


Estimación de la autonomía de un vehículo eléctrico según el estilo de conducción

ELECTRIC VEHICLE AUTONOMY ESTIMATION CONSIDERING DRIVING STYLE



DOI: <http://dx.doi.org/10.6036/7199> | Recibido: 22/06/2014 • Aceptado: 06/10/2014

■■■
Alberto Díaz-Álvarez, Francisco Serradilla-García,
José Javier Anaya-Catalán, Felipe Jiménez-Alonso,
José Eugenio Naranjo-Hernández

UNIVERSIDAD POLITÉCNICA DE MADRID. Instituto Universitario
de Investigación del Automóvil (INSIA). Campus Sur de la UPM.
Carretera de Valencia, km. 7 – 28031 Madrid.
Tfno: +34 91 3365317. joseeugenio.naranjo@upm.es

ABSTRACT

• This paper describes a process for estimating the autonomy of electric vehicles based on driver behavior.

To do this, 11 drivers will be monitored while driving across an urban route, collecting some parameters smartphones and their GPS and accelerometer devices and processing them for the extraction of a set of indicators that will determine the driver's driving profile. These indicators, along with the consumption of the vehicle, will be used to train a neural network to predict variables such as passenger comfort and the expected consumption in real traffic conditions.

Since there is a direct relationship between energy efficiency and aggressive driving, this model is also suitable for the scope of driving safety.

• **Keywords:** Eco-driving, Smartphone, GPS, Neural Networks, Energy Efficiency, Driver Modeling.

RESUMEN

En este trabajo se presenta un proceso para la estimación de la autonomía de vehículos eléctricos en función del comportamiento de los conductores al volante.

Para ello, se extraerá una serie de parámetros directamente del GPS y de los acelerómetros de smartphones en una ruta urbana realizada por 11 conductores. De ellos se elaborarán unos indicadores (perfil de conducción) que, junto con el consumo real del vehículo en las rutas, serán empleados para el entrenamiento de una red neuronal cuyo objetivo será la predicción de variables como el confort de los pasajeros y el consumo esperado en condiciones de tráfico reales.

Este modelo, además, es extrapolable al ámbito de la seguridad, ya que existe una relación directa entre eficiencia energética y agresividad en la conducción.

Palabras clave: Eco-driving, Smartphone, GPS, Redes de Neuronas, Eficiencia Energética, Modelado del conductor.

INTRODUCCIÓN

Los vehículos eléctricos son considerados una alternativa ecológica a los vehículos de combustión interna. Su impacto medioambiental, en lo que a gases contaminantes se refiere, es mucho menor en vehículos híbridos; en el caso de los vehículos eléctricos, nulo.

Sin embargo, a día de hoy los combustibles fósiles son todavía los más usados. Esta situación plantea dos problemas fundamentales:

- Entre los residuos generados por el uso de estos combustibles se incluyen algunos perjudiciales para el entorno, como el dióxido de carbono, principal responsable del efecto invernadero, así como otros perjudiciales para la propia sociedad, como el monóxido de carbono o las partículas de hollín, teniendo estas últimas una relación directa con el riesgo de cáncer de pulmón [9].
- El incremento de la cantidad de vehículos per cápita, junto con el hecho de que los combustibles fósiles son un recurso cada vez más escaso, están provocando un problema de escasez que necesita de soluciones alternativas a medio plazo y de acciones paliativas a corto plazo.

Un vehículo eléctrico tiene un efecto positivo en ambos puntos, sin tener en cuenta el origen de la electricidad utilizada en su carga, normalmente de centrales basadas en combus-

tibles fósiles. No obstante, la poca autonomía de sus baterías junto con la escasez de puntos de recarga - también denominadas *electrolineras* - son dos de los principales inconvenientes a la adopción en masa de este tipo de vehículos.

Está demostrado que la aplicación de técnicas de conducción eficiente impactan positivamente en el consumo de combustible y por tanto en el alcance del vehículo. Aunque muchas de las estrategias llevadas a cabo para maximizar la eficiencia de los combustibles en los vehículos se han basado casi exclusivamente en su modificación estructural (e.g. reducción de peso, mejora del coeficiente aerodinámico,...) existen estudios que indican que el comportamiento del conductor al volante es un factor determinante a la hora de evaluar la eficiencia de un vehículo en funcionamiento: dependiendo del estudio [3] [4], las mejoras oscilan entre un 5% y un 25%.

