



Escola d'Enginyeria de Telecomunicació i  
Aeroespacial de Castelldefels

UNIVERSITAT POLITÈCNICA DE CATALUNYA

# TRABAJO FINAL DE GRADO

**TÍTULO DEL TFG: Datos masivos aplicados a la movilidad urbana**

**TITULACIÓN: Grado en Ingeniería de Sistemas de Telecomunicación**

**AUTOR: Daniel Fernández Pizá**

**DIRECTOR: Lluís Jofre Roca**

**FECHA: 30 de Enero de 2020**



**Título:** Datos masivos aplicados a la movilidad urbana

**Autor:** Daniel Fernández Pizá

**Director:** Lluís Jofre Roca

**Fecha:** 30 de Enero del 2020

## Resumen

Este documento pretende mostrar la relevancia de los datos masivos como herramienta para la mejora de la gestión de la movilidad urbana. Para ello, se representan y analizan datos de movilidad del ámbito del STI (Sistema Tarifario Integrado) del área de Barcelona y se obtiene el factor que determina en mayor medida la elección del modo de transporte de los habitantes del AMB (Área Metropolitana de Barcelona) en sus desplazamientos a Barcelona utilizando técnicas de aprendizaje automático.

La representación de datos y el ejercicio de aprendizaje automático se ha realizado utilizando un entorno virtual llamado Google Colaboratory (también llamado Google Colab en su forma abreviada), el cual permite ejecutar y programar Python en el navegador sin necesidad de configuración previa y con acceso gratuito a GPUs (Graphics Processing Units).

La estructura del documento es la siguiente:

Un primer capítulo dedicado a caracterizar el AMB (municipios que la componen, localización, demografía y economía).

Acto seguido, se representan y analizan datos del ámbito del STI del área de Barcelona.

El tercer capítulo es un tutorial acerca del funcionamiento básico del entorno Google Colab.

Finalmente, se realiza un análisis predictivo con el fin de conocer cuál es la principal causa (distancia, coste del viaje en transporte privado o coste del viaje en transporte público) que motiva a los habitantes del AMB a elegir un modo de transporte u otro en sus desplazamientos a Barcelona.

**Título:** Datos masivos aplicados a la movilidad urbana

**Autor:** Daniel Fernández Pizá

**Director:** Lluís Jofre Roca

**Fecha:** 30 de Enero del 2020

## Overview

This document aims to show the relevance of Big Data as a tool for improving urban mobility management. To this end, mobility data from the STI (Integrated Tariff System) ambit of the Barcelona area are represented and analysed, and the factor that most determines the choice of transport mode of the inhabitants of the AMB (Barcelona Metropolitan Area) in their journeys to Barcelona is obtained using machine learning techniques.

The data representation and machine learning exercise has been done using a virtual environment called Google Colaboratory (also called Google Colab for short), which allows you to run and program Python in the browser without previous configuration and with free access to GPUs (Graphics Processing Units).

The structure of the document is as follows:

A first chapter dedicated to characterize the AMB (municipalities that compose it, location, demography and economy).

Then, data from the STI ambit of the Barcelona area are represented and analyzed.

The third chapter is a tutorial about the basic functioning of the Google Colab environment.

Finally, a predictive analysis is made in order to know what is the main cause (distance, cost of the trip in private transport or cost of the trip in public transport) that motivates the inhabitants of the AMB to choose one mode of transport or another in their trips to Barcelona.

# ÍNDICE

<b>INTRODUCCIÓN .....</b>	<b>1</b>
<b>Capítulo 1. Área Metropolitana de Barcelona .....</b>	<b>3</b>
1.1. Localización, usos del suelo y municipios metropolitanos .....	3
1.2. Demografía .....	5
1.2.1. Evolución de la población .....	5
1.2.2. Proyección de la población .....	8
1.3. Economía.....	11
1.3.1. Tasas de variación en volumen del PIB y PIB per cápita .....	11
1.3.2. Tasa de ocupación y paro .....	12
1.3.3. Tasa de ocupación y de paro juvenil .....	16
1.3.4. Salarios y brecha salarial por género .....	16
<b>Capítulo 2. Representación y análisis de datos de movilidad.....</b>	<b>18</b>
2.1. Caracterización Sistema Tarifario Integrado (STI) del área de Barcelona .....	18
2.2. Movilidad en el STI .....	19
2.2.1. Motivo del desplazamiento .....	19
2.2.2. Modo de transporte .....	20
2.2.3. Relación entre el motivo del desplazamiento y el modo de transporte .....	22
2.2.4. Modo de transporte en función del ámbito territorial .....	23
2.2.5. Modo de transporte en función de la comarca .....	24
2.2.6. Flujos intercomarcales .....	25
<b>Capítulo 3. Máquina virtual para un entorno de machine learning .....</b>	<b>28</b>
3.1. El entorno Google Colaboratory .....	28
3.2. ¿Por qué usar Google Colaboratory?.....	28
3.3. Funcionamiento y componentes básicos .....	29
3.3.1. El entorno de ejecución.....	32
3.3.2. Cómo utilizar un entorno con GPU o cambiar la versión de Python.....	34
3.4. Subir y utilizar archivos locales o externos .....	36
3.4.1. Desde local.....	36
3.4.2. Desde Google Drive.....	37
<b>Capítulo 4. Análisis predictivo para determinar el factor que más pesa en la elección del modo de transporte .....</b>	<b>39</b>
4.1. Presentación de los datos.....	39

4.2. Obtención y análisis de los resultados .....	40
<b>Capítulo 5. Conclusiones y ámbitos de trabajo futuros.....</b>	<b>45</b>
5.1. Conclusiones.....	45
5.2. Ámbitos de trabajo futuros .....	46
<b>REFERENCIAS.....</b>	<b>47</b>

## INTRODUCCIÓN

La movilidad en las ciudades y áreas metropolitanas demanda más actuaciones decisivas en favor de una movilidad sostenible atendiendo a las directrices europeas y, para ello, la tecnología en general y las TIC pueden contribuir de forma decisiva. Estas actuaciones, teniendo en cuenta la complejidad de las áreas urbanas, deben estar fundamentadas en una amplia toma de datos. Así, contar con una gran cantidad y variabilidad de datos de calidad permitiría defender mejor los proyectos (necesidad y viabilidad). Es aquí donde los datos masivos adquieren una importancia vital para llevar a cabo la implantación de un modelo de movilidad sostenible.

Hasta ahora se han venido realizando amplias campañas de trabajo de campo, basadas en gran parte en encuestas telefónicas y, en menor medida, encuestas domiciliarias presenciales, las cuáles presentan una serie de problemas que incrementan el sesgo en este tipo de estudios:

- Coste elevado y, como consecuencia, el tamaño de la muestra que se realiza acostumbra a ser muy reducido.
- Disminución significativa de los hogares con teléfono fijo y las bases de datos no son tan fáciles de manejar y mantener.
- Dependencia del hogar cuando realmente la movilidad depende del individuo.
- La información obtenida generalmente corresponde a un día laborable tipo o medio.

Viendo las limitaciones de las encuestas, aparece el término Big Data o datos masivos como alternativa para conseguir una gestión óptima de la movilidad en las grandes metrópolis. En un contexto globalizado e interconectado como el actual, millones de dispositivos que operan en la nube registran un sinfín de datos que cada uno de nosotros emitimos consciente o inconscientemente a diario. El Big Data, integrado en un sistema más amplio, que recoja y analice datos del sistema viario de las ciudades, puede ser utilizado como materia prima para diseñar un sistema de movilidad más inteligente, que optimice los tiempos y costes asociados al transporte, y gestione de manera más eficaz contratiempos como atascos, obras, accidentes, etc.

En la actualidad, existen aplicaciones que recopilan datos de manera masiva y en tiempo real y los tratan también en tiempo real para extraer información valiosa que pueda ayudar en la toma de decisiones y en la definición de soluciones alternativas de movilidad basadas en información abundante y precisa. A pesar de que aportan una solución tecnológica de gran calidad basada en información precisa de GPS y algoritmos y modelos matemáticos ya

probados, presentan todavía algunos retos para su aplicación. El principal de ellos es que requieren de datos que se recopilan por una aplicación que debe instalarse en los móviles. Esto no es fácil, puesto que los usuarios y ciudadanos no siempre cooperan.

Este proyecto pretende realizar una primera aproximación a la presentación de datos de movilidad y al uso de machine learning para hacer análisis predictivos utilizando Google Colab.

En el capítulo 1, se define el área metropolitana de Barcelona (municipios que la componen, extensión, etc.).

En el capítulo 2, se representan y analizan datos de movilidad del ámbito del Sistema Tarifario Integrado (STI) del área de Barcelona recopilados a través de encuestas haciendo uso de Google Colab.

En el capítulo 3, se explica que es Google Colab, cómo funciona y cuáles son sus ventajas respecto a otras alternativas.

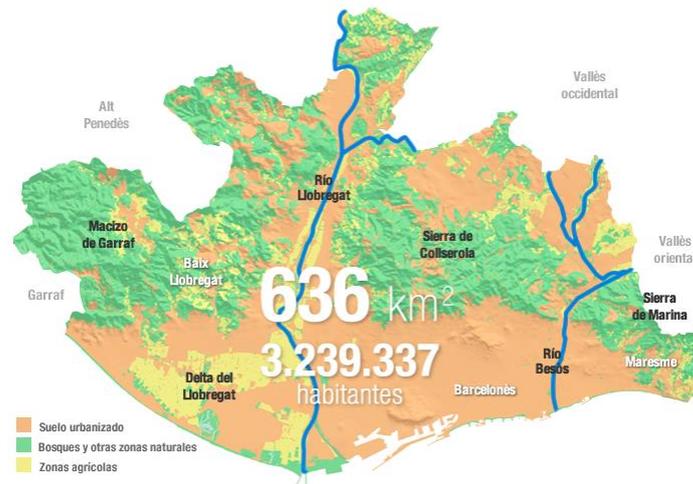
En el capítulo 4, se determina cuál es el factor que más peso tiene en la elección del modo de transporte de los residentes de los municipios del AMB en los flujos de conexión con Barcelona.

Finalmente, en el capítulo 5, se presentan unas primeras conclusiones y ámbitos de trabajo futuros.

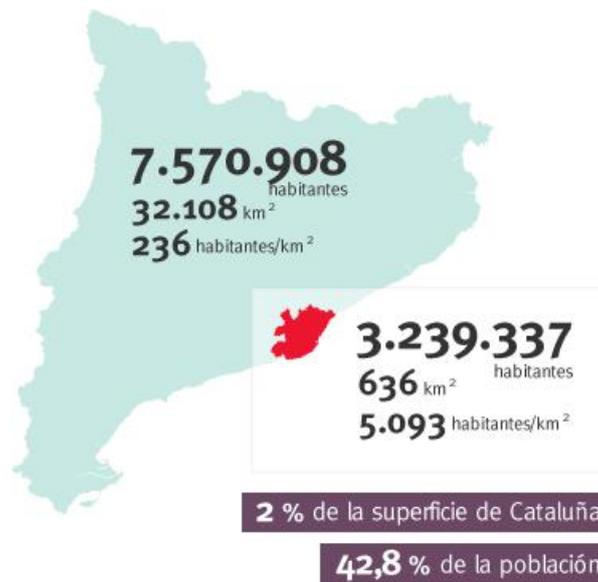
# Capítulo 1. Área Metropolitana de Barcelona

## 1.1. Localización, usos del suelo y municipios metropolitanos

El área metropolitana de Barcelona ocupa una posición estratégica en el sur de Europa, en el corazón del corredor mediterráneo que comunica España con el resto del continente. Esta localización privilegiada le ha permitido convertirse en el epicentro de Cataluña. Su territorio comprende los espacios agrícolas del Delta del Llobregat, las zonas totalmente urbanizadas del llano de Barcelona y las grandes áreas verdes de los macizos de Garraf, Collserola y la sierra de Marina. Viven 3.239.337 personas y tiene un territorio de 636  $km^2$ . En términos de población, representa un 42.8% de la población de Cataluña mientras que, en términos de superficie, ocupa únicamente un 2% de la superficie catalana. Constituye una de las regiones de mayor dimensión de Europa y ocupa la octava posición en cuanto a población. El 48% del territorio está urbanizado y el resto está ocupado por bosques y zonas agrícolas. Los municipios que la componen son los siguientes: Badalona, Badia del Vallès, Barberà del Vallès, Barcelona, Begues, Castellbisbal, Castelldefels, Cerdanyola del Vallès, Cervelló, Corbera de Llobregat, Cornellà de Llobregat, El Papiol, El Prat de Llobregat, Esplugues de Llobregat, Gavà, L'Hospitalet de Llobregat, La Palma de Cervelló, Molins de Rei, Montcada i Reixac, Montgat, Pallejá, Ripollet, Sant Adrià de Besòs, Sant Andreu de la Barca, Sant Boi de Llobregat, Sant Climent de Llobregat, Sant Cugat del Vallès, Sant Feliu de Llobregat, Sant Joan Despí, Sant Just Desvern, Sant Vicenç dels Horts, Santa Coloma de Cervelló, Santa Coloma de Gramenet, Tiana, Torrelles de Llobregat y Viladecans [5],[6].



