro estudio esto es difícil porque en Sevilla no hay aún esta opción de car-sharing.

Otro factor importante que facilita el uso ocasional del escúter compartido es el ser usuario asiduo de las bicicletas compartidas.

Resulta interesante observar que el hecho de no usar nunca automóvil o motocicleta privada es bastante significativo para convertirse en usuario ocasional de moto-sharing,

mientras que, por otro lado, si analizamos los usuarios frecuentes de moto-sharing, tenemos que distinguir entre los que usan su automóvil privado una o dos veces por semana (que reduce de forma importante la probabilidad de ser usuario frecuente) y la de usar su motocicleta privada una o dos veces por semana, en cuyo caso se incrementa muchísimo la probabilidad de convertirse en usuarios frecuentes de escúter compartido.

Otro apartado interesante es el de los viajes realizados a pie. En este caso el usuario ocasional de motosharing parece ser el que camina raramente, reduciendo la probabilidad de ser usuario ocasional tanto los que no andan nunca como los que andan más de dos veces por semana. De forma parecida, el usuario frecuente de moto-sharing se relaciona más con los que andan a pie una o dos veces por semana.

Por último y no menos interesante es el dato de observar los viajes diarios que se hacen durante el fin de semana. En este caso, aquellos ciudadanos que declaran realizar entre 2 y 3 viajes cada día del fin de semana son más propensos a usar el escúter compartido de forma ocasional que aquellos que declaran hacer menos de 2 viajes, mientras que estos mismos usuarios decremantan muchísimo la probabilidad de ser viajeros frecuentes.

5.3.2.3. Conclusión encuesta

Con todo ello, concluimos que el perfil teórico del usuario ocasional de escúteres eléctricos es el de una persona joven, de género masculino, ingresos propios, que suele vivir en pisos compartidos o en pareja y que dispone de vehículo propio (o familiar), aunque no lo usa nunca, que ya sabe conducir ciclomotores, que suele hacer 2 o 3 viajes diarios los fines de semana (lo que se puede relacionar con salidas de ocio), que camina raramente y que casi nunca usa taxi.

El perfil de uso frecuente de escúteres es de hombres jóvenes, pero se centra más entre 26 y 34 años, descartando estudiantes que trabajan a tiempo parcial, con estudios superiores (factor muy determinante), con ingresos propios pero no mayores de 1000 euros, con menos de 2 viajes diarios los fines de semana, que viaja una o dos veces por semana en motocicleta propia (muy importante), que suele hacer viajes a pie y al que preocupa el medio ambiente.

Capítulo 6

APLICACIÓN PRÁCTICA SOBRE SEVILLA

6.1. Información disponible

Hemos visto en los apartados anteriores que disponemos de las siguientes fuentes de información para hacer un análisis del uso de motosharing en la ciudad de Sevilla:

Como referencia de datos de movilidad, tenemos el “Diagnóstico del PMUS” realizado por el Ayuntamiento de Sevilla, con algunas incidencias ya comentadas, pero que es la única información fiable que nos da una matriz fija de Origen Destino estimada en 2016. Nos hubiera gustado localizar alguna fuente de información que nos facilitara matrices de origen-destino en función de días de la semana y horarios, pero hemos comprobado y ya hablado de las dificultades encontradas.

En cuanto al tipo de clientes, hemos encontrado pocos estudios, pero es importante la clusterización realizada por Degele *et al.* (2018) en Alemania, que nos clasifica los clientes en 4 grupos en el que básicamente los grupos interesantes son el 0 (por ser los de mayor rentabilidad) y el 1 (aunque poco rentables, son numerosos), pues entre ambos generan el 82 % de la rentabilidad de la empresa operaria.

Por otro lado, en este mismo análisis de perfil de clientes, tenemos la encuesta realizada en España por Gomez & Sobrino (2020), que nos describe unos perfiles potenciales, que coinciden en gran medida con los grupos 0 y 1 de la clusterización realizada por Degele.