Este es el motivo por el cual algunos vehículos incorporan además ayudas activas y pasivas para asistir al conductor a relacionar acciones con comportamientos eficientes. Estos dispositivos, denominados EDAS (del inglés *Ecological Driving Assistance Systems*) han de estar diseñados de tal forma que presenten la información de una forma simple y directa para asistir al conductor sin distraerle.

Por otro lado, los dispositivos móviles son una plataforma idónea para su utilización en este tipo de escenarios. Su amplia adopción por parte de la sociedad y el aumento en prestaciones y componentes (e.g. GPS, acelerómetro,...) nos proveen de dos ventajas fundamentales: la captura y análisis de datos y la presentación al usuario de dichos datos. Existen algunos trabajos previos que hacen uso de estos dispositivos para obtener indicadores relacionados con la conducción eficiente. En [2] y [8] se introducen unas aplicaciones para móviles que evalúan la eficiencia en el consumo de combustible, emitiendo sugerencias en tiempo real en función de la evaluación difusa de una serie de parámetros obtenidos directamente del vehículo. En [5], [6] y [7] se hace uso de elementos de los dispositivos móviles para obtener los indicadores a partir de los cuales ofrecer la información al conductor.

El presente artículo pretende establecer si es posible estimar, con un alto grado de precisión, el consumo en un coche eléctrico en función del estilo de conducción aplicado a éste, usando para ello componentes comunes a la inmensa mayoría de teléfonos móviles. De esta manera se podrá determinar el

impacto de determinados comportamientos al volante durante la conducción.

La estructura del artículo es la siguiente. En el apartado 2 se describirá el proceso de la recogida de datos así como los distintos datos obtenidos tanto del dispositivo móvil como de la centralita del automóvil. En el apartado 3 se introduce el proceso de caracterización de los perfiles de conductor a partir de los indicadores obtenidos. En el apartado 4 se indica cuál ha sido el proceso de estimación del consumo a partir de los perfiles de conductor obtenidos en el apartado 3. Por último, en el apartado 5 se describen las conclusiones obtenidas en el estudio.

2. MÉTODO

2.1. CAPTURA DE DATOS

El experimento fue llevado a cabo en un vehículo eléctrico *Mitsubishi i-MiEV*, tomando datos tanto desde un dispositivo móvil (*iPhone 4S*) y desde el propio coche a través del bus CAN.

Variable	Descripción	Unidades
V0	Tiempo desde inicio de marcha.	s
V1	Latitud	°
V2	Longitud	°
V3	Velocidad instantánea	Km/h
V4	Aceleración instantánea	Km/h/s
V5	<i>Jerk</i> (i.e. rapidez de aceleración) instantáneo	Km/h/s ²
V6	Eje x – Acelerómetro (lateral)	g
V7	Eje y – Acelerómetro (vertical)	g
V8	Eje z – Acelerómetro (sentido de la marcha)	g
V9	Eje y – Giroscopio	rad/s

Tabla 1: Descripción de variables del experimento




Fig. 1: Ruta seguida para la captura de datos

El *Mitsubishi i-MiEV* es un vehículo eléctrico puro que equipa un pack de 88 baterías de ion-litio. Éstas generan una potencia total de 16 kWh de corriente continua a 330V, lo que le confiere al vehículo una autonomía máxima de 150 Km según el ciclo europeo. Además, entre otros indicadores, nos permite conocer el consumo instantáneo de batería y el porcentaje de batería remanente a una frecuencia de muestreo de 20 Hz.

La captura de datos desde el dispositivo móvil se realizó a través de una aplicación basada en iOS denominada *CarAssistant*, donde eran monitorizados una serie de sensores del teléfono a una frecuencia de 1 Hz (la máxima permitida por los sensores en este dispositivo). Éstos fueron posteriormente almacenados en la memoria interna del móvil.

La Tabla 1 resume el conjunto de variables capturadas. Éstas se iban almacenando en la memoria interna del móvil según eran capturadas. Una vez finalizado cada trayecto, las variables eran extraídas para su procesamiento y posterior análisis.

Hay que destacar que, aunque la ubicación y posición del dispositivo se mantuvo constante en cada uno de los experimentos, la aplicación realiza una operación de calibrado al inicio de la misma para evitar los problemas relacionados con la interpretación de los datos capturados por el acelerómetro.

Estos datos fueron recopilados para 11 conductores conduciendo dicho vehículo eléctrico y siguiendo la ruta que ilustra la Figura 1. Dicha ruta corresponde a un circuito urbano en la ciudad de Madrid de 3,5 km. en un horario de tráfico fluido.

