

PROGRAMA DE PROYECTOS DE I+D EN COLABORACIÓN



UNIÓN EUROPEA
Fondo Europeo de
Desarrollo Regional

Una manera de hacer Europa



GENERALITAT
VALENCIANA



iVACE
INSTITUTO VALENCIANO DE
COMPETITIVIDAD EMPRESARIAL



Cool Routing

**Plataforma de optimización de cálculo de rutas de reparto
para vehículos eléctricos con carga refrigerada**

**E5.1. Plataforma de cálculo de consumos e Interfaz
de usuario**

ITE

Información del documento	
Título	E5.1. Plataforma de cálculo de consumos e Interfaz de usuario
Creador	Ignacio Benítez (ITE)
Description	Diseño y desarrollo del sistema de cálculo de consumo
Autores	Ignacio Benítez (ITE) Julio Díaz (ITE) Christian Conca (ITE)
Participantes	ITENE
Entidad responsable	ITE
Nivel de difusión	<input checked="" type="checkbox"/> Interno <input type="checkbox"/> Publico <input type="checkbox"/> Restringido
Fecha de entrega	30/06/17

Revisión			
Version	Fecha	Modificado por	Comentarios
v0.0	26/10/2016	Ignacio Benítez (ITE)	Primer borrador, con guión de contenidos
v0.1	12/05/2017	Julio Díaz (ITE)	Versión 0.1 de Entregable Se añade apartado 5.1
v0.2	22/05/2017	Christian Conca (ITE)	Versión 0.2 de Entregable. Se añade apartado 4
v0.3	06/06/2017	Julio Díaz (ITE)	Versión 0.3 de Entregable. Se finaliza apartado 5, Se añade conclusiones. Se hace revisión final del texto
vF0.1	19/06/2017	Caterina Tormo Domènech	Revisión y versión final
v0.5			

Tabla de contenidos

Tabla de contenidos	4
Índice de Figuras	5
Índice de Tablas	6
1 Términos y abreviaciones	7
2 Sumario	8
3 Introducción	9
4 Diseño y desarrollo de la plataforma de cálculo de consumos e interfaz de comunicaciones	11
4.1 Plataforma de cálculo de consumos	11
4.1.1 Estilo de arquitectura REST	11
4.2 Interfaces y comunicaciones	12
4.2.1 Entidades	12
4.2.2 Operaciones (cálculo/estimación de consumos)	15
4.2.3 Objeto de salida (definición de la ruta + estimación de consumos)	16
4.3 Servicios	16
4.3.1 Servicio A: Cálculo/estimación de consumos sobre rutas	17
4.3.2 Servicio B: Reajuste del modelo off-line	17
5 Diseño y desarrollo de modelo de predicción de consumo energético	18
5.1 Antecedentes y planteamiento del modelo	18
5.1.1 Definición del problema y objetivos del modelo	18
5.1.2 Referencias y antecedentes	18
5.1.3 Planteamiento del modelo teórico	19
5.1.4 Degradación con el uso (SOH)	20
5.1.5 Influencia de las variables externas	22
5.1.6 Modelo y procedimiento para reajuste offline de forma periódica	26
5.2 Modelado y simulación	27
5.2.1 Ejemplo	28
5.2.2 Recomendaciones	28
6 Conclusiones	30
7 Referencias	31

Índice de Figuras

Figura 1.- Plan de trabajo Cool Routing	8
Figura 2. Intercambio de datos cliente-servidor mediante arquitectura REST	12
Figura 3 Servicios que implementa la PTCC y su flujo de datos	16
Figura 4.- Arquitectura del Sistema de recolección de datos.....	19
Figura 5.- Modelo simplificado de la batería	20
Figura 6.- Esquema Circuito para cálculo del SOC/SOH.....	21
Figura 7.- Modelo de sistema discreto	22
Figura 8.- Planteamiento del algoritmo de EKF	¡Error! Marcador no definido.
Figura 9.- Fuerzas que afectan al vehículo	22
Figura 10.- Triángulo de distancia – elevación.....	25
Figura 11.- Ejemplo de Red Neural con Backpropagation	27

Índice de Tablas

Tabla 1. Características técnicas del servidor para la PTCC.....	11
Tabla 2. Propiedades definidas para Route	13
Tabla 3. Propiedades de Solution	13
Tabla 4. Propiedades de Vehicle	13
Tabla 5. Propiedades de Model	14
Tabla 6. Propiedades de CalculatedRoute.....	14
Tabla 7. Propiedades de Node.....	15
Tabla 8. Descripción peticiones GET	15
Tabla 9. Descripción peticiones POST.....	15

1 Términos y abreviaciones

Acrónimo	Definición
BMS	<i>Battery Management System</i> . Sistema de gestión de batería
DLL	<i>Dynamic Link-Library</i> . Biblioteca de Enlace Dinámico
EKF	<i>Extended Kalman Filter</i> . Filtro de Kalman Extendido
ICE	<i>Internal Combustion Engine</i> . Vehículos convencionales de combustión interna
PTCR	Plataforma Cálculo de Rutas
PTCC	Plataforma Cálculo de Consumo
PTRD	Plataforma recogida de Datos
REST	<i>Representational State Transfer</i> . Transferencia de Estado Representacional.
SOC	<i>State Of Charge</i> . Estado de Carga de la batería del vehículo, indicado en porcentaje (%)
SOH	<i>State Of Health</i> . Estado de Salud de la batería del vehículo, indicado en porcentaje (%)
V.E.	Vehículo Eléctrico

2 Sumario

El presente documento describe los trabajos realizados en el Paquete de Trabajo 5, Plataforma de cálculo de consumos (ver figura 1). Esta Plataforma tiene por objetivo el diseño de detalle y desarrollo de un prototipo funcional de cálculo de consumos del vehículo eléctrico de carga en la nube, incluyendo tanto las comunicaciones con la plataforma de recogida de datos (PT3) como con la plataforma de cálculo de rutas (PT4).

Para ello se desarrollan los algoritmos de estimación de consumo general del V.E. durante su funcionamiento y el modelo de consumo de la caja refrigerada. El algoritmo a desarrollar dentro de la plataforma está enfocado a entornos de rutas urbanas de reparto de mercancía, uso del aire acondicionado o la calefacción, características de la batería, características de la cámara refrigerada, condiciones meteorológicas y el frenado regenerativo. En base a toda la información se desarrolla una herramienta de cálculo de consumos. Adicionalmente, el algoritmo cuenta con la flexibilidad necesaria para tomar en cuenta el relieve del trayecto (si hay que subir pendientes o bajarlas), los tipos de carretera por los que discurre el trayecto (por poblado, por carretera secundaria o por autopista).

