

Efectos de la monitorización individual del consumo de combustible en trayectos cotidianos

Andrés García Martínez

Investigador, Centro de Investigación del Transporte TRANSyT. Universidad Politécnica de Madrid, España

Andrés Monzón de Cáceres

Director, Centro de Investigación del Transporte TRANSyT. Catedrático, Universidad Politécnica de Madrid, España

Álvaro García-Castro

Investigador, Centro de Investigación del Transporte TRANSyT. Universidad Politécnica de Madrid, España

RESUMEN

El excesivo gasto energético y las emisiones de gases de efecto invernadero (GEI) constituyen un problema a nivel mundial con importantes implicaciones a nivel medioambiental y económico. Uno de los sectores que en mayor medida contribuyen a agravar esta situación es el transporte por carretera, el cual aporta alrededor del 20% del total de emisiones de GEI, porcentaje aún mayor en el caso de España.

Entre las políticas aplicadas para atajar este problema podemos destacar el uso de las Tecnologías de la Información y de las Comunicaciones (TIC), incluyendo la promoción de un estilo de conducción más eficiente y los sistemas avanzados de ayuda a la conducción. La monitorización de los consumos es actualmente posible a nivel individual, ya que muchos de los turismos actuales proporcionan el consumo medio por trayecto en la pantalla del ordenador de a bordo.

El objetivo de este estudio es estimar la influencia del conocimiento de una ruta y de la monitorización del consumo en la reducción del mismo y las emisiones asociadas de CO₂. Para ello se ha seguido la evolución de varios conductores en trayectos repetitivos.

Los resultados muestran que el ahorro de combustible desde el momento en que un conductor realiza un tramo desconocido hasta el momento en que está acostumbrado a él es de un 8%. Estos resultados justifican la optimización de la gestión de infraestructuras, de forma que se produzca un ahorro global en el consumo de todos los usuarios que las utilizan.

1. INTRODUCCIÓN

1.1 El problema de las emisiones de Gases de Efecto Invernadero. Tendencias

La emisión de gases de efecto invernadero (GEI) es un problema global, tanto en sus causas como en sus consecuencias (Ramanathan y Feng, 2009). En los últimos tiempos se han producido grandes avances en tecnologías de motores. No obstante, el sector transporte sigue siendo uno de los mayores emisores.

Según la Agencia Medioambiental Europea (EEA, 2013) las emisiones del transporte por carretera han disminuido en los últimos años, pero sigue aportando aproximadamente el 93% de las emisiones atribuibles al sector transporte, lo que supone un 20,4% del total.

Más concretamente, en el caso de España, el sector transporte es la fuente de emisiones de GEI que presenta un mayor crecimiento, destacando también el transporte por carretera (Pérez y Monzón, 2006). El transporte en España contribuye con el 41% de emisiones de CO₂ sobre el total (ITF/OECD, 2010) y se encuentra entre los ratios más altos de Europa de consumo de energía del transporte per cápita transporte.

En este contexto, muchos de los esfuerzos encaminados a reducir la emisión de GEI se centran en el sector del transporte por carretera (Mendiluce et al., 2010). La comisión Europea propone una política integrada para atajar el problema desde varios puntos, entre los que se pueden citar la gestión de la demanda, el cambio hacia modos más limpios, la mejora en las tecnologías de los vehículos y el uso de Tecnologías de la Información y la Comunicación (TIC).

Esta ponencia presenta en primer lugar una revisión del estado del arte en relación con la monitorización del consumo en vehículos. En la tercera sección se explica la metodología empleada en el caso de estudio de Madrid. A continuación se detallan los resultados obtenidos y por último las conclusiones del mismo.

1.2 El proyecto europeo “ICT-Emissions”

El objetivo del proyecto de investigación “ICT-Emissions” (7º Programa Marco) es desarrollar una metodología para modelizar en detalle los efectos en las emisiones de GEI de una serie de TIC aplicadas al transporte. Cada una de las TIC consideradas afecta a las emisiones de CO₂ de distinta manera. Desde un punto de vista macroscópico se puede considerar que la demanda, la composición de la flota y la velocidad media determinan el nivel de emisiones (Ntziachristos y Samaras, 2000). Sin embargo, si analizamos más en detalle cada vehículo, los procesos de aceleración y deceleración, así como el rendimiento del motor resultan determinantes. Por otra parte, los ámbitos de aplicación son muy variables y los efectos en determinados entornos pueden producir resultados no deseados, por lo que se manifiesta la necesidad de utilizar modelos para simular estos posibles efectos antes de realizar las grandes inversiones que en algunos casos requieren estas

medidas. La metodología propuesta en el proyecto “ICT-Emissions” se basa principalmente en la interacción de los diversos modelos de simulación (vehículo, tráfico y emisiones) en sus niveles micro y macro.

2. MONITORIZACIÓN DE CONSUMOS

Las TIC aplicadas al transporte constituyen un campo muy amplio que puede tener efectos positivos en la eficiencia, seguridad, comodidad y del medio ambiente (Commission of the European Communities, 2008).

Las nuevas tecnologías permiten realizar una monitorización completa del vehículo. Los datos extraídos se utilizan para diversos fines. Es el caso de la utilización de teléfonos inteligentes como herramienta para inventariar carreteras (Higuera de Frutos y Castro, 2014). Otro ejemplo es el desarrollo de una metodología para monitorizar la posición del vehículo en un carril (Tu et al., 2013).