A lo largo de la ruta se evitó circular por túneles, con el objetivo de pasar por todos los semáforos existentes en la ruta y, de esta manera, maximizar las lecturas de datos en los comportamientos de frenada y aceleración de los conductores.

2.2. PERFIL DEL CONDUCTOR

A fin de definir el perfil del conductor desde el punto de vista de la eficiencia energética, es necesario caracterizar cuáles son las características más relevantes que definen su comportamiento a partir de los datos obtenidos en los ensayos realizados. Para ello, se han organizado los datos capturados por cada conductor (datos micro), definiendo aquellos capaces de representar ese gran volumen de datos, y descartando tanto los superfluos como los errores de captura.

De esta manera, se ha realizado previamente un proceso de filtrado de información no relevante, consistente en la eliminación de las muestras de velocidad 0 (vehículo detenido, por lo que no aportan información) y de las muestras con aceleración fuera del rango $[-10, 10]$ (para descartar errores ocasionales en las lecturas del GPS).

Una vez filtrados los datos relevantes, se han seleccionado las variables características que son capaces de definir el comportamiento del conductor (datos macro). Para esta caracterización de los conductores se han empleado 3 variables: velocidad, aceleración y *jerk*, siendo éste definido como la derivada de la aceleración en función del tiempo.

En un principio, para cada una de estas tres variables, se seleccionaron media y varianza de todas las medidas obtenidas en los ensayos para cada uno de los conductores. No obstante, una vez generados los datos y realizado un posterior análisis, quedó patente que el uso de estos 6 datos macro

(media y varianza de la velocidad, la aceleración y el *jerk*) provoca una pérdida de gran cantidad de información relevante para el modelado del comportamiento (e.g. una conducción con numerosos cambios suaves en la aceleración es un caso completamente distinto a una conducción con pocas pero bruscas aceleraciones y deceleraciones, y sin embargo arrojar indicadores macro con medias y varianzas similares).

Por ello, con el fin de modelar estas situaciones, se ha procedido a dividir el conjunto de muestreo en varias particiones, las cuales tienen significación por sí mismas y ayudan a generar un mejor perfil del comportamiento del conductor en maniobras claves para modelar la eficiencia energética. Concretamente, la aceleración se ha dividido en dos particiones, **aceleración positiva (PA)** y **aceleración negativa (NA)**. Asimismo, el *jerk* se ha dividido en cuatro particiones, las cuales corresponden con las siguientes situaciones:

- **Jerk Positivo con Aceleración Positiva.** Corresponde a la situación en la que el conductor está iniciando (incrementando) la aceleración para llegar a una velocidad objetivo más alta. Se denominará a esta situación *jerk* de inicio de marcha (**SMJ**).
- **Jerk Negativo con Aceleración Positiva.** Corresponde a la situación en la que el conductor está llegando a la nueva velocidad deseada y disminuye la aceleración (que sigue siendo positiva) para acomodarse a la nueva velocidad. Se denominará *jerk* de llegada a velocidad de cruce (**CTJ**).
- **Jerk Negativo con Aceleración Negativa.** Corresponde a la situación en la que el conductor inicia una maniobra de reducción de velocidad (e.g. frenada). Se denominará *jerk* de inicio de frenada (**SBJ**).
- **Jerk Positivo con Aceleración Negativa.** Corresponde a la situación en la que el conductor está terminando una maniobra de frenada o de reducción de velocidad. Se denominará *jerk* de fin de frenada (**EBJ**).

El motivo de esta caracterización es la detección de posibles comportamientos ineficientes en los conductores (e.g. frenadas no progresivas o finales de frenada bruscos o no mantenimiento de velocidad constante). Del mismo modo, parece intuitivo pensar que conductores más bruscos producirán valores más elevados en todos los indicadores, y que esta brusquedad deberá correlacionar con otros factores como el confort de los pasajeros y el consumo del vehículo.

Los conjuntos de la caracterización más el conjunto de valores de *velocidad* (V) arrojan un total de 7 conjuntos a analizar. Las variables que serán usadas para modelar el comportamiento de los conductores serán la media y la varianza de cada uno de los conjuntos, resultando un total de 14 variables.

Una vez definidas las variables que se utilizarán a la hora de modelar el comportamiento de los conductores, se ha procedido a realizar un conjunto tomas de datos de una serie de conductores en condiciones controladas, de manera que sus datos sean comparables entre ellos. Así, cada uno de los conductores realizó la ruta especificada en el apartado 2.1, teniendo en cuenta, eso sí, que hay una componente aleatoria que no se puede modelar, como son los estados de los semáforos o el estado del tráfico, los cuales deben ser considerados como ruido inherente al problema.