En este documento se hace referencia a las pruebas de simulación empleadas para validar el prototipo inicial y la metodología a emplear para su perfeccionamiento mediante pruebas de campo.



Figura 1.- Plan de trabajo Cool Routing

3 Introducción

Hoy en día, los vehículos eléctricos son capaces de informar al conductor de la distancia que pueden recorrer (autonomía restante) o bien el estado de carga del vehículo (SOC) mediante los algoritmos desarrollados por los propios fabricantes. Sin embargo, estas estimaciones son en tiempo real, basados en la lectura del estado actual de la batería del vehículo, y no permiten que los usuarios de VE puedan planificar un viaje o trayecto determinado como actualmente son capaces de realizar con los ICE convencionales usando GPS comerciales o aplicaciones como el GoogleMaps [1] [2]

Los usuarios de vehículos eléctricos han desarrollado necesidades distintas a las tradicionales, no miden los viajes en horas a conducir, sino en km disponibles de autonomía [3] [4]. La problemática reside en que la estimación facilitada por el vehículo no garantiza que el usuario llegue a su destino, ya la estimación no tiene en cuenta los factores externos a la batería que condicionan un trayecto determinado y que puede afectar al estado de la batería (SOC). La plataforma de cálculo de consumo desarrolla un simulador de alta precisión de estimación del estado de la batería al final del trayecto planificado.

El algoritmo desarrollado dentro de la plataforma permite integrar con las características de la batería, la estimación del cálculo de consumo que puede generar el relieve del trayecto elegido (si hay que subir pendientes o bajarlas), los tipos de carretera por los que discurre el trayecto (por poblado, por carretera secundaria o por autopista), el uso del aire acondicionado o la calefacción, características de la cámara refrigerada, condiciones meteorológicas. Esta herramienta junto con la planificación de rutas de reparto desarrollada en el paquete de trabajo 4, permite generar un producto no existente en el mercado actual. Cabe destacar, que la plataforma de cálculo de consumos es interoperable lo que le permitirá poder integrarse con otros proyectos o soluciones.

A la novedad del producto desarrollado hay que añadir un componente realmente innovador en la herramienta que no contemplan anteriores proyectos capaces de realizar cálculo de consumo on-line o las actuales aplicaciones en fase de desarrollo. Este componente es el desarrollo de la estimación del consumo que puede producir una carga refrigerada, lo que provee a las empresas de logística de una solución única en el desarrollo del modelo de negocio de reparto de productos refrigerados empleando vehículos eléctricos.

El desarrollo del algoritmo de estimación introduce el uso de un factor que el algoritmo de cálculo de SOC integrado por los fabricantes no es capaz de tomar en cuenta en la actualidad. Que es la variabilidad y efecto directo del peso en el consumo de energía que deberá realizar un V.E. en cualquier trayecto. Las pérdidas en el sistema de propulsión o tren de potencia son cualquier pérdida que resulta del proceso de convertir la energía en la batería en el esfuerzo de torsión en las ruedas del coche. Estos incluyen pérdidas en el inversor, el motor trifásico de inducción de CA, engranajes, Etc. En comparación con la aerodinámica, las pérdidas en el tren motriz son más difíciles de obtener a partir de simples ecuaciones físicas, ya que el rendimiento de los diversos subsistemas del vehículo necesita ser modelado individualmente. Entre ellas la causa principal de la resistencia a la rodadura es el efecto de la "histéresis": la energía necesaria para deformar la forma del neumático es mayor que la energía de recuperación. La potencia necesaria para superar la resistencia a la rodadura es una función de la fuerza normal N (peso soportado por el neumático) y el coeficiente de resistencia al rodamiento (C_r), y es proporcional a la velocidad V [1]: Por tanto, si consideramos que un vehículo de reparto con carga refrigerada introducirá no solo el peso en si del producto a entregar sino del sistema de refrigeración, esto es una modificación considerable de las características básicas del vehículo y que tiene, como se puede observar en el apartado 6.1., una incidencia notable en el cálculo de consumo energético a desarrollar para un vehículo en movimiento.

Se toma en cuenta en el modelo desarrollado es la incidencia de la climatología en el entorno de funcionamiento del V.E., reflejado principalmente en la temperatura exterior incidente sobre el vehículo, ya que no solo tiene un factor directo sobre el comportamiento de la batería sino sobre la climatización necesaria en la cabina del conductor [3] [4].

Para desarrollar el algoritmo de cálculo de consumo energético se han tomado en cuenta investigaciones anteriores y trabajos publicados para comparar y evaluar el diseño del modelo de estimación desarrollado. Entre estos trabajos cabe desatacar los siguientes:

Van Haaren [1], ha presentado un estudio caracterizando el desempeño de dek V.E. y el comportamiento de conducción de la población de Estados Unidos y da una visión general del porcentaje de viajes que se pueden cubrir con un V.E. completamente cargado. El estudio considera los factores que juegan un papel importante en el consumo de energía del vehículo como el efecto del entorno del trayecto, climatología, rango de ansiedad del conductor, etc. Para ello usa fundamentalmente un registro de datos suministrado por la empresa Tesla que recoge diferentes trayectos y datos sobre los consumos detectados en los diferentes sistemas mecánicos y eléctricos del Tesla Roadster en función de la capacidad de la batería consumida a diferentes velocidades constantes de conducción.

Wu et al. [2], han presentado una investigación que aborda una cuestión fundamental, cómo medir y estimar el consumo de energía de los vehículos eléctricos. Para ellos han implementado un sistema de recolección de datos, similar al utilizado en CoolRouting. Adicionalmente, con un recolección de datos de aproximadamente 5 meses, han demostrado que el V.E. es más eficiente cuando se conduce en las rutas urbanas que en autopista, en lo que respecta al consumo energético por km de conducción.