Nuestro objetivo final consistía en optimizar la distribución de los escúteres por la ciudad de forma que se maximice el beneficio. Pero hablar de maximizar el beneficio implica conocer al detalle la oferta y la demanda, que en una situación ideal pasaría por disponer de la demanda y la oferta exacta que existe en pequeñas celdas espaciales de la ciudad en cada corto periodo de tiempo. Esto obviamente es imposible, porque no podemos prever todos los movimientos urbanos con precisión, dado el alto componente aleatorio de estos, por lo que el objetivo ideal sería estimar las ofertas y demandas en zonas en las que pudiéramos estimar un comportamiento según la población existente (como la sección censal), en un periodo de tiempo corto, no mayor a una hora. Con esa información podríamos valorar la posibilidad para la empresa de mover escúteres de alguna zona a otra en momentos dados, si es que fuera mayor el beneficio, o incluso la opción de ofertar

al usuario distintos precios para conseguir equilibrar las zonas y minimizar la posibilidad de que queden algunas con falta de oferta.

Lo cierto es que tras analizar los fuentes existentes, no hemos conseguido obtener los datos de demanda que hubiéramos querido. Por una parte, los datos de movilidad se limitan a una única matriz de Origen-Destino genérica, sin establecer diferenciación entre días de la semana o fines de semana y mucho menos entre horas, agrupada únicamente en 12 distritos de Sevilla. Por otra parte los datos del tipo de cliente, solo hemos obtenido una encuesta online de la que tenemos únicamente los resultados finales, en odd ratios, lo cual sólo nos sirve para saber qué variables de los posibles clientes son significativas y en qué proporción respecto a un valor base. Pero con todo ello, no podemos encontrar una función que nos estime de forma matemática el número de clientes que pudiera existir en cada sección censal.

6.2. Zonas óptimas para la disponibilidad de los escúteres en Sevilla.

No obstante, aún no teniendo datos precisos, hemos decidido realizar una aproximación a modo de ejemplo de lo que podríamos obtener con datos válidos. Para determinar el porcentaje de clientes, usaremos los resultados obtenidos de la encuesta de Gomez & Sobrino (2020). En ella se diferencia de forma univariante la probabilidad de que un usuario realice un viaje, en el caso de ser hombre o mujer, o según 4 tramos de edad o 4 tramos de renta. Podemos observar los resultados en la siguiente tabla:

Cuadro 6.1: Prob. de usar escúter eléctrico según encuesta

	ocasional	frecuente
hombre	0.187	0.117
mujer	0.103	0.037
ed_25	0.166	0.030
ed_26_34	0.196	0.167
ed_35_49	0.160	0.120
ed_50	0.047	0.047
in_0	0.144	0.032
in_1000	0.194	0.139
in_1000_2000	0.132	0.047
in_2000	0.175	0.175

De la matriz O-D obtenida en el ‘Diagnóstico’ del Ayuntamiento de Sevilla, vamos a quedarnos con los datos de las macrozonas generadoras de viajes, sirviéndonos como datos del número de desplazamientos estimados que se generan diariamente en cada macrozona.

A partir de datos del padrón continuo del INE a 2019 obtenemos para cada sección censal la población total, por sexo y por tramo de 5 años de edad (que hemos convertido de forma proporcional a los tramos que tenemos en la tabla anterior) y de la web experimental del INE hemos obtenido datos de renta personal por sección censal a 2017 (de la cual también

