

19



OFICINA ESPAÑOLA DE
PATENTES Y MARCAS

ESPAÑA



11 Número de publicación: **2 535 689**

51 Int. Cl.:

G08G 1/01 (2006.01)

12

TRADUCCIÓN DE PATENTE EUROPEA

T3

96 Fecha de presentación y número de la solicitud europea: **12.12.2012 E 12382494 (8)**

97 Fecha y número de publicación de la concesión europea: **18.02.2015 EP 2610836**

54 Título: **Dispositivo y método para la predicción 'on-line' del ciclo de conducción en un vehículo automóvil**

30 Prioridad:

30.12.2011 ES 201132144

45 Fecha de publicación y mención en BOPI de la traducción de la patente:

13.05.2015

73 Titular/es:

**SEAT, S.A. (100.0%)
Autovía A-2, Km. 585
08760 Martorell (Barcelona) ES**

72 Inventor/es:

**VALERA GARCÍA, JUAN JOSÉ;
CAUS ROQUETA, JORDI y
LUX, GERHARD**

74 Agente/Representante:

LEHMANN NOVO, María Isabel

ES 2 535 689 T3

Aviso: En el plazo de nueve meses a contar desde la fecha de publicación en el Boletín europeo de patentes, de la mención de concesión de la patente europea, cualquier persona podrá oponerse ante la Oficina Europea de Patentes a la patente concedida. La oposición deberá formularse por escrito y estar motivada; sólo se considerará como formulada una vez que se haya realizado el pago de la tasa de oposición (art. 99.1 del Convenio sobre concesión de Patentes Europeas).

DESCRIPCIÓN

Dispositivo y método para la predicción 'on-line' del ciclo de conducción en un vehículo automóvil

Campo de la invención

5 La presente invención se engloba dentro del campo de la automoción y más en concreto dentro de los dispositivos y métodos para la predicción 'on-line' (mientras el vehículo está circulando) del ciclo de conducción de un vehículo híbrido con respecto a un horizonte de predicción preseleccionado. El objeto de la invención es proporcionar la predicción realizada al subsistema de administración de energía del vehículo híbrido para que dicho vehículo adapte su estrategia energética en función de dicha predicción y de esta forma pueda reducir el consumo del vehículo, así como optimizar los diferentes flujos energéticos que se encuentran en un vehículo híbrido para aumentar su eficiencia energética, su autonomía y reducir las emisiones de CO₂.

Antecedentes de la invención

15 Es bien conocido el hecho de que si el ciclo de conducción (velocidad del vehículo = f (tiempo)) y el ciclo de pendientes o gradientes del terreno (gradiente = f (tiempo)) se conocen de antemano, es posible calcular una estrategia energética óptima para el sistema de propulsión de un vehículo híbrido-eléctrico que minimice una función de coste compuesta por términos relacionados con el consumo, las emisiones y / o la eficiencia energética, entre otros, del vehículo.

Para alcanzar el óptimo global, existen tres inconvenientes u obstáculos que superar:

20 1) El ciclo de conducción que tiene que realizar el conductor no se conoce de antemano. Aunque se conociera el destino final y el trayecto a realizar, el ciclo de conducción depende del estilo de conducción del conductor y de las posibles perturbaciones relacionadas con el entorno de conducción, tales como la congestión del tráfico, las condiciones meteorológicas, los límites de velocidad por obras, etc.

2) Aunque se conociera de antemano el ciclo de conducción, es necesario contar con un comportamiento del vehículo bien modelado para construir la función de coste que resulta de plantear el problema de optimización.

25 3) Una vez planteado el problema de optimización, es necesario resolverlo para calcular el óptimo global. En este sentido, cabe señalar que se trata de resolver un problema de optimización no lineal, no convexo y no cuadrático, por lo que: (i) no existe solución explícita o analítica del mismo, y (ii) existen técnicas para encontrar el óptimo global tales como la programación dinámica (DP), pero se trata de técnicas que no pueden ser tratadas computacionalmente en sistemas de control 'on-line' en tiempo real. Por tanto, se deben realizar ciertas aproximaciones al problema para su resolución con un coste computacional adecuado. Así, la solución se acercará al óptimo global, aunque dicho óptimo global no puede alcanzarse (estrategias subóptimas).

35 La presente invención se centra en el desarrollo de un sistema o dispositivo que contribuye a solucionar el primer inconveniente o barrera relacionado con el conocimiento previo del ciclo de conducción que va a realizar el vehículo. De este modo, este sistema o dispositivo obtiene la predicción 'on-line' del futuro ciclo de conducción (velocidad* = f* (tiempo)) y el ciclo de pendientes gradientes del terreno (gradiente* = f* (tiempo)) con respecto a un horizonte de predicción preseleccionado, enviando esta predicción al sistema de administración de energía del vehículo híbrido-eléctrico. Por lo tanto, el sistema de administración de energía del vehículo podrá utilizar esta predicción en el planteamiento del problema de optimización de energía y en la resolución o búsqueda de una solución (administración de energía / reparto de potencia-energía en el sistema de propulsión) que sea óptima y cercana a la solución global óptima.

40 El modelo de un conductor se refiere a la representación por medio de formulaciones matemáticas o algoritmos inteligentes del comportamiento del conductor de un vehículo, es decir, de las tareas del conductor para analizar o inferir qué acciones toma el conductor con dicho vehículo.

45 En la referencia bibliográfica [1] (Boyras, Sathyanarayana, y Hansen, 2009) se describen diferentes técnicas o algoritmos de modelado de conductor. Los modelos eran inicialmente lineales, siendo reemplazados gradualmente por modelos no lineales, probabilísticos y por técnicas inteligentes, tales como lógica borrosa y redes neuronales, como se describe en la referencia bibliográfica [2] (Panou, Bekiaris, y Papakostopoulos, 2007). Sin embargo, las últimas tendencias de modelado de conductor se dirigen a una combinación de todas o algunas de las técnicas antes mencionadas, refiriéndose a este grupo de modelos como híbrido. En esta clasificación habría que añadir autómatas tipo Mealy utilizados en [3] (Kiencke y Nielsen, "Road y Driver Models", 2005) para la lógica de control de las maniobras de vehículos.

50 Un enfoque más amplio relaciona el modelo del conductor con el modelo puramente dinámico del coche, así como con el entorno del conductor y su vehículo, es decir, la ciudad y otros conductores. Por tanto, se pueden definir diferentes tipos de modelos de conductor de acuerdo con la realidad que mejor quieren representar.

Existen muchos campos de aplicación de dichos modelos y la tendencia en las últimas décadas es que tengan una repercusión cada vez mayor, [2] (Panou, Bekiaris, y Papakostopoulos, 2007). Si las diferentes aplicaciones se agrupan bajo paraguas comunes, existen principalmente tres tendencias, a las que se añade una cuarta de acuerdo con el último trabajo realizado en este campo.

5 1. El comportamiento del conductor de acuerdo con los procesos cognitivos y fisiológicos

- a. Análisis del comportamiento del conductor
- b. Inferencia del comportamiento del conductor
- c. Entrenamiento y asesoría del conductor

2. Control del vehículo

- 10
- a. Simulación y prototipado
 - b. Dinámica del vehículo
 - c. Sistemas de control para asistencia en la conducción y la seguridad (ABS, ESC, control de tracción....)
 - d. Conducción autónoma

3. Simulación del tráfico

- 15
- a. Microscópico
 - b. Macroscópico

4. Estrategias energéticas

20 La primera tendencia se centra en las características del comportamiento humano del conductor, es decir, el análisis de dicho comportamiento, la interpretación de gestos y emociones por una parte y la inferencia de ese comportamiento en el control del vehículo, maniobras y estrategia de conducción. Resulta obvio incluir el modelo jerárquico de control de Michon (1985) dentro de este paraguas. La primera distinción que hace es diferenciar entre modelos externos de estado de tipo entrada-salida y los de tipo interno. La otra distinción se refiere a modelos funcionales o modelos de taxonomía. Michon afirma que los modelos son generalmente de abajo hacia arriba (internos) y que los modelos de arriba hacia abajo son por lo general inespecíficos y demasiado simplificados. Su modelo de tipo de proceso cognitivo, el Modelo de Control Jerárquico, divide la tarea de conducción en tres niveles acoplados y jerárquicos:

- 25
- 1. El nivel estratégico: planificación del trayecto, elección de ruta
 - 2. El nivel de maniobrabilidad: se refiere al conductor con los otros vehículos
 - 3. El nivel de control: se refiere al nivel de control del vehículo

30 Un cuarto nivel sería el nivel puramente de comportamiento, [2] (Panou, Bekiaris, y Papakostopoulos, 2007). Otra clasificación adecuada del comportamiento del conductor es la que distingue entre el seguimiento de un trayecto deseado y la de la estabilidad en caso de perturbaciones.

35 El segundo grupo de aplicaciones se centra exclusivamente en la tarea de control del vehículo. Este grupo tiene una correlación directa con el nivel de control de Michon. El control de un vehículo se divide en dos, control longitudinal (acelerador y freno) y control lateral (volante). Se considera a Tustin (1947) el primer autor en publicar un modelo de conductor en forma matemática. McRuer y Krendel, Ragazzini y Jackson ([4] Abe, 2009) se unieron más tarde a Tustin realizando aportaciones de interés.

40 Aunque en un principio el control longitudinal y el lateral fueron controlados de forma independiente, recientes aportaciones relacionan ambos controles ya que uno afecta al otro ([1] Boyraz, Sathyanarayana, y Hansen, 2009). Estos controles se estudian junto con las diferentes maniobras del vehículo. Las tres principales maniobras son las de mantenimiento en el carril, las de cambio de carril y las de control de velocidad de acuerdo con las señales de tráfico y el seguimiento de un vehículo. Para un resumen crítico exhaustivo de estas técnicas ver [5] (Khodayari, Ghaffari, Ameli, y Flahatgar, 2010). Además de estos controles específicos para cada maniobra, se proporciona una lógica de decisión para establecer qué maniobra es la adecuada para cada situación. La referencia [3] (Kiencke y Nielsen, Road and Driver Models, 2005) propone un autómata de Mealy.

45

El tercer tipo de modelos se centra en la simulación de tráfico, tanto microscópicamente (comportamiento individual con respecto al tráfico) como macroscópicamente (grandes entornos con varios conductores) ([6] Fernández, 2010).

5 El cuarto tipo de modelos se refiere a los utilizados en la búsqueda de un sistema óptimo de administración de energía para vehículos híbridos. La importancia del modelo de conductor en estas aplicaciones se debe a que su comportamiento afecta considerablemente a la distribución de energía.

En la referencia bibliográfica [7] (Froberg y Nielsen, 2008) se desarrolla un nuevo modelo de conductor específicamente para simulaciones inversas dinámicas con el fin de optimizar los tiempos de simulación utilizados en la búsqueda de estrategias de energía y de propulsión. Su objetivo es la eficiencia de la simulación de ciclos de conducción, no su aplicación en tiempo real.

10 Sin embargo, además del efecto del conductor, también influye considerablemente el tipo de vía, la situación del tráfico, el modo de funcionamiento y la tendencia en la conducción ([8] Murphey Y., 2008). La clave para este problema es la predicción del comportamiento del conductor y del entorno del conductor para determinar así el modo de funcionamiento óptimo. Sólo recientemente se han acometido investigaciones en esta dirección. Los algoritmos utilizados se basan parcialmente en técnicas inteligentes.

15 Un trabajo relevante es el de la referencia [9] (Langari y Won, 2005). Este trabajo presenta un sistema para identificar el ciclo de conducción por medio de una red neuronal LQV y un sistema de lógica borrosa con el propósito de mejorar la administración de energía (IEMA). Mediante el análisis del ciclo de conducción actual, intenta identificarlo comparándolo con 9 ciclos de conducción previamente seleccionados de diferentes vías. Por lo tanto, la predicción no tiene en cuenta los datos reales del entorno en un futuro, sino que los estima a partir de ciclos tipo.