**Mapa 1.1** Usos del suelo del Área metropolitana de Barcelona



**Mapa 1.2** Localización del Área Metropolitana de Barcelona en Cataluña

## 1.2. Demografía

### 1.2.1. Evolución de la población

La evolución de la población tanto del AMB como de Cataluña en los últimos años presenta dos etapas bien diferenciadas: crecimiento hasta 2009 y estancamiento después de este año. Cabe decir que el crecimiento fue más rápido en Cataluña que en el área metropolitana, de este hecho resulta una pérdida de peso del área metropolitana sobre Cataluña, pasando del 46% de 2003 a un 43% en 2009, año en que se estancan las dinámicas. Entre 2017 y 2018 se ha seguido dando un estancamiento, aunque se pueden apreciar algunas diferencias entre los municipios del AMB. El conjunto de municipios ganó 12.987 habitantes, lo que representa el 0,40% respecto al año anterior. Es remarcable el crecimiento prácticamente nulo del municipio de Barcelona (pierde 466 habitantes, el 0,03%), y el crecimiento relativamente importante de los municipios grandes de su alrededor, con L'Hospitalet de Llobregat a la cabeza, con un aumento de 3.719 personas (+1,45%), pero también Badalona (1.893 habitantes, +0.88%) y Santa Coloma de Gramenet (1.224 habitantes, +1.04%) [7]

**Tabla 1.1** Variación de la población de los municipios del AMB, en valor absoluto i en %, 2017-2018

	<u>2017</u>	<u>2018</u>	<u>Variació</u>	<u>% variació</u>
Badalona	215.848	217.741	1.893	0,88
Badia del Vallès	13.466	13.417	-49	-0,36
Barberà del Vallès	32.860	32.839	-21	-0,06
Barcelona	1.620.809	1.620.343	-466	-0,03
Begues	6.830	6.961	131	1,92
Castellbisbal	12.297	12.332	35	0,28
Castelldefels	65.954	66.375	421	0,64
Cerdanyola del Vallès	57.723	57.740	17	0,03
Cervelló	8.909	8.970	61	0,68
Corbera de Llobregat	14.439	14.643	204	1,41
Cornellà de Llobregat	86.610	87.173	563	0,65
Esplugues de Llobregat	45.890	46.355	465	1,01
Gavà	46.538	46.705	167	0,36
Hospitalet de Llobregat, l'	257.349	261.068	3.719	1,45
Molins de Rei	25.492	25.687	195	0,76
Montcada i Reixac	35.063	35.599	536	1,53
Montgat	11.748	11.819	71	0,60
Pallejà	11.416	11.486	70	0,61
Palma de Cervelló, la	2.998	2.982	-16	-0,53
Papiol, el	4.102	4.103	1	0,02
Prat de Llobregat, el	63.897	64.132	235	0,37
Ripollet	37.899	38.347	448	1,18
Sant Adrià de Besòs	36.624	36.669	45	0,12
Sant Andreu de la Barca	27.303	27.332	29	0,11
Sant Boi de Llobregat	82.142	82.904	762	0,93
Sant Climent de Llobregat	4.038	4.107	69	1,71
Sant Cugat del Vallès	89.516	90.664	1.148	1,28
Sant Feliu de Llobregat	44.198	44.474	276	0,62
Sant Joan Despí	33.873	34.084	211	0,62
Sant Just Desvern	17.201	17.494	293	1,70
Sant Vicenç dels Horts	27.982	27.901	-81	-0,29
Santa Coloma de Cervelló	8.082	8.179	97	1,20
Santa Coloma de Gramenet	117.597	118.821	1.224	1,04
Tiana	8.645	8.709	64	0,74
Torrelles de Llobregat	5.950	5.945	-5	-0,08
<u>Viladecans</u>	<u>65.993</u>	<u>66.168</u>	<u>175</u>	<u>0,27</u>
<b>Total AMB</b>	<b>3.247.281</b>	<b>3.260.268</b>	<b>12.987</b>	<b>0,40</b>

Por otro lado, el proceso de envejecimiento demográfico que se viene produciendo desde hace décadas en los grandes entornos urbanos occidentales no es ajeno al AMB, donde actualmente uno de cada cinco habitantes tiene 65 años o más. El año 2040, será uno de cada cuatro habitantes. Esto quiere decir que la población mayor está adquiriendo cada vez más peso en la estructura poblacional metropolitana. Según el Padrón municipal de habitantes, entre el año 2000 y el 2017, la edad media en la metrópolis se ha incrementado aproximadamente 2 años, de 41,3 a 43,1 años. Además, entre el 2000 y el 2018, la población metropolitana de 65 años o más ha pasado de 520.078 a 643.347 habitantes. Un incremento porcentual del 23.7% que supone un aumento del peso del colectivo en la estructura poblacional de 2 puntos, pasando del 17.8% al 19.7%. Este incremento resulta especialmente importante en los conjuntos más envejecidos de población

debido principalmente al aumento de la esperanza de vida<sup>1</sup>. La población metropolitana de 85 años o más se ha incrementado un 92.5%, lo que se ve reflejado también en el índice de sobreenvjecimiento<sup>2</sup> (10.7 el año 2000 i 16.6 el año 2018) [8].

Otro aspecto a tener en cuenta en el proceso de envejecimiento en la metrópolis es su manifestación territorial. En primer lugar, cabe decir que Barcelona mantiene actualmente una estructura poblacional más envejecida que la de la periferia. El peso de la población mayor<sup>3</sup> y los índices de envejecimiento<sup>4</sup>, sobreenvjecimiento y dependencia de la gente mayor<sup>5</sup>, así lo indican (**Tabla 1.2**). Pero lo que cabe resaltar es que el proceso de envejecimiento está siendo más intensivo en la primera corona metropolitana que en el municipio de Barcelona, de manera que la distribución de la población mayor está tendiendo a ser más homogénea territorialmente en la metrópolis [8].

En cualquier caso, hay matices que es importante señalar acerca de este fenómeno. La población mayor, aunque ha aumentado en términos absolutos, ha perdido peso respecto a la población menor de 16 años (de 130,4 en el 2000, al 128,9 en el 2018). No obstante, como muestra la **Tabla 1.2** (en la siguiente página), esta reducción es debida básicamente al municipio de Barcelona (19,4 puntos menos respecto al 2000), mientras que en la primera corona metropolitana la tendencia ha sido claramente la contraria (crecimiento de 16,4 puntos). En cambio, la tendencia al sobreenvjecimiento es clara en toda el área metropolitana. El conjunto de población más envejecido (85 años o más) aumenta su representación en la pirámide poblacional, pero de forma más acusada en el centro de la metrópolis (incremento de 7.6 en Barcelona y 4.5 puntos en el resto del área metropolitana). En relación a la población potencialmente activa (índice de dependencia demográfica de la gente mayor), la gente mayor de la metrópolis también incrementa su presencia, pero aquí también de manera exclusiva en la periferia metropolitana (incremento de 9.1 puntos), ya que el centro metropolitano se mantiene relativamente estable [8].

---

<sup>1</sup> Según Idescat, la esperanza de vida al nacer ha pasado entre el año 2000 y 2016 de los 79,6 años a los 83,6.

<sup>2</sup> El índice de sobreenvjecimiento es el porcentaje de población muy mayor (85 años o más) respecto de la población mayor (65 años o más). Al ser un porcentaje, un valor del 50% significa que la mitad de la población de 65 años o más, tiene 85 o más.

<sup>3</sup> El peso de la población mayor es el porcentaje de población de 65 años o más sobre el conjunto de la población.

<sup>4</sup> El índice de envejecimiento es el nombre de población mayor (65 años o más) por cada 100 jóvenes (población menor de 16 años). Un valor de 200 significa que hay el doble de gente mayor que de gente joven (200 mayores de 64 años por cada 100 menores de 16).

<sup>5</sup> El índice de dependencia de la gente mayor es un indicador de dependencia económica de la gente mayor. Relaciona la población mayor, en edades generalmente inactivas, con la población en edades teóricamente activas. Al venir multiplicado por 100, un valor de 200 significa que hay el doble de gente adulta mayor que gente en edad activa (200 mayores de 64 años, por cada 100 de 16 a 64 años).

**Tabla 1.2** Indicadores demográficos básicos según territorio. Población total. Área metropolitana de Barcelona, 2000-2018

	Barcelona	Área metropolitana sin Barcelona	Área metropolitana de Barcelona	Cataluña
Población de 65 años o más				
2000	22,1	13,3	17,8	17,3
2018	21,5	17,9	19,7	18,7
Variación puntos porcentuales 2000-2018	-0,6	4,6	1,9	1,4
Índex d'envelliment				
2000	179,6	88,3	130,4	118,1
2018	160,2	104,7	128,9	113,4
Variación puntos porcentuales 2000-2018	-19,4	16,4	-1,5	-4,7
Índice de sobreenvjecimiento				
2000	11,6	9,1	10,7	10,7
2018	19,2	13,6	16,6	16,6
Variación puntos porcentuales 2000-2018	7,6	4,5	5,9	5,9
Índice de dependencia gente mayor				
2000	33,7	18,6	26,0	25,5
2018	33,1	27,7	30,4	28,9
Variación puntos porcentuales 2000-2018	-0,6	9,1	4,4	3,4
Relación de masculinidad población 65 años o más				
2000	62,9	72,5	66,3	71,0
2018	66,5	75,4	70,5	74,9
Variación puntos porcentuales 2000-2018	3,6	2,9	4,2	3,9

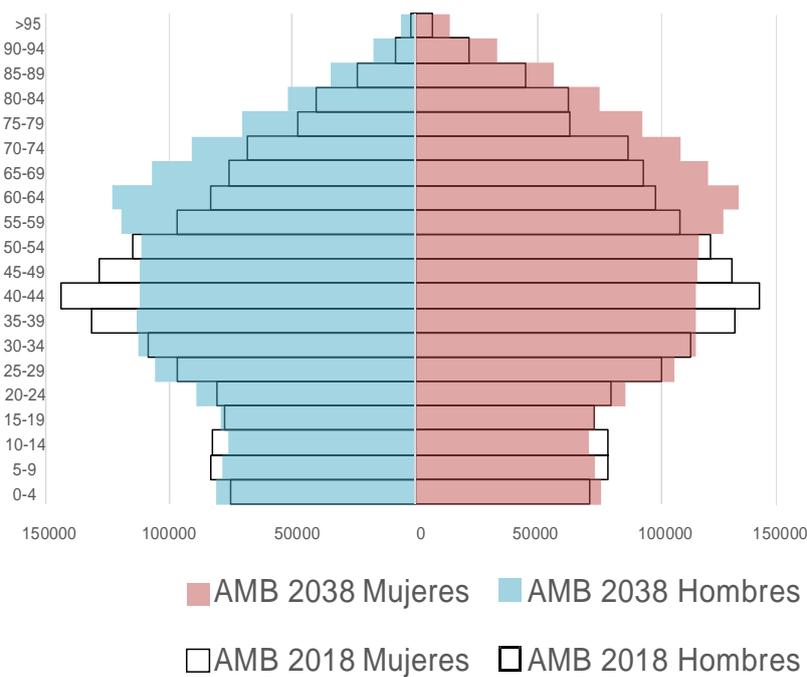
Finalmente, cabe destacar la reducción del desequilibrio entre sexos entre la población de más de 65 en el proceso de envejecimiento de la metrópolis. Los hombres incrementan su peso en la estructura poblacional de manera progresiva tanto en el centro como en la periferia (3.6 y 2.9 puntos, respectivamente), si bien el núcleo se mantiene como un territorio más feminizado que la primera corona [8].

### 1.2.2. Proyección de la población

Habiendo observado la tendencia de envejecimiento experimentada por el área metropolitana de Barcelona durante los últimos años se puede poner en cuestión si esta pauta continuará en el futuro, cuál será su intensidad y cómo

será su distribución a lo largo del territorio. Así, para responder a estas preguntas, se han elaborado unas proyecciones poblacionales a 20 años vista, es decir, hasta el año 2038, y con base 1 de Enero de 2018 en línea con las proyecciones territoriales que proporciona Idescat. En estas proyecciones se han definido tres escenarios que combinan varias hipótesis relativas a cinco componentes demográficos: fecundidad, esperanza de vida, migración con el resto de España, migración con el extranjero y migración interna. Los escenarios contemplados para cada uno de estos componentes son alto, medio y bajo, de manera que, por ejemplo, el escenario alto supone una combinación de fecundidad alta, esperanza de vida alta i migración alta. Con el fin de sintetizar el análisis de las proyecciones, se elige trabajar con un escenario medio que, de acuerdo con Idescat, se trata del escenario más probable de evolución del crecimiento y la estructura demográfica en Catalunya atendiendo a los datos recientes [8].

Los datos de población proyectados a partir de un escenario medio informan de un aumento de la población mayor de unas 231.000 personas en el conjunto del área metropolitana de Barcelona, llegando hasta las 874.400 personas, lo que representaría un 36% más de esta población el 2038. Se puede ver en el **Gráfico 1.1** un ensanchamiento por la cúspide a partir de los 55 años en la pirámide poblacional [8].

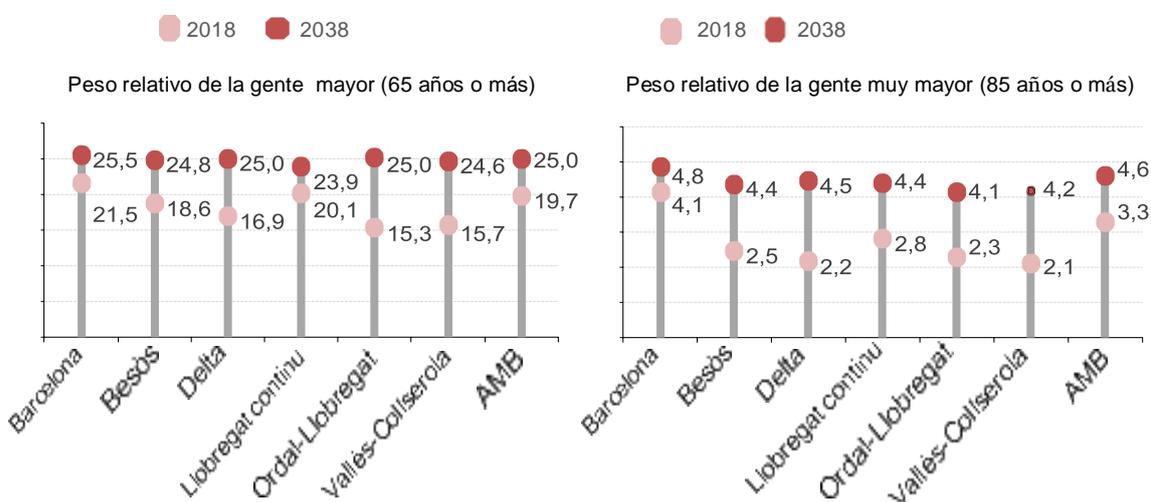


**Gráfico 1.1** Pirámides de población área Metropolitana de Barcelona, 2018 y 2038

Este incremento relativo sería causado en su mayor parte por la población más envejecida, la que tiene o supera los 85 años (49,9%). El progresivo proceso de envejecimiento tendría una evolución desigual en toda la metrópolis, siendo más importante en los subámbitos metropolitanos periféricos de Ordal-Llobregat (86,4%), Vallès-Collserola (78,2%) y Delta (71,5%), tratándose éstos precisamente de aquellos donde la población mayor tiene actualmente un peso menor sobre el conjunto de la población (**Tabla 1.3**). En cambio, el municipio de Barcelona sería donde menos crecería este colectivo (22,1%) y el único para el cual la población más mayor tendría una tasa de incremento inferior a la menos envejecida. Se estima una tendencia a la homogeneización del peso de la población mayor en los diferentes subámbitos situándose alrededor de un cuarto de la población total en el caso de la población de 65 años o más y superior al 4% para la población más envejecida de 85 años o más [8].