Fiori et al. [5], introducen en su estudio del consumo energético de los V.E. el factor de frenado regenerativo y la incidencia del consumo de los sistemas auxiliares (Aire Acondicionado, etc.) sobre el modelo de potencia empleada por el coche durante un trayecto. El estudio demuestra que el uso del sistema de calefacción y aire acondicionado puede reducir significativamente la eficiencia del V.E. y la autonomía de viaje, consecuentemente. Para ello analizaron el desempeño del Nissan Leaf, el BMW i3 y el Tesla Modelo S.

Kim et al. [6], propone una manera eficiente de estimar la potencia requerida por un V.E. basándose en un historial de consumo de energía, velocidad y aceleración, así como la información de características de las rutas mediante mapas previamente descargados. Esta predicción ayuda a BMS a programar y determinar eficientemente el modo de funcionamiento en tiempo real de las baterías, para satisfacer las demandas de potencia del V.E.

Jayasinghe y Nadishan [7], presentan un método para estimar el SOC basado en una red neuronal. En este trabajo la red es entrenada cada vez que la batería alcanza su voltaje de circuito abierto en estado estacionario usando un algoritmo de "retropropagación" o *backpropagation*. Desarrollando un algoritmo sencillo de implementar a la vez que con suficiente robustez para obtener una estimación muy fiable para el SOC, incluso considerando el envejecimiento de la batería y los efectos de la temperatura.

El presente documento está estructurado principalmente en dos secciones: en la primera, la sección 4, se presenta el diseño y desarrollo de la plataforma de cálculo de consumos y el interfaz de comunicaciones utilizado para integrarlo tanto con la plataforma de recogida de datos como con la PTCR. Mientras que en la sección 5 se especifica el desarrollo de modelo de predicción de consumo energético implementado.

4 Diseño y desarrollo de la plataforma de cálculo de consumos e interfaz de comunicaciones

La Plataforma de Cálculo de Consumos (PTCC) es el módulo encargado de calcular el gasto energético que existe en un vehículo eléctrico a lo largo de una ruta definida. Dicho cálculo se integra dentro del proyecto como un servicio web disponible bajo demanda a petición de la Plataforma de Recogida de Datos (PTRD).

La PTCC implementa tanto las interfaces de acceso como el cálculo del estado de la carga de la batería (SOC), traduciendo la ruta (formada por dos o más puntos) al consumo necesario de energía eléctrica llevada a cabo por el Vehículo Eléctrico (VE) que realizaría al llegar al destino. Dicha traducción se constituye mediante la utilización de un algoritmo que utiliza el modelo de la batería del coche y características dinámicas del coche, basando su cálculo de consumo eléctrico en la variación de diferentes parámetros de entrada.

4.1 Plataforma de cálculo de consumos

La PTCC es un desarrollo software programado sobre un servidor con las siguientes características:

Tipo de máquina	Virtual
Sistema Operativo	Windows Server 2008 R2 (64 bits)
RAM	2 Gb
Disco Duro	100 Gb
Nº Procesadores	2

Tabla 1. Características técnicas del servidor para la PTCC

El servidor está ubicado físicamente en las instalaciones del Instituto Tecnológico de la Energía (ITE), al cual se puede acceder, mediante uso de servicios web, a través de la dirección IP 46.24.7.150 y el puerto 8181.

El desarrollo de la aplicación que implementa la PTCC se ha realizado utilizando dos entornos de programación diferentes.

- 1) Visual Studio 2013. Para el desarrollo de servicios web, interfaces de acceso y tareas en background.
- 2) Matlab 2012. Para el modelado de la batería y estimación del consumo.

La integración del desarrollo realizado en Matlab se completa mediante la compilación de una biblioteca de enlace dinámico (DLL, en inglés Dynamic-Link Library) y su integración en el servidor.

El desarrollo del servidor para la implementación de los servicios web, se ha realizado bajo el framework de Microsoft .NET utilizando C# como lenguaje de programación.

El almacenamiento de los datos se realiza a través de bases de datos MySQL. Estas bases de datos permiten a la PTCC, desarrollada con diferentes lenguajes de programación, un acceso sencillo (mediante comunicación ODBC) a los datos almacenados en la base de datos.

Los servicios web implementan el interfaz de acceso a la funcionalidad de la plataforma, en nuestro caso al cálculo del consumo de VE. Para ello se hace uso de un estilo de arquitectura de Transferencia de Estado Representacional (REST, en inglés Representational State Transfer).

4.1.1 Estilo de arquitectura REST

REST es un estilo de arquitectura software que describe cualquier interfaz HTTP utilizada en el intercambio de datos o en la ejecución de operaciones sobre los mismos, en cualquier formato sin las abstracciones adicionales de los protocolos basados en patrones de intercambio de mensajes.

La arquitectura REST hace uso del protocolo HTTP cumpliendo con una serie de puntos:

- **Arquitectura basada en cliente-servidor:** Consiste en una separación clara entre los dos agentes básicos en un intercambio de información (cliente y servidor). Estos dos agentes deben ser independientes entre sí, lo que implica una flexibilidad elevada.
- **Stateless:** El servidor no almacena datos para mantener el estado del mismo.
- **Cacheable:** El sistema no fuerza al cliente a saber por qué capas se tramita la información.
- **Interfaz uniforme:** Simplifica el protocolo y aumenta la escalabilidad del sistema.

La siguiente figura muestra un esquema de bloques del intercambio de datos entre cliente y servidor:

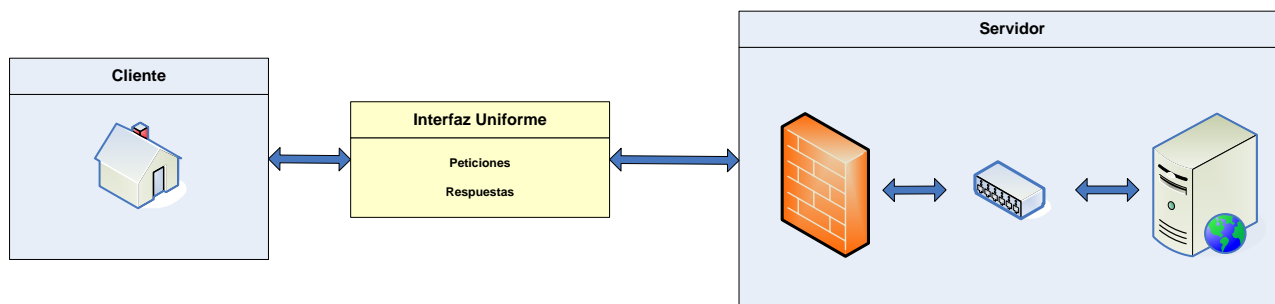


Figura 2.- Intercambio de datos cliente-servidor mediante arquitectura REST

El servidor REST contiene:

- **URI del recurso:** Dirección web para dar acceso a un determinado método definido.
- **Tipo de representación del recurso:** Respuesta con cabecera indicando el tipo del contenido de la respuesta. Normalmente se utiliza JSON, XML o TXT.
- **Operaciones:** Soporta distintos tipos de operaciones que puede ser GET, PUT, POST, DELETE, UPDATE, entre otros.
- **Estado:** Mensaje con información del estado de la respuesta que puede ser *OK* (Código 200), *No Content* (Código 204), *Bad Request* (Código 400), entre otros.