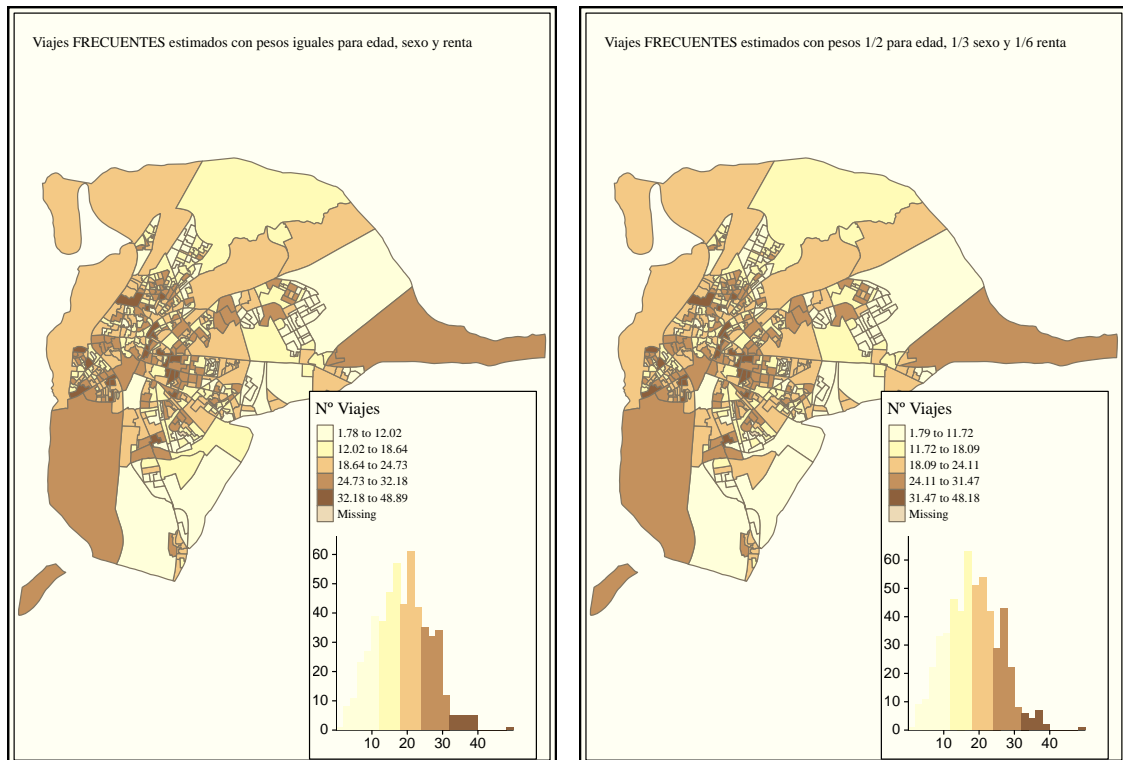
hemos realizado una estimación para la adaptarlo a los mismos intervalos valorados en la encuesta).