Fig. 2: Valores de los indicadores obtenidos para los 11 conductores analizados. El eje de las abscisas indica el indicador medido. El eje de las ordenadas izquierdo mide los valores relacionados con la velocidad (Kmh en el caso de las medias y Kmh^2 en el caso de las varianzas) mientras que el eje de las ordenadas derecho mide los valores de las aceleraciones (Kmh/s en el caso de las medias y Kmh^2/s^2 en el caso de las varianzas) y los Jerk (Kmh/s^2 en el caso de las medias y Kmh^2/s^4 en el caso de las varianzas)

La Figura 2 resume los resultados obtenidos para los 11 conductores sobre los que se realizó el estudio. Cada uno de los colores de las gráficas se corresponde a uno de los conductores tanto en la correspondiente a las medias como a la correspondiente en las varianzas.

Las figuras representan el valor del vector de variables para cada uno de los 11 conductores que han participado en los ensayos. Puede observarse que existe una amplia variabilidad en los datos entre conductores, y sin embargo, como parece lógico, hay bastante relación entre los diferentes indicadores de un mismo conductor, es decir, que quien es brusco acelerando suele también ser brusco frenando, etc.

Se puede apreciar que la forma que adquiere la gráfica para cada conductor mantiene una estructura similar pero en rangos distintos de actuación (e.g. conductores s01 y s05, con gráficas similares pero tomando este último valores menores en cada uno de los indicadores), acentuándose o suavizándose en algunos. Se puede apreciar que la información es coherente y suficiente para modelar las diferencias y similitudes de cada conductor, de tal manera que permite establecer un patrón para modelar su comportamiento.

Una vez representado como vector de características de cada conductor, es necesario añadir un dato adicional, a fin de enlazar esas características con la eficiencia energética en la realización de esa ruta. Para ello se ha utilizado el porcentaje de batería consumida (ver Tabla 2) durante el ensayo para cada uno de esos 11 conductores.

3. SISTEMA NEURONAL PARA EL MODELADO DEL CONSUMO DE LOS CONDUCTORES

Como para cada muestra se conoce el consumo de batería obtenido a partir del equipamiento del vehículo, se planteó el desarrollo de un sistema predictor del consumo en función del perfil del conductor. Esto permitiría en futuros desarrollos informar al conductor en tiempo real de su grado de eficiencia

en la conducción y estimar la autonomía del vehículo con el patrón de conducción actual.

Las redes neuronales son estructuras computacionales que efectúan una serie de cálculos no lineales de sus entradas produciendo una serie de salidas. Son capaces de resolver problemas numéricos adaptando sus interconexiones para minimizar el error obtenido en sus salidas con respecto a una serie de datos de entrenamiento [12].

En nuestro trabajo hemos utilizado la topología de red neuronal denominada perceptrón multicapa. Esta arquitectura es una de las más usadas en problemas prácticos de ingeniería debida, principalmente, a su potencia y simplicidad.

Para el entrenamiento de la red neuronal se hizo uso del algoritmo de retropropagación (del inglés *back-propagation*) usando como entradas los 14 indicadores de cada uno de los

Conductor	% de batería consumida en la ruta
S1	2,7
S2	2,72
S3	3,45
S4	2,74
S5	3,06
S6	3,1
S7	2,97
S8	2,91
S9	2,74
S10	3,14
S11	2,56

Tabla 2: Porcentaje de batería consumida en la ruta de cada uno de los conductores analizados

conductores (7 medias y 7 varianzas para los valores de velocidad, aceleración positiva y negativa, y *jerks* de inicio de marcha, llegada a velocidad de cruce, inicio de frenada y fin de frenada), usando como salida esperada de la red el consumo de cada uno de los conductores. Se realizaron dos experimentos utilizando el programa SALMON (*System for Automated Learning: Modeling of Operative Networks*) [11] desarrollado por nuestro grupo de investigación.

El objetivo de la red diseñada es asociar una serie de valores de entrada que describen el perfil de cada conductor (descritos anteriormente) calculados a partir de las lecturas de un teléfono móvil con el consumo medido en el vehículo eléctrico una vez terminado el recorrido.