4.2 Interfaces y comunicaciones

El acceso a la PTCC se realiza a través de la dirección HTTP definida. El único acceso externo que permite la aplicación es la obtención del cálculo de consumo. Para ello, es necesario definir una serie de entidades, métodos y conocer las respuestas que puede proporcionar la PTCC:

4.2.1 Entidades

4.2.1.1 Route (definición de la ruta)

La entidad "route" define una ruta con las siguientes propiedades:

ID	Tipo	Requerido	Descripción
createdAt	String	No	Fecha de creación del registro en base de datos.
destination	String	Sí	Destino de la ruta.
id	Int	No	Identificador único en base de datos.
origin	String	Sí	Origen de la ruta.

solution	Solution	Sí	Objeto en formato JSON.
start_time	String	Sí	Fecha y hora del comienzo de la ruta.
status	Int	Sí	Estado de la ruta (códigos descritos en el entregable 3.1).
updatedAt	String	No	Fecha de última modificación del registro en base de datos.
vehicle	Vehicle	Sí	Objeto en formato JSON.
vehicleId	Int	Sí	Identificador único del vehículo.
version	Double	Sí	Versión de la plataforma PTCR.
waypoints	String	Sí	Objeto JSON en formato <i>String</i> .

Tabla 2. Propiedades definidas para Route

Los diferentes estados que puede adoptar el campo status está definido en el entregable E3.1.

4.2.1.2 Solution (definición de la solución)

La entidad "Solution" define una solución con las siguientes propiedades:

ID	Tipo	Requerido	Descripción
cost	Int	Sí	Duración total de la ruta (segundos)
route	List<CalculatedRoute>	Sí	Lista de entidades <i>CalculatedRoute</i> .
soc_inicial	Double	Sí	Porcentaje del SOC inicial.

Tabla 3. Propiedades de Solution

4.2.1.3 Vehicle (definición del vehículo)

La entidad "Vehicle" define un vehículo con las siguientes propiedades:

ID	Tipo	Requerido	Descripción
createdAt	String	No	Fecha de creación del registro en base de datos.
id	Int	No	Identificador único en base de datos.
license	String	No	Identificador de matrícula del vehículo, único para cada vehículo.
model	Model	No	Objeto en formato JSON.
modelId	Int	No	Identificador único del modelo del vehículo.
node	Node	No	Objeto en formato JSON.
nodeId	Int	No	Identificador único del nodo.
soc	Double	No	Último valor de SOC obtenido del vehículo.
status	Int	No	Código de 3 dígitos que indica el estado actual del vehículo
updatedAt	String	No	Fecha de última modificación del registro en base de datos.

Tabla 4. Propiedades de Vehicle

Los diferentes estados que puede adoptar el campo status está definido en el entregable E3.1.

4.2.1.4 Model (definición del modelo de vehículo)

La entidad “Model” define un modelo de vehículo con las siguientes propiedades:

ID	Tipo	Requerido	Descripción
battery_capacity	Int	No	Capacidad total de la batería (kWh)
company	String	No	Marca del vehículo
createdAt	String	No	Fecha de creación del registro en base de datos.
id	Int	No	Identificador único en base de datos.
max_load	Int	No	Capacidad máxima del vehículo (número de cajas)
name	String	No	Descripción del vehículo.
updatedAt	String	No	Fecha de última modificación del registro en base de datos.

Tabla 5. Propiedades de Model

4.2.1.5 CalculatedRoute (definición de una ruta calculada)

La entidad “CalculatedRoute” define una ruta calculada con las siguientes propiedades:

ID	Tipo	Requerido	Descripción
demand	Int	No	Cantidad (número de cajas) del pedido.
distance	Double	No	Distancia entre punto de salida y llegada.
duration	Int	No	Tiempo estimado entre el punto de salida y llegada.
end_location	Node	No	Objeto en formato JSON.
id	Int	No	Identificador único en base de datos.
start_location	Node	No	Objeto en formato JSON.

Tabla 6. Propiedades de CalculatedRoute

4.2.1.6 Node (definición de un nodo)

La entidad “Node” define un nodo con las siguientes propiedades:

ID	Tipo	Requerido	Descripción
address	String	No	Dirección del nodo.
arrival_time	String	No	Fecha y hora de llegada.

departure_time	String	No	Fecha y hora de salida.
door	String	No	Puerta.
est_arrival	String	No	Estimación del tiempo de llegada.
floor	String	No	Altura.
id	Int	No	Identificador único en base de datos.
lat	Double	No	Latitud GPS.
lng	Double	No	Longitud GPS.
name	String	No	Descripción.
phone	String	No	Número de teléfono.
soc	Double?	No	Valor de SOC estimado/calculado.
waitT	Int	No	Tiempo de espera.

Tabla 7. Propiedades de Node

4.2.2 Operaciones (cálculo/estimación de consumos)

Las operaciones se articulan sobre peticiones HTTP de tipo GET (obtener) o POST (agregar) ejecutadas sobre una URL base a la que se agrega otro fragmento de URL.

Método	GET
Fragmento	/Info
Respuesta del servidor	200 OK. Si la ejecución ha sido correcta. 404 Not Found. Si el servidor no se encuentra activo.
Salida	Objeto en formato JSON con las siguientes propiedades de tipo string: - Name, indicando la descripción del servidor. - Version, indicando la versión de aplicación activa. - URL, indicando la dirección completa del servidor.