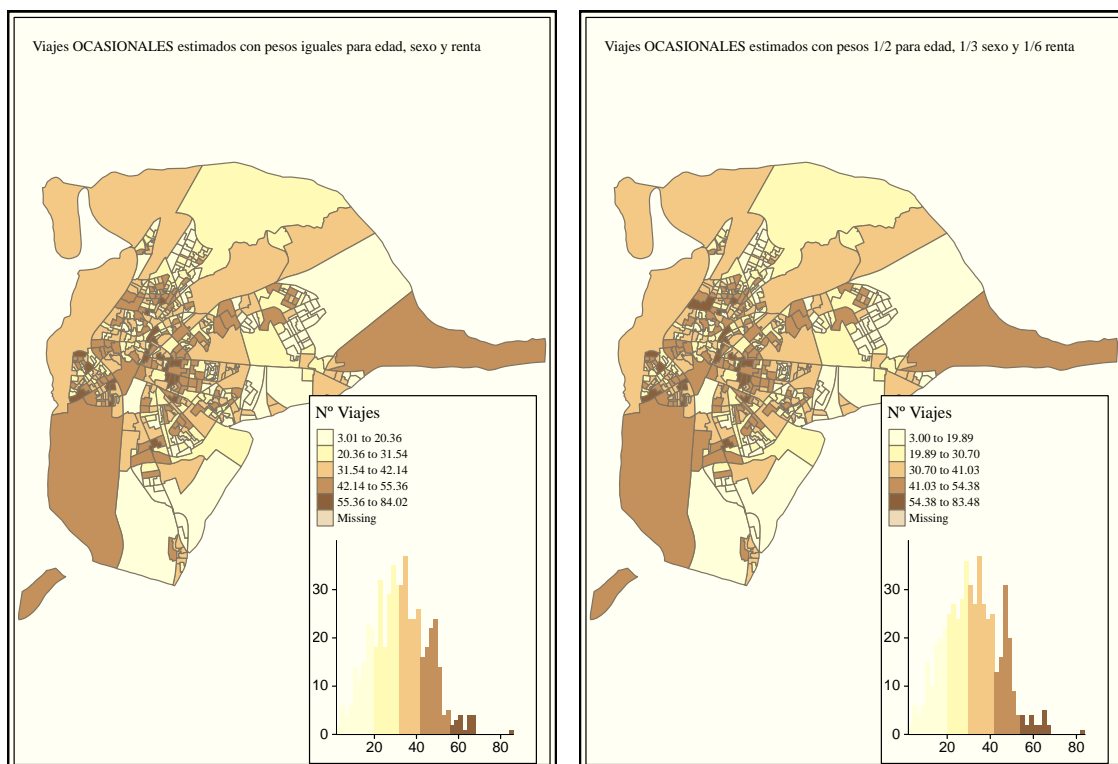
Con todo ello, hemos podido generar una estimación del número de viajes generados en cada sección censal según el sexo de los residentes, otra estimación según la edad de los residentes y una última estimación según la renta estimada de los residentes de esa sección censal.

Finalmente tendríamos que encontrar el peso a dar a cada una de las variables estimadas, que no podemos calcular y por tanto, hemos realizado dos valoraciones, una con pesos iguales para cada variable y otra en la que damos 3/6 a sexo, 2/6 a edad y 1/6 a renta.

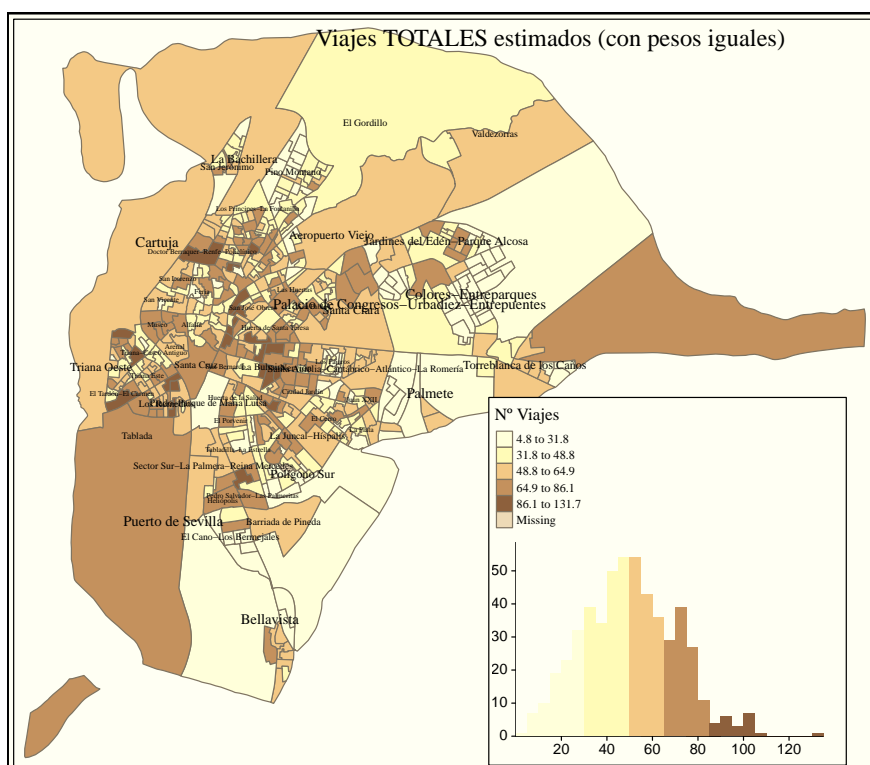
También hemos realizado las estimaciones de viajeros ‘frecuentes’ y la estimación de viajeros ‘ocasionales’, según la misma denominación dada en la encuesta.