20 De una manera muy similar, la referencia [10] (Murphey, et al., 2008) desarrolla su propio algoritmo y dicho algoritmo se aplica a un vehículo convencional, logrando reducciones de combustible de hasta el 2,68% en tiempo real. Los autores hacen hincapié en que la mejora con un algoritmo de DP (programación dinámica) en off-line es de 2,81%. Su sistema IPC se basa en redes neuronales para la predicción del entorno de conducción actual. Se analiza después con ciclos de conducción tipo para su identificación. Una evolución de este mismo algoritmo se puede encontrar en [11] (Park, et al., 2009). Al igual que en la referencia anterior, los datos del entorno futuro no se tienen en cuenta.

30 Otro algoritmo similar es el que se muestra en la referencia [12] (Huang, Tan, y He, 2010). Los autores primero realizan un análisis estadístico del ciclo de conducción de muestra en tiempo real y luego predicen las condiciones de conducción mediante un SVM (máquina de vectores de soporte) y una red neuronal. Tiene una precisión del 95%. Sin embargo, toda la predicción se basa en los datos recogidos en tiempo real por lo que no incluye datos del entorno en un futuro.

Otro enfoque para el problema es mediante el reconocimiento del patrón de conducción por medio de la lógica borrosa y la posterior predicción mediante Hidden Markov Models ([13] Montazeri- Gh, Ahmadi, y Asadi, 2008). El óptimo no está asegurado porque se utiliza lógica borrosa.

35 El éxito de la estrategia de control depende en gran medida de la calidad de esa predicción, así como de la longitud de dicha predicción ([14] Koot, Kessels, Jager, Heemels, den, y Steinbuch, 2005). El algoritmo utilizado debe ser óptimo, aunque dada la complejidad del problema se logra un *quasi óptimo*. Para incluir la mayor cantidad posible de información del entorno del conductor, se deben obtener datos del estado de la carretera y de la congestión del tráfico y del tipo de vía y el límite de velocidad. Con la ayuda de sistemas de navegación modernos de tipo GPS, sería posible obtener estos datos. Esta tecnología puede dar como resultado una mayor eficiencia y precisión en la predicción del comportamiento del conductor y, de ese modo, del comportamiento del sistema de propulsión inteligente, que es fundamental en la eficiencia global de los vehículos híbridos eléctricos.

Bibliografía

45 [1] Boyraz, P., Sathyanarayana, A., & Hansen, J. H. (2009). "Driver behavior modeling using hybrid dynamic systems for 'driver-aware' active vehicle safety. (ESV) Enhanced Safety for Vehicles", -, 13-15.

[2] Panou, M., Bekiaris, E., & Papakostopoulos, V. (2007). Modelling Driver Behaviour in European Union and International Projects. In Modelling Driver Behaviour in Automotive Environments (pp. 3-25). Springer London.

[3] Kiencke, U., & Nielsen, L. (2005). Road and Driver Models. In Automotive Control Systems (pp. 425-464). Springer Berlin Heidelberg.

50 [4] Abe, M. (2009). Vehicle Handling Dynamics. El Sevier.

[5] Khodayari, A., Ghaffari, A., Ameli, S., & Flahatgar, J. (2010). A historical review on lateral and longitudinal control of autonomous vehicle motions. (pp. 421-429).

- [6] Fernandez, A. (2010). Simulación del comportamiento de los conductores mediante agentes inteligentes. Universidad Complutense Madrid.
- [7] Froberg, A., & Nielsen, L. (2008). Efficient Drive Cycle Simulation. Vehicular Technology, IEEE Transactions on, 57, 1442-1453.
- 5 [8] Murphey, Y. (2008). Intelligent Vehicle Power Management - An Overview. In Computational Intelligence in Automotive Applications (Vol: 132, pp. 223-251). Springer Berlin / Heidelberg.
- [9] Langari, R., & Won, J.-S. (2005). Intelligent energy management agent for a parallel hybrid vehicle-part I: system architecture and design of the driving situation identification process. Vehicular Technology, IEEE Transactions on, 54, 925-934.
- 10 [10] Murphey, Y., Chen, Z. H., Kiliaris, L., Park, J., Kuang, M., Masrur, A., et al. (2008). Neural learning of driving environment prediction for vehicle power management., (pp. 3755-3761).
- [11] Park, J., Chen, Z., Kiliaris, L., Kuang, M., Masrur, M., Phillips, A., et al. (2009). Intelligent Vehicle Power Control Based on Machine Learning of Optimal Control Parameters and Prediction of Road Type and Traffic Congestion. Vehicular Technology, IEEE Transactions on, 58, 4741-4756.
- 15 [12] Huang, X., Tan, Y., & He, X. (2010). An Intelligent Multifeature Statistical Approach for the Discrimination of Driving Conditions of a Hybrid Electric Vehicle. Intelligent Transportation Systems, IEEE Transactions on, PP, 1-13.
- [13] Montazeri-Gh, M., Ahmadi, A., & Asadi, M. (2008). Driving condition recognition for genetic fuzzy HEV Control. (pp. 65-70).
- 20 [14] Koot, M., Kessels, J., Jager, B. d., Heemels, W., den, P. v., & Steinbuch, M. (2005). Energy management strategies for vehicular electric power systems. Vehicular Technology, IEEE Transactions on, 54, 771-782.

Descripción de la invención

La presente invención consiste en un dispositivo y un método para la predicción 'on-line' (mientras el vehículo está circulando) del ciclo de conducción en un vehículo con respecto a un horizonte de predicción preseleccionado. El dispositivo propuesto se basa en una estrategia de predicción compuesta por una etapa de preprocesamiento de las 25 entradas recibidas, una red neuronal artificial (RNA), y una etapa de postprocesamiento para la obtención de la predicción. La estrategia se apoya en tres fuentes de información principales:

- Ejemplos / datos utilizados para entrenar la red neuronal artificial.
- Base de datos de tráfico (señales de tráfico según trayecto a realizar).
- Sistema de navegación de segunda generación con información de tráfico en tiempo real. Utilización de la 30 información (eventos y estado del tráfico) que facilita este tipo de sistemas de forma anticipada.

El dispositivo predice el futuro ciclo de conducción (velocidad Vs tiempo, y gradiente del trayecto Vs tiempo), mientras el vehículo está circulando. Para ello, el dispositivo utiliza cierta información (medidas) del ciclo de conducción realizado en el pasado reciente, así como cierta información (de los nuevos sistemas de navegación que están conectados con sistemas de gestión del tráfico en tiempo real, sistemas de segunda generación) de carácter 35 anticipativo relacionada con los futuros eventos de tráfico que se producirán en el trayecto que se está realizando.

El objeto principal de este dispositivo y método es el de proporcionar la predicción realizada al subsistema de administración de energía del vehículo híbrido para que dicho vehículo adapte su estrategia energética en función de dicha predicción, y de esta forma pueda reducir el consumo del vehículo, así como optimizar los diferentes flujos energéticos que se encuentran en un vehículo híbrido para aumentar su autonomía y reducir las emisiones de CO₂.

40 El dispositivo propuesto tiene un canal de comunicación para conectarse al sistema de navegación de segunda generación del vehículo y otro canal de comunicación para conectarse al subsistema (Unidad de Control Electrónico, ECU) que realiza funciones de administración de energía en un vehículo híbrido.

El dispositivo / método propuesto recibe la medida de velocidad actual del vehículo, así como información del subsistema de navegación relacionada con información sobre el trayecto que se está realizando (límites de 45 velocidad, pendientes de carreteras, ...), así como información en tiempo real de eventos de tráfico que se están produciendo en los puntos próximos por los que va a circular el vehículo (atascos, retenciones, ...).

Esta información (medida de velocidad e información del sistema de navegación) se preprocesa y utiliza como entrada en una red neuronal con una topología específica que obtiene principalmente dos salidas. La primera salida

corresponde a la predicción del ciclo de conducción (velocidad Vs tiempo*) hecha con respecto a un horizonte de predicción seleccionado (generalmente dado en Km), mientras que la segunda salida corresponde a la predicción del ciclo de pendientes (pendiente Vs tiempo*) con respecto al horizonte seleccionado. El dispositivo y el método propuestos obtienen además una tercera salida relacionada con el estilo de conducción del usuario. Para obtener esta tercera salida, se utiliza un sistema de inferencia borrosa utilizando reglas específicas expertas que se basan en parámetros específicos que se están obteniendo con las medidas del ciclo de conducción del pasado reciente.

Por último, hay que señalar que el algoritmo y técnica de predicción propuestos (basados en red neuronal, sistema de inferencia borrosa y etapas de preprocesamiento y postprocesamiento de la información) funcionan 'on-line' mientras el vehículo está circulando, calculando y obteniendo nuevas predicciones (actualización de la predicción) en cada instante de muestreo seleccionado para ello.

La red neuronal utilizada trata de obtener la función no lineal que mejor se aproxima a la circulación actual del vehículo-conductor. Para ello, esta red aprende gradualmente el comportamiento del vehículo y los diferentes modos de conducción del conductor habitual mediante los ciclos de conducción que finalmente se van realizando. Por tanto, se refiere a un dispositivo / método con capacidad de autoaprendizaje.

En cuanto a las diferencias con respecto a otros sistemas similares, se puede señalar que este dispositivo / método no trata de caracterizar o clasificar el ciclo de conducción que se está realizando (como lo hacen la mayoría de los sistemas / técnicas revisados) de acuerdo con unos ciclos patrón, y tomar acciones en base a esta clasificación en función de un sistema basado en normas, sino que el dispositivo propuesto obtiene la predicción utilizando información tomada del pasado reciente de la conducción y de la futura información de eventos de tráfico, integrándose de este modo con sistemas de navegación que utilizan las nuevas tecnologías (redes móviles, gestión de tráfico, la conexión a servidores de gestión y supervisión del tráfico, etc.) con el fin de construir 'on-line' (mientras se circula) el ciclo de conducción más probable que seguirá el vehículo-conductor en los próximos kilómetros del trayecto que es se está realizando. Además, el dispositivo / método propuesto es capaz de hacer la predicción sin conocer de antemano el destino final del trayecto, aunque es más preciso y exacto y ofrece un enorme potencial si la ruta y / o destino final se conoce de antemano: indicado en el sistema de navegación por el conductor o incluso reconocible por el propio sistema (trayectos realizados habitualmente). Por tanto, si el destino final y la ruta que se está realizando son conocidos de antemano, el horizonte de predicción seleccionado puede ser muy grande, obteniendo una alta precisión en la predicción. Sin embargo, si no se conocen el destino final y la ruta, el horizonte de predicción seleccionado debe ser menor si se desea mantener precisión en la predicción, o de otro modo (grandes horizontes de predicción) la precisión de la predicción podría verse afectada debido a que el sistema o dispositivo tiene que optar por (o tiene que adivinar) una ruta de entre todas las posibles rutas que el conductor va a seguir en base a datos estadísticos y probabilidades. Se debe señalar que aunque el destino / ruta no se conozca de antemano, el dispositivo seguirá funcionando aunque con una cierta penalización en la precisión. Por otra parte, y debido a que las predicciones se realizan 'on-line' (mientras el vehículo circula), tales predicciones se renovarán en cada instante de muestreo y por tanto las decisiones de ruta que el conductor toma se tienen en cuenta en el "recálculo" de las predicciones en cada instante de muestreo.

El método para la predicción 'on-line' del ciclo de conducción en un vehículo automóvil comprende:

- una etapa de preprocesamiento de datos que a su vez comprende:

- recibir la velocidad del vehículo;
- recibir información de tráfico correspondiente al trayecto previsto para el vehículo dentro de al menos un horizonte de predicción considerado;
- obtener, a partir de la información de tráfico recibida, un ciclo de conducción de referencia correspondiente al trayecto previsto dentro de al menos dicho horizonte de predicción;
- calcular la desviación de la velocidad del vehículo con respecto al ciclo de conducción de referencia;

- una etapa de procesamiento de datos por medio de una red neuronal, que comprende obtener de forma recursiva las desviaciones previstas para el horizonte de predicción, utilizando para ello, como entradas de la red neuronal, las desviaciones de velocidad calculadas previamente y que corresponden a un pasado reciente en un número de muestras de retardo, así como información relativa al ciclo de conducción de referencia que contiene información que pertenece tanto al pasado reciente en un número de muestras de retardo como al futuro próximo en un número de muestras de futuro próximo;

- una etapa de postprocesamiento de datos que comprende obtener, a partir de las desviaciones previstas y del ciclo de conducción de referencia para el horizonte de predicción, la velocidad estimada para dicho horizonte de predicción.