Tabla 8. Descripción peticiones GET

Método	POST
Fragmento	/OnlineCalculation
Cuerpo del mensaje	Entidad de tipo <i>Route</i>
Respuesta del servidor	200 OK. Si la ejecución ha sido correcta. 400 Bad request. Si el cuerpo del mensaje no cumple con la definición de la entidad <i>Route</i> . 404 Not Found. Si el servidor no se encuentra activo. 500 Internal Server Error. Si ha ocurrido un error a la hora de ejecutar el algoritmo.
Respuesta	Entidad <i>Route</i> con el cálculo de SOC añadido a todas las entidades <i>Node</i> .

Tabla 9. Descripción peticiones POST

4.2.3 Objeto de salida (definición de la ruta + estimación de consumos)

La PTCC tiene como respuesta un objeto en formato JSON que conforma la entidad *Route*, un ejemplo del mismo se muestra a continuación:

```
"route":[
  [
    {
      "id":0,
      "distance":4033,
      "duration":767,
      "start_location":{
        "id":46,
        "lat":39.4723177,
        "lng":-0.392310700000053,
        "address":"Carrer de Santa Maria Micaela, 18, 46008 València, Valencia, España",
        "soc":2776.5,
        "arrival_time":null,
        "departure_time":null,
        "phone":null,
        "name":null,
        "est_arrival":null,
        "floor":null,
        "door":null,
        "waitT":0
      },
      "end_location":{
        "id":1,
        "lat":39.4697726,
        "lng":-0.374104900000002,
        "address":"Carrer de Correus, 14, 46002 València, Valencia, España",
        "soc":2771.2113633562276,
        "arrival_time":null,
        "departure_time":null,
        "phone":null,
        "name":null,
        "est_arrival":null,
        "floor":null,
        "door":null,
        "waitT":0
      },
      "demand":0
    }
  ]
]
```

4.3 Servicios

A continuación se enumeran los diferentes servicios que la PTCC es capaz de procesar durante su ejecución:

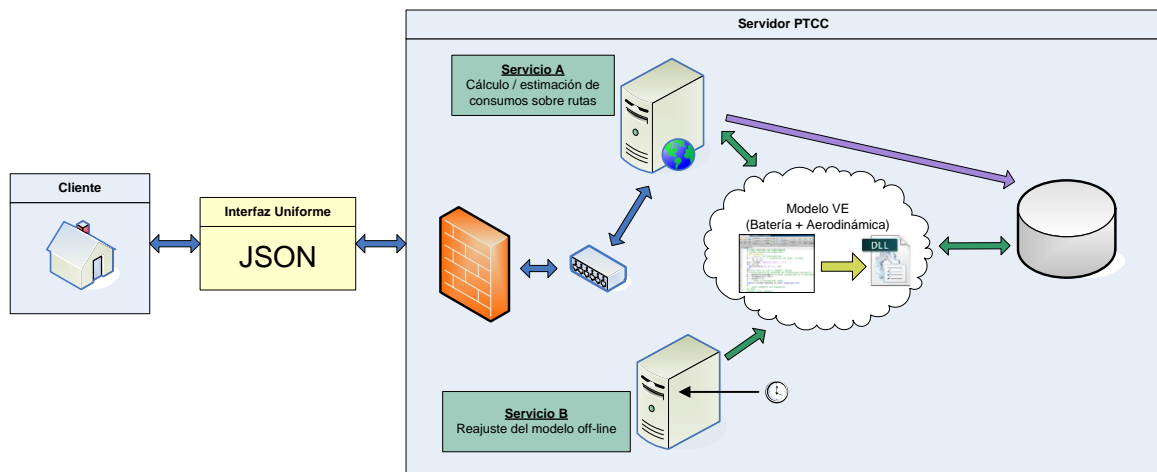


Figura 3.- Servicios que implementa la PTCC y su flujo de datos

4.3.1 **Servicio A: Cálculo/estimación de consumos sobre rutas**

El cálculo/estimación de consumos sobre rutas es el servicio encargado de proporcionar al cliente una estimación del consumo energético que existe entre dos o más puntos geográficos. La ejecución del servicio se realiza bajo demanda.

4.3.2 **Servicio B: Reajuste del modelo off-line**

El reajuste del modelo off-line es el servicio encargado de ir actualizando los parámetros variables del modelo definido del VE. Periódicamente, en un intervalo de tiempo previamente definido, la plataforma realiza la siguiente secuencia de acciones:

- Recogida de datos históricos, tanto de rutas ejecutadas como de valores recogidos de CANBus.
- Evaluación de los datos (aprendizaje).
- Reajuste de parámetros del modelo del VE.
- Activar modo *stand-by* hasta nueva interrupción.

Con estas acciones mencionadas, a lo largo de la utilización de la plataforma se permitirá un reajuste de parámetros dinámicos del modelo del VE, siendo capaz de estimar, cada vez más fiel a la realidad, la energía consumida.

5 Diseño y desarrollo de modelo de predicción de consumo energético

5.1 Antecedentes y planteamiento del modelo

5.1.1 Definición del problema y objetivos del modelo

Los Vehículos eléctricos (V.E.) representan muchas de las ventajas del desarrollo de las Smart Cities, bajo consumo energético, disminución de las emisiones contaminantes, descenso del ruido, y reducción de los costes operacionales. Sin embargo, con la tecnología actual, siguen adoleciendo de una serie de barreras a superar: largos tiempos de recarga, limitado número de estaciones de carga instaladas, y autonomía de viaje restringida. Lo que en el caso de los vehículos comerciales de carga, impide a los V.E. competir abiertamente con los vehículos convencionales de combustión interna (ICE).

El objeto del modelo de predicción de consumo energético a desarrollar para Cool Routing es precisamente brindar el soporte necesario por los V.E. de carga en la optimización de la planificación de la ruta de trabajo diario mediante la estimación del estado de carga (SOC) y del estado de la salud (SOH) de las baterías de dichos vehículos, basado en la ruta a desarrollar y las características propias del vehículo. Mediante la solución a desarrollar el conductor puede interactuar con el planificador de ruta y el módulo de predicción, empleando la información para decidir el mejor viaje y realizar el trabajo de la manera más eficiente posible.