**Tabla 1.3** Variación absoluta y relativa de la población mayor según grupos de edad y territorio de residencia. Población de 65 años y más. Área metropolitana de Barcelona, 2018-2038

	Variación absoluta			Variación relativa		
	De 65 a 84 años	de 85 años o más	de 65 anys o más	De 65 a 84 anys	de 85 años o más	de 65 años o más
Barcelona	63.031	14.177	77.208	22,3	21,2	22,1
Besòs	20.006	8.080	28.086	31,4	83,0	38,3
Delta	31.370	10.383	41.754	61,6	138,5	71,5
Llobregat continu	22.110	10.220	32.329	26,0	73,9	32,7
Ordal-Llobregat	15.246	3.402	18.649	83,0	105,7	86,4
Vallès-Collserola	25.967	7.060	33.027	71,1	124,2	78,2
Àrea metropolitana de Barcelona	177.730	53.323	231.053	33,1	49,9	35,9



**Gráfico 1.2.** Peso relativo de la población mayor de 65 años o más y de 85 años o más sobre el total de la población según el territorio de residencia. Área metropolitana de Barcelona, 2018-2038

### 1.3. Economía

#### 1.3.1. Tasas de variación en volumen del PIB y PIB per cápita

El PIB per cápita aumenta progresivamente en todos los ámbitos geográficos definidos en la **Tabla 1.4** a partir del año 2013, siendo este crecimiento de mayor magnitud entre los años 2017 y 2018 ( 5,7% en Barcelona, 6,1% fuera del AMB, 6,4% en el AMB y 5,8% en Cataluña). El PIB per cápita en los municipios del AMB el 2018 es de 38.244 euros, un valor superior al del conjunto de Cataluña (32.000 euros). Destaca el PIB per cápita de Barcelona,

que es de 50.169 euros, prácticamente doblando el del AMB sin Barcelona (26.642).

**Tabla 1.4** PIB per cápita de Barcelona, AMB sin Barcelona, AMB y Cataluña en euros 2012-2018

<u>PIB per cápita</u>	<u>Barcelona</u>	<u>AMB sin Barcelona</u>	<u>AMB Cataluña</u>
2012	42.723	21.512	32.106 26.812
2013	42.386	21.457	31.815 26.688
2014	43.397	22.585	32.865 27.414
2015	44.859	23.425	33.992 28.499
2016	46.259	24.080	35.019 29.445
2017	47.464	24.946	35.943 30.245
2018	50.169	26.462	38.244 32.000

### 1.3.2. Tasa de ocupación y paro

La tendencia observada en la tasa de ocupación<sup>6</sup> entre los años 2015 y 2018 es positiva en todos los casos, produciéndose un incremento de alrededor de 5 puntos porcentuales, excepto en el municipio de Barcelona donde la subida es ligeramente menor, pues se pasa de un 50,8 en el primer trimestre de 2015 a un 54,3 en el último trimestre de 2018, lo que se traduce en un aumento de 3,5 puntos. En cuanto a la segregación por sexos, la tasa de ocupación de la mujer es inferior a la del hombre, manteniéndose en estos años una diferencia más o menos estable de entre 9 y 12 puntos en todos los ámbitos territoriales (el peor caso se da para España, donde la diferencia llega a ser de 11,7 puntos en el último trimestre de 2018). La tasa de ocupación del hombre tiene mayor crecimiento entre 2015 y 2018 que la de las mujeres (2,2 puntos más de crecimiento en España, 1,6 en Cataluña, 1,7 en la provincia de Barcelona y 1,5 en el municipio de Barcelona). Por último, el porcentaje más grande de personas ocupadas en el último trimestre de 2018 corresponde a la provincia de Barcelona (54,9%), seguido de cerca por Cataluña (54,4%) y el municipio de Barcelona (54,3%). España se encuentra lejos de estas cifras con un 50,1% al cierre de 2018. (Véase **Tabla 1.5**)

<sup>6</sup> La tasa de ocupación es la relación que existe entre la población ocupada y la población de 16 años o más. Tasa de ocupación= (población ocupada/población de 16 años o más)\*100.

**Tabla 1.5** Evolución por sexos de la tasa de ocupación en España, Cataluña, Barcelona y la provincia de Barcelona entre 2015 y 2018. Valores expresados en %

Ámbito territorial	Año	Trimestre	Hombre	Mujer	Ambos sexos
España	2015	Primer trimestre	50,7	40,2	45,3
España	2015	Segundo trimestre	52	41,1	46,4
España	2015	Tercer trimestre	52,8	41,3	46,9
España	2015	Cuarto trimestre	52,6	41,7	47
España	2016	Primer trimestre	52,6	41,4	46,8
España	2016	Segundo trimestre	53,2	42,1	47,5
España	2016	Tercer trimestre	53,9	42,5	48,1
España	2016	Cuarto trimestre	53,6	42,6	48
España	2017	Primer trimestre	53,5	42,3	47,8
España	2017	Segundo trimestre	54,6	43,1	48,7
España	2017	Tercer trimestre	55,4	43,5	49,3
España	2017	Cuarto trimestre	54,9	43,5	49,1
España	2018	Primer trimestre	54,5	43,1	48,7
España	2018	Segundo trimestre	55,8	44,2	49,8
España	2018	Tercer trimestre	56,4	44,3	50,2
España	2018	Cuarto trimestre	56,2	44,5	50,1
Cataluña	2015	Primer trimestre	54,3	45,5	49,8
Cataluña	2015	Segundo trimestre	55,8	46	50,7
Cataluña	2015	Tercer trimestre	56,5	46,4	51,3
Cataluña	2015	Cuarto trimestre	56,4	46	51
Cataluña	2016	Primer trimestre	56,5	46,6	51,4
Cataluña	2016	Segundo trimestre	57,4	47,4	52,2
Cataluña	2016	Tercer trimestre	57,7	48,4	52,9
Cataluña	2016	Cuarto trimestre	57,5	47,7	52,5
Cataluña	2017	Primer trimestre	57,2	47,8	52,3
Cataluña	2017	Segundo trimestre	58,3	48,9	53,4
Cataluña	2017	Tercer trimestre	59,5	49	54,1
Cataluña	2017	Cuarto trimestre	59	49,1	53,9
Cataluña	2018	Primer trimestre	58,5	48,9	53,5
Cataluña	2018	Segundo trimestre	59,3	49,6	54,3
Cataluña	2018	Tercer trimestre	59,9	49,7	54,7
Cataluña	2018	Cuarto trimestre	59,5	49,6	54,4
Prov. Barcelona	2015	Primer trimestre	54	46	49,8
Prov. Barcelona	2015	Segundo trimestre	55,7	46,1	50,7
Prov. Barcelona	2015	Tercer trimestre	56,3	46,4	51,1
Prov. Barcelona	2015	Cuarto trimestre	56,7	46,4	51,3
Prov. Barcelona	2016	Primer trimestre	56,7	47,3	51,8
Prov. Barcelona	2016	Segundo trimestre	57,7	48,1	52,7
Prov. Barcelona	2016	Tercer trimestre	58	48,7	53,2

Prov. Barcelona	2016	Cuarto trimestre	58,1	48,5	53,1
Prov. Barcelona	2017	Primer trimestre	58,1	49	53,4
Prov. Barcelona	2017	Segundo trimestre	58,5	49,2	53,6
Prov. Barcelona	2017	Tercer trimestre	59,8	49	54,1
Prov. Barcelona	2017	Cuarto trimestre	59,7	49,7	54,5
Prov. Barcelona	2018	Primer trimestre	59,3	49,6	54,2
Prov. Barcelona	2018	Segundo trimestre	59,5	50,1	54,6
Prov. Barcelona	2018	Tercer trimestre	59,7	49,8	54,6
Prov. Barcelona	2018	Cuarto trimestre	59,9	50,2	54,9
Barcelona	2015	Primer trimestre	54,2	47,9	50,8
Barcelona	2015	Segundo trimestre	56,3	48	51,8
Barcelona	2015	Tercer trimestre	56,2	47,5	51,5
Barcelona	2015	Cuarto trimestre	57,8	47,1	52
Barcelona	2016	Primer trimestre	58,1	47,6	52,4
Barcelona	2016	Segundo trimestre	58,3	49,6	53,6
Barcelona	2016	Tercer trimestre	60,1	48,9	54
Barcelona	2016	Cuarto trimestre	60,3	49,8	54,5
Barcelona	2017	Primer trimestre	60,2	50,7	55
Barcelona	2017	Segundo trimestre	59,2	50	54,3
Barcelona	2017	Tercer trimestre	60,3	48,8	54,3
Barcelona	2017	Cuarto trimestre	59,8	49,7	54,6
Barcelona	2018	Primer trimestre	58,9	49,2	53,8
Barcelona	2018	Segundo trimestre	60,2	49,3	54,5
Barcelona	2018	Tercer trimestre	58,6	49,9	54,1
Barcelona	2018	Cuarto trimestre	58,4	50,6	54,3

La tasa de paro<sup>7</sup> ha experimentado descensos entre 2016 y 2018 en todos los municipios del área metropolitana, siendo los más significativos los casos de Badia del Vallès (3,6 puntos menos pasando del 21% al 17,4%), Sant Vicenç dels Horts (3,4 puntos menos pasando del 16% al 12,6%) y Sant Climent de Llobregat (3,1 puntos menos pasando del 10% al 6,9%). El municipio que presenta una menor tasa de paro en 2018 es Sant Cugat del Vallès (6,1%), seguido de cerca por Begues (6,3%), Sant Just Desvern (6,4%) y Tiana (6,4%). En cambio, los municipios con mayor tasa de paro en 2018 son Badia del Vallès (17,4%) y Sant Adrià de Besòs (15,7%). A mayor distancia, aparecen Ripollet (13,2%), Santa Coloma de Gramenet (13,1%), Badalona (12,7%) Montcada i Reixac (12,6%) y Sant Vicenç dels Horts (12,6%). (Véase **Tabla 1.6**)

<sup>7</sup> La tasa de paro es la relación entre la población desocupada registrada mensualmente en las oficinas de ocupación (SOC) y la población activa estimada trimestralmente.

**Tabla 1.6** Tasa de paro registrado en los municipios metropolitanos los años 2016,2017 y 2018. Valores expresados en %

<b>Municipio</b>	<b>2016</b>	<b>2017</b>	<b>2018</b>
Badalona	14,8	13,7	12,7
Badia del Vallès	21	19	17,4
Barberà del Vallès	13,1	11,5	10,5
Barcelona	10,3	9,5	8,7
Begues	8	6,7	6,3
Castellbisbal	10,8	9,9	8,9
Castelldefels	11,3	10	9,1
Cerdanyola del Vallès	11,1	9,5	8,7
Cervelló	10,5	10	9,1
Corbera de Llobregat	9,9	8,9	7,9
Cornellà de Llobregat	12,8	11,4	10,6
Esplugues de Llobregat	11,3	10,1	9
Gavà	12,7	11,3	10,2
Hospitalet de Llobregat, l'	13,2	11,7	10,7
Molins de Rei	9,8	8,3	7,7
Montcada i Reixac	14,7	13,1	12,6
Montgat	11,1	10,1	9,9
Pallejà	10,9	9	8,2
Palma de Cervelló, la	10,3	10,5	8,8
Papiol, el	11,1	10,4	8,9
Prat de Llobregat, el	13,4	11,6	11,1
Ripollet	15,6	13,9	13,2
Sant Adrià de Besòs	18,3	16,9	15,7
Sant Andreu de la Barca	13,1	11,1	10,6
Sant Boi de Llobregat	14	11,9	11,4
Sant Climent de Llobregat	10	7,4	6,9
Sant Cugat del Vallès	7,5	6,6	6,1
Sant Feliu de Llobregat	10,6	9,2	8,2
Sant Joan Despí	10,2	9	7,9
Sant Just Desvern	7,6	6,9	6,4
Sant Vicenç dels Horts	16	14,1	12,6
Santa Coloma de Cervelló	8,8	7,7	7,1
Santa Coloma de Gramenet	15,7	14,2	13,1
Tiana	7,7	6,9	6,4
Torrelles de Llobregat	10,2	9,3	8,5
Viladecans	13,2	11,9	10,7

### 1.3.3. Tasa de ocupación y de paro juvenil

La tasa de ocupación juvenil (16-24 años), ya sea del municipio de Barcelona, la provincia de Barcelona o de Cataluña, ha seguido con la evolución positiva entre los años 2017 y 2018 situándose en el 31,2%, 34,2% y el 33%, respectivamente (aunque todavía se encuentran lejos de los valores previos a la crisis económica). En el caso de España, la tasa de ocupación experimentó un importante descenso, alcanzando puntualmente valores inferiores al 20%, aunque en los últimos años se ha empezado a recuperar hasta llegar al 24,3% en el 2018. En todos los casos, cabe destacar que la tasa de ocupación juvenil es significativamente más baja que la tasa de ocupación total y que, en general, la diferencia ha estado alrededor de 25 puntos porcentuales.

La tasa de paro juvenil de Barcelona en 2018 se ha situado en el 22,8% de la población activa. Esta cifra es menor que las de la provincia de Barcelona (27,5%), Cataluña (27,7%) y España (33,5%). De nuevo, en todos los casos la tasa de paro juvenil es mucho más elevada, prácticamente el doble, que la tasa de paro total [7].

### 1.3.4. Salarios y brecha salarial por género

Los salarios medios anuales de los trabajadores residentes en los 14 municipios de más de 40000 habitantes del AMB el año 2016 se situaron en los 27.290 euros. Las remuneraciones salariales medias de la mayoría de los municipios del AMB eran inferiores al salario medio total, siendo Santa Coloma de Gramenet el que presentaba un salario medio más bajo (20185 euros/año) y Sant Cugat del Vallès el que presentaba el salario medio más alto (40.769 euros).

La brecha salarial por género, entendida como la diferencia salarial entre hombres y mujeres expresada en porcentaje de los ingresos brutos medios de los hombres, fue del 24% (las mujeres cobraron de media 7.440 euros menos que los hombres) [7].