La etapa de preprocesamiento de datos puede comprender recibir información de eventos de tráfico que corresponde al trayecto previsto para el vehículo dentro de al menos el horizonte de predicción, y en la que dicha información de eventos de tráfico recibida es utilizada también para obtener el ciclo de conducción de referencia.

La red neuronal es preferiblemente una red neuronal dinámica recurrente de topología NARX previamente entrenada.

5 En una realización preferida, la velocidad del vehículo se muestrea en la etapa de preprocesamiento de datos de acuerdo con un tiempo de muestreo específico, y la obtención del ciclo patrón de referencia y el cálculo de la desviación de la velocidad del vehículo con respecto al ciclo de conducción de referencia se realiza para cada tiempo de muestreo.

La información relativa al ciclo de conducción de referencia puede comprender una velocidad patrón adelantada un número de muestras de futuro próximo, que es equivalente a la distancia de la visión del conductor y la anticipación del conductor con respecto a futuros cambios de situación del tráfico.

10 La información de tráfico puede incluir además al menos una de las siguientes informaciones:

- los límites de velocidad;
- información del tipo de vía;
- pendientes de la carretera;
- las señales de tráfico del trayecto previsto.

15 La información de eventos de tráfico puede incluir información relativa a al menos uno de los siguientes:

- estado del tráfico;
- límites de velocidad debido a obras en la carretera;
- condiciones de visibilidad;
- estado de la calzada.

20 La información de tráfico y la información de eventos de tráfico se reciben preferiblemente en el intervalo $[p, p + H]$, siendo p la posición actual del vehículo y H el horizonte de predicción seleccionado.

El método puede comprender obtener el estilo de conducción del conductor del vehículo de acuerdo con unos cálculos que dependen de un parámetro relativo al modo de cálculo del estilo de conducción seleccionado, donde los modos de cálculo se basan en al menos uno de los siguientes:

- 25
- cálculo basado en transformada de Fourier de un vector formado por los valores de velocidad del vehículo correspondiente al pasado reciente;
 - cálculo basado en la variación media de la velocidad durante un período de tiempo;
 - cálculo basado en los tiempos de reacción del conductor.

30 Otro objeto de la presente invención es un dispositivo de predicción 'on-line' del ciclo de conducción en un vehículo automóvil, que comprende:

- medios de comunicación configurados para recibir la velocidad del vehículo y para recibir, desde un sistema de navegación, información de tráfico correspondiente al trayecto previsto para el vehículo dentro de al menos un horizonte de predicción considerado;
- medios de procesamiento de datos configurados para:

- 35
- obtener, a partir de la información de tráfico recibida por los medios de comunicación, un ciclo de conducción de referencia correspondiente al trayecto previsto dentro de al menos dicho horizonte de predicción;
 - calcular la desviación de la velocidad del vehículo con respecto al ciclo de conducción de referencia;
- 40
- obtener de forma recursiva, mediante una red neuronal, las desviaciones previstas para el horizonte de predicción, utilizando para ello como entradas de la red neuronal las desviaciones de velocidad calculadas previamente y que corresponden a un pasado reciente en un número de muestras de retardo, así como información relativa al ciclo de conducción de referencia que contiene información perteneciente tanto al pasado reciente en un número de muestras de retardo
- 45
- como al futuro próximo en un número de muestras de futuro próximo;

- obtener, a partir de las desviaciones previstas y del ciclo de conducción de referencia para el horizonte de predicción, la velocidad estimada para dicho horizonte de predicción.

5 Los medios de comunicación pueden estar además configurados para recibir, del sistema de navegación, información de eventos de tráfico correspondiente al trayecto previsto para el vehículo dentro de al menos el horizonte de predicción, y donde los medios de procesamiento de datos están configurados para obtener el ciclo de conducción de referencia también usando dicha información de eventos de tráfico recibida por los medios de comunicación.

10 Los medios de procesamiento de datos están configurados preferiblemente para muestrear la velocidad del vehículo de acuerdo con un tiempo de muestreo específico y para obtener el ciclo patrón de referencia y el cálculo de la desviación de la velocidad del vehículo con respecto al ciclo de conducción de referencia para cada tiempo de muestreo.

El dispositivo también puede comprender el propio módulo de navegación.

Los medios de procesamiento de datos pueden configurarse para realizar el cálculo de predicción mientras el vehículo está circulando y cada vez que el vehículo avanza una distancia seleccionada mediante un parámetro.

15 Breve descripción de los dibujos

A continuación, se describe brevemente un conjunto de dibujos que ayudan a comprender mejor la invención y que se relacionan expresamente con una realización de dicha invención que se presenta como un ejemplo no limitativo de la misma.

20 La figura 1 muestra la estructura del sistema de predicción de un ciclo de conducción propuesto en la presente invención.

La figura 2 muestra la estrategia para la predicción del ciclo de conducción.

La figura 3 representa un ciclo de conducción real y un ciclo patrón en función del punto kilométrico.

La figura 4 muestra una estructura de la red neuronal NARX propuesta.

25 La figura 5 muestra una realización específica, con sus entradas y salidas, de la red neuronal NARX para una realización de la presente invención.

La figura 6 muestra un diagrama con los componentes del dispositivo de predicción objeto de la presente invención.

Descripción detallada de la invención

La estructura del dispositivo de predicción del ciclo de conducción propuesto se presenta en la figura 1 como una caja negra con entradas y salidas.

30 Como se puede observar, el dispositivo de predicción de ciclo de conducción 100 tiene como entradas la medida de velocidad instantánea del vehículo (en km / h) y dos entradas específicas referentes a la información de tráfico obtenidas por medio de un sistema de navegación 104, de información de tráfico (HTI, Horizon Traffic Information) y de información de eventos de tráfico (HTEI, Horizont Traffic Events Information). La entrada información de tráfico (HTI) contiene los límites de velocidad, las pendientes de la carretera y las señales de tráfico en el horizonte de predicción considerado. La entrada información de eventos de tráfico (HTEI) contiene información como el estado /
35 flujo del tráfico, obras, visibilidad y condiciones de la calzada. El horizonte de predicción (H) es el intervalo de predicción del ciclo de conducción.

A continuación, se explican en detalle los parámetros de entrada del dispositivo de predicción de ciclo de conducción 100:

40 - encendido (EN): Activación del dispositivo de predicción de ciclo de conducción 100, realizado a través del sistema de encendido 102 o del propio sistema de administración de energía (EMS) del vehículo 108. Esta entrada se utiliza para sincronizar el sistema con la aplicación que utilizará las predicciones hechas. Cuando esta entrada se activa a "1", el flanco de subida se utiliza para establecer la variable tiempo a 0 ($t = 0$) y se inicia la estrategia de predicción y el cálculo de las salidas.

45 - Velocidad del vehículo (V_{sp}): Velocidad instantánea del vehículo (por lo general en Km / h). Esta entrada (medida) podría obtenerse o bien a partir del sistema de navegación del vehículo 104 (como se muestra en la figura 1) o bien desde la unidad de control del vehículo por medio del bus de comunicaciones del mismo.

- Información de tráfico (Horizon Traffic Information, HTI): Entrada de tipo estructura obtenida del sistema de navegación del vehículo 104 con información del tráfico en tiempo real que contiene los siguientes vectores:

5 * Vector Límites_de_Velocidad (Horizon Speed limits HTI_HSL): Vector que contiene los límites de velocidad en condiciones de circulación ideales existentes en el intervalo $[p, p + H]$, siendo p la posición actual del vehículo y H el horizonte de predicción seleccionado (generalmente en Km). Por lo tanto son los límites de velocidad definidos por el tráfico (señales de tráfico correspondientes a los límites de velocidad) que existen en el trayecto que se está realizando. El tamaño de este vector depende de la resolución deseada (parámetro H_Resol (por lo general en Km)) y del tamaño del horizonte de predicción seleccionado H . Por tanto, el tamaño vendrá dado por: $Tamaño = H / H_Resol$. Debe indicarse que en lugar de dicho vector Límites_de_Velocidad, se podría sustituir por cualquier otro vector que suministre información a partir de la cual el dispositivo pueda deducir los límites de velocidad; por ejemplo, el tipo de vía (autopista, carretera con un arcén ancho, etc.) cuando no haya una limitación mayor.

15 * Vector Pendientes_de_la_Carretera (Horizon Road Slopes, HTI_HRS): Vector que contiene el valor de las pendientes de la carretera en % existentes en el intervalo $[p, p + H]$, siendo p la posición actual del vehículo y H el horizonte de predicción seleccionado. El tamaño de este vector depende de la resolución deseada (parámetro H_Resol) y del tamaño del horizonte de predicción seleccionado H . Por tanto, el tamaño vendrá dado por: $Tamaño = H / H_Resol$.

20 * Vector Señales_de_Stop (Horizon Stop Signals, HTI_HSS): Vector que contiene las próximas señales de stop, ceda el paso, semáforos y peajes de carretera existentes en el intervalo $[p, p + H]$, siendo p la posición actual del vehículo y H el horizonte de predicción seleccionado. El tamaño de este vector depende de la resolución deseada (parámetro H_Resol) y del tamaño del horizonte de predicción seleccionado H . Por tanto, el tamaño vendrá dado por: $Tamaño = H / H_Resol$. A modo de ejemplo, los valores que el vector contiene podrían ser:

- 25 0 => No hay señal
- 1 => Señal de stop
- 2 => señal de ceda el paso
- 3 => peaje
- 4 => Semáforo

30 Como se puede observar, se trata de información que se conoce de antemano de acuerdo con el trayecto que se esté realizando. Los sistemas de navegación tienen esta información en sus bases de datos y podrían proporcionarla de manera anticipada con respecto al horizonte de predicción seleccionado.

- Información_de_Eventos_de_Tráfico (Horizon Traffic Events Information, HTEI): Entrada de tipo estructura que contiene los siguientes vectores:

35 * Vector Estado_de_Tráfico (Horizon Traffic State, HTEI_HTS): Vector que contiene el estado del tráfico en el intervalo $[p, p + H]$, siendo p la posición actual del vehículo y H el horizonte de predicción seleccionado. El tamaño de este vector depende de la resolución deseada (parámetro H_Resol) y del tamaño del horizonte de predicción seleccionado H . Por tanto, el tamaño vendrá dado por: $Tamaño = H / H_Resol$. Los valores que este vector contiene dependerán del estado del tráfico en el horizonte de predicción seleccionado el cuál vendrá dado por el sistema de navegación y su información de tráfico en tiempo real. Cada elemento del vector podría tener valores diferentes, tales como los siguientes:

- 40 0 => tráfico muy fluido.
- 1 => Tráfico fluido.
- 2 => Tráfico denso.
- 3 => Tráfico muy denso.
- 45 4 => Tráfico parado.

* Vector Obras_en_la_Carretera (Horizon Road Works, HTEI_HRW): Vector que contiene los límites de velocidad debido a obras en la carretera existentes en el intervalo $[p, p + H]$, siendo p la posición actual del vehículo y H el horizonte de predicción seleccionado. El tamaño de este vector depende de la resolución deseada (parámetro H_Resol) y del tamaño del horizonte de predicción seleccionado H . Por tanto, el tamaño vendrá dado por: $Tamaño =$

H / H_Resol. Los valores que este vector contiene dependen de las obras de la carretera dentro del horizonte de predicción seleccionado que vendrá dado por el sistema de navegación y su información de tráfico en tiempo real.

5 * Variable Condiciones_de_Visibilidad (Horizon Visibility, HTEI_HV): Variable que contiene el estado de las condiciones de visibilidad (efecto de niebla, lluvia o nieve) en el horizonte seleccionado. A modo de ejemplo, podría tener los siguientes valores:

0 => Visibilidad buena.