El modelo de predicción de consumo energético (PMEC) debe ser capaz de estimar el nivel de SOC basándose principalmente en el estado actual del mismo, información sobre el trazado de posibles rutas, y la información meteorológica (en particular, la temperatura) de la zona de trabajo y adaptando los cálculos según las características climáticas estacionales y las velocidades a desarrollar durante el trayecto. El PMEC también debe contar con la posibilidad de corregir las estimaciones disponiendo de un módulo de entrenamiento que procese el histórico de conducción del vehículo, desviaciones entre la predicción y los datos registrados por el CAN-bus del V.E.

5.1.2 Referencias y antecedentes

Dada la importancia que tiene para el conductor de un vehículo hacer eficiente la conducción para aprovechar al máximo la capacidad de consumo del mismo, en el sector de logística y transporte se han realizado numerosos estudios con el fin de alcanzar dicho objetivo [2] [8] .

Un paso importante para encontrar soluciones a la mejora de la eficiencia en el sistema de transporte, en especial de V.E., es el desarrollo de modelos de predicción del consumo energético en tiempo real. Dentro de esa primera etapa, es importante identificar las diferentes características de los V.E. , el entorno en que se desarrolla la ruta y los patrones de comportamiento de los conductores de este tipo de vehículo [2]. Partiendo del clásico modelo electroquímico de la batería, se requiere añadir los parámetros físicos relacionados con la conducción como son la distancia recorrida y la velocidad [8].

En un vehículo en operación no es posible realizar una medición de circuito abierto del voltaje (OCV) para conocer el valor directo del SOC. Lo que hace necesario un modelo matemático fiable junto con un algoritmo de estimación robusto [9]. Debe tener un equilibrio entre la exactitud del modelo para captar la dinámica del sistema [1] y la complejidad del mismo para implementaciones en tiempo real [6].

Este modelo matemático presenta una gran no-linealidad, por lo que requiere métodos eficaces y robustos que permitan predecir los estados futuros del sistema – en particular, el SOC de la batería -.

De los métodos de estimación del SOC de la batería propuestos en la literatura científicas, destacan varias aplicaciones del Filtro de Kalman [10], ya sea en su modo Extendido [9] [11] [12] o “Unscented” [13] , con resultados admisibles. Por lo tanto, se ha decidido implementar esta técnica dentro del PEMC para realizar la estimación del SOC.

Así mismo, al modelo además de los incluir parámetros propios del modelado de la dinámica del vehículo y de la batería, debe incluir variables exógenas asociadas al clima (en especial, la temperatura ambiente) de la zona donde se desarrolla la ruta, del comportamiento del conductor (que permita definir un perfil de conducción) y de la ruta a desarrollar (urbana o de carretera). [2] [4]

Esta adaptación del algoritmo puede hacerse on-line o en los momentos de recarga mediante aprendizaje que incluya también la reducción del SOC debido al envejecimiento de la batería. Este módulo de observación se entrena usando una red neuronal similar al planteamiento de [7] [14] [15] [16]. Donde, básicamente, la ANN (red neuronal) puede modelar el complejo comportamiento no lineal de los parámetros basado en el principio de *aprendizaje mediante patrones*, sin la formulación matemática que requiere el Filtro de Kalman.

5.1.3 Planteamiento del modelo teórico

El P MEC propuesto consiste principalmente en un módulo de entrada de los datos recogidos por los sensores instalados en el V.E, se evalúa el nivel del SOC de la batería mediante la estimación de los estados futuros de los parámetros empleados en la caracterización matemática del nivel de consumo energético a la que se vería sometida la batería para el trayecto indicado por el conductor/usuario. Adicionalmente, se incorporan al modelo una serie de parámetros externos que se ha considerado afectan el comportamiento del consumo energético del V.E. en trayectos determinados. Y se pueden utilizar tanto para la estimación de estados como para la corrección del modelo en sí.

Predicción de consumo

Como se menciona en párrafos anteriores, el módulo de predicción de consumo consiste esencialmente de tres componentes: el Modelo de la batería a emplear, los parámetros que condicionan la conducción del V.E. y que afectan directa e indirectamente el consumo de la batería, y los datos que recoge el sistema CAN bus del V.E. que sirven de entrada principal al P MEC

- Sistema de Recolección de datos

El sistema de recolección de datos utiliza la sensorización propia del V.E. más una serie de sensores adicionales instalados por ITENE en el V.E., recopilación de datos meteorológicos obtenidos del website Weather Underground, así como información del tráfico y las rutas propuestas provistos por el servidor de Cool Routing desarrollado por ITENE.

Los datos del V.E. en uso incluyen el estado de carga de la batería, la corriente, el voltaje de baterías, la temperatura externa durante el evento, la duración del mismo. La información de conducción del vehículo incluye velocidad y posición del vehículo (latitud, longitud y elevación).

La recolección de datos sirve como base para esta investigación.

La arquitectura del sistema de recolección de datos es similar a la representada en la Fig. 4:



Figura 4.- Arquitectura del Sistema de recolección de datos

En primer lugar, se utiliza un CAN bus para registrar los datos del vehículo a través del BMS. Los datos se envían a un Smartphone (o tablet) a través de Bluetooth. Al mismo tiempo, el sistema de posicionamiento global (GPS) en un Smartphone recopila datos de localización de vehículos y genera trayectorias de trayecto. Los datos de la trayectoria se sincronizan con los datos de uso del vehículo utilizando una aplicación App instalada en el Smartphone. Los datos sincronizados se transmiten entonces a una base de datos a través de redes WiFi o móviles. ITENE ha desarrollado una aplicación web para publicar información útil derivada de datos en bruto a los usuarios del V.E. El objetivo de este sistema es que resulte general y pueda ser aplicado a cual-

quier VE.

- Modelado de la batería

El objetivo principal del PMEC es la predicción de cuánta capacidad de la batería se consumirá para un trayecto propuesto por el planificador de rutas.

El método más común para la estimación de SOC es el recuento de Coulomb. Este método es sencillo y fácil de implementar. Sin embargo, requiere conocimiento del SOC inicial. [13]. Además, como es un método de bucle abierto, el ruido de medición y el envejecimiento de la batería pueden causar deriva.

Otro método es el basado en voltaje, que infiere SOC por una tabla de consulta de voltaje de circuito abierto (OCV) -SOC. Sin embargo, la medición OCV requiere un largo período de reposo antes de que el voltaje de los terminales converja al OCV real y puede generar grandes errores si el modelo empleado no es exacto. [9]

Con métodos de inteligencia computacional se puede tener suficiente precisión si los datos de entrenamiento son suficientes para cubrir las condiciones de carga de la batería. Sin embargo, la recolección de datos para el entrenamiento que cubra todas las condiciones de carga puede tomar mucho tiempo.