**Tabla 1.7 Salarios medios por sexo, 14 municipios AMB, euros/año, 2016**

	<u>Total</u>	<u>Home</u>	<u>Dona</u>	<u>Diferència home dona</u>	
				<u>euros/any</u>	<u>en %</u>
Santa Coloma de Gramenet	20.185	23.778	16.472	7.306	30,7
Hospitalet de Llobregat, l'	21.564	24.887	17.989	6.898	27,7
Badalona	22.580	25.725	19.303	6.422	25,0
Cornellà de Llobregat	23.314	27.051	19.311	7.740	28,6
Sant Boi de Llobregat	23.662	27.026	19.788	7.238	26,8
Espanya	23.677	26.797	20.266	6.531	24,4
Prat de Llobregat, el	23.789	27.068	20.239	6.829	25,2
Viladecans	24.255	27.887	19.898	7.989	28,6
Catalunya	25.491	29.074	21.723	7.351	25,3
Esplugues de Llobregat	26.603	29.532	23.194	6.338	21,5
Cerdanyola del Vallès	26.781	31.466	22.221	9.245	29,4
Gavà	27.030	32.529	21.364	11.165	34,3
AMB	27.290	31.003	23.563	7.440	24,0
Sant Feliu de Llobregat	28.093	31.948	23.894	8.054	25,2
Barcelona	29.176	32.819	25.669	7.150	21,8
Castelldefels	29.442	35.022	24.046	10.976	31,3
<u>Sant Cugat del Vallès</u>	<u>40.769</u>	<u>49.342</u>	<u>32.636</u>	<u>16.706</u>	<u>33,9</u>

## Capítulo 2. Representación y análisis de datos de movilidad

### 2.1. Caracterización Sistema Tarifario Integrado (STI) del área de Barcelona

El ámbito territorial del STI (**Mapa 2.1**) lo conforman las siguientes comarcas: Barcelonès, Maresme, Baix Llobregat, Vallès Occidental, Vallès Oriental, Alt Penedès, Bages, Garraf, Anoia, Osona, Berguedà y Moianès. También están incluidos algunos municipios de las comarcas de Selva y Baix Penedès.



**Mapa 2.1** Ámbito territorial STI [9]

El STI tiene una extensión de  $8.112,8 \text{ km}^2$ , lo que supone más del 25% del territorio de Cataluña. La superficie urbanizada es de  $1.004,5 \text{ km}^2$ , lo que corresponde a un 12,4% del ámbito territorial. La densidad total de población es de  $709,4 \text{ hab/km}^2$ , pero considerando solo el suelo urbano, la densidad es de  $5.729,7 \text{ hab/km}^2$  [9].

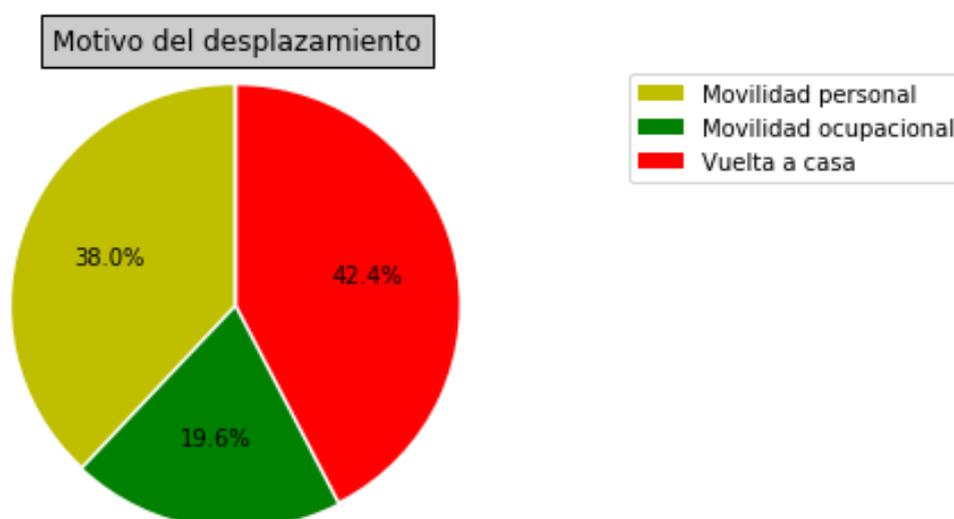
## 2.2. Movilidad en el STI

Hay 4.815.772 personas residentes en el ámbito del STI, las cuales realizan 18.957.915 desplazamientos<sup>8</sup> en un día laborable, lo que se traduce en una media de 3,9 desplazamientos por persona en un día laborable [10].

### 2.2.1. Motivo del desplazamiento

Es necesario definir los motivos de los desplazamientos para hacer la radiografía de la movilidad de un ámbito geográfico. Se distinguen tres tipos de desplazamientos en función del motivo que los propicia: movilidad personal, movilidad ocupacional y la vuelta a casa. La movilidad personal se refiere a los desplazamientos por motivos de ocio, compras, gestiones del hogar, visita médica, etc.; la movilidad ocupacional tiene como objetivo acudir al puesto de trabajo o de estudio; y la vuelta a casa es el viaje de retorno para cualquiera de los otros dos motivos.

En 2018, se producen 7,2 millones de desplazamientos al día por motivos personales, cifra muy superior a los 3,7 millones que se originan por motivos ocupacionales. El resto de desplazamientos son los de vuelta a casa (8 millones de desplazamientos al día) [10]. En el **Gráfico 2.1** se observan los porcentajes que representa cada uno de los motivos respecto al número total de desplazamientos en el STI.

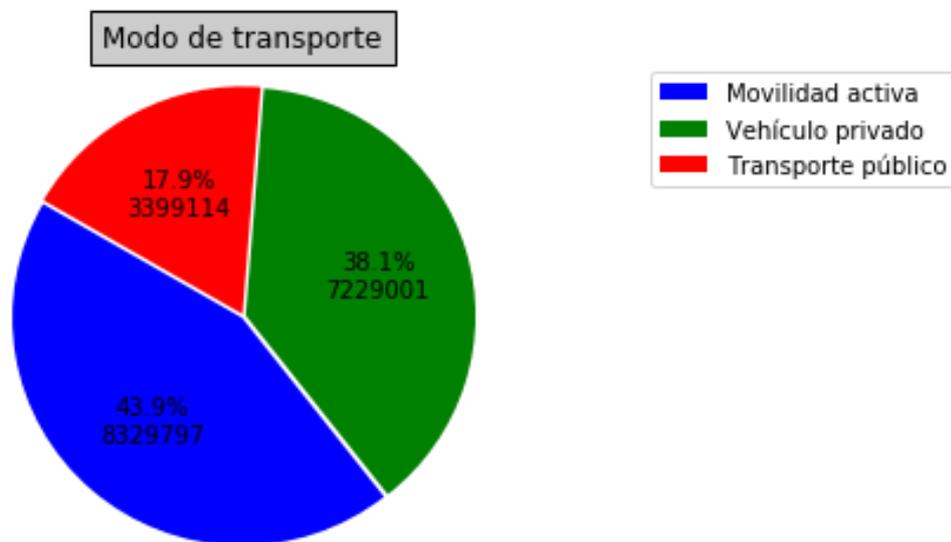


**Gráfico 2.1** Motivos de los desplazamientos en el ámbito STI 2018

<sup>8</sup> Un desplazamiento se corresponde con un único motivo y puede estar compuesto por una o más etapas llevadas a cabo con modos de transporte diferentes

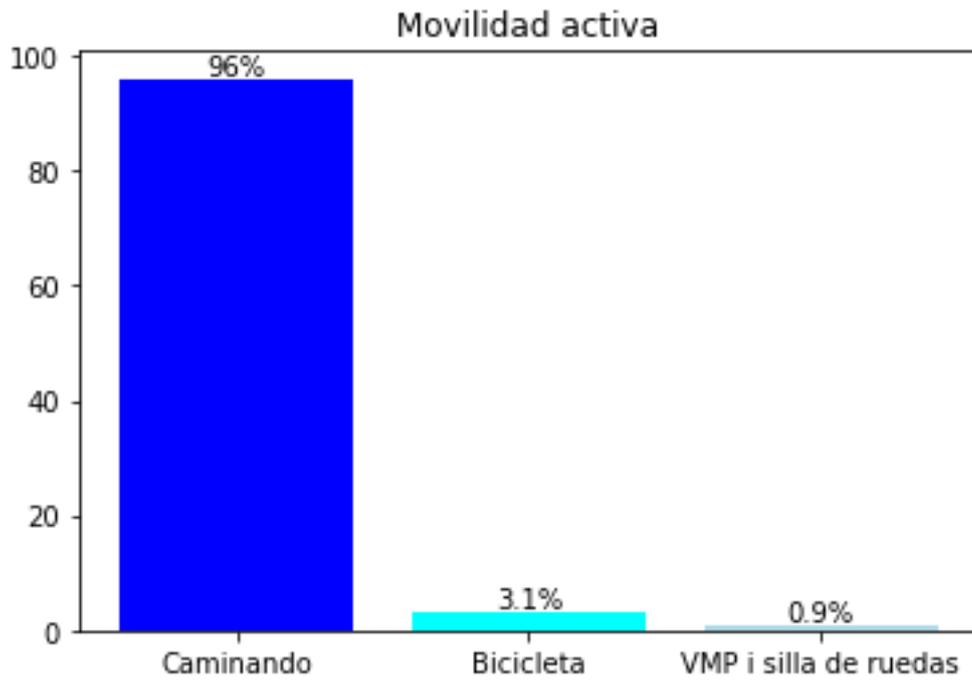
### 2.2.2. Modo de transporte

Se definen tres modos de transporte: movilidad activa (hace referencia a modos no motorizados, tales como caminar o ir en bicicleta), vehículo privado (coche, moto, camión o furgoneta) y transporte público (metro, autobús, tranvía, etc.). En el **Gráfico 2.2** se puede ver que los modos principales de transporte utilizados por la población del STI son la movilidad activa (43,9%) y el vehículo privado (38,1%). En transporte público se realizan el 17,9% de los desplazamientos en día laborable [10].

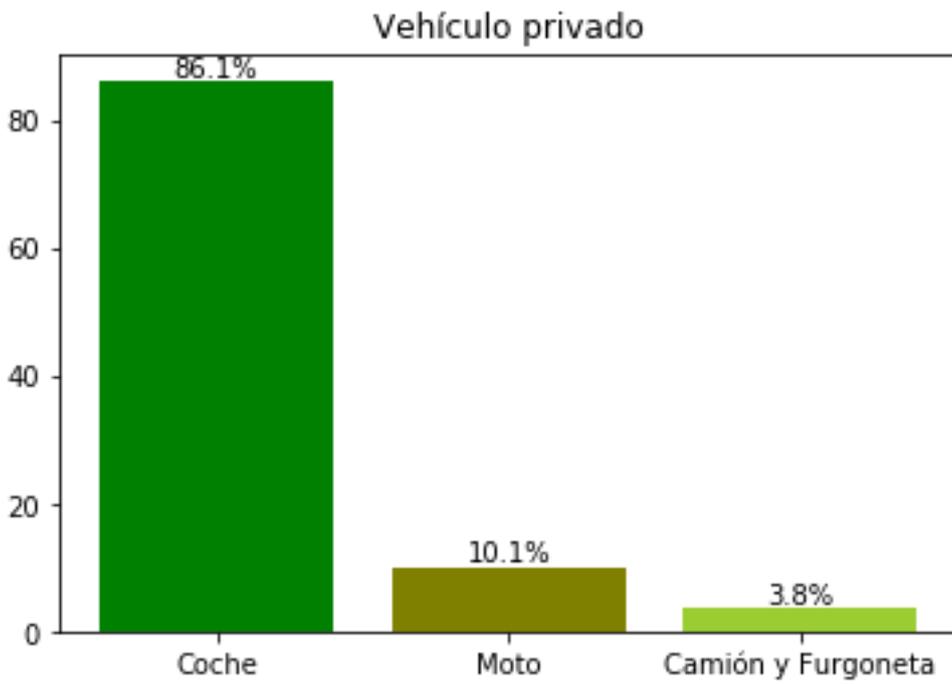


**Gráfico 2.2** Uso modos de transporte residentes STI en 2018

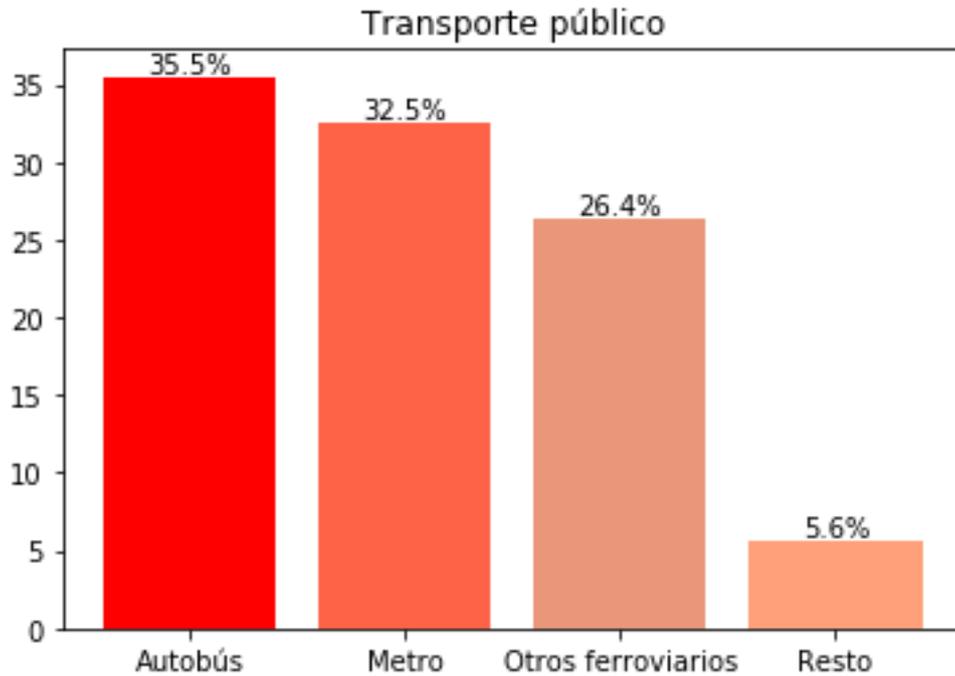
Dentro de la movilidad activa (**Gráfico 2.3**) hay un predominio claro de los desplazamientos a pie (96%) y, en el caso del vehículo privado (**Gráfico 2.4**), el coche se lleva la mayor parte del protagonismo (86,1%). En cuanto al transporte público (**Gráfico 2.5**), el autobús es el más utilizado (35,5%), seguido de cerca por el metro (32,5%) [10].