Existen numerosos estudios en los que se ha registrado el consumo de combustible. Baric (2013) evalúa técnicas de conducción eficiente en un tramo mixto en urbano y autopista. Anteriormente se desarrolló un modelo de regresión con el consumo como variable dependiente e indicadores basados en patrones de conducción como variables independientes (Wang et al., 2008). Cappiello (2002) estimó el consumo a partir de un modelo estadístico basado en características del vehículo. Sin embargo, no se han encontrado referencias donde se monitorice el consumo para comprobar si éste disminuye progresivamente a medida que un conductor repite un trayecto cotidiano.

El consumo de un viaje concreto depende directamente de la experiencia adquirida por el conductor en el trayecto en viajes inmediatamente anteriores. Por ello, la disminución del consumo está relacionada con una curva de aprendizaje. Esta curva describe el incremento de aprendizaje obtenido en el transcurso del tiempo y es conocida por otros nombres como curva progresiva o curva de experiencia. Los modelos más conocidos que representan fielmente la curva de aprendizaje son: log-lineal, Stanford-B, plateau, DeJong y S-model (Yelle, 1979).

3. CASO DE ESTUDIO DE MADRID - M30

A continuación se explican los tramos de aplicación de las medidas TIC y la metodología empleada con detalle.

3.1. Zonas de estudio

Se han escogido siete tramos, de los cuales cuatro se encuentran en la autopista de circunvalación M-30 y tres en zonas urbanas. En la Figura 1 aparecen detallados en un mapa de Madrid. En la Tabla 1 se incluye información de la salida y llegada de cada uno

de los trayectos.

El tramo 1 (Ventas - Costa Rica) está localizado en la zona este de la autopista M-30 (sentido norte). Cuenta con tres o cuatro carriles según la zona y una vía de servicio paralela de tres carriles. La hora punta tiene lugar a primera hora de la mañana. Su longitud es de 5,8 km y está limitado a 90 km/h.



Fig. 1 - Tramos de estudio en la toma de datos de Madrid

Tramo	Salida	Llegada
1	Ventas	Costa Rica
2	Costa Rica	Ventas
3	San Pol de Mar	Arroyofresno
4	Arroyofresno	San Pol de Mar
5	C/Sirio	C/Corregidor
6	C/del Maestro Sorozábal	C/San Pol de Mar
7	Paseo Marqués de Monistrol	C/del Maestro Sorozábal

Tabla 1 – Zonas de inicio y final de cada tramo

El tramo 2 (Costa Rica - Ventas) se engloba en la zona este de la autopista M-30 (sentido sur). Cuenta con tres o cuatro carriles a lo largo de su recorrido y una vía de servicio paralela de tres carriles. La hora punta se alcanza durante la tarde, su longitud es de 5,3 km y está limitado a 90 km/h.

El tramo 3 (San Pol de Mar - Arroyofresno) está comprendido en la zona oeste de la autopista M-30 (sentido norte). Tiene tres carriles y la intensidad en hora punta tiene lugar por la mañana. Su longitud es de 5,4 km y está limitado a 90 km/h en su totalidad.

El tramo 4 (Arroyofresno - San Pol de Mar) es una autopista de 3 carriles con una longitud de 6,7 km. Una gran parte del tramo está limitado a 90 km/h, excepto los últimos 100 m., limitados a 70 km/h (entrada del túnel). En la hora punta, que tiene lugar por la tarde, se da con frecuencia una situación de congestión debido al cuello de botella provocado por la entrada de la carretera de Castilla M-500.

Queda patente el comportamiento asimétrico en cuanto a intensidades de circulación y periodos de hora punta en la autopista M-30.

Los tramos 5, 6 y 7 se corresponden con áreas urbanas, con varias intersecciones reguladas por semáforos. Cuentan con una longitud de 1,2 km, 1,3 km y 1,6 km, siendo el número de paradas medio en cada trayecto de 1,5, 2,8 y 3,4, respectivamente.

3.2. Metodología. Caso de estudio de Madrid

Como parte del proyecto “ICT-Emissions”, durante los meses de marzo y abril de 2013, y en coordinación con el Departamento de Tecnologías del Tráfico de Madrid, se desarrolló una campaña de toma de datos con el objetivo de registrar los perfiles de velocidad y el consumo de combustible en diversos tramos antes y después de la aplicación de diferentes medidas TIC en dos tramos de la autopista de circunvalación M-30. Estas medidas fueron el control de velocidad por tramo en una sección en el este de la autopista M-30 y mensajes de velocidad variable en el oeste. La Figura 2 y la Tabla 2 muestran los días y el horario en que se llevó a cabo la campaña de toma de datos.

Tres turismos FIAT se utilizaron en este estudio, un Punto gasolina con motor 1,2 l y dos diesel, Punto y Bravo, con motorizaciones 1,3 l y 1,6 l respectivamente. El total de viajes registrados es de 3.800 aproximadamente.



Fig. 2 - Calendario de la campaña de toma de datos

Los vehículos estaban equipados con un dispositivo GPS (747+ GPS Recorder) para recopilar datos de distancia recorrida, posición y velocidad instantánea con una frecuencia de 1 Hz, permitiendo así obtener perfiles de velocidad y aceleración. Los datos recogidos por el dispositivo son más tarde descargados para su posterior tratamiento. El consumo de combustible se registró manualmente mediante el ordenador de a bordo del vehículo, que indicaba el consumo medio en l/100 km.

Día de la semana	Viaje	Horario
Lunes	1, 2, 5	De 9:30 a 13:30
Martes	3, 4, 6, 7	De 16:30 a 19:30
Jueves		
Miércoles	1, 2, 5 (6 de marzo y 10 de abril)	De 7:30 a 20:30
	3, 4, 6, 7 (13 de marzo y 17 de abril)	De 7:30 a 20:30
Viernes	1, 2, 5	De 9:30 a 12:00
	3, 4, 6, 7	De 12:00 a 14:30

Tabla 2 - Horarios de la campaña de toma de datos

La campaña de medición de datos consiste en registrar un número representativo de viajes en los tramos escogidos mediante la técnica del vehículo flotante. De esta manera se obtienen los perfiles de velocidad con el GPS y el consumo de combustible con el ordenador de a bordo del vehículo.