Figura 5.- Modelo simplificado de la batería

El desarrollo de métodos de filtrado para establecer la estimación de lazo cerrado [10] actualmente son los que se presentan como mejor opción. El modelo de circuito equivalente y el modelo electroquímico se utilizan para establecer un modelo de espacio de estado de batería, donde se usa la corriente como entrada, el voltaje de terminal es la salida y el SOC se establece como el estado oculto. El diagrama esquemático de este modelo se muestra en la Fig. 5, en la que el OCV y R están conectados en serie. OCV es el voltaje del terminal cuando no se inyecta corriente, y es una función del SOC.

Para modelar la dinámica del sistema de baterías de manera más directa se emplea un circuito equivalente simplificado con voltaje terminal V como el OCV menos la caída de voltaje de la resistencia interna R , tal como se muestra en la Ec. 1:

$$V = OCV - I * R \quad \text{Ec. 1}$$

Donde, I es la corriente de entrada.

Se observa fácilmente como a medida que el SOC disminuye, el OCV también disminuirá.

- Identificación de los parámetros

Para identificar los parámetros que definen el modelo de batería del V.E., y por consecuencia estimar el SOC de la misma se emplea una técnica basada en EKF.

A cada instante de tiempo, el filtro propone un voltaje basado en la corriente acumulada medida y el modelo del sistema. La tensión estimada se compara entonces con la tensión medida. La diferencia entre los voltajes estimados y medidos se utiliza entonces para calcular un término de corrección para ajustar el SOC. Se formula un modelo de espacio de estados para realizar la estimación del SOC y de R dado que no pueden ser observados directamente con las medidas registradas.

5.1.4 Degradación con el uso (SOH)

No hay un método común para estimar el SOH. La forma más intuitiva es establecer una relación entre el número de ciclos de carga y descarga más el tiempo desde salida de fábrica para determinar el estado de la salud de la batería. Sin embargo, este tipo de estimación no es posible emplearla en un modelo generalizado, dado que usualmente se desconoce tanto el momento de salida de fábrica de la batería, así como el número de cargas/descargas y condiciones de temperatura en que ocurrieron antes de aplicar el PMEC.

El SOH de la batería es la capacidad de la misma para almacenar energía y mantener la carga durante largos períodos, en relación con sus capacidades iniciales o nominales. [11]. El SOC en una batería completamente cargada disminuye con el uso de la misma. Sin embargo, a medida que el material activo en las placas celulares gradualmente se degrada por mecanismos tales como pérdida de superficie activa de la placa, por pérdida de contacto eléctrico entre rejillas metálicas y materiales activos, o por el crecimiento de cristales de sulfatos inactivos. Dichos mecanismos de pérdida de capacidad afectan directamente el SOH de la batería, e indirectamente la estimación del SOC de la misma.

La detección de la degradación de SOH permitiría al PMEC tomar medidas correctivas y notificar en casos especiales al usuario para realizar mantenimiento o reemplazo de la batería. La medición de la capacidad de la celda por medio de una descarga de corriente baja es impracticable para las aplicaciones de V.E., por lo que se requieren técnicas en línea que realicen la estimación del SOH empleando mediciones en los terminales de la batería mientras se conduce el V.E.

Por lo que se hace necesario modificar el circuito descrito según la Ec. 1. De manera de tener un modelo que permita el cálculo del SOC y el SOH con el mismo EKF a aplicar. Donde, C_{bulk} modela el voltaje de circuito abierto de la célula, R_d representa la autodescarga de la célula, el voltaje a través de la capacitancia se denomina V_{Cb} , se agrega una capacitancia de doble capa $C_{surface}$ en paralelo con la transferencia de carga representada por R_t . [11]. Con lo que se diseña un modelo Randle de 2º orden tal como el que se presenta en la figura 6:

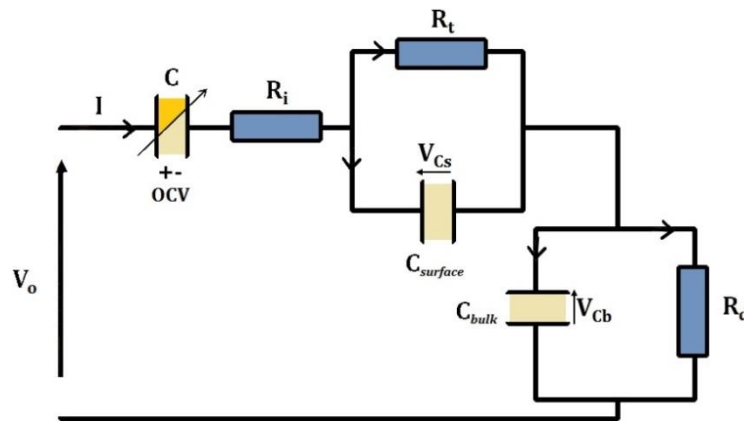


Figura 6.- Esquema Circuito para cálculo del SOC/SOH

Dado que las derivadas de V_{Cb} y V , están acopladas por elementos no lineales, se requiere un EKF para la estimación efectiva de las variables de estado.

$$\dot{x} = f(x, u); \quad y = C(x); \quad \text{Donde, } x = [SOC, V_{Cs}, V_{Cb}]^T \quad \text{Ec. 2}$$

Esta estimación implica un aumento en la tasa de cálculo, como consecuencia de los Jacobianos, covarianzas, ruidos y matrices de perturbación incluidos en el sistema de estados.

El EKF requiere un modelo de pequeña señal del sistema, a cada paso de la muestra, para linealizar alrededor del punto de funcionamiento, x_0, u_0 . A partir de la expansión por series de Taylor (ignorando la presencia de ruido):

$$\delta x = \mathbf{F}(x) \delta x + \mathbf{B} \delta u; \quad \delta y = \mathbf{C} \delta x \quad \text{Ec. 3}$$

Donde, $\delta x = x - x_0, \quad \delta u = u - u_0$

El sistema de estados continuo es aproximado a uno discreto mediante una transformación del tipo $s = f(z)$, empleando una derivación (*backward rule*) [17]. De modo que el sistema es redefinido según la Ec. 4:

$$x_{k+1} = \mathbf{A}_d x_k + \mathbf{B}_d u_k; \quad y_{k+1} = \mathbf{C}_d x_{k+1} \quad \text{Ec. 4}$$

En la figura 7 se puede observar una representación gráfica del sistema




Figura 7.- Modelo de sistema discreto

Se realiza la estimación mediante la aplicación del algoritmo de Kalman. El proceso consiste en un algoritmo recursivo de predicción-corrección.