1 => Visibilidad media.

2 => Visibilidad mala.

3 => Visibilidad muy mala.

10 * Variable Condiciones_de_la_Calzada (Horizon Road Conditions, HTEI_HRC): Variable que contiene el estado de la calzada (efecto del hielo, agua, etc.) dentro del horizonte seleccionado. A modo de ejemplo, podría tener los siguientes valores:

0 => Calzada en buenas condiciones.

1 => Calzada un poco resbaladiza.

15 2 => Calzada resbaladiza.

3 => Calzada muy resbaladiza.

20 Como se puede observar, en este caso estas variables no se conocen de antemano y tienen un carácter dinámico. Los sistemas de navegación a utilizar deben tener la característica de poder obtener la información de tráfico y eventos en tiempo real. Algunos tipos de modelos que pueden obtener este tipo de información en tiempo real están empezando a venderse hoy. A tal fin, los dispositivos o bien se conectan a sistemas de gestión del tráfico a través de comunicaciones (RDS, 802.11x, etc.) o bien obtienen la información mediante la creación de redes de comunicación cuyos usuarios son los sistemas de navegación a bordo del vehículo. Estos vehículos / usuarios comparten información con un servidor que infiere el estado del tráfico en base a las medidas de velocidad y la posición que recibe de los diferentes vehículos que forman la red. Hoy en día hay modelos de sistemas de navegación que comparten información de varios millones de usuarios / vehículos en zonas o regiones geográficas específicas.

El dispositivo de predicción de ciclo de conducción 100 utiliza los siguientes parámetros:

30 - Tiempo de muestreo (ST): tiempo de muestreo seleccionado expresado en segundos. Variable de tipo real. El dispositivo de predicción de ciclo de conducción 100 muestrea la entrada de velocidad instantánea del vehículo V_{sp} de acuerdo con el valor introducido en este parámetro.

- Nivel de Filtro de Kalman (KFL): El dispositivo de predicción de ciclo de conducción 100 filtra en tiempo real la entrada de velocidad instantánea del vehículo V_{sp} de acuerdo con el valor introducido (entre 0 y 4) en este parámetro.

35 - Horizonte de Predicción (H): Horizonte de predicción deseado, generalmente expresado en Km. La predicción con respecto al horizonte seleccionado: $p \rightarrow p + H$ se realiza desde la posición actual del vehículo (p).

40 - Resolución de Horizonte (H_Resol): Resolución deseada para el horizonte seleccionado, normalmente expresada en Km. Por ejemplo, para un horizonte de predicción $H = 10$ Km, si seleccionamos un valor de $H_Resol = 0,01$ kilómetros, el tamaño del vector horizonte de predicción será de 1.000 elementos. Este parámetro representa además cada cuántos kilómetros de avance del vehículo se realiza / recalcula la predicción, por ejemplo, si $H_Resol = 0,05$ Km, la predicción se realizará / recalculará cada 50 m de avance del vehículo.

- Número de muestras de retardo (DSN): Número de muestras seleccionadas para conformar el pasado reciente. Por ejemplo, un valor de 40 significa que la distancia considerada como el pasado reciente es $40 \times H_Resol$ (Km), es decir, el pasado reciente serían los últimos $40 \times H_Resol$ Kilómetros.

45 - Número de muestras futuro próximo (FSN): Número de muestras seleccionadas para conformar el futuro próximo. Por ejemplo, un valor de 2 significa que la distancia considerada como el futuro próximo es $2 \times H_Resol$ (Km), es decir, el futuro próximo serán los próximos $2 \times H_Resol$ kilómetros. Este parámetro se elige generalmente de manera que la distancia considerada como futuro próximo sea equivalente a la distancia de visión, anticipación y reacción del conductor. Por ejemplo, un valor de FSN que haga que la distancia del futuro próximo sea de 0,2 kilómetros,

quiere decir que el alcance de visión y, por tanto, de anticipación del conductor ante próximos cambios en los límites de velocidad (señales de tráfico) es de 200 metros.

- 5 - Modo de cálculo del estilo de conducción (DSCM): Modo de cálculo del estilo de conducción del conductor. La manera en que el dispositivo calcula el estilo de conducción se selecciona por medio de este parámetro. Los modos de cálculo pueden ser: cálculo basado en la transformada de Fourier (valor medio y valor del primer armónico o señal fundamental) (DSCM = 1), cálculo basado en la variación media de la velocidad durante un período de tiempo (DSCM = 2), o cálculo basado en los tiempos de reacción del conductor (DSCM = 3).

10 El dispositivo de predicción de ciclo de conducción 100 obtiene las siguientes salidas, mostradas en la figura 1, las cuales se proporcionan a una unidad externa 108, que puede ser el Sistema de Administración de Energía (EMS) del vehículo o cualquier otra aplicación de terceros:

- Velocidad Estimada (V_{sp}^*): La predicción de la velocidad con respecto al horizonte H se realiza en el espacio y en el tiempo. En concreto:

- 15
- $V_{sp}^* [p, p + H]$: la velocidad en el intervalo espacial $[p, p + H]$ se estima, siendo p la posición actual del vehículo y H el horizonte de predicción seleccionado.
 - $V_{sp}^* [t, t + T_H]$: la velocidad en el intervalo de tiempo $[t, t + T_H]$ se estima, siendo t el instante actual en el tiempo y T_H (s) el tiempo estimado en el que el vehículo alcanza el horizonte de predicción.

- Pendiente de la Carretera Estimada (S_{est}): la predicción de la pendiente de la carretera con respecto al horizonte H se realiza en el espacio y en el tiempo. En concreto:

- 20
- $S^* [p, p + H]$: la pendiente en el intervalo espacial $[p, p + H]$ se estima, siendo p la posición actual del vehículo y H el horizonte de predicción seleccionado.
 - $S^* [t, t + T_H]$: la pendiente en el intervalo de tiempo $[t, t + T_H]$ se estima, siendo t el instante actual en el tiempo y T_H (s) el tiempo estimado en el que el vehículo alcanzará el horizonte de predicción.

25 - Estilo de Conducción (DS): se obtiene el estilo de conducción del conductor del vehículo.

A continuación se explican las estrategias, algoritmos y técnicas utilizados para la obtención de cada una de dichas salidas del dispositivo de predicción del ciclo de conducción 100:

1. Predicción de velocidades estimadas (salidas $V_{sp}^* [p, p + H]$ y $V_{sp}^* [t, t + T_H]$)

30 La estrategia de predicción creada se basa en utilizar una Red Neuronal Artificial (RNA) de topología NARX (red autorregresiva no lineal con entradas exógenas) previamente entrenada. Esta estrategia se completa con una serie de funciones de pre y post procesamiento de tanto las entradas como de las salidas de esta RNA-NARX. El objetivo de la RNA-NARX es aprender el comportamiento y modo de conducción de la combinación conductor y vehículo mediante la evaluación de las desviaciones de la velocidad del vehículo con respecto a un ciclo de conducción de referencia o patrón correspondiente al trayecto que se está realizando.

35 El ciclo de conducción de referencia o patrón para el próximo horizonte se construye dinámicamente en cada tiempo de muestreo en función de la información recibida a través de las entradas Información de Tráfico (HTI) e Información de Eventos de Tráfico (HTEI). También en cada instante de muestreo, la RNA-NARX obtiene las desviaciones previstas de velocidad (con respecto al ciclo de referencia) para el próximo horizonte utilizando para ello el ciclo de conducción de referencia (ciclo patrón) y las desviaciones de velocidad producidos en el pasado reciente del trayecto. Por lo tanto, el ciclo de conducción real previsto con respecto al horizonte de predicción seleccionado puede obtenerse finalmente mediante el uso de la predicción de las desviaciones previstas de velocidad y el ciclo de referencia previsto.

45 El diagrama de bloques correspondiente a la estrategia utilizada por el dispositivo de predicción del ciclo de conducción se muestra en la figura 2. A continuación se explica en detalle las tres etapas de la estrategia: el preprocesamiento (200), la red neuronal artificial (202) y el postprocesamiento (204). El preprocesamiento (200), la red neuronal artificial (202) y el postprocesamiento (204) se realizan por medio de procesamiento de datos, utilizando por ejemplo un sistema o dispositivo basado en un microcontrolador o microprocesador con el apoyo de un conjunto de elementos de memoria y puertos de entrada / salida y de comunicación.

50 En el preprocesamiento (200), la primera función que se realiza consiste en aplicar un filtro en tiempo real 206 en la variable de entrada Velocidad del Vehículo (V_{sp}). En una realización preferida, el tipo de filtro aplicado es un Filtro de Kalman en tiempo real. La segunda función en el preprocesamiento (200) consiste en realizar una transformación de dominio 207 en la variable V_{spkf} obtenida como salida después de aplicar el filtro 206. Una transformación desde el dominio tiempo al dominio distancia (punto kilométrico) se realiza mediante esta segunda función 207, obteniendo la

variable interna Punto_Kilométrico (PKm). Esta variable se obtiene mediante integración numérica de la velocidad V_{spkf} . Por lo tanto, esta función genera gradualmente un vector de dos columnas $[V_{spf(i)}, PKm(i)]$ donde cada fila "i" se calcula de acuerdo con el algoritmo presentado en (1) en cada tiempo de muestreo "k". Se puede observar que el vector PKm(i) es siempre creciente y tiene además un muestreo constante "i", que se corresponde con una distancia de H_Resol. La variable $V_{spf(i)}$ representa la velocidad del vehículo correspondiente a cada punto kilométrico PKm(i).

$$V_{spkf}(k) = \text{filtro_Kalman}(V_{sp}(k), V_{sp}(k - 1), \dots)$$

$$IncrKm = \left(\frac{|V_{spkf}(k) + V_{spkf}(k-1)|}{2 \times 3600} \right) \times (ST)$$

$$\text{Distancia} = \text{Distancia} + IncrKm$$

$$\text{si } (\text{Distancia} - PKm(i)) > H_Resol \quad (1)$$

10 entonces

$$PKm(i + 1) = PKm(i) + H_Resol$$

$$V_{spf}(i + 1) = V_{spkf}(k)$$

$$i = i + 1$$

por tanto

15 termina si

La siguiente función que se realiza en esta etapa es el cálculo del vector de desviación 208, que consiste en calcular para cada punto kilométrico PKm(i), la desviación existente entre la velocidad del vehículo $V_{spf(i)}$ y la velocidad patrón o ciclo de conducción de referencia $V_{pat}(i)$ (siendo $V_{pat}(i)$ la velocidad permitida para dicho punto kilométrico i). El cálculo para construir el vector de desviación $DV_{sp}(i)$ se muestra en el algoritmo (2) y se realiza a medida que se van construyendo los vectores PKm(i) y $V_{spf}(i)$.

$$V_{spkf}(k) = \text{filtro_Kalman}(V_{sp}(k), V_{sp}(k - 1), \dots)$$

$$IncrKm = \left(\frac{|V_{spkf}(k) + V_{spkf}(k-1)|}{2 \times 3600} \right) \times (ST)$$

$$\text{Distancia} = \text{Distancia} + IncrKm$$

$$\text{si } (\text{Distancia} - PKm(i)) > H_Resol$$

25 entonces

(2)

$$PKm(i + 1) = PKm(i) + H_Resol$$

$$V_{spf}(i + 1) = V_{spkf}(k)$$

$$DV_{sp}(i + 1) = V_{pat}(i + 1) - V_{spf}(i + 1)$$

$$i = i + 1$$

30 por tanto

termina si

El vector de velocidad patrón $V_{pat}(i)$ se construye utilizando la información de tráfico disponible procedente del sistema de navegación (entrada Información de Tráfico HTI). Si el trayecto a seguir (destino final y ruta a seguir) es conocido, se pueden conocer las señales de tráfico correspondientes a los límites de velocidad existentes en cada punto kilométrico de dicha ruta o trayecto a seguir. En la figura 3 se puede observar un ejemplo en el que se ha representado, a modo de ejemplo, un ciclo de conducción real realizado en un trayecto específico, marcada en azul la velocidad del vehículo $V_{spf}(i)$ y su vector de velocidad patrón correspondiente $V_{pat}(i)$ marcado en rojo. Se puede observar que ambos vectores se representan con respecto al vector Punto_Kilométrico PKm(i). El ciclo representado

35

a modo de ejemplo en la figura 3 se ha realizado con un vehículo que estaba equipado con un sistema de adquisición de datos a bordo. Si no se conoce el trayecto a realizar, dicho trayecto debe estimarse mediante métodos probabilísticos con el fin de construir el vector de velocidad patrón para el próximo horizonte. Lógicamente en este caso, cuanto mayor sea el próximo horizonte de predicción seleccionado, el error en la obtención del vector de velocidad patrón y por tanto en la predicción final hecha podría ser penalizado.