Como complemento a la recogida de datos con el dispositivo GPS, se anotaban a su vez en una hoja de ruta la fecha, el conductor, hora de salida, hora de llegada, incidencias de tráfico y climatología para cada viaje.

Para poder estudiar la evolución del consumo de los conductores es necesario disponer de una serie temporal de datos continua en el tiempo, no interrumpida y sin fallos o cambios en los patrones de conducción. Por ello, del total de viajes registrados, se han tomado como válidos los realizados exclusivamente por los conductores del vehículo FIAT Punto 1,3 l diesel. En el caso del vehículo FIAT Punto 1,2 l gasolina, se produjeron fallos en la toma de datos del consumo del ordenador de a bordo, por lo que no se dispone de una serie temporal de datos no interrumpida. Por otra parte, el conductor del vehículo FIAT Bravo 1,6 l diesel realizó técnicas de conducción eficiente, cambiando sus patrones de conducción.

El total de viajes registrados en la campaña de toma de datos fue de 3.800 aproximadamente, de los cuales se han considerado válidos para el análisis 966, que están especificados en la Tabla 3.

El posterior tratamiento de estos datos, teniendo también en cuenta los datos obtenidos de circulación, incidencias y condiciones climatológicas, permiten obtener los resultados de

ahorro de combustible y CO₂, así como la obtención teórica de la curva de aprendizaje seguida por los conductores. Para obtener ésta última se ha comparado cada viaje con la media de los veinte viajes realizados con anterioridad. En la bibliografía no aparecen referencias en relación con la curva de aprendizaje del transporte. No obstante, la curva del olvido de Ebbinghaus (Weiten y McCann, 2009) nos indica que tras 31 días sólo se recuerda un 20% de lo aprendido. Por ello, en el estudio se considera que un conductor recuerda los detalles con claridad hasta una frontera de 31 días e intenta que el valor de consumo de un nuevo viaje se sitúe por debajo de la media de los veinte viajes anteriores (equivalente a los días laborables de un mes, donde es más común que se repita un trayecto).

Tramo	Tipo de viaje	Número de viajes conductor 1	Número de viajes conductor 2	Número de viajes total	Distancia (km)
1	Autopista	80	80	160	5.8
2	Autopista	82	98	180	5.3
3	Autopista	59	56	115	5.4
4	Autopista	61	49*	110	6.7
5	Urbano	87	96	183	1.2
6	Urbano	63	50	113	1.3
7	Urbano	60	45	105	1.6
Total		492	474	966	

Tabla 3 - Número de viajes registrados

*. El tramo 4 del conductor 2 se llevó a cabo en la mayoría de los viajes bajo situaciones de congestión elevadas. La muestra, eliminando dichos viajes, es demasiado reducida para realizar un análisis que arroje resultados significativos.

4. RESULTADOS

Después de tratar y analizar todos los datos recogidos, se hace patente un descenso progresivo del consumo conforme el conductor repite el trayecto. La presentación de resultados se estructura como sigue. En primer lugar, se analiza el ahorro por conductor y tramo comparando la media de los diez últimos viajes y los diez primeros. A continuación se presenta un modelo de regresión lineal simple con el consumo como variable dependiente y el número de viajes como variable independiente. En último lugar, se estima la curva de aprendizaje teórica.

4.1. Comparación de la situación inicial y final

El primer análisis nos lleva a comprobar si existe un descenso del consumo entre los primeros viajes realizados en el mes de marzo y los últimos en el mes de abril.

Para ello se ha calculado la media del consumo de los primeros diez viajes realizados por cada conductor y la media de los diez últimos. En la Figuras 3 y 4 se presentan los resultados obtenidos en autopista y en urbano, respectivamente, con el porcentaje de ahorro

de consumo para cada uno de los tramos.