De esta forma, nos salen 2 gráficos de estimaciones de viajes frecuentes (para pesos iguales y para pesos diferentes) y otros dos gráficos para viajeros ocasionales. Como podemos comprobar, la diferencia de estimación final de viajes usando un modelo de pesos u otro es muy pequeña.



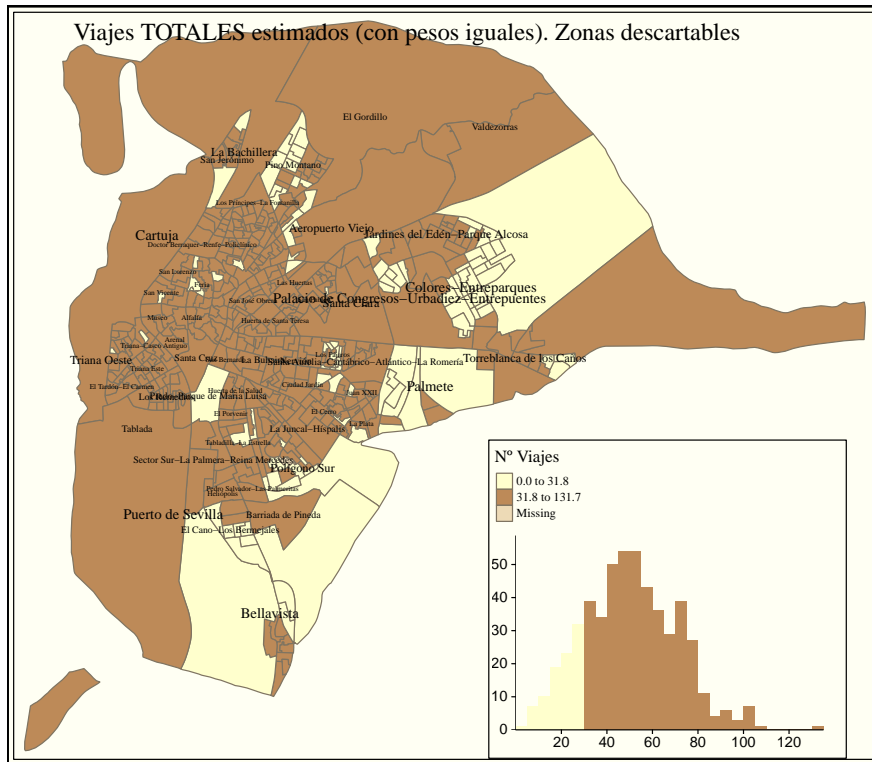


Finalmente hemos realizado un gráfico sumando la demanda de viajeros frecuentes y viajeros ocasionales, lo que entendemos puede darnos una idea, si no exacta del número de viajes esperados en cada sección censal, sí creemos que puede ser fiable para determinar las secciones censales de mayor demanda esperada:



Por último, queremos comparar nuestros resultados con el mapa de cobertura de las

empresas existentes. Para ello, hemos realizado el mismo mapa, pero agrupando todas las zonas mejores y dejando una zona con las zonas de menor petición de escúteres, lo que podríamos valorar como zonas en las que no merecería la pena llevar las motocicletas y por tanto, zonas descartables.



Si comparamos este gráfico con el de cobertura de Muving (por ejemplo), observamos que ciertamente tienen muchas coincidencias (salvando que el nuestro recoge toda la extensión de secciones censales, mientras que el Muving está recortado sin importar límites de secciones censales). No obstante, también comprobamos que Muving tiene descartada zonas, que desde un punto objetivo tendrían demanda, como el Polígono San Pablo o una gran extensión en la zona Sur, eliminación que aparentemente no se debe a razones objetivamente rentables, sino probablemente a otras razones más subjetivas.