El conocimiento previo del trayecto a realizar o, en su defecto, su estimación, permite construir el vector de velocidad patrón $V_{pat}(i)$ en cada tiempo de muestreo, en la etapa construcción ciclo patrón 212 de la figura 2 utilizando la entrada información de tráfico (HTI). Una vez que se construye el vector, dicho vector puede variar de acuerdo con diferentes eventos que pueden ocurrir como resultado de las diferentes condiciones de tráfico que existan en dicho trayecto y que son impredecibles por naturaleza. Por lo tanto, este vector de velocidad patrón $V_{pat}(i)$ podría cambiar gradualmente o adaptarse mientras el vehículo está circulando (on-line), utilizando para dicha adaptación la información de tráfico en tiempo real recibida a través del sistema de navegación 104 por medio de la entrada Información de Eventos de Tráfico (HTEI).

Finalmente, en esta etapa de preprocesamiento 200, se generan los vectores $NN_DV_{sp}(i)$ y $NN_V_{pat}(i)$, que son las entradas de la red neuronal artificial 202. El vector $NN_DV_{sp}(i)$ se genera en la etapa 209 y contiene las últimas muestras DSN del vector $DV_{sp}(i)$, donde DSN (parámetro del dispositivo de predicción de ciclo de conducción 100) representa el número de muestras que definen el tamaño del vector $NN_DV_{sp}(i)$, o lo que es lo mismo, el tamaño del pasado reciente. Por tanto, el vector $NN_DV_{sp}(i)$ contiene los últimos valores DSN del vector $DV_{sp}(i)$, ver algoritmo (3).

para $(j = k, a, j = k - DSN)$
 $NN_DV_{sp}(j) = DV_{sp}(j)$ (3)
 $j = j - 1$
 termina para

El vector $NN_V_{pat}(i)$ se genera en la etapa 210 y por un lado contiene las últimas muestras DSN del vector $V_{pat}(i)$, donde DSN representa el número de muestras que definen el tamaño del pasado reciente, y por otro lado las futuras muestras FSN del vector $V_{pat}(i)$, donde FSN (parámetro del dispositivo de predicción de ciclo de conducción 100) representa el número de muestras que definen el tamaño del futuro próximo. Por tanto, el vector $NN_V_{pat}(i)$ contiene los últimos valores DSN del vector $V_{pat}(i)$ y los próximos valores FSN del vector $V_{pat}(i)$, ver algoritmo (4).

para $(j = k, a, j = k - DSN)$
 $NN_V_{pat}(j) = V_{pat}(j)$ (4)
 $j = j - 1$
 termina para
 para $(j = k, a, j = k + FSN)$
 $NN_V_{pat}(j) = V_{pat}(j)$
 $j = j + 1$
 termina para

En resumen, las funciones realizadas en esta etapa del preprocesamiento 200 están destinadas a la construcción de los vectores $NN_DV_{sp}(i)$, y $NN_V_{pat}(i)$ que son las entradas a la red neuronal artificial 202 creada y utilizada para llevar a cabo la predicción del ciclo de conducción.

La topología de la red neuronal artificial 202 seleccionada para realizar la predicción está dentro de las redes neuronales dinámicas recurrentes y se conoce como NARX (red no lineal autoregresiva con entradas exógenas). El modelo NARX se basa en el modelo lineal ARX que se utiliza comúnmente en el análisis y la predicción de series de tiempo. La ecuación que define el modelo NARX no lineal se muestra en (5), donde y representa la variable de salida y x_1, x_2, \dots, x_n , representan las posibles entradas del modelo o sistema a modelar, f representa una posible función no lineal, y $NumRetardosY, NumRetardosX_{1..n}$, representan el número de muestras previas que se tienen en cuenta para el cálculo de la salida de la función no lineal.

$$y(k + 1) = f(y(k), y(k - 1), y(k - 2), \dots, y(k - \text{NumRetardosY}), x_1(k), x_1(k - 1), x_1(k - 2), \dots, x_1(k - \text{NumRetardosX}_1), x_2(k), x_2(k - 1), x_2(k - 2), \dots, x_2(k - \text{NumRetardosX}_2), \dots, x_n(k), x_n(k - 1), x_n(k - 2), \dots, x_n(k - \text{NumRetardosX}_n)) \quad (5)$$

5 Un modelo NARX no lineal se puede aplicar a través de una red neuronal feed-forward que se aproxime a la función no lineal f. La figura 4 muestra un diagrama de la estructura de la red neuronal 202 propuesta en el que se pueden observar las entradas 400, la salida 408 y la capa de entrada 402, la capa oculta 404 y la capa de salida 406 las cuales están formadas por neuronas. Como se puede observar, las entradas y la salida se corresponden con las presentes en (5).

10 Cada entrada en una red neuronal corresponde a una serie de parámetros (pesos y bias 410) que unen cada neurona de entrada con las neuronas correspondientes que forman la capa de neuronas ocultas 404. Por lo tanto, el valor de cada neurona que pertenece a la capa oculta 404 se calcula aplicando una función normalmente no lineal a la suma del producto de las neuronas de entrada por sus correspondientes pesos añadidos a los bias. Esta operación se transmite poco a poco a las neuronas que forman la capa de salida 406, donde el valor de cada salida se obtiene por medio de la aplicación de una función lineal o no lineal a la suma del producto en la dirección feed forward.

15 Dados varios ejemplos / pruebas realizados donde se han registrado los datos de entrada y salida de la función no lineal que ha de ser aproximada por una red neuronal de tipo NARX, el proceso de entrenamiento de la red neuronal definida consiste en la obtención de los parámetros de la misma (pesos y bias 410 de todas las conexiones) que llevan a la obtención de las salidas de los ejemplos con un mínimo error para las entradas de los ejemplos. Por lo tanto, la red neuronal "aprende" de estos ejemplos adquiriendo la propiedad de "generalizar" cuando se producen otras secuencias y entradas diferentes en la red. El éxito del entrenamiento de la red depende del algoritmo de entrenamiento utilizado, del número de capas y neuronas seleccionadas y especialmente de los ejemplos utilizados para su entrenamiento, los cuales deben tener suficiente información para que la red adquiera la propiedad de generalizar y no la propiedad de sobreaprender los ejemplos utilizados.

20 Para el caso que nos ocupa en relación a la predicción del ciclo de conducción, la salida a estimar (salida de la red) es la desviación de velocidad en el siguiente punto kilométrico, $D*V_{sp}(k + 1)$. Como entradas se encuentran la variable NN_DV_{sp} junto con sus correspondientes muestras DSN anteriores, la variable V_{pat} junto con sus correspondientes muestras DSN anteriores y muestras FSN posteriores, ver figura 5.

25 La red calcula la salida en el instante k + 1, pero ya que en este caso la predicción debe realizarse con respecto a un horizonte H, este cálculo se puede repetir n veces de una manera recursiva y de esta forma calcular la predicción de la desviación prevista de velocidad ($D*V_{sp}$) con respecto al horizonte H de predicción seleccionado. Lógicamente, para llevar a cabo esta predicción con respecto al horizonte H, las propias variables estimadas de la salida de la red ($D*V_{sp}$) son necesarias, como se representa mediante la línea de puntos de la figura 5. El algoritmo básico para llevar a cabo la predicción con respecto al horizonte H se muestra en (6), donde en la subfunción preparación_entradas_NARX(), se construyen los vectores de entrada en la red junto con sus muestras correspondientes, ver figuras 2 y 5. Para construir el vector de entrada NN_DV_{sp} , es necesario utilizar la propia salida estimada de la red $D*V_{sp}$ cuando se está aplicando la red neuronal durante el horizonte H de predicción, debido a que los valores reales de la variable DV_{sp} son todavía desconocidos. Por tanto, los vectores V_{pat} , DV_{sp} , y $D*V_{sp}$ son necesarios para preparar las entradas de la red, como se muestra en (6).

40 $para (j = i + 1)a(j = i + H / H_Resol)$

$$(NN_DV_{sp}, NN_V_{pat}) = \text{preparación_entradas_NARX}(V_{pat}, DV_{sp}, D*V_{sp}) \quad (6)$$

$$D*V_{sp}(j) = \text{salida_red_neuronal_NARX}(NN_DV_{sp}, NN_V_{pat})$$

termina para

45 Después de realizar varios ejemplos y entrenamientos con datos de ciclos de conducción tanto reales como obtenidos por medio de un simulador de conducción virtual en escenarios en los que la conducción "no urbana" predomina con respecto a la conducción "urbana" en el trayecto, los parámetros y la estructura de la red que mejor aproximan estas desviaciones son los siguientes:

$H_Resol = 0,05 \text{ km}$

$DSN = 40 \text{ retardos (equivalentes a un pasado reciente de 2 Km)}$

50 $FSN = 4 \text{ (equivalente a un futuro próximo del 0,2 Km)}$

Número de neuronas en la capa oculta = 20

Funciones utilizadas en neuronas de la capa oculta = Tangente sigmoide.

Función utilizada en neuronas de la capa de salida = Lineal (purelin).

5 Tal y como se muestra arriba, la red neuronal NARX 202 obtiene la estimación de la desviación de velocidad prevista para el horizonte seleccionado desde i hasta $i + H / H_Resol$, como salida para cada punto kilométrico i (PKm (i)).

El propósito de las funciones realizadas en la etapa de postprocesamiento 204 es para obtener finalmente las salidas:

- $V_{sp}^* [i, i + H]$: Vector de velocidad del vehículo prevista para el próximo horizonte en el dominio de punto kilométrico. Velocidad = f (PKm)

10 - $V_{sp}^* [t, t + T_H]$: Vector de velocidad del vehículo prevista para el próximo horizonte con respecto al dominio del tiempo. Velocidad = f (tiempo)

15 La obtención del vector velocidad $V_{sp}^* [i, i + H]$ en el dominio correspondiente al Punto _ Kilométrico (PKm) es simple y directa. Sólo hay que utilizar los puntos del vector de velocidad patrón correspondientes al horizonte seleccionado. Su cálculo se muestra en (7), restando la estimación de la desviación de velocidad prevista para el horizonte seleccionado (DV_{sp}^*).

para $(j = i + 1)$ a $(j = i + H / H_Resol)$

$(NN_DV_{sp}, NN_V_{pat}) = \text{preparación_entradas_NARX}(V_{pat}, DV_{sp}, D^*V_{sp})$

$D^*V_{sp}(j) = \text{Salida_red_neuronal_NARX}(NN_DV_{sp}, NN_V_{pat})$ (7)

$V_{sp}^*(j) = V_{pat}(j) - DV_{sp}^*(j)$

20 termina para

25 La obtención del vector de velocidad $V_{sp}^* [t, t + T_H]$ en el dominio del tiempo es algo más compleja ya que requiere la realización de la transformación 222 desde el dominio "Punto Kilométrico" al dominio del tiempo. Una distancia equivalente a H_Resol se recorre en cada paso i , por lo que al conocer la velocidad en dicho instante, se puede estimar el incremento de tiempo que ha sido necesario utilizar para recorrer dicha distancia a dicha velocidad en cada paso i . La ecuación (8) muestra el cálculo que se realiza.

$$IncrT(i \rightarrow i + 1) = \frac{PKm(i + 1) - PKm(i)}{\frac{(V_{sp}^*(i + 1) + V_{sp}^*(i))}{2}} \quad (8)$$