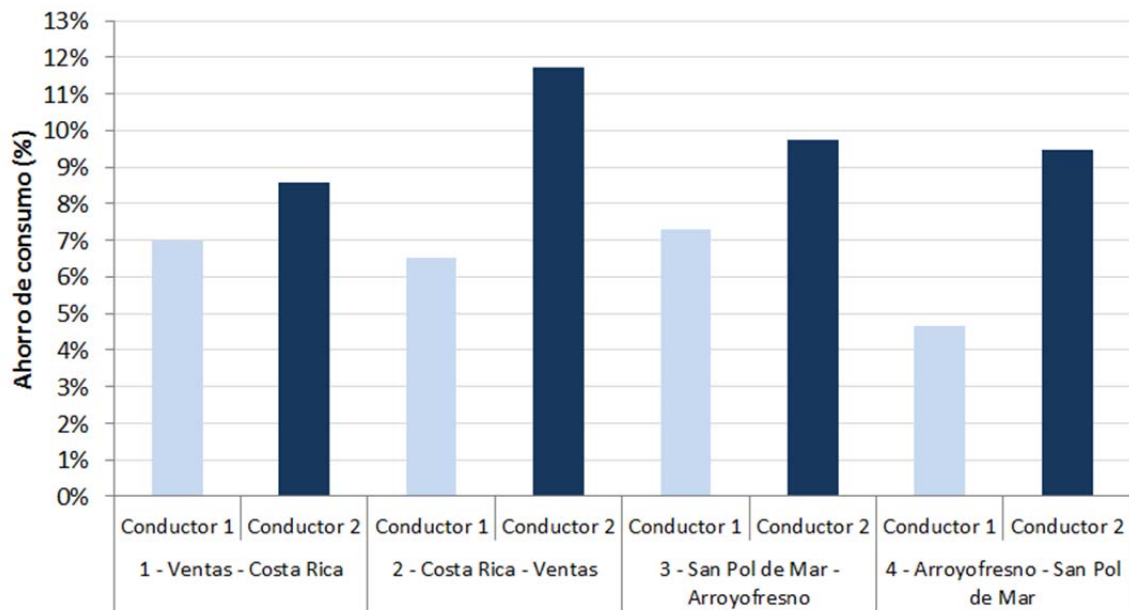


Fig. 3 - Porcentaje de ahorro en autopista por tramo y conductor

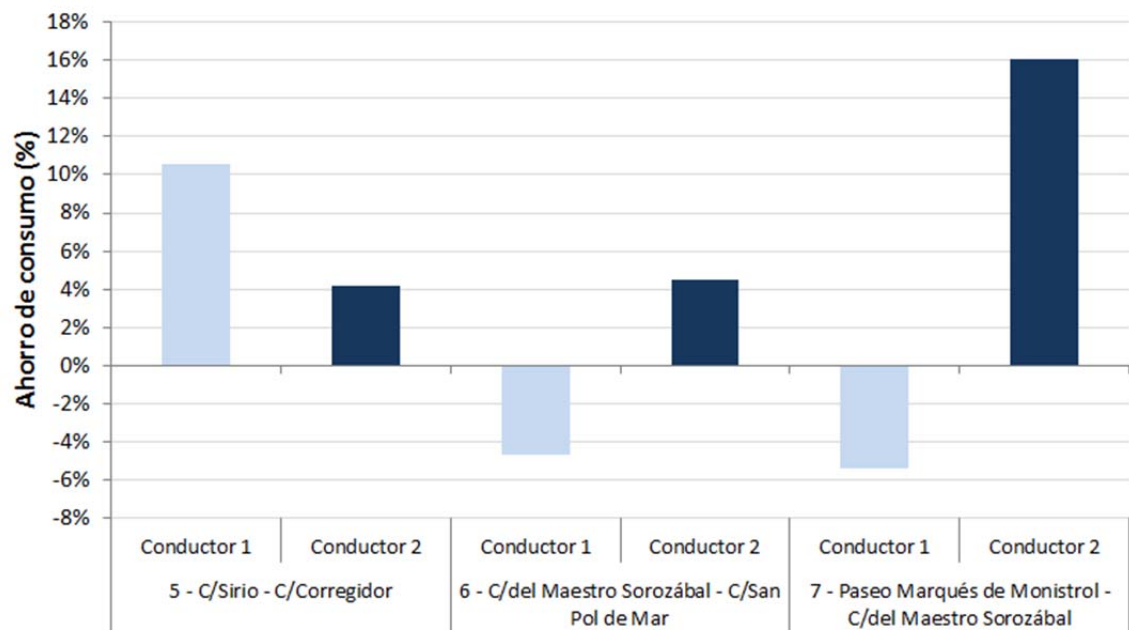


Fig. 4 - Porcentaje de ahorro en urbano por tramo y conductor

En todos los tramos de autopista se percibe un ahorro medio de consumo y CO₂ de un 8%. En urbano el efecto no es tan claro, en los tramos 6 y 7 el conductor 1 consume más en los diez últimos viajes que en los diez primeros. Sin embargo, se registra un ahorro medio de un 6%, excepto en el tramo 6 que permanece invariante debido a la variabilidad del tráfico del trayecto.

4.2. Análisis de regresión lineal

A continuación, se ha realizado un análisis estadístico con todos los datos disponibles. En él se busca establecer una relación con el consumo como variable dependiente y el número de viajes como variable independiente. La ecuación del modelo de regresión propuesto es el siguiente:

$$\text{Consumo} = \beta_0 + \beta_1 \cdot \text{número_viajes} \quad (1)$$

En primer lugar, se han comprobado los cinco supuestos de Gauss-Markov para poder validar el modelo de regresión lineal.

El supuesto más fuerte es el de la normalidad de las variables. Se propone un Z-test basado en la asimetría y curtosis para comprobar la normalidad de la variable dependiente (Ghasemi y Zahediasl, 2012). Los estadísticos utilizados son los siguientes:

$$Z_{\text{asimetría}} = \frac{\text{Valor asimetría}}{SE_{\text{asimetría}}}, \quad Z_{\text{curtosis}} = \frac{\text{Excess Kurtosis}}{SE_{\text{excess curtosis}}}$$

La hipótesis nula formulada es H_0 : los valores de asimetría y curtosis son igual a cero. La normalidad de la variable dependiente quedará probada si no es posible rechazar la hipótesis nula. Por otra parte, se formula la hipótesis alternativa H_1 : los valores de asimetría y curtosis son distintos de cero.