Figura 6.1: mapa muing

Capítulo 7

CONCLUSIONES

El resultado obtenido no ha sido el esperado en un siglo en el que una gran mayoría de la población lleva un teléfono inteligente que le tiene geolocalizado, que le indica dónde se encuentra el mejor restaurante más cercano, a que hora llega el siguiente autobús o dónde se ubica el vehículo compartido más próximo.

Por un lado, apreciamos una gran escasez de estudios de demanda, pues sólo hemos encontrado un estudio de clusterización en Alemania y una encuesta en España, que además no nos ha aportado demasiadas garantías, al haberse realizado sobre una población muy sesgada y de la que no hemos obtenido mucha información significativa en su análisis multivariante.

Por otro lado, la información sobre movimientos de la ciudadanía, que esperábamos fuera en la actualidad muy potente, sigue estando limitada a la obtenida por los organismos públicos, pues aunque todos sabemos que las grandes corporaciones digitales disponen de una ingente información sobre nuestros desplazamientos, básicamente porque bastantes app utilizadas en nuestros smartphones les facilitan continuamente nuestra ubicación, parece una información demasiado valiosa y delicada que las empresas no están muy dispuestas a compartir.

En la parte positiva, la evolución en los últimos años de las entidades públicas como el INE, que siguen una continua y vertiginosa adaptación a los tiempos facilitando importante información georreferenciada de la población, siempre de forma anonimizada.

Con todo ello, hemos podido realizar una simulación de mapas de demanda, únicamente en cuanto a las secciones censales generadoras de viajes, dejando para un trabajo futuro la posibilidad de estudiar, a ser posible con mejores datos, dónde estaría la demanda a la hora de volver a casa.

Nos quedamos pendiente también para futuros trabajos, realizar nuestro propio análisis de localización de usuarios a través de Twitter, para comprobar cuántas personas en Sevilla se encuentran geolocalizadas voluntariamente en Twitter y valorar la posibilidad de crear matrices de Origen-Destino a partir de ellos.

Bibliografía

Allaire, J., Xie, Y., McPherson, J., Luraschi, J., Ushey, K., Atkins, A., Wickham, H., Cheng, J., Chang, W. & Iannone, R. (2020). *Rmarkdown: Dynamic documents for r*.

Banister, D. (2003). Critical pragmatism and congestion charging in london. *International Social Science Journal*, **55**, 249–264.

Banister, D. (2008). The sustainable mobility paradigm. *Transport policy*, **15**, 73–80.

Banister, D. & Hickman, R. (2007). How to design a more sustainable and fairer built environment: Transport and communications. *Intelligent Transport Systems, IEE Proceedings*, **153**, 276–291.

Banister, D. & Marshall, S. (2000). *Encouraging transport alternatives: Good practice in reducing travel*. Stationery Office.

Barth, M. & Shaheen, S. (2016). Classification of shared vehicle systems.

Batty, M. (2013). Big data, smart cities and city planning. *Dialogues in Human Geography*, **3**, 274–279.

Blanford, J. (2015). Geo-located tweets. enhancing mobility maps and capturing cross-border movement. *PLoS ONE*, **10**.

Bosque-Sendra, J. (2015). Neogeografía, big data y tig: Problemas y nuevas posibilidades. *Polígonos. Revista de Geografía*, 165.

Caceres, N., Romero, L., Benitez, F. & Del Castillo, J. (2012). Traffic flow estimation models using cellular phone data. *Intelligent Transportation Systems, IEEE Transactions on*, **13**, 1430–1441.

Cass, N., Shove, E. & Urry, J. (2005). Social exclusion, mobility and access1. *The Sociological Review*, **53**, 539–555.

Cepolina, E. & Farina, A. (2012). A new shared vehicle system for urban areas. *Transportation Research Part C Emerging Technologies*, **21**.