**Gráfico 2.3** Distribución desplazamientos en modos no motorizados



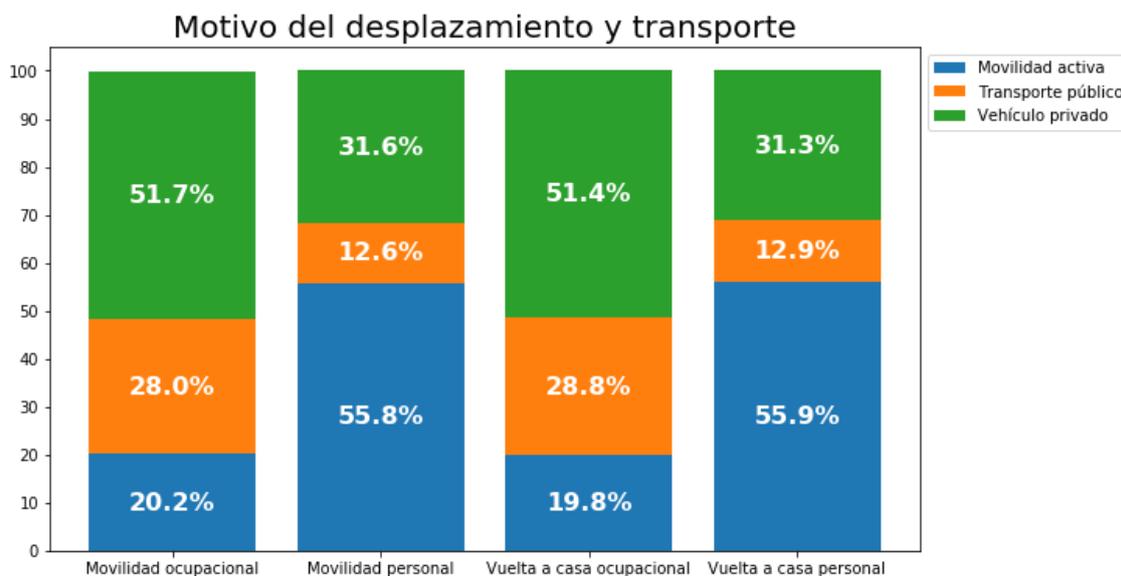
**Gráfico 2.4** Distribución desplazamientos en vehículo privado



**Gráfico 2.5.** Distribución desplazamientos en transporte público

### 2.2.3. Relación entre el motivo del desplazamiento y el modo de transporte

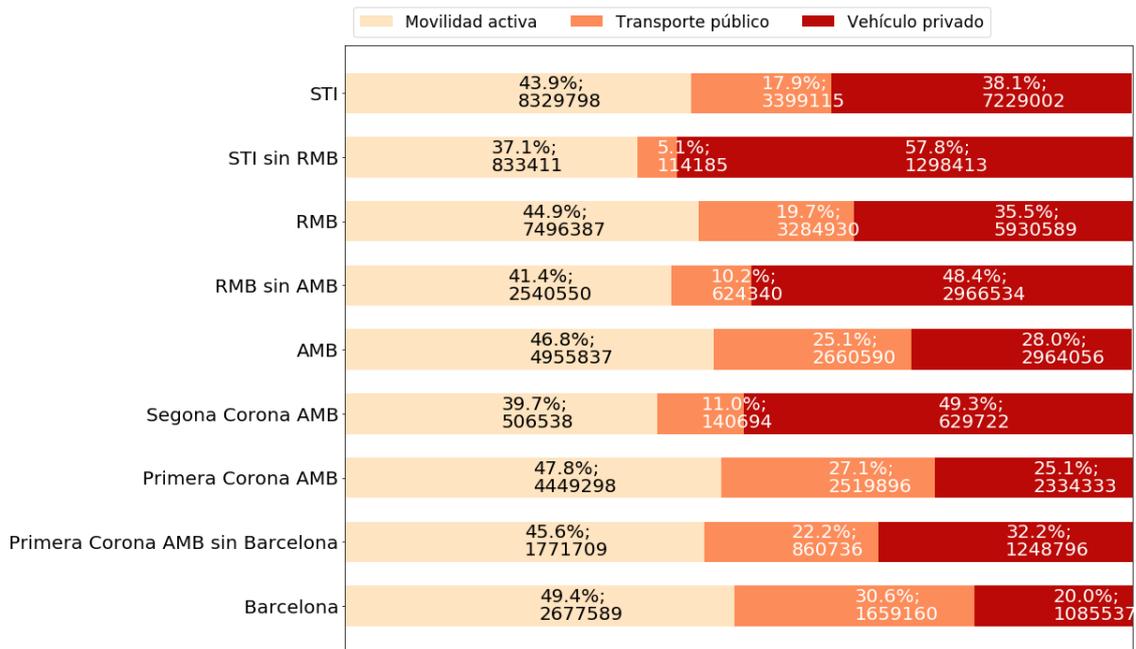
En los desplazamientos al lugar de trabajo o de estudio (movilidad ocupacional) se prioriza el uso del vehículo privado (51,7%) respecto al transporte público (28,0%) y a la movilidad activa (20,0%). En cambio, en los desplazamientos por motivos personales, el modo más utilizado es la movilidad activa (55,8%), seguido del vehículo privado (31,6%) y del transporte público (12,6%). De forma lógica, el modo de transporte elegido para la vuelta a casa, ya sea ocupacional o personal, es el mismo que el de la ida [10]. (Véase **Gráfico 2.6**)



**Gráfico 2.6** Modo de transporte elegido según el motivo del desplazamiento

#### 2.2.4. Modo de transporte en función del ámbito territorial

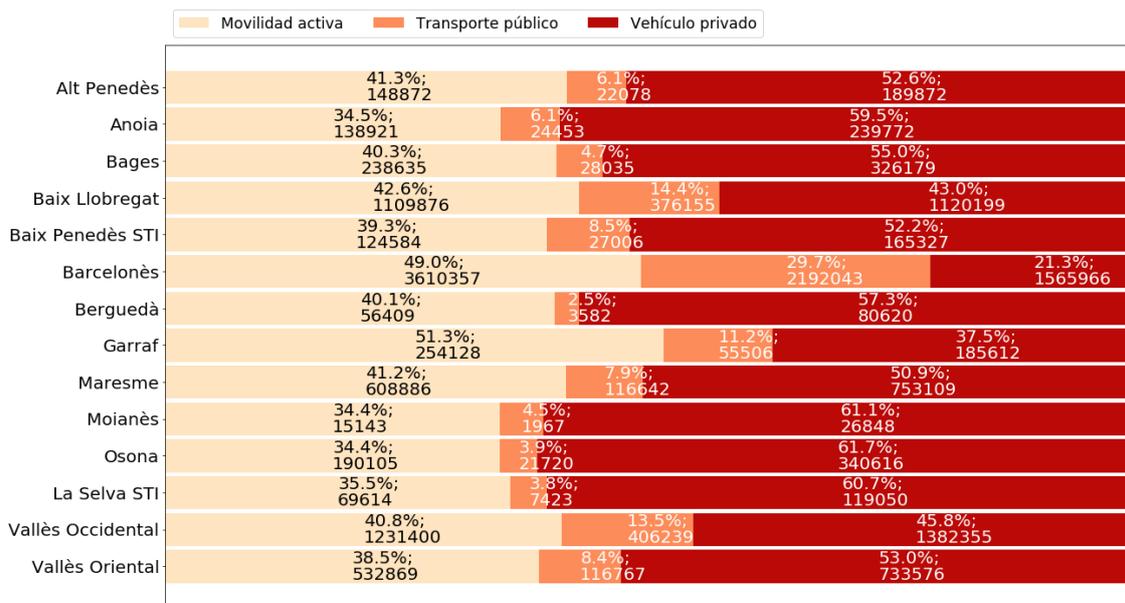
La población del STI da preferencia al uso del vehículo privado cuanto más se aleja el ámbito de residencia de Barcelona, en detrimento del transporte público. En la capital catalana se utiliza el transporte público en el 30,6% de los desplazamientos, mientras que los residentes del resto de la RMB (Región Metropolitana de Barcelona) lo hacen en el 10,2% de sus desplazamientos en día laborable y, en el caso de los residentes del resto del STI (quiere decir que se excluye la RMB), en el 5,1% [10]. El ámbito con un comportamiento más similar a la capital metropolitana es la primera corona del AMB (incluye los municipios de Barcelona, L'Hospitalet de Llobregat, El Prat de Llobregat, Sant Boi de Llobregat, Cornellà de Llobregat, Viladecans, Gavà, Sant Joan Despí, Sant Just Desvern, Sant Feliu de Llobregat, Esplugues de Llobregat, Santa Coloma de Gramenet, Badalona, Sant Adrià de Besòs, Tiana, Montgat, Montcada i Reixac y Castelldefels) ,donde un 27,1% de los desplazamientos se realiza en transporte público, aunque ya se empieza a observar el fenómeno del aumento del uso del transporte privado a medida que se incrementa la distancia con la capital catalana (25,1% respecto al 20% de Barcelona). Todo lo anterior se puede comprobar visualmente en el **Gráfico 2.7**.



**Gráfico 2.7** Uso modos de transporte según ámbito territorial

### 2.2.5. Modo de transporte en función de la comarca

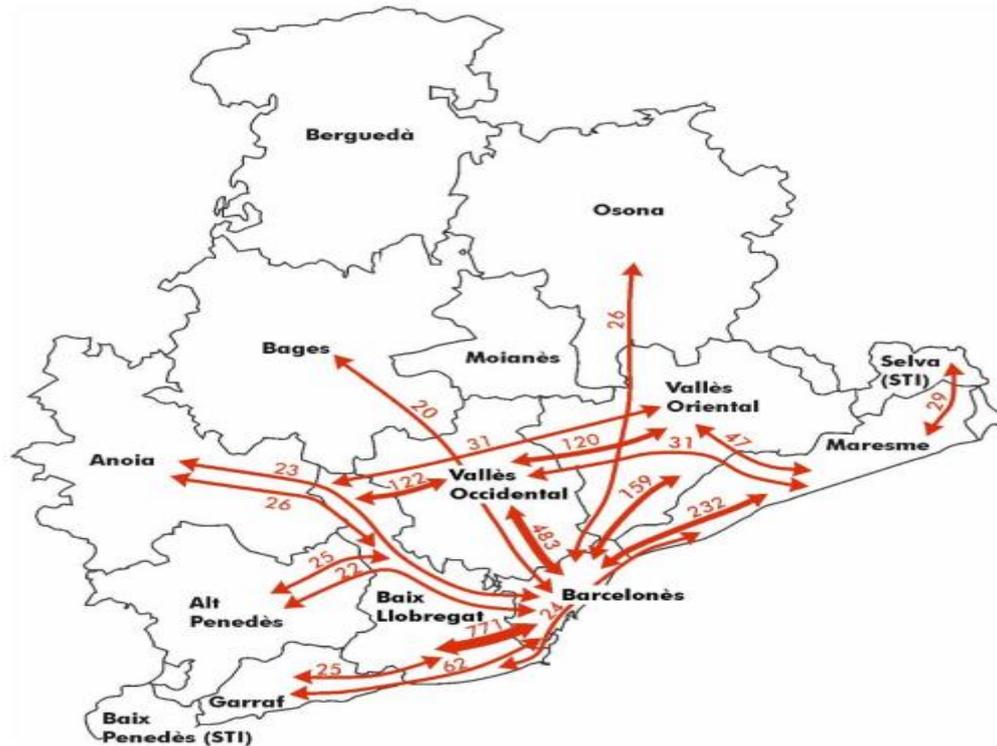
El Barcelonès destaca como la comarca con un comportamiento más sostenible, donde la suma de desplazamientos en transporte público y haciendo uso de la movilidad activa resulta en un 78,7% del total. Se destacan también en este aspecto, aunque en menor medida, las comarcas del Garraf (63,5%), el Baix Llobregat (57%) y el Vallès Occidental (54,3%). La población de la comarca de Osona es la que hace un mayor uso del transporte privado (61,7%), seguida por la del Moianès (61,1%) [10]. Estas dos comarcas están bastante alejadas del AMB y, como consecuencia, poco integradas en el STI, lo que explicaría estos datos. (Ver **Gráfico 2.8**)



**Gráfico 2.8** Uso modos de transporte según la comarca

### 2.2.6. Flujos intercomarcales

Los flujos principales intercomarcales (ver **Mapa 2.2**) son los que se dan entre el Barcelonès y el Baix Llobregat (771 mil desplazamientos), entre el Barcelonès y el Vallès Occidental (483 mil desplazamientos), entre el Barcelonès y el Maresme (232 mil desplazamientos), entre el Barcelonès y el Vallès Oriental (159 mil desplazamientos) y entre el Barcelonès y el Garraf (62 mil desplazamientos).



**Mapa 2.2** Flujos intercomarcales expresados en millares [10]

Los principales movimientos de personas de las comarcas del Baix Llobregat, el Garraf, Alt Penedès, Osona, el Vallès Occidental, el Vallès Oriental, el Maresme y el Baix Penedès (municipios del STI) se producen con el Barcelonès.

Los residentes en la comarca de Anoia originan y reciben más desplazamientos de la comarca del Baix Llobregat que de cualquier otra; los de Bages del Vallès Occidental; los de Selva (municipios del STI) del Maresme; los de Moianès de Osona; y los de Berguedà de Bages [10].

#### 2.2.6.1. *Modo de transporte en los principales flujos intercomarcales*

El mayor porcentaje de uso de transporte público, teniendo en cuenta únicamente los principales flujos nombrados en el apartado anterior [2.2.6], se da en el flujo del Barcelonès con el Garraf, siendo este valor igual al 57,6%. Se intuye que la causa de este hecho es que no hay una alternativa rápida en vehículo privado para cubrir este trayecto que no sea una vía de pago [9].

El porcentaje de desplazamientos sostenibles (movilidad activa y transporte público) cobra también importancia entre el Barcelonès y el Baix Llobregat, siendo este del 46% (42% en transporte público y 4% de movilidad activa). Muy

cerca está el 45% del flujo entre el Barcelonès y el Vallès Occidental [9], gracias a una excelente conexión con la línea Barcelona-Vallès de los Ferrocarriles de la Generalitat de Catalunya (FGC).

La relación entre el Maresme y el Barcelonès se produce en su mayoría en vehículo privado, pues solo 1 de cada 3 trayectos se realizan en transporte público (33,7%)[9]. Esto podría ser debido a la cantidad de incidencias que se registran en Rodalies de RENFE (Red Nacional de los Ferrocarriles Españoles), ocasionando retrasos importantes, sumado a la existencia de una alternativa más rápida por carretera a un precio más o menos asequible.

## Capítulo 3. Máquina virtual para un entorno de machine learning

### 3.1. El entorno Google Colaboratory

Google Colaboratory [1] es un entorno gratuito de Jupyter Notebook [2] (de ahora en adelante, simplemente Jupyter) que no requiere configuración y que se ejecuta completamente en la nube. Esa es la definición oficial, pero es necesario ahondar un poco más en ella para quién no esté familiarizado con Jupyter o Python [3].