Tramo	Conductor	n	Asimetría	SE _{asimetría}	Curtosis	SE _{curtosis}	Z _{asimetría}	Z _{curtosis}
1	1	80	.332	.269	-.428	.532	1.234	-.805
	2	80	.583	.269	-.234	.532	2.167*	-.440
2	1	82	-.121	.266	-.462	.526	-.455	-.878
	2	98	.167	.244	-.223	.483	.684	-.462
3	1	59	.128	.311	-.677	.613	.412	-1.104
	2	56	.352	.319	-.382	.628	1.103	-.608
4	1	61	-.309	.306	-.257	.604	-1.010	-0.425
	2	49	.606	.340	-.473	.668	1.782	-.0708
5	1	87	.278	.258	-.565	.511	1.078	-1.106
	2	96	.002	.246	-.752	.488	.008	-1.541
6	1	63	.331	.302	.008	.595	1.096	0.013
	2	50	-.194	.337	-.948	.662	-.576	-1.432
7	1	60	.303	.309	-.243	.608	.981	-.400
	2	45	.219	.354	.149	.695	.619	.214

Tabla 4 - Asimetría, curtosis y valores de los estadísticos Z de cada tramo por conductor

*. El viaje 1 del conductor 2 tiene un valor de $Z_{\text{asimetría}}$ de 2,167, mayor que 1,96. Aun así, al ser la muestra mediana ($50 < n < 300$) se puede considerar el p-valor como 3,29 (Kim, 2013), concluyendo que la muestra es normal.

Para muestras pequeñas ($n < 50$), si el valor absoluto del estadístico Z de la asimetría y la curtosis son mayores que el p-valor 1,96, que corresponde a un nivel de significancia del 5% (ensayo de dos colas) existen evidencias suficientes para rechazar la hipótesis nula y concluir que la distribución de la variable dependiente consumo es no normal. Se adopta un análisis restrictivo, pues la muestra de cada tramo es sensiblemente mayor que 50 en la mayoría de los casos. La Tabla 4 muestra el valor de los estadísticos Z.

Por tanto, para todos los casos, los valores de los estadísticos Z son aceptables y se puede concluir que no existen evidencias suficientes para rechazar la hipótesis nula. En la Tabla 5 aparece el coeficiente de determinación para cada uno de los viajes y conductor, así como la correlación bivariada de Pearson entre las variables y el coeficiente β_1 y su significancia estadística.

Tramo	Conductor	n	Correlación Pearson	Sig.	Coef. β_0	Sig.	Coef. β_1	Sig.	R ²
1	1	80	-.455**	.000	4.235	.000***	-.003***	.000	.207
	2	80	-.603**	.000	4.393	.000***	-.005***	.000	.364
2	1	82	-.372**	.001	2.034	.000***	-.002***	.001	.138
	2	98	-.472**	.000	2.307	.000***	-.003***	.000	.223
3	1	59	-.609**	.000	3.612	.000***	-.006***	.000	.370
	2	56	-.603**	.000	3.793	.000***	-.009***	.000	.364
4	1	61	-.303*	.018	2.964	.000***	-.003***	.018	.092
	2	49	-.198	.173	3.311	.000***	-.005	.173	.039
5	1	87	-.381**	.000	4.388	.000***	-.006***	.000	.145
	2	96	-.160	.118	4.517	.000***	-.003	.118	.026
6	1	63	.329**	.009	5.394	.000***	.008***	.009	.108
	2	50	-.193	.179	6.019	.000***	-.005	.179	.037
7	1	60	.079	.549	4.920	.000***	.002	.549	.006
	2	45	-.346*	.020	5.549	.000***	-.016***	.020	.120

Tabla 5 - Coeficientes de correlación de Pearson, coeficientes β , R² y significatividad

*. La correlación es significativa al nivel 0.05 (bilateral)

**.. La correlación es significativa al nivel 0.01 (bilateral)

***. El coeficiente es significativo con un nivel de confianza del 95%

El coeficiente de correlación de Pearson hace referencia a la media de los productos cruzados de las puntuaciones estandarizadas de dos variables. Su valor oscila, en términos absolutos, entre 0 y 1. Un valor positivo indica que existe una relación directa entre las variables, mientras que un valor negativo indica que existe una relación indirecta entre ellas. Valores cercanos a 1 en valor absoluto indican relación fuerte entre las variables y valores cercanos a 0 indican relación débil.

En tramos de autopista (tramos 1-4), la correlación de Pearson y el valor del coeficiente β_1 tienen una significatividad que permite aceptar estadísticamente los resultados obtenidos. En el caso del viaje 4 del conductor 2 no es así. Como ya se ha indicado, el viaje se realizó en un horario en el que existía una situación de congestión diaria. Esto explica que el

patrón de conducción varíe con la situación de congestión y no sea posible establecer una relación entre las variables.

Los coeficientes beta adquieren un valor medio de -0.004 aproximadamente, lo cual según el modelo de regresión planteado, un conductor verá disminuido su consumo en -0.004 l/100 km cada vez que realice un nuevo viaje en un tramo desconocido. Esto es válido hasta el momento en que el tramo es conocido totalmente, es decir, cuando el consumo en un viaje no difiere significativamente de la media de los cinco últimos viajes realizados.

El coeficiente R^2 explica qué cantidad de la variable dependiente “consumo” está explicada por la variable independiente del modelo “número de viajes”. Los valores de R^2 en tramos de autopista se sitúan en torno a 0,30, lo cual indica que el número de viajes explica un 30% el consumo de un vehículo y, por tanto, de las emisiones de CO_2 .

En el caso de tramos urbanos, la baja significancia de algunos coeficientes β_1 indica que no es posible establecer una relación clara entre las variables. La existencia de factores externos que influyen en el consumo tales como congestión, señalización semafórica, etc. provocan este fenómeno. Valores de significancia mayores que 0,05 indican que no existe evidencia estadística al 95% que la correlación de Pearson y el coeficiente de β_1 sean distintos de cero. Sin embargo, se ha demostrado que sí existe un ahorro en el consumo al comparar los primeros diez viajes con los diez últimos en cada tramo.

4.3. Curva de aprendizaje

Para representar la curva de aprendizaje de cada viaje y conductor, se introducen en un gráfico de dispersión el porcentaje del sumatorio del ahorro de combustible en ordenadas y el porcentaje de número de viajes en abscisas. A continuación, se dibuja la curva de tendencia de la nube de puntos, obteniendo así las curvas de aprendizaje individuales, representadas en las Figuras 5 y 6.