Por tanto, la variable tiempo comienza con el instante actual en el tiempo y los incrementos de tiempo en cada paso i en el intervalo de predicción se calculan y acumulan de acuerdo con (9).

tiempo*(i) = tiempo_actual

30 para $(j = i + 1)$ a $(j = H / H_Resol)$

$$IncrT = \frac{(PKm(j) - PKm(j - 1)) \times 3600}{\frac{(V_{sp}^*(j) + V_{sp}^*(j - 1))}{2}} \quad (9)$$

tiempo*(j) = tiempo * ($j - 1$) + IncrT

termina para

2. Predicción de pendientes estimadas (salidas $S^* [i, i + H]$ y $S^* [t, t + T_H]$)

35 La obtención del vector $S^* [i, i + H]$, que contiene las pendientes de la carretera en relación al horizonte de predicción del punto kilométrico actual, es directa porque se conoce previamente la pendiente de la carretera en todos los puntos kilométricos del trayecto que se está realizando o se espera realizar (vector S_{road}). Suponiendo que estas

pendientes se almacenan en el vector pendientes de la carretera (HTI_HRS), se procede según el algoritmo mostrado en (10).

$$\begin{aligned} & \text{para } (j = i + 1) a(j = H / H_Resol) \\ S^*(j) &= S_{road}(j) \end{aligned} \quad (10)$$

5 termina *para*

Para la obtención del vector S^* $[t, t + T_H]$, correspondiente a las pendientes con respecto al horizonte de predicción desde el instante actual en el tiempo, es necesario realizar también una transformación de dominio desde el dominio "Punto Kilométrico " hasta el dominio del tiempo. Para ello, se procede de manera similar a la que se explicó anteriormente en la etapa de postprocesamiento 204. Por lo tanto, a cada punto $S(i)$ del intervalo correspondiente al horizonte de predicción le corresponde un instante en el tiempo, tiempo*(i) de acuerdo con (11).

$$\begin{aligned} & \text{tiempo}^*(i) = \text{tiempo_actual} \\ & \text{para } (j = i + 1) a(j = H / H_Resol) \\ \text{IncrT} &= \frac{(PKm(j) - PKm(j - 1)) \times 3600}{(V_{sp}^*(j) + V_{sp}^*(j - 1)) / 2} \end{aligned} \quad (11)$$

$$\text{tiempo}^*(j) = \text{tiempo}^*(j - 1) + \text{IncrT}$$

15 termina *para*

3. Estilo de conducción (salida DS)

El estilo de conducción se obtiene de diferentes maneras de acuerdo con la selección realizada mediante el parámetro DSCM (Modo de Cálculo de Estilo de Conducción). A continuación se describen las formas en la que se obtienen en función de la selección realizada:

20

- Cálculo basado en la transformada de Fourier: DSCM = 1

Este método trata de observar las variaciones de velocidad que está provocando el conductor con respecto al vehículo, así como sus frecuencias. Parece lógico pensar que, por ejemplo, en un tramo donde el límite de velocidad es de 80 Km / h (velocidad patrón), si la velocidad del vehículo es más alta y oscilante a este límite, la conclusión probable sería que el conductor tiene prisa y está conduciendo de manera agresiva. La transformada de Fourier aplicada a la señal de velocidad del vehículo ofrece la posibilidad de calcular el valor medio o continuo de la señal (valor DC), así como las amplitudes del armónico principal y de otros órdenes. Al relacionar estos valores con la señal de velocidad patrón, se pueden sacar conclusiones sobre el modo de conducción. Por lo tanto, el proceso de cálculo consiste en aplicar la transformada de Fourier a la señal de velocidad del vehículo con respecto a un intervalo correspondiente al pasado reciente, obtener las magnitudes de valor medio y amplitud del primer armónico (señal fundamental) y relacionarlos con sus correspondientes en la señal de velocidad patrón para ver la variación existente. Este proceso se muestra en (12), donde D representa el número deseado de muestras anteriores (pasado reciente) que se evalúan en el algoritmo, DC representa el valor continuo de la señal después de realizar la transformada rápida de Fourier, y A1 representa la amplitud del primer armónico (señal fundamental) después de la transformada. Debe señalarse el uso del índice i en el algoritmo (dominio Punto Kilométrico).

25

30

35

$$\begin{aligned} & \text{para } (j = 1) a (j = D) \\ & \text{vector } (j) = V_{sp} (i - D + j) \\ & \text{VectorPatrón}(i) = V_{sp}\text{Patrón}(i - D + j) \\ & \text{termina } \text{para} \\ & \text{FFT1} = \text{FFT}(\text{vector}) \\ & \text{FFT2} = \text{FFT}(\text{VectorPatrón}) \\ & \text{EstiloConducción } 1 = \frac{\text{FFT1.DC}}{\text{FFT2.DC}} \times 100(\%) \end{aligned} \quad (12)$$

40

$$\text{EstiloConducción 2} = \frac{\text{FFT1.A1}}{\text{FFT2.A1}} \times 100(\%)$$

5 - Cálculo basado en la variación media de la velocidad en un período de tiempo: DSCM = 2

Este método trata de observar la variación media de velocidad del vehículo en un intervalo de tiempo predeterminado. Esta medida también podría indicar el grado de agresividad en la conducción. El proceso para su obtención se presenta en (13). Como se puede observar, se utiliza esta vez el índice k (dominio del tiempo) obteniendo la media de las variaciones de velocidad con respecto al valor medio de la velocidad en el intervalo de tiempo correspondiente a D x ST, siendo ST el tiempo de muestreo seleccionado mediante el correspondiente parámetro.

para(j = 1) a(j = D)

Vector(j) = V_{sp}(k - D + j)

Termina para

ValorMedio = FunciónMedia (vector)

para (j = 1) a(j = D) (13)

Variación(j) = abs(vector(j) – ValorMedio)

termina para

$$\frac{\sum_{j=1}^{j=D} \text{Variación}(j)}{D \times ST}$$

EstiloConducción.1 =

20

- Cálculo basado en los tiempos de reacción del conductor: DSCM = 3

Este método se basa en la obtención del tiempo de anticipación del conductor en caso de un próximo cambio de límite de velocidad. Por ejemplo, un conductor que comienza a acelerar 100 metros antes de la señal de tráfico correspondiente a un cambio de límite de velocidad (a un valor superior) es muy probable que esté conduciendo de manera agresiva. Además, un conductor que empieza a frenar en un punto kilométrico mayor que el correspondiente donde se encuentra situada una señal de tráfico que indica un cambio de límite de velocidad (a un valor inferior), se supone que está conduciendo de manera agresiva. La medida de estos valores de anticipación y retraso en el pasado reciente combinados con la desviación de velocidad acontecida en los regímenes permanentes (a velocidad constante, como en los métodos anteriores) podría proporcionar un estilo de conducción más exacto.

25

30 La figura 6 muestra de una manera no limitativa los componentes de un dispositivo de predicción de ciclo de conducción 100, que realiza las etapas del método descrito anteriormente.

El dispositivo comprende unos primeros medios de comunicación 600 para recibir la información de la velocidad del vehículo y del tráfico, por lo general procedente del sistema de navegación 104 (la velocidad del vehículo puede ser recibida por otros medios, por ejemplo a partir de medidas realizadas por el propio vehículo). Dichos primeros medios de comunicación 600 pueden incluir un puerto de comunicaciones CANbus.

35

El dispositivo 100 puede comprender unos segundos medios de comunicación 602 para recibir la señal de encendido (EN) del sistema de encendido 102 o del propio sistema de administración de energía del vehículo 108. En una realización preferida, dichos segundos medios de comunicación 602 comprenden un puerto de entrada digital.

40

El dispositivo 100 comprende unos medios de procesamiento de datos 604, por ejemplo una unidad DSP o un microcontrolador con alta capacidad de cálculo para realizar las diferentes etapas de cálculo. Dichos medios de procesamiento de datos 604 disponen de, o tiene acceso a, medios de almacenamiento de datos 606, por ejemplo, una memoria RAM y una memoria EPROM.

ES 2 535 689 T3

El dispositivo tiene medios de comunicaciones para comunicar con el sistema de administración de energía del vehículo 108, por ejemplo a través de un puerto de comunicaciones CANbus 608. También puede tener un puerto de salida digital 610.

REIVINDICACIONES

1. Método para la predicción 'on-line' del ciclo de conducción en un vehículo automóvil mientras está circulando, siendo el ciclo de conducción la velocidad del vehículo como una función de tiempo, caracterizado por que comprende:
- 5 - una etapa de preprocesamiento de datos (200), que a su vez comprende:
- recibir la velocidad del vehículo (V_{sp});
 - recibir información de tráfico (HTI) correspondiente al trayecto previsto para el vehículo dentro de al menos un horizonte (H) de predicción considerado;
- 10 • obtener (212) un ciclo de conducción de referencia (V_{pat}) correspondiente al trayecto previsto dentro de al menos dicho horizonte (H) de predicción a partir de la información de tráfico (HTI) recibida;
- calcular (208) la desviación (DV_{sp}) de la velocidad del vehículo (V_{sp}) con respecto al ciclo de conducción de referencia (V_{pat});
- una etapa de procesamiento de datos mediante una red neuronal (202) que comprende obtener de forma recursiva las desviaciones previstas ($D*V_{sp}$) para el horizonte (H) de predicción, utilizando para ello las desviaciones de velocidad ($NN_{DV_{sp}}$) calculadas previamente y que corresponden a un pasado reciente en un número de muestras de retardo (DSN), así como información relativa al ciclo de conducción de referencia ($NN_{V_{pat}}$) que contiene información perteneciente tanto al pasado reciente en un número de muestras de retardo (DSN) como al futuro próximo en un número de muestras de futuro próximo (FSN), como entradas de la red neuronal (202);
- 15 - una etapa de postprocesamiento de datos (204) que comprende la obtención de la velocidad estimada (V^*_{sp}) para dicho horizonte (H) de predicción a partir de las desviaciones previstas ($D*V_{sp}$) y el ciclo de conducción de referencia (V_{pat}) para el horizonte (H) de predicción.
- 20
2. Método de acuerdo con la reivindicación 1, caracterizado por que la etapa de preprocesamiento de datos (200) comprende recibir información de eventos de tráfico (HTEI) correspondientes al trayecto previsto para el vehículo dentro de al menos el horizonte (H) de predicción, y donde dicha información de eventos de tráfico (HTEI) recibida también se utiliza para obtener el ciclo de conducción de referencia (V_{pat}).
- 25
3. Método de acuerdo con cualquiera de las reivindicaciones anteriores, caracterizado por que la red neuronal (202) es una red neuronal dinámica recurrente previamente entrenada de topología NARX.
4. Método de acuerdo con cualquiera de las reivindicaciones anteriores, caracterizado por que la velocidad del vehículo (V_{sp}) se muestrea en la etapa de preprocesamiento de datos (200) de acuerdo con un tiempo de muestreo determinado (ST); y donde la obtención (212) del ciclo patrón de referencia (V_{pat}) y el cálculo de la desviación (DV_{sp}) de la velocidad del vehículo (V_{sp}) con respecto al ciclo de conducción de referencia (V_{pat}) se realiza para cada tiempo de muestreo (ST).
- 30
5. Método de acuerdo con cualquiera de las reivindicaciones anteriores, caracterizado por que la información relativa al ciclo de conducción de referencia (V_{pat}) comprende una velocidad patrón adelantada un número de muestras de futuro próximo (FSN), que es equivalente a la distancia de visión del conductor y a la anticipación del conductor con respecto a próximos cambios en la situación del tráfico.
- 35
6. Método de acuerdo con cualquiera de las reivindicaciones anteriores, caracterizado por que la información de tráfico (HTI) incluye además al menos una de las siguientes informaciones:
- los límites de velocidad;
- 40 - información del tipo de vía;
- las pendientes de la carretera;
 - las señales de tráfico del trayecto previsto.
7. Método de acuerdo con cualquiera de las reivindicaciones anteriores, caracterizado por que la información de eventos de tráfico (HTEI) incluye información relativa a al menos uno de los siguientes:
- 45 - estado del tráfico;
- límites de velocidad debido a obras en la carretera;

- condiciones de visibilidad;
- condiciones de la calzada.