Python es un lenguaje de programación poderoso y fácil de aprender. Cuenta con estructuras de datos eficientes y de alto nivel y un enfoque simple pero efectivo a la programación orientada a objetos. Pero en el contexto de Google Colab sus características más importantes son que se trata de un lenguaje ideal para scripting y que es un lenguaje interpretado.

Python trae consigo un modo interactivo que con un intérprete de línea de comandos permite lanzar sentencias y obtener los resultados, pero sus funcionalidades se quedaron cortas para los desarrolladores, por lo que surgió IPython, que más tarde evolucionaría en Jupyter.

Jupyter es un entorno interactivo que permite desarrollar código Python de manera dinámica. Jupyter se ejecuta en local como una aplicación cliente-servidor y posibilita tanto la ejecución de código como la escritura de texto, favoreciendo así la interactividad del entorno y que se pueda entender el código como la lectura de un documento.

### 3.2. ¿Por qué usar Google Colaboratory?

La principal ventaja que ofrece esta herramienta es que libera a la computadora de tener que llevar a cabo un trabajo demasiado costoso tanto en tiempo como en potencia o incluso permite realizar ese trabajo a pesar de que la máquina no disponga de recursos suficientemente potentes, ya que facilita al usuario un entorno en la nube con la posibilidad de hacer uso de sus GPU (Graphics Processing Unit). Y todo esto, como ya se ha mencionado, de forma gratuita.

Otro de los beneficios que tiene lo indica el propio nombre, Colaboratory, es decir, colaborativo, pues permite realizar tareas en la nube y compartir los cuadernos si se necesita trabajar en equipo.

Cabe destacar también que Google Colab tiene preinstaladas la mayor parte de las librerías de Python, lo que significa que se dispondrá prácticamente de todo el software necesario instalado, traduciéndose esto en un ahorro de tiempo considerable. Además, hay posibilidad de instalar otras librerías que se requieran.

Por todo esto, Google Colab es una magnífica opción para principiantes que quieran tener un primer contacto con machine learning<sup>9</sup> y deep learning<sup>10</sup> pero sin incurrir en gastos de procesamiento cloud.

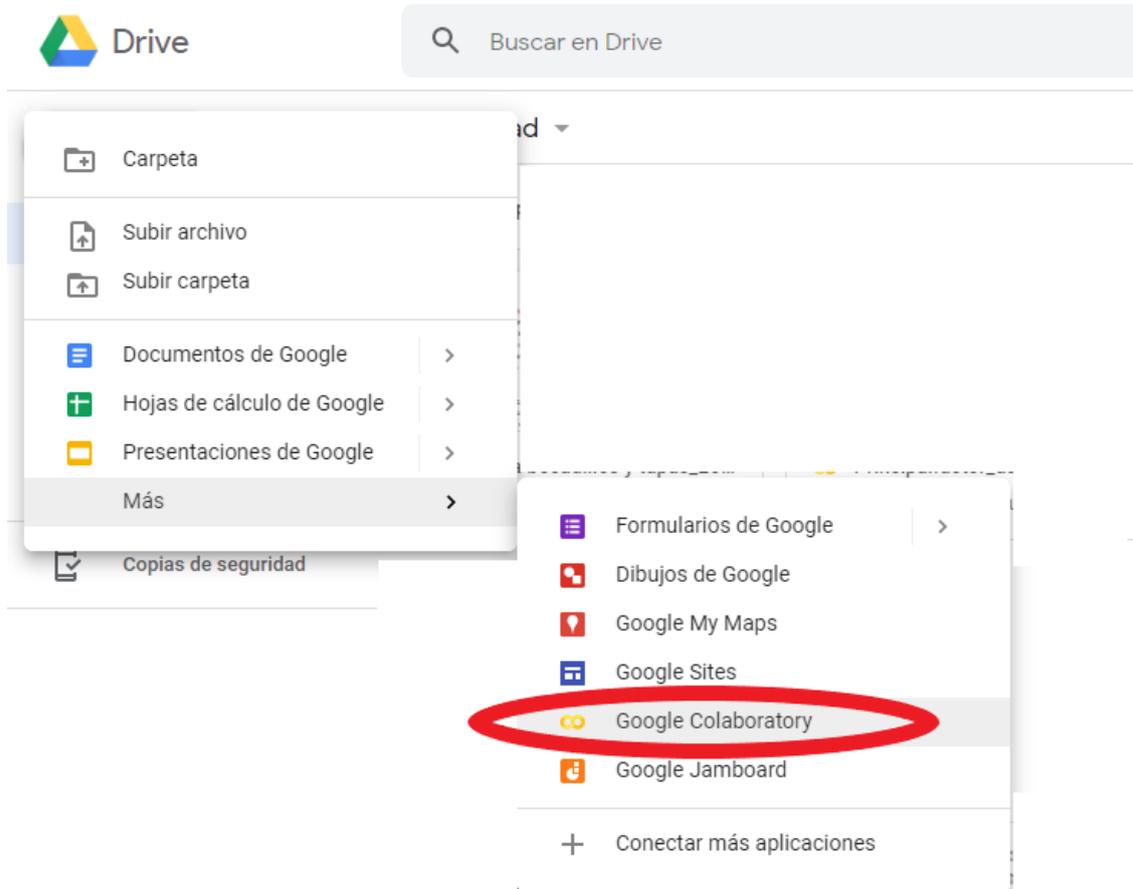
### 3.3. Funcionamiento y componentes básicos

Para hacer uso de Google Colab basta con acceder a la cuenta de Google del usuario y, o bien entrar directamente al enlace de Google Colab o ir al Google Drive del usuario, pulsar el botón de Nuevo y desplegar el menú de Más para seleccionar Colaboratory, lo que creará un nuevo cuaderno (notebook).

---

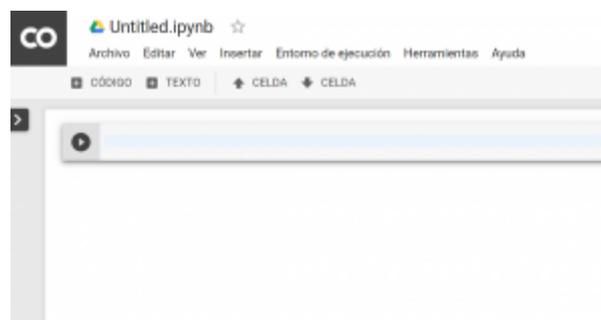
<sup>9</sup> El machine learning (aprendizaje automático en español) es el subcampo de las ciencias de computación y una rama de la inteligencia artificial, cuyo objetivo es desarrollar técnicas que permitan que las computadoras aprendan.

<sup>10</sup> El deep learning (aprendizaje profundo en español), también conocido como redes neuronales, es un aspecto de la inteligencia artificial (AI) que se ocupa de imitar los procesos que el ser humano utiliza para adquirir conocimientos.



**Fig. 3.1** Acceso a Google Colab

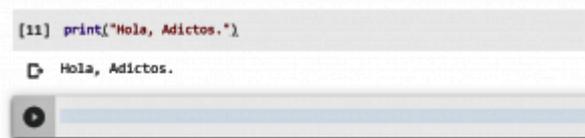
Un cuaderno es un documento que contiene código ejecutable (por ejemplo, Python) y también elementos de texto enriquecido (links, figuras, etc.). Es el entorno con el que va a trabajar el usuario en Colab y tiene el siguiente aspecto (**Fig. 3.2**) nada más crearlo:



**Fig. 3.2** Cuaderno creado

En la parte superior se localiza el nombre del cuaderno (obviamente se puede cambiar a voluntad) y su formato es .ipynb, que viene de IPython Notebook y es un formato que permite ejecutar cuadernos tanto en IPython, como en Jupyter y Colab. El fichero .ipynb contiene en formato JSON cada celda y su contenido.

Un cuaderno está formado por celdas. Una celda es la unidad de ejecución mínima dentro de un cuaderno, es decir, es donde se incluye el código y se ejecuta. Para ejecutar una celda se puede pulsar el botón con el icono de Play que se encuentra a la izquierda o pulsando Ctrt+Enter (ejecutar celda) o Shift+Enter (Ejecutar celda y saltar a la siguiente). Como se ve en la **Fig. 3.3**, tras la ejecución, debajo de la celda aparece el resultado (si lo hay).



**Fig. 3.3** Ejemplo de ejecución de una celda

En la parte izquierda de una celda ejecutada se puede observar un número entre corchetes (**Fig. 3.3**). Este número indica el orden en el que se ha ejecutado cada celda. En la **Fig. 3.3**, por ejemplo, se puede ver un 11 porque la celda ha sido ejecutada 11 veces. Si a continuación se añadiera una celda y se ejecutara, el número que aparecería a la izquierda de ésta sería un 12. De este modo, el número aumenta cada vez que se ejecuta una celda, independientemente de si ha sido ejecutada anteriormente. Al pasar el cursor por esta parte izquierda de la celda también se puede ver información acerca de quién ejecutó la celda, en qué momento y cuánto tardó la ejecución.

Desde los botones de la parte superior (+Código o +Texto) o en el menú Insertar (ver **Fig. 3.2**) podemos añadir nuevas celdas, tanto específicas para código como para texto. La distinción que hace Colab sobre ellas es que las celdas de código son ejecutables, mientras que las de texto muestran directamente el texto que incluyamos y disponen también de un pequeño editor de texto (**Fig. 3.4**).

También existe la posibilidad de cambiar el orden de las celdas con las flechas de la parte superior (ver **Fig. 3.2**), hacia arriba (también con el atajo Ctrl+M K) o hacia abajo (Ctrl+M J), o modificarlas con el menú desplegable de la parte

derecha de cada celda, borrándolas (Ctrl+M D) o añadiendo comentarios y enlaces.



```
[11] print("Hola, Adictos.")
```

Hola, Adictos.

---

#Hola, Adictos

---

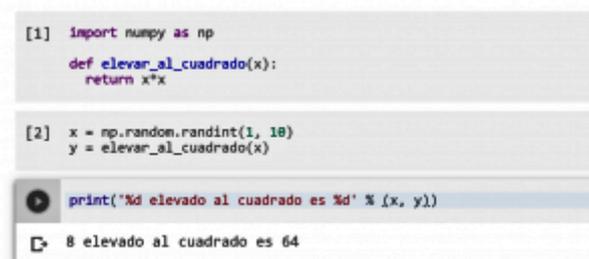
**Hola, Adictos**

**Fig. 3.4** Ejemplo de celda de texto

### 3.3.1. El entorno de ejecución

Cada celda es independiente, pero todas las celdas en un cuaderno utilizan el mismo kernel. El kernel es el motor de computación que está por debajo y cuya función es ejecutar el código y devolver el resultado para mostrarlo en la celda. El estado del kernel persiste durante el tiempo, lo que significa que aunque cada celda sea independiente, las variables declaradas en una celda se pueden utilizar en las demás.

Habitualmente, el flujo de ejecución de las celdas será de arriba hacia abajo, el orden natural en el que están creadas, pero es posible que en algún momento se precise ejecutar o cambiar algo en una celda anterior. Aquí es donde resulta útil el número que aparece a la izquierda que, como se ha comentado anteriormente, indica el orden de ejecución.



```
[1] import numpy as np

def elevar_al_cuadrado(x):
    return x*x

[2] x = np.random.randint(1, 10)
    y = elevar_al_cuadrado(x)

print('%d elevado al cuadrado es %d' % (x, y))
```

8 elevado al cuadrado es 64

**Fig. 3.5** Ejecución de una función que eleva al cuadrado un nombre aleatorio

En este cuaderno, primero se importa la librería numpy<sup>11</sup> [4] y luego se declara una función para elevar números al cuadrado. En celdas siguientes, se utiliza esa función y la librería para elevar al cuadrado números aleatorios.

```
[1] import numpy as np
    def elevar_al_cuadrado(x):
        return x*x

[2] x = np.random.randint(1, 10)
    y = elevar_al_cuadrado(x)

[5] print('%d elevado al cuadrado es %d' % (x, y))
↳ 8 elevado al cuadrado es 24

[4] y = 24
```

**Fig. 3.6** Ejemplo de obtención de un resultado erróneo debido a una ejecución de las celdas en el orden incorrecto

Ahora se puede ver en la **Fig. 3.6** un cambio del valor de “y” en la celda añadida y como al ejecutar la celda la frase imprimida deja de tener sentido, pero gracias a los números de orden se puede descubrir lo que ha ocurrido.

Todo esto facilita mucho la separación del código en bloques lógicos sin la necesidad de volver a importar librerías, o recrear variables o funciones.

Desde el menú de Entorno de Ejecución (ver **Fig. 3.2**) se puede reiniciar el estado del entorno de ejecución (Ctrl+M) para liberar toda la memoria que hayamos utilizado (perdiendo variables y demás), interrumpir cualquier ejecución lanzada (Ctrl+M I), y lanzar ejecuciones sobre las celdas: Ctrl+F9 para ejecutar todo el cuaderno, Ctrl+F8 para ejecutar las celdas anteriores, Ctrl+Shift+Enter para ejecutar las celdas seleccionadas o Ctrl+F10 para ejecutar la siguiente celda.

Cuando se crea un nuevo cuaderno, este es estático, es decir, se ve su contenido, pero no se está conectado a ningún entorno de ejecución. El cuaderno se conecta a una VM de Google Compute Engine (la infraestructura de máquinas virtuales de Google en la nube) cuando una celda es ejecutada o se pulsa sobre el botón de Conectar. Al hacerlo, el cuaderno toma un momento en conectarse y después muestra, de ahí en adelante, el espacio de RAM y disco que se está consumiendo. La máquina en un inicio cuenta con 12 GB de RAM y 50 GB de almacenamiento en disco disponibles para el uso.

<sup>11</sup> Numpy es una librería de Python que proporciona potentes estructuras de datos, implementando matrices y matrices multidimensionales y que garantiza cálculos eficientes con ellas.



**Fig. 3.7** A la izquierda se ve el botón de Conectar que se ha de pulsar para conectarse a la máquina virtual de Google y, en el lado derecho, se puede comprobar que el cuaderno se ha conectado y la RAM y disco que se está consumiendo.

Se dispone de un tiempo de conexión a la máquina virtual limitado, siendo éste de 12 horas. Una vez transcurrido ese intervalo, se limpia el ambiente y se pierden los archivos y las variables que se tengan almacenados. Si se están llevando a cabo ejecuciones que necesitan mucho tiempo, se debe tener en cuenta lo siguiente: el entorno se desconecta al transcurrir más de 90 minutos sin utilizar un cuaderno. Para que esto no suceda es suficiente con dejar la ventana del navegador abierta o celdas ejecutándose. La ventaja para dichos casos es que, si se deja una celda ejecutándose y se cierra el navegador, la ejecución continuará y se tendrá el resultado al abrir el navegador nuevamente.