Se ha calculado el porcentaje del número de viajes para normalizar los valores y poder comparar las figuras, al no contar todos los tramos con el mismo número de viajes registrados. Por otra parte, el ahorro de consumo se calcula como el decremento entre el consumo de un viaje y la media de los veinte viajes anteriores. A continuación se calcula el sumatorio de todos los valores de ahorro de consumo y de la misma forma, se halla el porcentaje para normalizar los valores y poder comparar las figuras.

Cada trayecto, en función de sus características y situación de tráfico, necesitará que un conductor realice un número de viajes distinto para conocerlo en su totalidad. Se ha considerado que un tramo es conocido totalmente cuando no existen variaciones importantes de consumo entre un viaje y la media de los cinco viajes anteriores. En todos los casos se observa una estabilización en el ahorro de consumo, y por tanto, la llegada a la fase final de la curva de aprendizaje, en la que su pendiente es horizontal.

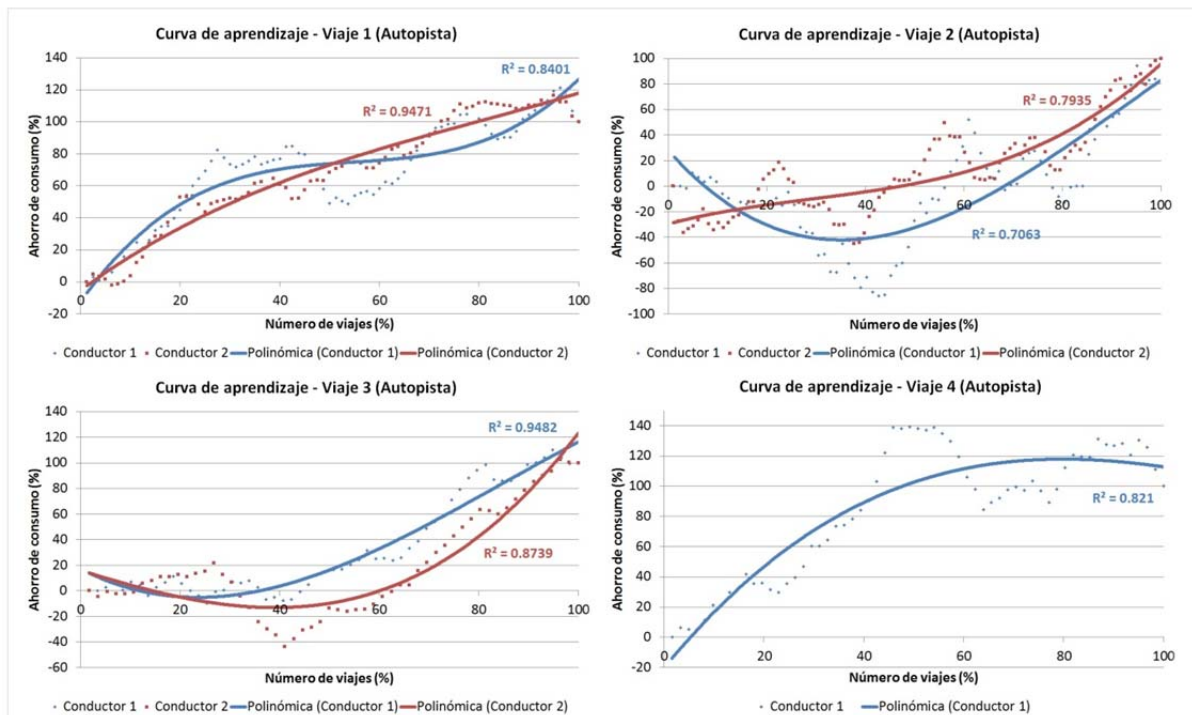


Fig. 5 - Curvas de aprendizaje en autopista por tramo y conductor

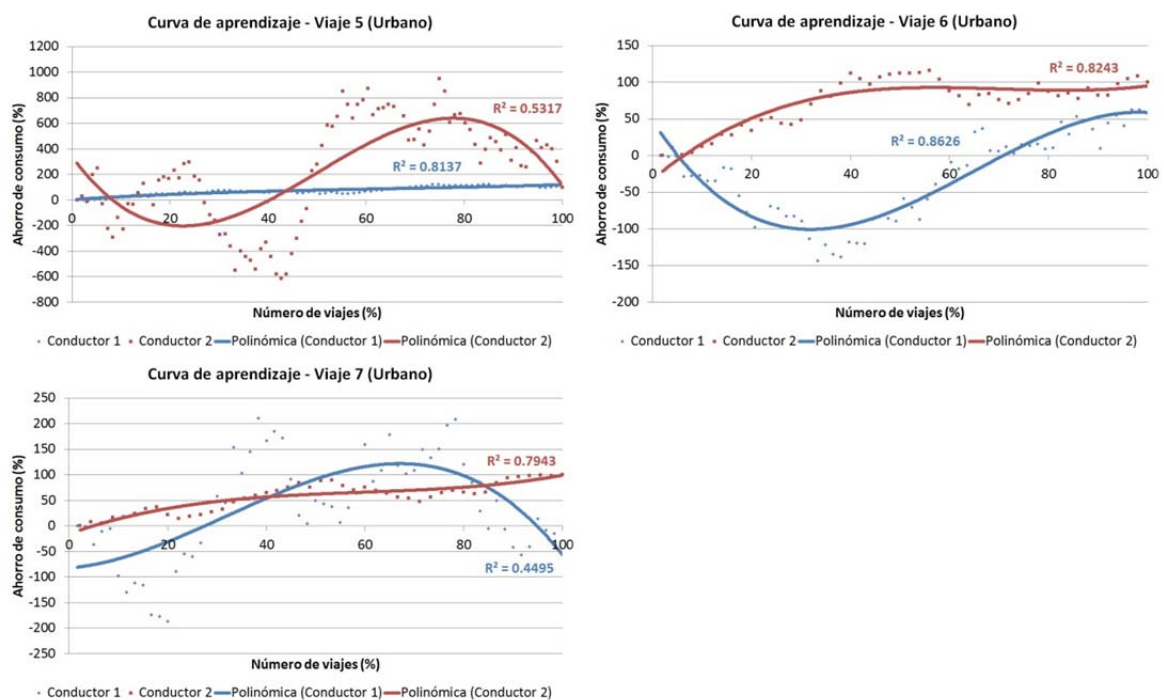


Fig. 6 - Curvas de aprendizaje en urbano por tramo y conductor

El modelo que mejor se ajusta a la nube de puntos es el S-model, que se identifica con una curva de tendencia polinómica cúbica. No existen diferencias significativas entre ajustar la curva mediante una ecuación polinómica de grado 3 o grado superior. En un primer análisis se puede observar cómo en autopista se produce generalmente un incremento progresivo del grado de aprendizaje conforme el número de viajes realizados es mayor.

Sin embargo, en urbano no se observa la misma tendencia. En el viaje 5 existen fuertes variaciones que incluso llegan a un ahorro del 600% y en el viaje 7 del conductor 1 se puede observar cómo se produce una bajada de la curva en los viajes finales.