El problema fundamental del uso de redes (o de cualquier otro procedimiento de aproximación de funciones) es el problema de la generalización. Un sistema generaliza correctamente si es capaz de, una vez ajustado, comportarse adecuadamente al tratar con datos no conocidos previamente, es decir, que no se encontraban entre los datos con los que se ajustó el sistema. La técnica tradicional para estimar el error que se cometerá con datos desconocidos, y por tanto medir la capacidad de generalización del sistema, es la conocida como “evaluación cruzada”, que se basa en guardar una serie de datos del conjunto inicial para que no sean utilizados en el ajuste, de modo que a todos los efectos son datos desconocidos para el sistema. Después del ajuste se comprueba la bondad del sistema con esos datos desconocidos, midiendo el error cuadrático medio (RMS del inglés *Root Mean Squared*) entre las salidas que deberían obtenerse para esos datos desconocidos y las que realmente proporciona el sistema.

En situaciones en las que el conjunto de datos es muy pequeño, sin embargo, prescindir de algunos de los datos para seguir el procedimiento descrito resultaría en un conjunto de entrenamiento aún menor. Para estos casos es recomendable el uso de un procedimiento denominado *bootstrap* [10], el cual consiste en repetir el proceso de ajuste muchas veces, dejando fuera un dato aleatorio cada vez. Después de cada uno de estos ajustes se mide el RMS del pronóstico para el dato que se excluyó. Una vez realizados todos los ajustes se promedia el RMS obtenido, siendo éste un indicador bastante robusto del error que se espera cometer en la fase de explotación del sistema.

En nuestro caso, cada ajuste se realizó con 10 ejemplos de entrenamiento (los 11 sujetos menos el excluido por el algoritmo de *bootstrap*), cada uno con los valores del perfil del conductor como entrada y el consumo realizado por dicho conductor como salida (14 entradas, 1 salida). Se entrenó




Fig. 3: Representación de la red de neuronas implementada. Cada una de las entradas se corresponde con cada una de las variables, siendo aquellas que comienzan por m las medias y por v las varianzas

cada red candidata durante 10.000 *epochs* (cada *epoch* es una iteración de cada uno de los ejemplos en el algoritmo de entrenamiento de la red). Después de esto se calculó el RMS entre el consumo predicho por la red y el consumo real del vehículo para el ejemplo excluido. El proceso se repitió 10.000 veces, promediando el RMS de todos los ajustes realizados.

Después de experimentar con diferente número de neuronas y capas de neuronas en los perceptrones, la red con mejor generalización (menor RMS de *bootstrap*) tenía una arquitectura de 14 neuronas de entrada (una por cada variable del perfil del conductor), 6 neuronas en una capa intermedia (oculta) y 1 neurona de salida (el consumo predicho), la cual está representada gráficamente en la Figura 3. Esta red era capaz de predecir el consumo del vehículo eléctrico a partir de los datos del perfil del conductor (aquellos obtenidos con el *smartphone*) con un RMS de 0,0799, con desviación típica de 0,0013. Estos valores, en las unidades de consumo (de 0 a 100%), significan un RMS absoluto de 0,3196% de batería consumida. Esto significa según el teorema central del límite que el 68,2% de las mediciones se encontrarán en el rango $[c-0,3196, c+0,3196]$, siendo c el consumo real que se medirá al final del recorrido.

Con la red entrenada se realizó un análisis de sensibilidad para determinar en qué medida la variación en cada una de las entradas influía en la salida. En la Tabla 3 podemos observar los resultados de dicho análisis donde la influencia se

mNA	mPA	mSMJ	mCTJ	mSBJ	mEBJ	mV	vNA	vPA	vSMJ	vCTJ	vSBJ	vEBJ	vV
0,272	0,145	0,205	0,282	0,031	0,268	0,625	0,232	0,013	0,125	0,150	0,513	0,045	1,0

Tabla 3: Análisis de sensibilidad de las variables de entrada

representa como valores dentro del intervalo $[0, 1]$, siendo 0 ninguna influencia y 1 la máxima influencia.

Realizado el análisis de sensibilidad se determinó que 6 de las entradas (marcadas en negrita) tenían una contribución muy baja en la salida, de modo que se probó a repetir el experimento con una red con las 8 variables de entrada que resultaron más significativas, y se consiguió con ello mejorar la generalización de la red, que pasó a un RMS de 0,0625 que se traduce en un RMS absoluto de 0,25%. Esto implica que el 75% de las mediciones del sistema de encontrarán dentro del rango $[c-0,0625, c+0,0625]$.