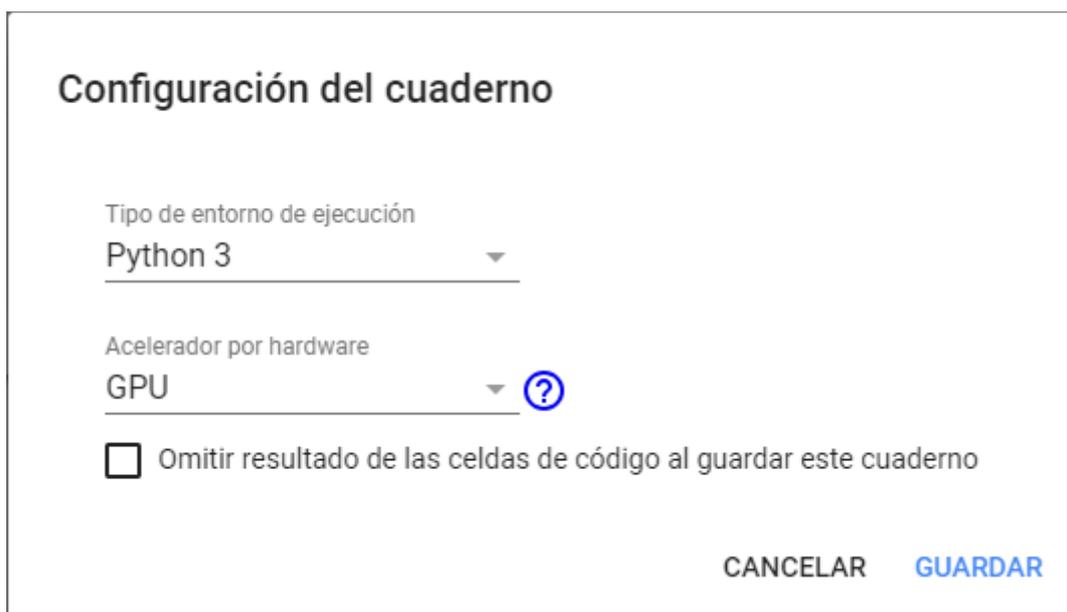
### 3.3.2. Cómo utilizar un entorno con GPU o cambiar la versión de Python

El entorno predeterminado al que se conecta Colab utiliza un kernel con Python 3 y no permite la ejecución con GPU. Inicialmente, Colab utilizaba Python 2, pero en la actualidad permite crear nuevos cuadernos tanto en Python 3 como en Python 2, desde el menú de Archivo (véase **Fig. 3.8**).



**Fig. 3.8** Cómo crear nuevo cuaderno en Python 3 o Python 2

En caso de querer cambiar la versión de Python cuando el cuaderno ya se ha creado o utilizar la GPU en lugar de la CPU ( Central Processing Unit) para realizar ejecuciones más potentes, como la creación de modelos de aprendizaje profundo, Colab permite cambiar los ajustes del entorno para utilizar una GPU de forma gratuita. Sólo se debe ir al desplegable de Entorno de Ejecución (véase **Fig. 3.8** para localizarlo) y seleccionar Cambiar tipo de entorno de ejecución.



**Fig. 3.9** Ajustar entorno para utilizar GPU

Aquí se puede la cambiar la versión entre Python 3 y Python 2 y cambiar el Acelerador por hardware de None a GPU o a TPU (Tensor Processing Unit), que son unidades de procesamiento de tensores específicas de Google para ejecutar modelos de machine learning.

Al pulsar Guardar, se guardan los ajustes y se cambia el entorno de ejecución para obtener una máquina con esos ajustes. Podría suceder que por temas de limitación de recursos no fuera posible conectarse a una máquina con GPU. Esto sería debido a un exceso de usuarios o a la limitación de uso de estas GPU que impone Google para evitar, entre otras cosas, que se minen criptomonedas. Así que podría suceder una desconexión del entorno en el caso de estar realizando una ejecución muy prolongada y potente. En el supuesto de no poder conectarse a un entorno, Colab informará que no hay entornos con GPU disponibles. Es posible comprobar si se está conectado al entorno de GPU observando que el botón Conectar, situado en la parte superior, tenga un tick verde o ejecutando el siguiente código:

```
import tensorflow as tf

device_name = tf.test.gpu_device_name()

if device_name != '/device:GPU:0':

    raise SystemError('GPU no encontrada')

print('Encontrada GPU: {}'.format(device_name))
```

Si se obtiene un error como resultado, no se está conectado a una GPU. En caso de estar conectado, la respuesta será: Encontrada GPU: /device:GPU:0.

### **3.4. Subir y utilizar archivos locales o externos**

Existen varias maneras de subir archivos que se puedan necesitar para los cuadernos de los usuarios.

#### **3.4.1. Desde local**

Para subir un archivo desde local se debe ejecutar el siguiente fragmento de código:

```
from google.colab import files

files.upload()
```

Al ejecutarlo, aparece el típico botón de subida de archivos que abre una ventana para los archivos que se quieran subir del sistema. Existe también la opción de ir al menú lateral y en la pestaña de Archivos pulsar el botón Subir.

El directorio raíz de Colab es /content. Por tanto, es el directorio que aparece abierto cuando se abre la pestaña de Archivos y es el directorio donde se guardan todos los ficheros que se suban. Si se sube un archivo llamado procesos.csv, el path para acceder sería /content/procesos.csv.

Del mismo modo que se suben archivos, se pueden descargar de la máquina remota con:

```
files.download()
```

Así, para el descargar el fichero que se ha subido se utiliza:

```
files.download("procesos.csv")
```

### 3.4.2. Desde Google Drive

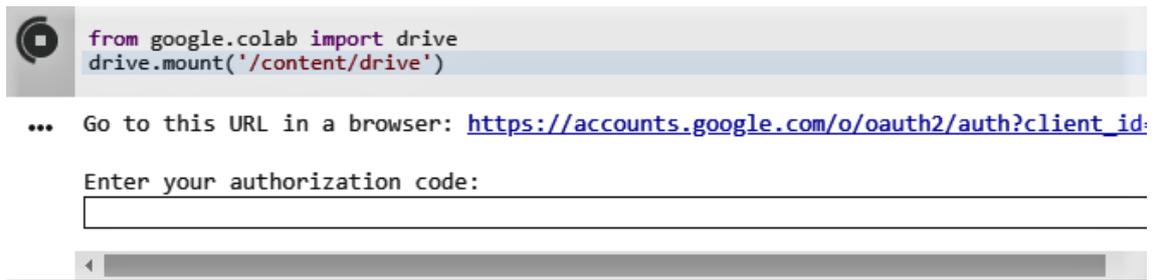
Esta opción permite utilizar archivos almacenados en Google Drive. Existen varias opciones, tales cómo utilizar la API REST de Drive o la librería de Python PyDrive, pero la más cómoda es montar el Google Drive del usuario localmente en la máquina.

La ventaja de usar esta opción no es solamente que se puedan tener los archivos alojados en Google Drive y acceder fácilmente a ellos. Cuando se trabaja con machine learning o ciencia de datos, la mayoría de las veces los archivos de datos son enormes. Así que si cada vez que el usuario se conecta a un entorno distinto tiene que subir estos archivos, se pierde demasiado tiempo. Para evitarlo, se tienen estos archivos alojados en Drive y se monta Drive en la máquina, de forma que se pueda acceder a ellos como si estuvieran en local.

Para montar Drive en la máquina se lanza el siguiente código:

```
from google.colab import drive
drive.mount('/content/drive')
```

Al ejecutarlo se abre una URL donde se pide un código para autorizar a Colab a utilizar el Drive del usuario y se tiene que pegar en el input que aparece (**Fig. 3.10**).



```
from google.colab import drive
drive.mount('/content/drive')
```

... Go to this URL in a browser: [https://accounts.google.com/o/oauth2/auth?client\\_id:](https://accounts.google.com/o/oauth2/auth?client_id:)

Enter your authorization code:

**Fig. 3.10** Resultado ejecución celda para montar Drive en la máquina

Terminado el proceso, se ha montado el Drive del usuario dónde ha sido indicado (/content/drive) y es posible acceder tranquilamente a los archivos.

## Capítulo 4. Análisis predictivo para determinar el factor que más pesa en la elección del modo de transporte

### 4.1. Presentación de los datos

Para llevar a cabo el estudio se obtiene el porcentaje de uso de modos de transporte sostenibles (movilidad activa y transporte público) en los flujos de conexión entre cada uno de los municipios del AMB y Barcelona [11]. Seguidamente, se obtienen los valores de los factores que se van a tomar en cuenta, los cuales, en caso de tratarse de precios, serán referidos al año 2018. Estos factores son: la distancia, calculada desde el centro de cada municipio al centro de Barcelona en línea recta; el coste por kilómetro del transporte público, calculado obteniendo el precio por viaje suponiendo que los usuarios de los municipios de la primera corona utilizan el título de transporte integrado T-10 (1,02 €/viaje) y los de la segunda el título T-mes (1,82€/viaje), posteriormente, dividiendo el precio por viaje entre la distancia ; y el coste del transporte privado, calculado con un precio fijo para el combustible de 1,32€/litro y utilizando el recorrido más rápido. Se puede ver la tabla resultante más abajo (**Tabla 4.1**).

**Tabla 4.1** Datos de uso de modos de transporte sostenibles en los flujos de conexión entre cada uno de los municipios del AMB y Barcelona y valores de los factores que pueden influir en esta elección para cada uno de los municipios. Datos correspondientes al año 2018

municipios	Coste por viaje transporte público	Coste viaje transporte privado	Distancia	Uso modos de transporte sostenibles (%)	Coste por km transporte público
Montcada i Reixac	1.020	1.950	11	52,4	0.093
Hospitalet de Llobregat	1.020	1.190	7	78,3	0.146
Gavà	1.020	2.170	17	45	0.060
Prat de Llobregat	1.020	1.690	9	53,5	0.113
Sant Vicenç dels Horts	1.820	2.010	13	41,7	0.140
Badalona	1.020	1.410	9	61	0.113
Montgat	1.020	1.740	13	47,5	0.078
Sant Boi de Llobregat	1.020	1.760	12	52.600	0.085
Sant Feliu de Llobregat	1.020	1.680	10	19.700	0.102
Santa Coloma de Gramenet	1.020	1.410	8	60.300	0.128
Sant Cugat del Vallès	1.820	1.940	12	61.000	0.152
Sant Joan Despí	1.020	1.750	9	66.200	0.113
Tiana	1.020	2.060	13	37.100	0.078

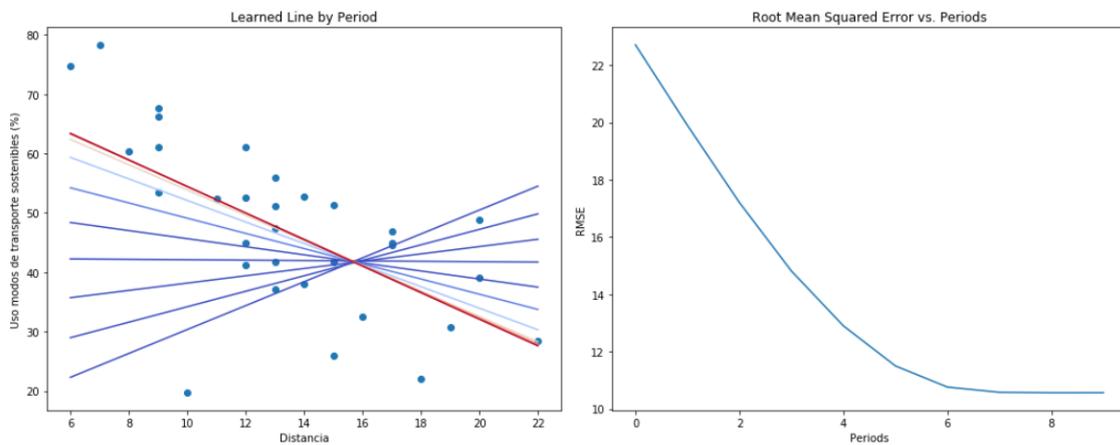
Castellbisbal	1.820	2.960	19	30.700	0.096
Castelldefels	1.020	2.370	20	48.800	0.051
Esplugues de Llobregat	1.020	1.190	7	63.900	0.146
Cornellà de Llobregat	1.020	1.740	9	67.600	0.113
Badia del Vallès	1.820	2.520	14	52.800	0.130
Cerdanyola del Vallès	1.820	1.960	12	44.900	0.152
Papiol	1.820	2.540	14	38.100	0.130
Corbera de Llobregat	1.820	3.030	20	39.000	0.091
Sant Adrià de Besòs	1.020	1.180	6	74.800	0.170
Begues	1.820	3.360	22	28.400	0.083
Molins de Rei	1.820	2.170	13	51.100	0.140
Palma de Cervelló	1.820	2.710	17	46.900	0.107
Ripollet	1.820	2.220	12	41.200	0.152
Pallejà	1.820	2.260	15	25.900	0.121
Barberà del Vallès	1.820	2.320	15	41.800	0.121
Santa Coloma de Cervelló	1.820	2.610	13	56.000	0.140
Cervelló	1.820	2.660	18	22.100	0.101
Torrelles de Llobregat	1.820	2.700	16	32.600	0.114
Sant Just Desvern	1.020	1.400	9	39.400	0.113
Viladecans	1.020	1.940	15	51.300	0.068
Sant Andreu de la Barca	1.820	2.580	17	44.600	0.107
Sant Climent de Llobregat	1.820	2.360	16	46.500	0.114

## 4.2. Obtención y análisis de los resultados

Haciendo uso de los datos de la **Tabla 4.1** se procede a utilizar Google Colab que, sirviéndose de técnicas de machine learning, va a obtener una predicción del porcentaje de uso de modos de transporte sostenibles en función de cada uno de los tres factores nombrados en el apartado anterior [4.1]. Esta predicción va a ser una regresión lineal, la cual nos va a indicar el grado de dependencia que hay entre las dos variables estudiadas, es decir, una mayor pendiente indica un grado de dependencia mayor. Esto significa que el factor con mayor peso en la elección de un modo de transporte sostenible será aquel con el que se obtenga una recta de mayor pendiente. Se debe prestar también atención al valor de la raíz del error cuadrático medio, ya que su valor permite hacerse una idea de lo buena que es una predicción, es decir, cuanto más pequeño sea más se acerca la predicción a la realidad.