Esto es explicado por la existencia de diferentes elementos propios del tráfico que influyen en el consumo de combustible, tales como semáforos, intersecciones, glorietas, aceleraciones y deceleraciones frecuentes propias de una zona urbana, pasos de peatones, situaciones de congestión, etc. Todos estos elementos son más propios de zonas urbanas y provocan que en éstas no sea posible aplicar esta metodología de curva de aprendizaje, al no producirse todos los viajes bajo las mismas circunstancias. Aún así, como se mostraba en el epígrafe anterior, se produce un ahorro de consumo si se compara el consumo de los diez últimos viajes con los diez primeros.

La Figura 7 muestra la totalidad de las curvas de aprendizaje en todos los trayectos, descartando los tramos urbanos. Es posible observar cómo la curva de aprendizaje global comienza con una clara tendencia ascendente en los primeros viajes. A continuación, no se aprecia mejoría y la curva se mantiene casi horizontal hasta el 50% de viajes realizados aproximadamente. Es entonces cuando se muestra un ascenso prolongado mayor que el inicial hasta alcanzar el final y volver a estabilizarse.

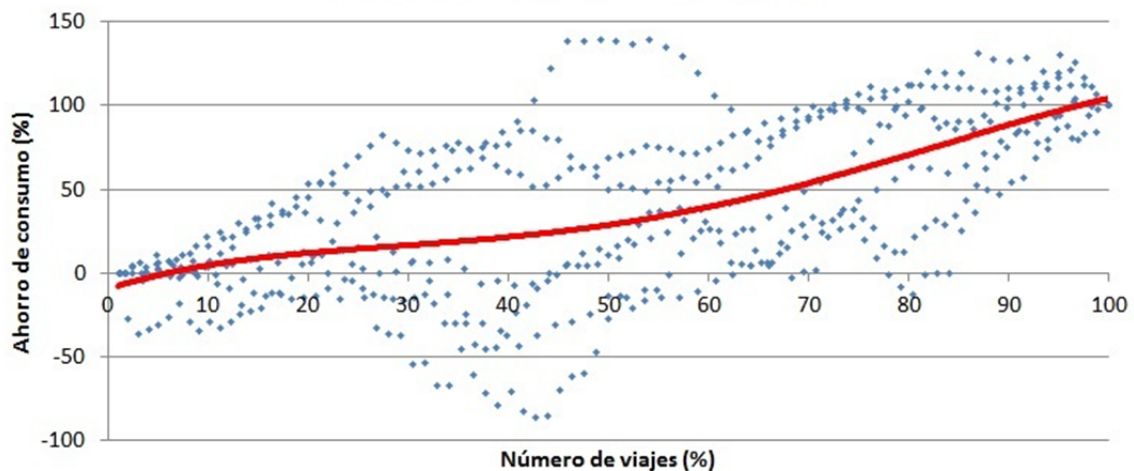


Fig. 7 - Curva de aprendizaje total en autopista

La Figura 8 muestra la curva de aprendizaje teórica para tramos de autopista urbana. Está basada en los resultados obtenidos en la Figura 6. La primera fase de la curva (Trayecto desconocido - Inicio) tiene una pendiente positiva mayor que la segunda fase (Aprendizaje lento), en la que la curva adopta un aspecto casi horizontal. En la tercera fase (Aprendizaje acelerado) la pendiente es mayor y más pronunciada que en la primera fase. En la última fase (Trayecto conocido - Final), el usuario ha optimizado su conducción y conoce perfectamente el trayecto. En esta última fase no se producen reducciones significativas de consumo.




Fig. 8 - Curva de aprendizaje teórica

Los ahorros de consumo y emisiones se verían modificados en caso de que la curva de aprendizaje cambiara. Medidas como una optimización de la gestión de la información y tecnologías disponibles, campañas de educación vial, técnicas de conducción eficiente, etc. podrían variar la curva de aprendizaje del conductor. De esta forma, la experiencia en el tramo se adquiriría más rápido, con el consecuente ahorro de consumo y CO₂.