5 8. Método de acuerdo con cualquiera de las reivindicaciones anteriores, caracterizado por que la información de tráfico (HTI) y la información de eventos de tráfico (HTEI) se reciben dentro del intervalo $[p, p + H]$, siendo p la posición actual del vehículo y H el horizonte de predicción seleccionado.

9. Método de acuerdo con cualquiera de las reivindicaciones anteriores, caracterizado por que comprende la obtención del estilo de conducción (DS) del conductor del vehículo de acuerdo con unos cálculos que dependen de un parámetro relativo al modo de cálculo del estilo de conducción (DSCM) seleccionado, donde los modos de cálculo se basan en al menos uno de los siguientes:

- 10 - cálculo basado en transformada de Fourier de un vector formado por los valores de velocidad de vehículo correspondientes al pasado reciente;
- cálculo basado en la variación media de la velocidad durante un período de tiempo;
 - cálculo basado en los tiempos de reacción del conductor.

15 10. Dispositivo para la predicción 'on-line' del ciclo de conducción en un vehículo automóvil mientras está circulando, siendo el ciclo de conducción la velocidad del vehículo como una función de tiempo, caracterizado por que comprende:

- medios de comunicación (600) configurados para recibir la velocidad del vehículo (V_{sp}) y para recibir desde un sistema de navegación (104) información de tráfico (HTI) correspondiente al trayecto previsto para el vehículo dentro de al menos un horizonte (H) de predicción considerado;

20 - medios de procesamiento de datos (604) configurados para:

- obtener (212) un ciclo de conducción de referencia (V_{pat}) correspondiente al trayecto previsto dentro de al menos dicho horizonte (H) de predicción a partir de la información de tráfico (HTI) recibida por los medios de comunicación;

25 • calcular (208) la desviación (DV_{sp}) de la velocidad del vehículo (V_{sp}) con respecto al ciclo de conducción de referencia (V_{pat});

30 • obtener de manera recursiva las desviaciones previstas (D^*V_{sp}) para el horizonte (H) de predicción mediante una red neuronal (202), utilizando para ello las desviaciones de la velocidad ($NN_{DV_{sp}}$) previamente calculadas y correspondientes al pasado reciente en un número de muestras de retardo (DSN), así como información relativa al ciclo de conducción de referencia ($V_{NN_{pat}}$) que contiene información perteneciente tanto al pasado reciente en un número de muestras de retardo (DSN) como al futuro próximo en un número de muestras de futuro próximo (FSN), como entradas de la red neuronal (202);

- obtener la velocidad estimada (V^*_{sp}) para dicho horizonte (H) de predicción a partir de las desviaciones previstas (D^*V_{sp}) y del ciclo de conducción de referencia (V_{pat}) para el horizonte (H) de predicción.

35 11. Dispositivo de acuerdo con la reivindicación 10, caracterizado por que los medios de comunicación (600) están configurados, además, para recibir, del sistema de navegación (104), información de eventos de tráfico (HTEI) correspondiente al trayecto previsto para el vehículo dentro de al menos el horizonte (H) de predicción y donde los medios de procesamiento de datos (604) están configurados para obtener el ciclo de conducción de referencia (V_{pat}) utilizando también dicha información de eventos de tráfico (HTEI) recibida por los medios de comunicación.

40 12. Dispositivo de acuerdo con cualquiera de las reivindicaciones 10 a 11, caracterizado por que la red neuronal (202) es una red neuronal (202) dinámica recurrente previamente entrenada de tipología NARX.

45 13. Dispositivo de acuerdo con cualquiera de las reivindicaciones 10 a 12, caracterizado por que los medios de procesamiento de datos (604) están configurados para muestrear la velocidad del vehículo (V_{sp}) de acuerdo con un tiempo de muestreo específico (ST) y para obtener (212) el ciclo patrón de referencia (V_{pat}) y el cálculo de la desviación (DV_{sp}) de la velocidad del vehículo (V_{sp}) con respecto al ciclo de conducción de referencia (V_{pat}) para cada tiempo de muestreo (ST).

14. Dispositivo de acuerdo con cualquiera de las reivindicaciones 10 a 13, caracterizado por que la información relativa al ciclo de conducción de referencia (V_{pat}) comprende una velocidad patrón adelantada un número muestras de futuro próximo (FSN), que es equivalente a la distancia de visión del conductor y a la anticipación del conductor con respecto a próximos cambios de situación del tráfico.

15. Dispositivo de acuerdo con cualquiera de las reivindicaciones 10 a 14, caracterizado por que los medios de procesamiento de datos están configurados para realizar el cálculo de predicción mientras el vehículo está circulando y cada vez que el vehículo avanza una distancia seleccionada mediante un parámetro (H_Resol).