**Tabla 4.2** Parámetros estadísticos de los valores de la columna porcentaje de uso de modos de transporte sostenibles de la **Tabla 4.1** y de los obtenidos en la predicción para el caso de la distancia.

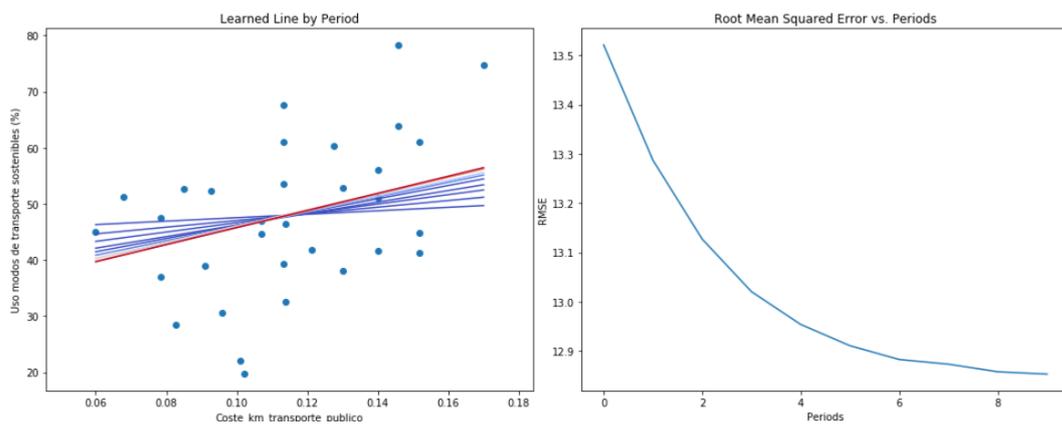
	predictions	targets
<b>count</b>	35.000	35.000
<b>mean</b>	47.297	47.563
<b>std</b>	9.095	14.013
<b>min</b>	27.604	19.700
<b>25%</b>	41.031	39.200
<b>50%</b>	47.745	46.900
<b>75%</b>	55.577	54.750
<b>max</b>	63.410	78.300



**Gráfico 4.1** A la izquierda, predicción en el uso de los modos de transporte sostenibles en función de la distancia, y a la derecha, evolución del RMSE (raíz del error cuadrático medio) a lo largo de los periodos.

**Tabla 4.3** Parámetros estadísticos de los valores de la columna porcentaje de uso de modos de transporte sostenibles de la **Tabla 4.1** y de los de la predicción para el caso del coste por km del transporte público.

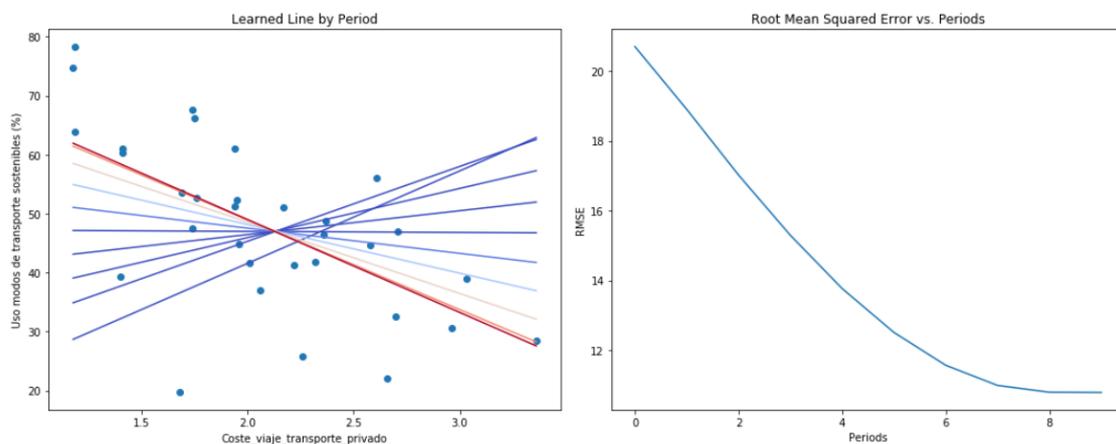
	predictions	targets
<b>count</b>	35.000	35.000
<b>mean</b>	47.800	47.563
<b>std</b>	4.314	14.013
<b>min</b>	38.330	19.700
<b>25%</b>	44.919	39.200
<b>50%</b>	47.824	46.900
<b>75%</b>	51.124	54.750
<b>max</b>	56.455	78.300



**Gráfico 4.2** A la izquierda, predicción en el uso de los modos de transporte sostenibles en función del coste por km del transporte público, y a la derecha, evolución del RMSE (raíz del error cuadrático medio) a lo largo de los periodos.

**Tabla 4.4** Parámetros estadísticos de los valores de la columna de uso de modos de transporte sostenibles de la **Tabla 4.1** y de los de la predicción para el caso del coste del viaje en transporte privado.

	predictions	targets
<b>count</b>	35.000	35.000
<b>mean</b>	47.419	47.563
<b>std</b>	8.640	14.013
<b>min</b>	27.586	19.700
<b>25%</b>	40.662	39.200
<b>50%</b>	48.067	46.900
<b>75%</b>	53.108	54.750
<b>max</b>	61.931	78.300



**Gráfico 4.3** A la izquierda, predicción en el uso de los modos de transporte sostenibles en función del coste del viaje en transporte privado, y a la derecha, evolución del RMSE (raíz del error cuadrático medio) a lo largo de los periodos.

Se va a proceder ahora al análisis de los resultados. Se observa en el **Gráfico 4.2** (el de la izquierda) que la pendiente es inferior a la de los otros dos gráficos (ver parte izquierda, tanto del **Gráfico 4.1** como del **Gráfico 4.3**). Entre estos dos, es difícil ver a simple vista cuál es el que presenta una mayor pendiente. Para ello, se va a examinar el valor máximo y mínimo para sendas predicciones (viendo la **Tabla 4.2** y la **Tabla 4.4**) y se va a obtener la diferencia entre ambos valores. La predicción para la que se obtenga el valor más grande será la que tenga mayor pendiente. Para la predicción en función de la distancia, este valor es de 35,81, mientras que para la predicción en función del precio del viaje en transporte privado es de 34,35. Así, se obtiene como resultado que la distancia es el factor que más influye en la elección de un modo de transporte sostenible

en los flujos de conexión entre cada uno de los municipios del AMB y Barcelona, de modo que cuanto más se aleja el usuario de la capital catalana menor es el uso de modos de transporte sostenibles.

## Capítulo 5. Conclusiones y ámbitos de trabajo futuros

### 5.1. Conclusiones

Es un hecho que la población mayor de 65 años va a ir adquiriendo más peso en la pirámide poblacional del AMB a corto, medio y largo plazo. Este es un dato que no pueden obviar las administraciones públicas a la hora de trazar planes futuros de movilidad, ya que pueden caer en el error de aislar de la sociedad a este grupo de población si lo hacen.

Habiendo analizado la movilidad en el ámbito del STI, se infiere que la movilidad activa y el vehículo privado son los medios de transporte más utilizados, siendo la motivación principal de los desplazamientos la vuelta a casa seguida de la movilidad personal. El uso del vehículo privado es mayoritario en la movilidad ocupacional, mientras que en la movilidad personal predomina la movilidad activa.

La movilidad en el STI, así como en cualquier área metropolitana, se caracteriza por su heterogeneidad. Combina vehículos privados con autobuses, metros y tranvías. Fluctúa en horas punta durante el transcurso del día y registra jornadas con mucha más congestión que otras. Además, se ve afectada por sucesos puntuales y más o menos imprevistos, tales como la celebración de un evento o un fenómeno meteorológico adverso. El estudio de movilidad en el que se ha basado este trabajo no tiene en cuenta la gran variabilidad de los datos, ya que la información obtenida, basada en encuestas telefónicas, corresponde a un día laborable tipo o medio y tiene una dependencia del hogar, cuando la movilidad depende realmente del individuo. Así, se concluye que para obtener una radiografía mucho más precisa de la movilidad y actuar en consecuencia la administración pública debe disponer de una cantidad ingente de datos para poder aplicar tecnología Big Data. Pero para ello es necesaria la colaboración de los ciudadanos, que deben prestarse a compartir toda la información acerca de sus desplazamientos.

Se ha podido ver que Google Colab es una herramienta ideal para el desarrollo de aplicaciones de machine learning, todo ello sin depender de la potencia de la computadora, de forma gratuita y sin necesidad de configurar nada. Únicamente se necesita un navegador. Se dispone de un tutorial extenso con gran cantidad de ejemplos y ejercicios para practicar de una gran utilidad para los iniciados. Pero los recursos que ofrece esta herramienta no están garantizados ni son ilimitados e incluso pueden variar los límites de uso. Es el precio que hay que pagar por la gratuidad de los recursos.

En este primer contacto con las herramientas de machine learning, se ha aprendido a obtener información útil de un conjunto de datos a partir de sus

parámetros estadísticos (media, desviación estándar, etc.) y, también, visualizando su matriz de correlación. Finalmente, se ha sido capaz de extraer conclusiones en base a los resultados que se han obtenido con el machine learning.

Como se ha observado en el análisis predictivo de la movilidad en el AMB, la distancia que separa los lugares es lo más importante para los habitantes de una ciudad a la hora de tomar la decisión de elegir un modo de transporte u otro, de modo que, cuanto mayor es la distancia menor es el porcentaje de uso de modos de transporte sostenibles (transporte público y movilidad activa). Por el contrario, el precio del transporte público tiene poco peso en la elección del modo de transporte.

## **5.2. Ámbitos de trabajo futuros**

Este apartado tiene como objetivo presentar algunos ámbitos en los que podría profundizar más este Trabajo Final de Grado en un futuro.

Disponiendo de una base de datos de movilidad mucho más amplia y variada, se podría predecir el comportamiento de los viajeros cuando las condiciones climatológicas son adversas, lo que permitiría tomar mejores decisiones con el fin de evitar las congestiones que se suelen producir en esas circunstancias.

Teniendo en cuenta lo aprendido en este trabajo, se podrían aplicar los conocimientos adquiridos al mundo del fútbol, de forma que se estaría en condiciones de aconsejar a un equipo que jugadores fichar. También se podría medir el rendimiento individual de un grupo de futbolistas con el objetivo de saber cuándo existe riesgo de lesión o cuándo se encuentran en su mejor momento.

## REFERENCIAS

- [1] Google Colab. <https://colab.research.google.com/notebooks/welcome.ipynb>
- [2] Gwydion Martín (18 de Enero, 2018). Primeros pasos con Jupyter Notebook. Adictos al trabajo. Disponible en: <https://www.adictosaltrabajo.com/2018/01/18/primeros-pasos-con-jupyter-notebook/>
- [3] Qué es Python. Desarrollo web. Disponible en: <https://desarrolloweb.com/articulos/1325.php>
- [4] Numpy. <https://numpy.org/>
- [5] Àrea metropolitana de Barcelona (AMB). El área metropolitana| Conocer el área metropolitana| Localización y usos del suelo Disponible en: <http://www.amb.cat/s/es/web/area-metropolitana/coneixer-l-area-metropolitana/localitzacio-i-usos-del-sol.html>
- [6] Àrea metropolitana de Barcelona (AMB). El área metropolitana| Municipios metropolitanos Disponible en: <http://www.amb.cat/s/es/web/area-metropolitana/municipis-metropolitans.html>
- [7] Institut d'Estudis Regionals i Metropolitans de Barcelona (Mayo 2019). La metròpoli en 100 indicadors. L'AMB EN XIFRES 2018 Recuperado de: <https://iermb.uab.cat/es/amb-en-xifres/la-metropoli-en-100-indicadors-lamb-en-xifres-2018-2/>
- [8] Institut d'Estudis Regionals i Metropolitans de Barcelona (Julio 2019). Canvi demogràfic, envelliment i metròpoli Recuperado de: [http://www.amb.cat/es/web/desenvolupament-socioeconomic/estudis-socioeconomics/detall/-/estuditerritorial/canvi-demografic--envelliment-i-metropoli/8015174/11708? EstudiTerritorialSearchListPortlet WAR\\_AMBSearchPortletportlet\\_pageNum=1& EstudiTerritorialSearchListPortlet WAR\\_AMBSearchPortletportlet\\_tipus\\_estudi=estudis\\_socioeconomics& EstudiTerritorialSearchListPortlet WAR\\_AMBSearchPortletportlet\\_detailBackURL=%2Fes%2Fweb%2Famb%2FInstitucio%2Festudis-metropolitans%2Fllistat](http://www.amb.cat/es/web/desenvolupament-socioeconomic/estudis-socioeconomics/detall/-/estuditerritorial/canvi-demografic--envelliment-i-metropoli/8015174/11708? EstudiTerritorialSearchListPortlet WAR_AMBSearchPortletportlet_pageNum=1& EstudiTerritorialSearchListPortlet WAR_AMBSearchPortletportlet_tipus_estudi=estudis_socioeconomics& EstudiTerritorialSearchListPortlet WAR_AMBSearchPortletportlet_detailBackURL=%2Fes%2Fweb%2Famb%2FInstitucio%2Festudis-metropolitans%2Fllistat)
- [9] Autoritat del Transport Metropolità (Mayo 2019). Enquesta de mobilitat en dia feiner 2018 (EMEF 2018). La mobilitat a l'àmbit territorial del Sistema Tarifari Integrat. Recuperado de: [https://observatori.atm.cat/enquestes-de-mobilitat/Enquestes\\_ambit\\_ATM/EMEF/2018/EMEF\\_2018\\_Informe\\_STI.pdf](https://observatori.atm.cat/enquestes-de-mobilitat/Enquestes_ambit_ATM/EMEF/2018/EMEF_2018_Informe_STI.pdf)

[10] Autoritat del Transport Metropolità (Abril 2019). Enquesta de mobilitat en dia feiner 2018 (EMEF 2018). Fulletó principals resultats. Recuperado de: [https://observatori.atm.cat/enquestes-de-mobilitat/Enquestes\\_ambit\\_ATM/EMEF/2018/Informe\\_publicacio\\_EMEF\\_2018.pdf](https://observatori.atm.cat/enquestes-de-mobilitat/Enquestes_ambit_ATM/EMEF/2018/Informe_publicacio_EMEF_2018.pdf)

[11] Àrea Metropolitana de Barcelona (AMB). Mobilitat| Planificació| Estudis mobilitat Disponible en: <http://www.amb.cat/s/web/mobilitat/planificacio/estudis-de-mobilitat.html>