Cheng, Z., Caverlee, J. & Lee, K. (2010). You are where you tweet: A content-based approach to geo-locating twitter users. *International Conference on Information and Knowledge Management, Proceedings*, pp. 759–768.

Clarke, M. (2016). Big data in transport. *Institution of Engineering and Technology Sector Insights*, 1–70.

Dahl, D.B., Scott, D., Roosen, C., Magnusson, A. & Swinton, J. (2019). *Xtable: Export tables to latex or html*.

Degele, J., Gorr, A., Haas, K., Kormann, D., Krauss, S., Lipinski, P., Tenbih, M.,

- Koppenhoefer, C., Fauser, J. & Hertweck, D. (2018). Identifying e-scooter sharing customer segments using clustering. pp. 1–8.
- Ebadi, N., Kang, J. & Hasan, S. (2017). Constructing activity-mobility trajectories of college students based on smart card transaction data. *International Journal of Transportation Science and Technology*, **6**.
- Espié, S., Boubezoul, A., Aupetit, S. & Bouaziz, S. (2013). Data collection and processing tools for naturalistic study of powered two-wheelers users' behaviours. *Accident; analysis and prevention*, **58**.
- Europe, E. (2015). Big data europe for smart , green and integrated transport 1st workshop report. *22th World Congress on ITS*.
- Galouchko, K. (2020). Wall street mines apple and google mobility data to spot revival. *Bloomberg*.
- García Paredes, I. (2013). *La movilidad cotidiana en las regiones urbanas de andalucía. la movilidad por razón de trabajo* (J. de Andalucía, Ed.). Junta de Andalucía.
- Gomez, J. & Sobrino, N. (2020). Exploring the adoption of moped scooter-sharing systems in spanish urban areas. *Cities*, 102424.
- Gutiérrez-Puebla, J., García Palomares, J.C. & Henar Salas-Olmedo, M. (2016). Big (geo)Data en ciencias sociales: Retos y oportunidades. *Revista de Estudios Andaluces*, 1–33.
- Hecht, B., Hong, L., Suh, B. & Chi, E. (2011). Tweets from justin beiber's heart: The dynamics of the 'location' field in user profiles. *Conference on Human Factors in Computing Systems - Proceedings*, pp. 237–246.
- Howe, E. & Jakobsen, F.J. (2019). *Global scooter sharing market report*.
- IECA. (2019). Demarcaciones censales, de datos espaciales de referencia de andalucía (dera).
- Illgen, S. & Höck, M. (2018). Literature review of the vehicle relocation problem in one-way car sharing networks. *Transportation Research Part B: Methodological*, **120**.
- INE. (2019). Atlas de distribución de renta de los hogares. indicadores de renta media.
- Jorge, D. & Homem de Almeida Correia, G. (2013). Carsharing systems demand estimation and defined operations: A literature review. *European Journal of Transport and Infrastructure Research*, **13**, 201–220.
- Kafyeke, T. (2017). Sharing is caring: The rise of electric scooters. *RESET. Digital for Good*.
- Kopp, P. (2011). The unpredicted rise of motorcycles: A cost benefit analysis of the paris case. *Transport Policy*, **18**, 613–622.
- Li, X., Ma, J., Cui, J., Ghiasi, A. & Zhou, F. (2016). Design framework of large-scale one-way electric vehicle sharing systems: A continuum approximation model. *Transportation Research Part B: Methodological*, **88**, 21–45.
- Li, T., Sun, D., Peng, J. & Yang, K. (2018). Smart card data mining of public transport destination: A literature review. *Information*, **9**, 18.
- Luque-Calvo, P.L. (2017). *Escribir un trabajo fin de estudios con r markdown*. Disponible

en <http://destio.us.es/calvo>.

Lyons, G. & Kenyon, S. (2003). Social participation, personal travel and internet use.

Lyons, G. & Urry, J. (2005). Travel time use in the information age. *Transportation Research Part A: Policy and Practice*, **39**, 257–276.