5. CONCLUSIONES

Este estudio aporta datos concretos sobre la influencia de la experiencia del conductor en un tramo y la monitorización del consumo en la reducción del mismo y las emisiones asociadas de CO₂. Se ha comprobado con un número significativo de viajes que el experimento presenta resultados positivos.

La experiencia adquirida en un trayecto, junto con la monitorización del consumo, lleva al conductor a optimizar su conducción. A medida que un tramo es conocido, se consigue homogeneizar el comportamiento del vehículo, evitando procesos de aceleración y frenado. Por tanto, además de cumplir el objetivo principal (reducción de consumo), demuestra un gran potencial de disminución de emisiones.

La curva de aprendizaje obtenida demuestra, que después de un inicio de aprendizaje lento con una pendiente casi horizontal, tiene lugar un aprendizaje acelerado al alcanzar el 50% de los viajes necesarios para que un conductor se habitúe a un trayecto.

En tramos de autopista, se puede concluir que un 30% del consumo y de las emisiones de

CO₂ está explicado por el número de viajes realizados, y que el ahorro desde el momento en que un conductor realiza un tramo desconocido hasta el momento en que está acostumbrado a él es de un 8%. En tramos urbanos, no es posible establecer una relación estadística que relacione el consumo con el número de viajes, pero sí se ha observado un ahorro de consumo entre la situación inicial y final de un 4%.

Las recomendaciones de gestión de infraestructuras que se derivan del estudio, son la búsqueda de una mayor homogeneidad de carreteras, una buena señalización, realización de campañas de educación vial y la consecución de un mayor porcentaje de conductores que apliquen técnicas de conducción eficiente. Como consecuencia, los usuarios optimizarían su conducción en un trayecto con un número menor de repeticiones, con el consecuente ahorro de consumo y CO₂.

Como futura investigación, sería interesante estudiar el efecto concreto que tendrían las medidas citadas en la curva de aprendizaje, con el objetivo de modificarla y reducir el número de viajes necesarios para alcanzar la fase de aprendizaje acelerado.

AGRADECIMIENTOS

Este trabajo ha sido financiado en parte por la Comisión Europea, bajo el proyecto ICT Emissions, "Desarrollo de una metodología y herramientas para evaluar el impacto de las medidas TIC en las emisiones del transporte por carretera". Grant Agreement N° 288568. Igualmente, se agradece la colaboración del Ayuntamiento de Madrid, Calle-30 y CRF FIAT en el desarrollo de la toma de datos.

REFERENCIAS

BARIC, D., ZOVAK, G. y PERISA, M. (2013). Effects of eco-drive education on the reduction of fuel consumption and CO₂ emissions. *Promet-Traffic & Transportation* 25(3), pp. 265-272.

CAPPIELLO, A., CHABINI, I., NAM, EK., LUE, A. y ZEID, MA. (2002). *A statistical model of vehicle emissions and fuel consumption*. IEEE 5th International Conference on Intelligent Transportation Systems, Proceedings, pp. 801-809.

COMMISSION OF THE EUROPEAN COMMUNITIES (2008). *Action plan for the deployment of Intelligent Transport Systems in Europe*. Tech. Report. COM (2008) 886, 2008.

EUROPEAN ENVIRONMENT AGENCY. Annual European Union greenhouse gas inventory 1990-2011 and inventory report 2013. European Environment Agency. 2013.

GHASEMI, A. y ZAHEDIASL, S. (2012). Normality Tests for Statistical Analysis: A

Guide for Non-Statisticians. *International Journal of Endocrinology & Metabolism* 10(2), pp. 486-489.

HIGUERA DE FRUTOS, S. y CASTRO, M. (2014). Using smartphones as a very low-cost tool for road inventories. *Transportation Research Part C* 38(1), pp. 136-145.

ITF/OECD. Transport greenhouse gas emissions: Country data 2010. International Transport Forum, 2010.

KIM, HY. (2013). Statistical notes for clinical researchers: assessing normal distribution (2) using skewness and kurtosis. *Restorative Dentistry & Endodontics* 38(1), pp. 52-54.

MENDILUCE, M., PEREZ-ARRIAGA, I. y OCAÑA, C. (2010). Comparison of the evolution of energy intensity in Spain and in the EU15. Why is Spain different? *Energy Policy* 38(1), pp. 639-645.

NTZIACHRISTOS, L. y SAMARAS, Z., (2000). Speed-dependent representative emission factors for catalyst passenger cars and influencing parameters. *Atmospheric Environment* 34(1), pp. 4611-4619.

PÉREZ, P. J., y MONZÓN, A. (2006). Informe sobre transporte y medio ambiente. Trama 2006. *Centro de Publicaciones Secretaría General Técnica Ministerio de Medio Ambiente*.

RAMANATHAN, V. y FENG, Y. (2009). Air pollution, greenhouse gases and climate change: Global and regional perspectives. *Atmospheric Environment* 43(1), pp. 37-50.

TU, C., VAN WYK, BJ., HAMAM, Y., DJOUANI, K. y SHENGZHI DU (2013). Vehicle position monitoring using Hough transform. *IERI Procedia* 4, pp. 316-322.

WANG, H., FU, L., ZHOU, Y. y LI, H. (2008). Modelling of the fuel consumption for passenger cars regarding driving characteristics. *Transportation Research Part D* 13(1), pp. 479-482.

WEITEN, W. y MCCANN, D. (2009). *Psychology: Themes and Variations, Second Canadian Edition*. Nelson Education, Toronto.

YELLE, L. E. (1979). The learning curve: historical review and comprehensive survey. *Decision Sciences* 10(2), pp. 302-328.