4. CONCLUSIONES

El experimento del entrenamiento del perceptrón con una capa oculta demuestra que existe una relación no lineal entre los indicadores del perfil y del consumo, pero que es posible estimar con bastante precisión el consumo del vehículo eléctrico a partir de las mediciones realizadas por el *smartphone*. Sin embargo, sería necesario ampliar esta investigación con la recogida de datos de más usuarios para estimar con validación cruzada el error esperado en caso de llevar el sistema a explotación.

Los resultados arrojados por el análisis de sensibilidad indican que los factores más influyentes son la varianza de la velocidad (**vV**), la media de la velocidad (**mV**) y la varianza

en el *jerk* de inicio de frenada (**vSBJ**), ordenados de mayor a menor influencia. Esto es debido a que son las variables que mayor variación producen en la salida de la red cuando sus valores cambian, manteniendo las demás variables en su valor medio. Por tanto, en el caso que nos ocupa, los cambios bruscos en la velocidad de conducción son los que mayor impacto tienen sobre el consumo.

El RMS obtenido en la estimación del consumo producido indica que, haciendo uso del modelo desarrollado en el presente artículo, es posible predecir con bastante precisión el consumo esperado en un vehículo eléctrico a partir del estilo de conducción, y por tanto, que es posible determinar el grado de eficiencia de un conductor en un trayecto.

Asimismo, el haber aislado las variables que más influyen en el consumo permitirá, en futuros trabajos, la definición de comportamientos considerados como malos hábitos para asistir al conductor en detección de los mismos, y, por tanto, en aumentar la eficiencia de la conducción.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Ministerio de Ciencia e Innovación (TRA2010-0225-C03-03, TRA2010-15645 y TRA201348314-C3-2-R) y por la Comunidad de Madrid a través del proyecto SEGVAUTO-II (S2009/DPI-1509).

BIBLIOGRAFÍA

- [1] Andrieu P. & Pierre G. "Using statistical models to characterize eco-driving style with an aggregated indicator". IEEE 2012. Intelligent Vehicles Symposium (IV) (págs. 63-68). IEEE.
- [2] Araujo R. Igreja A. & De Castro R. "Driving coach: A smartphone application to evaluate driving efficient patterns". IEEE 2012. Intelligent Vehicles Symposium (IV) (págs. 1005-1010).
- [3] Barkenbus J. "Eco-driving: An overlooked climate change initiative". Elsevier 2010. Energy Policy 38 (2) 762-769.
- [4] Boriboonsomsin K. Vu A. & Barth M. "Eco-driving: Pilot evaluation of driving behavior changes among US drivers". IEEE 2010.
- [5] Corcoba M. & Organero M. "Artemisa: An eco-driving assistant for Android OS". IEEE 2011 Consumer Electronics-Berlin (ICCE-Berlin) IEEE International Conference on (págs. 211-215).
- [6] Ishikawa N. Onda K. Watanabe K. Kobayashi K. & Kurihara Y. "Mobile phone application for ecodriving". IEEE 2010. SICE Annual Conference 2010 Proceedings of (págs. 2424-2447). IEEE.
- [7] Johnson D. & Trivedi M. "Driving style recognition using a smartphone as a sensor platform". IEEE 2011. Intelligent Transportation Systems (ITSC) 2011 14th International IEEE Conference on (págs. 1609-1615).
- [8] Magana V. & Organero M. "Artemisa: Using an Android device as an Eco-Driving assistant". IEEE 2011. IEEE International Conference on Consumer Electronics.
- [9] Olsson A. Gustavsson P. Kromhout H. Peters S. Vermeulen R. Brüske I. y otros. "Exposure to diesel motor exhaust and lung cancer risk in a pooled analysis from case-control studies in Europe and Canada". IEEE 2011 (A. T. Soc Ed.) American journal of respiratory and critical care medicine 183 (7) 941-948.
- [10] Franke Jürgen and Michael H. Neumann. "Bootstrapping neural networks". Neural Computation 12.8 (200): 1929-1949.
- [11] Naranjo J. E. Jiménez F. Serradilla F. J. and Zato J. G. "Floating car data augmentation based on infrastructure sensors and neural networks". (2012) Intelligent Transportation Systems IEEE Transactions on 13(1) 107-114.
- [12] Calvo J.L. Machón I. López H. "Controlador Neuro-Robusto para sistemas no lineales" DYNA. JUNIO 2011. Vol. 86-3 p.308-317. DOI: <http://dx.doi.org/10.6036/3949>