Marquet, O. & Miralles-Guasch, C. (2016). City of motorcycles. on how objective and subjective factors are behind the rise of two-wheeled mobility in barcelona. *Transport Policy*, **52**, 37–45.

Martin, E. & Shaheen, S. (2016). Impacts of car2go on vehicle ownership, modal shift, vehicle miles traveled, and greenhouse gas emissions: An analysis of five north american cities.

Miralles-Guasch, C. & Melo, M. (2013). Las fuentes de información sobre movilidad: La visión de los profesionales. ejemplo de aplicación de metodología delphi. *Rev Transp Territ*, **8**, 100–116.

Miralles-Guasch, C., Melo, M. & Marquet, O. (2014). On user perception of private transport in barcelona metropolitan area: An experience in an academic suburban space. *Journal of Transport Geography*, **36**, 24–31.

Moro, E. (2016). Ciudades movilidad y social media. *VII Congreso Estatal RITSI*.

Módenes, J.A. (2008). Movilidad espacial, habitantes y lugares: Desafíos conceptuales y metodológicos para la geodemografía. *Estudios Geográficos. CSIC*, **69**, 157–178.

Nair, R. & Miller-Hooks, E. (2014). Equilibrium network design of shared-vehicle systems. *European Journal of Operational Research*, **235**, 47–61.

Noland, R.B. & Polak, J.W. (2002). Travel time variability: A review of theoretical and empirical issues. *Transport Reviews*, **22**, 39–54.

Osorio Arjona, J. & García-Palomares, J. (2017). Nuevas fuentes y retos para el estudio de la movilidad urbana. *Cuadernos Geográficos, Universidad de Granada (0210-5462)*, **56**, 247–267.

Pronello, C., Longhi, D. & Gaborieau, J.-B. (2018). Smart card data mining to analyze mobility patterns in suburban areas. *Sustainability*, **10**, 3489.

R Core Team. (2016). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria.

Ribeiro, J. & Pappa, G. (2017). Strategies for combining twitter users geo-location methods. *GeoInformatica*, 1–25.

RStudio Team. (2015). *RStudio: Integrated development environment for r*. RStudio, Inc., Boston, MA.

Sánchez, R., Timbiano, R. & Medina, W. (2009). Servicio de localización a través de una red umts.

Schwanen, T. (2016). Geographies of transport ii: Reconciling the general and the particular. *Progress in Human Geography*, **41**.

Shaheen, S., Chan, N. & Micheaux, H. (2015a). One-way carsharing's evolution and operator perspectives from the americas. *Transportation*, **42**.

Shaheen, S., Chan, N., Bansal, A. & Cohen, A. (2015b). Shared mobility: A sustainability

& technologies workshop: Definitions, industry developments, and early understanding. *Transportation Sustainability Research Center. UC Berkeley.*

Shaheen, S., Cohen, A. & Jafee, M. (2018). *Innovative mobility: Carsharing outlook.*

Sobrino, N. & Monzón, A. (2014). The impact of the economic crisis and policy actions on ghg emissions from road transport in spain. *Energy Policy*, **74**, 486–498.

Tascón, M. & Coullaut, A. (2017). *Big data y el internet de las cosas: Qué hay detrás y cómo nos va a cambiar*, First Editionn. (Catarata, Ed.). Catarata.

Techopedia. ‘Definition - what does business intelligence (bi) mean?’

WeAreSocial. (2019). Informe de wearesocial y hootsuite.

Wickham, H. (2019). *Stringr: Simple, consistent wrappers for common string operations.*

Wickham, H., Chang, W., Henry, L., Pedersen, T.L., Takahashi, K., Wilke, C., Woo, K., Yutani, H. & Dunnington, D. (2020). *Ggplot2: Create elegant data visualisations using the grammar of graphics.*

Wickham, H., François, R., Henry, L. & Müller, K. (2019). *Dplyr: A grammar of data manipulation.*

Xie, Y. (2020). *Knitr: A general-purpose package for dynamic report generation in r.*