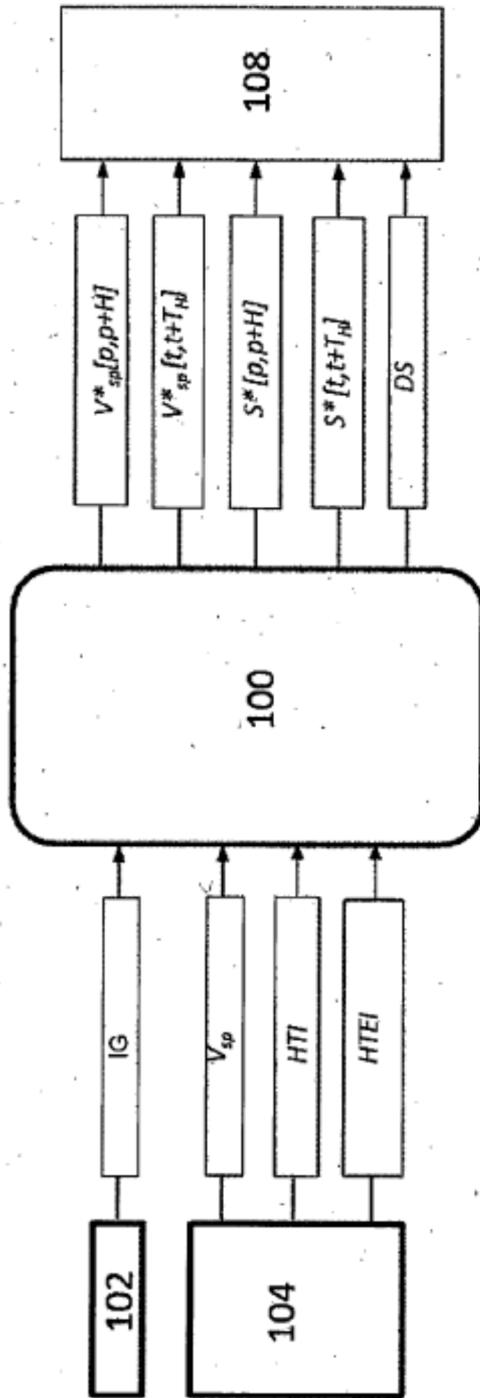


Fig. 1

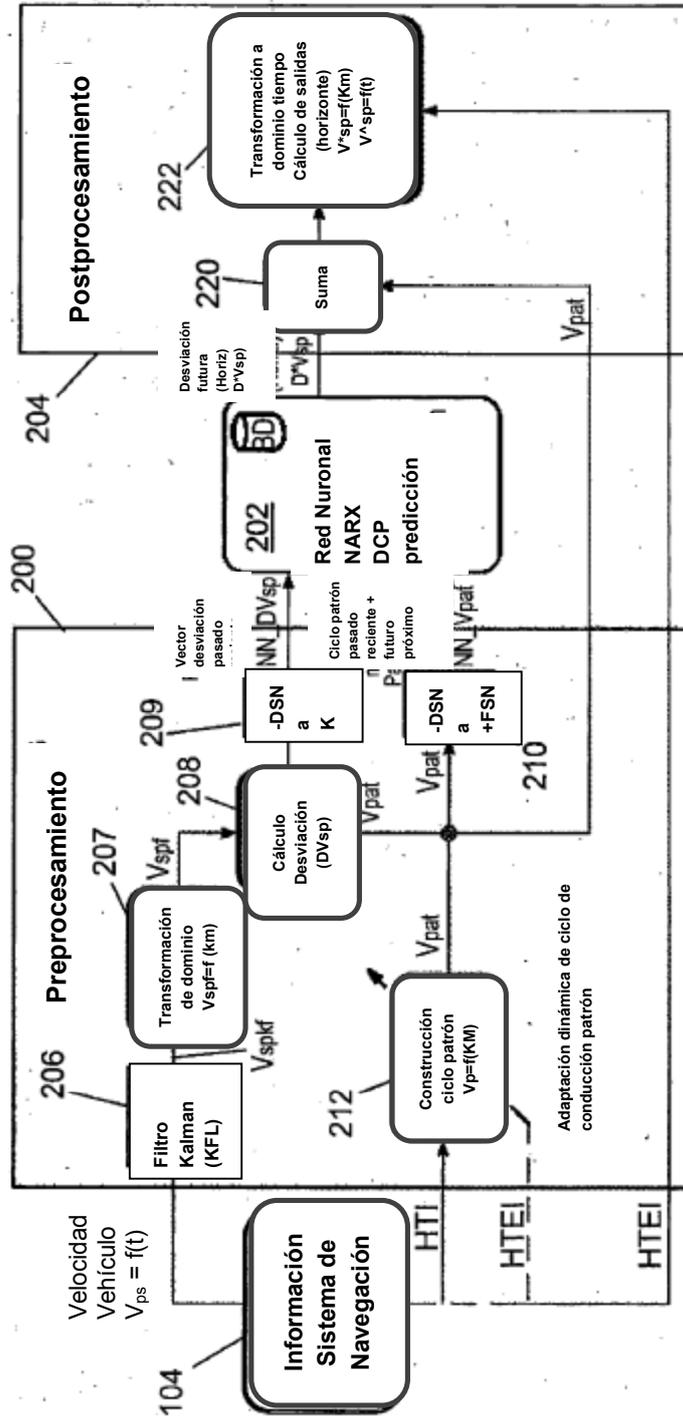


Fig. 2

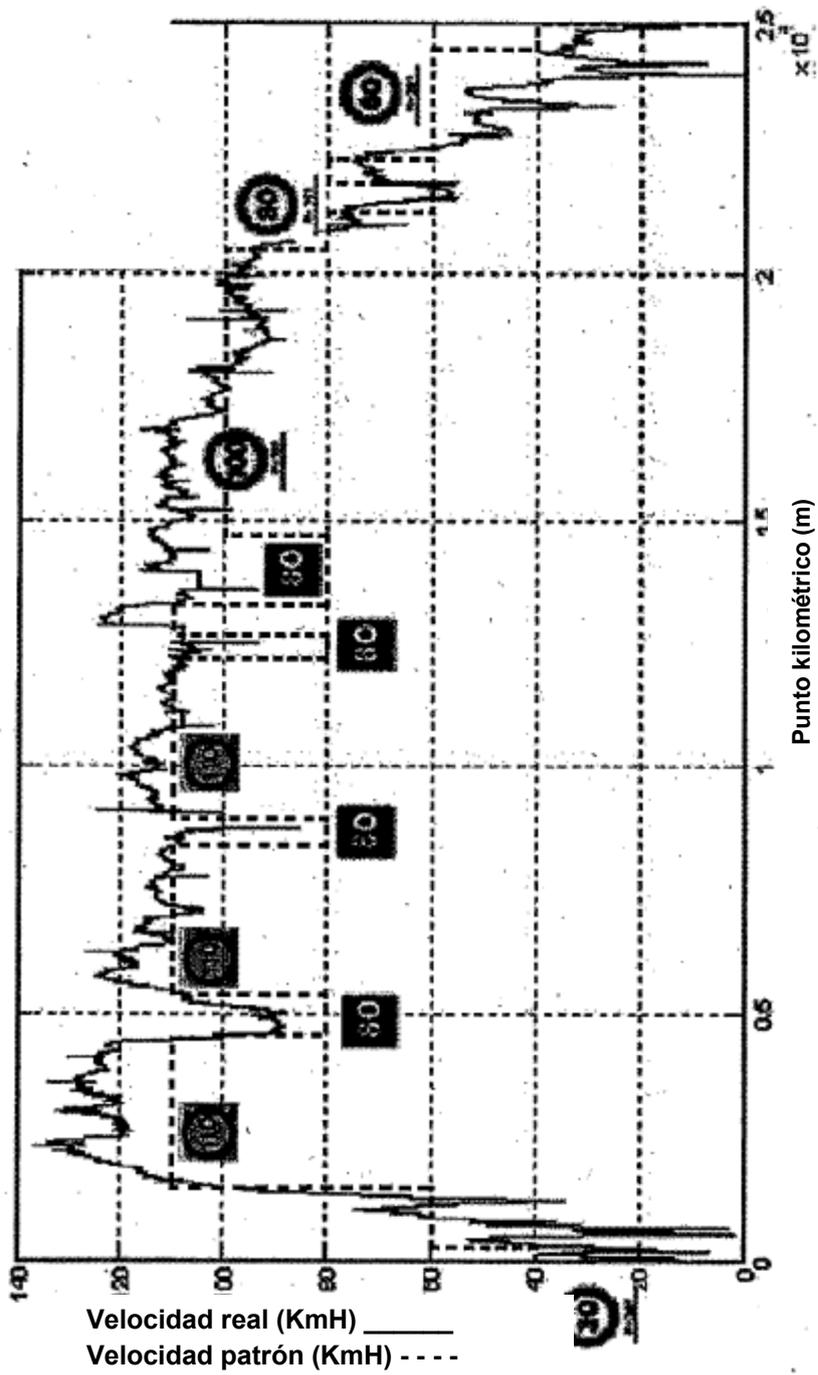


Fig. 3

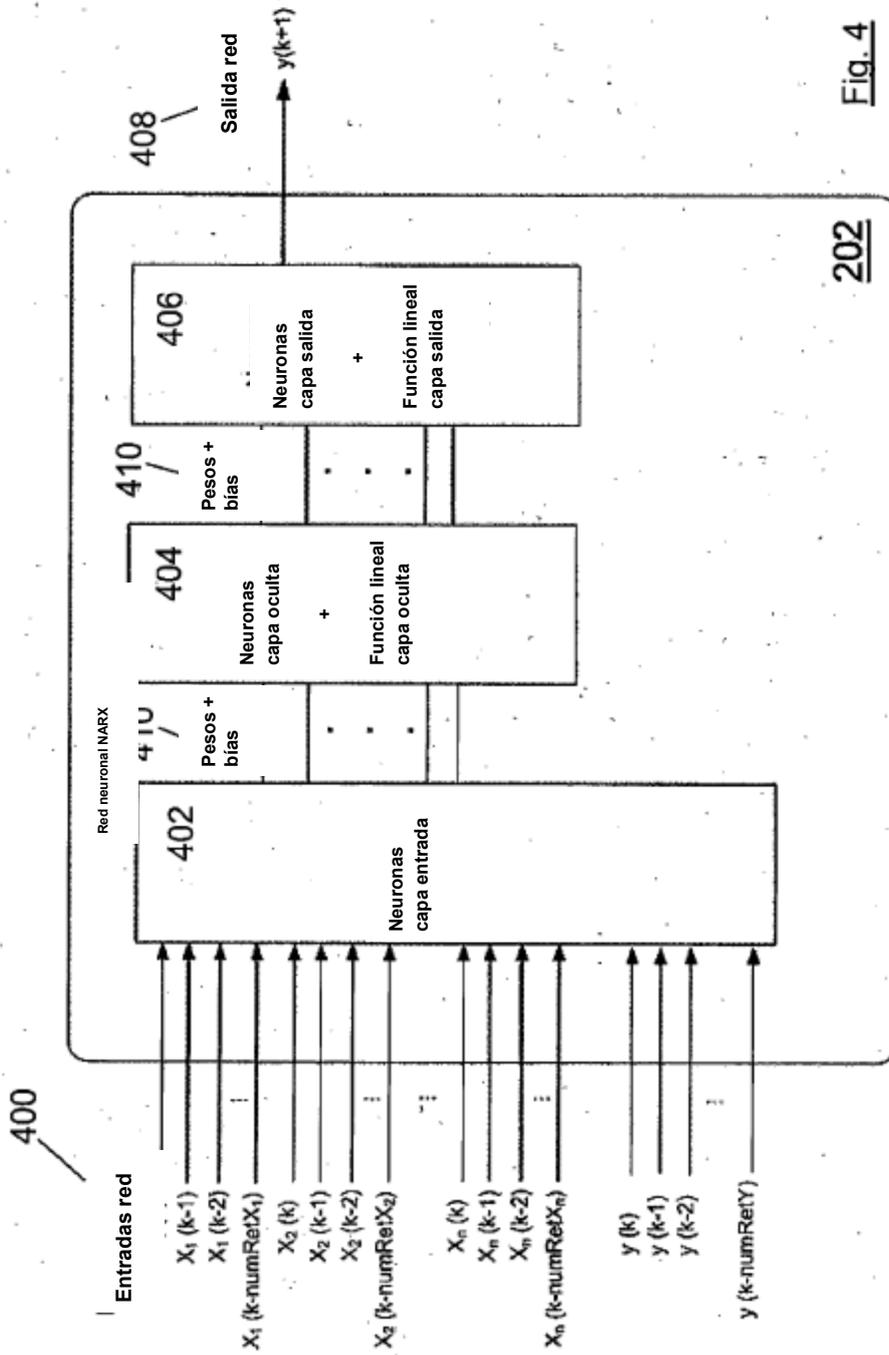


Fig. 4

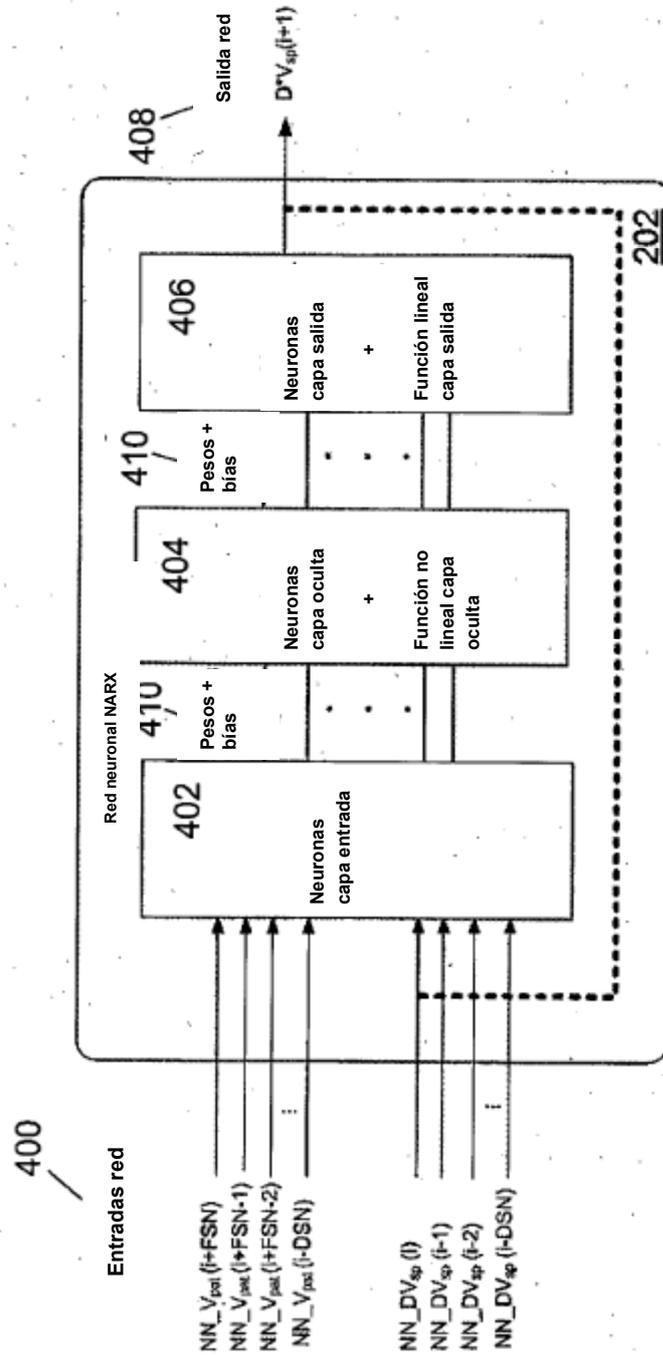


Fig. 5

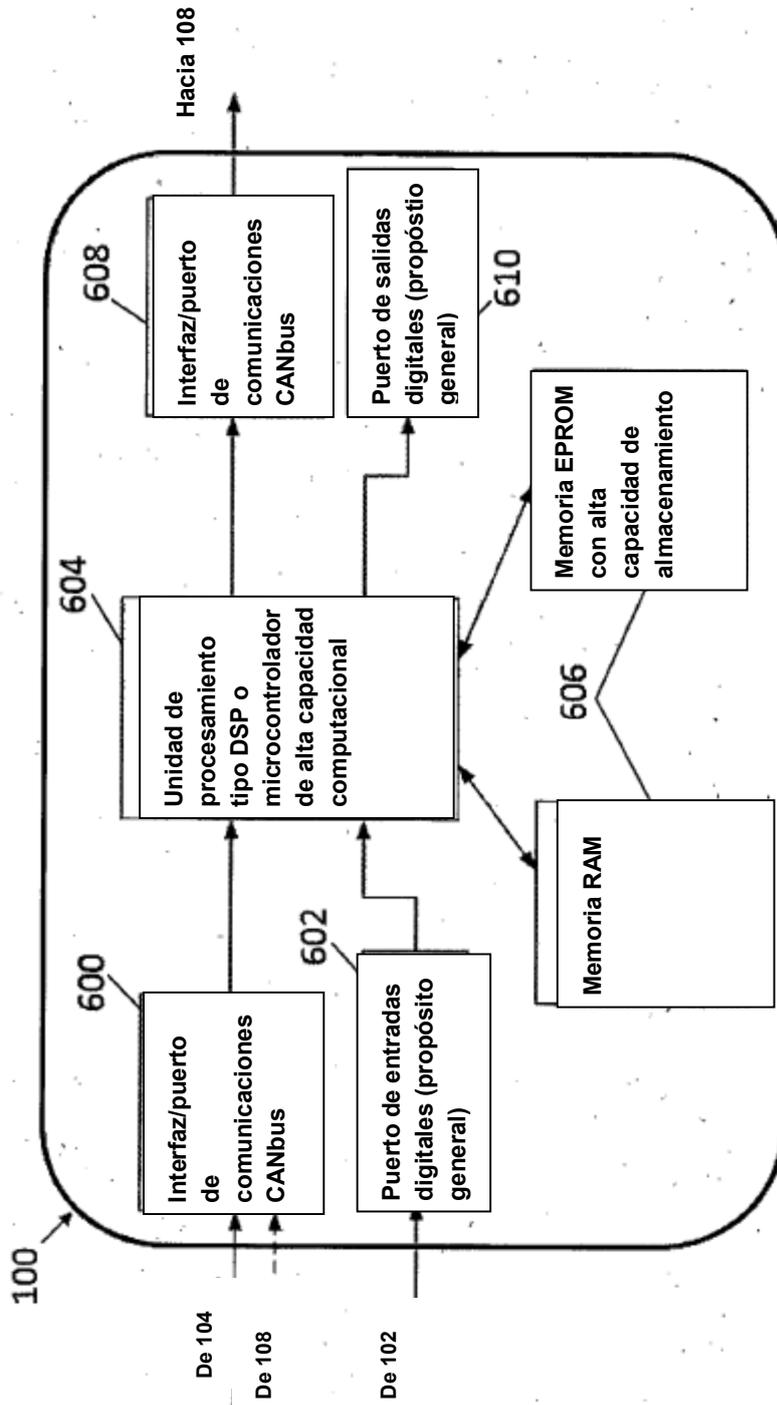


Fig. 6