5.1.5 Influencia de las variables externas

Existen otro grupo de factores externos que pueden afectar la predicción del SOC tales como el rendimiento del vehículo, el consumo de energía de los componentes clave, el comportamiento de los conductores, condiciones de la carretera, pendiente de la carretera, resistencia a la rodadura y aerodinámica que afecta el campo de conducción.

El PMEC propuesto es esencialmente una representación estadística basada en los principios físicos subyacentes de la dinámica y cinemática del V.E. que afectan el consumo de energía de la batería.

El consumo de batería a rueda [18] de un vehículo eléctrico es una función de la energía mecánica requerida en las ruedas, determinada por los parámetros cinemáticos sobre una trayectoria, la eficiencia del tren automotriz y el consumo de energía de los sistemas auxiliares del vehículo. La energía mecánica total requerida en las ruedas, puede expresarse en función de los parámetros cinemáticos que describen el movimiento del vehículo, tal como ilustra la figura 8:

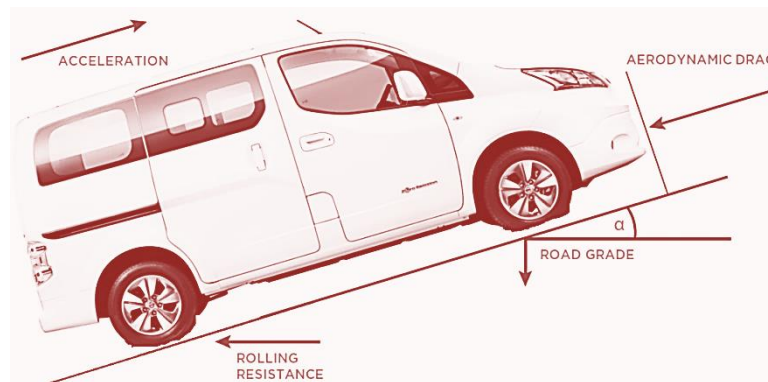


Figura 8.- Fuerzas que afectan al vehículo

Las Ec. 5 y 6 que representan la dinámica del vehículo [5], [6]. La potencia total (P_{total}) se calcula a partir de la suma de las fuerzas implicadas en el movimiento de un vehículo multiplicadas por la velocidad de tracción del vehículo:

$$P_{total} = F_a V + F_{air} V + F_c V + F_r V \quad \text{Ec. 5}$$

$$P_{total} = \left(m a + \frac{1}{2} \rho_{air} C_d A_F V^2 + m g \sin(\alpha) + m g K_r \cos(\alpha) \right) V \quad \text{Ec. 6}$$

Las variables que caracterizan la Ec. 6 son las siguientes:

- ρ_{air} : Densidad del aire
- C_d : Coeficiente de resistencia aerodinámica
- A_F : Área frontal del vehículo
- α : Gradiente de la carretera
- K_r : Coeficiente de resistencia a la rodadura

También es importante tomar otra serie de factores externos que pueden afectar el consumo energético del vehículo durante su funcionamiento.

- Influencia de climatología

La climatología en que se realiza la conducción afecta de manera directa el SOC y el SOH de la batería. Ya sea por efecto directo de las temperaturas, tanto los gradientes cálidos como los gélidos afectan el desempeño de la batería durante su ciclo de trabajo y el grado de envejecimiento del equipo. También existe el efecto indirecto de la variable temperatura que implica el uso del sistema de climatización del vehículo, ya sea para utilizar el A/C como el sistema de calefacción, lo que requiere mayor demanda energética de la batería. Se ha comprobado experimentalmente el efecto de las temperaturas extremas en la tasa de descarga de un V.E.

El resto de variables climatológicas (humedad, presión atmosférica, velocidad del viento) en conjunto influyen en el modo de conducción: reducción de la velocidad media, uso de luces del vehículo, mayor ocurrencia de frenados, cambios en la conducta tipo del usuario. Adicionalmente, los cambios de estación impliquen cambios en la demanda del uso de luces del vehículo.

Todo este tipo de situaciones climatológicas se ven reflejadas en diferentes comportamientos estacionales del consumo energético del vehículo que impiden un modelo matemático constante a lo largo del año.

- Climatización del vehículo

La calefacción y refrigeración de la cabina del conductor puede representar una de las cargas más significativas de la batería dependiendo del conductor y las condiciones externas al vehículo. La energía utilizada para controlar el clima de la cabina depende de las condiciones meteorológicas, la exposición a la luz solar y la posición de las ventanas laterales. [3]

A efectos de cálculo, se supone que el vehículo dispone de un sistema de climatización automático con el punto de consigna de temperatura de la cabina especificado por el conductor y de que las ventanillas laterales no están abiertas cuando el climatizador está en funcionamiento. Los efectos de la luz directa del sol son ignorados para esta estimación.

De manera que la energía requerida para el control del clima del V.E. es representada como:

$$P_{climate} = \begin{cases} 0 & , \text{ off} \\ P_{heat} (T_{cabin} - T_{air}) & , \text{ heating} \\ P_{cool} (T_{air} - T_{cabin}) & , \text{ cooling} \end{cases} \quad \text{Ec. 7}$$

Dónde:

- $P_{climate}$ es la energía usada para el control del clima.
 - P_{heat} es la potencia por grado utilizado para la calefacción, incluido el desembocadura.
 - P_{cool} es la potencia por grado utilizado para el enfriamiento.
 - T_{cabin} es el punto de consigna de la temperatura de la cabina.
 - T_{air} es la temperatura del aire exterior.
- #### - Influencia del peso y la refrigeración

Como uno de los objetivos principales del Cool Routing es lograr una plataforma de estimación de consumos para utilizar en la optimización de la planificación de rutas de reparto para vehículos de carga, se debe tomar en cuenta la variación continua y significativa del peso conjunto del vehículo. Esto requerirá incrementos en

la demanda de tracción del V.E. que podrían resultar significativos y a su vez aumentar puntualmente el consumo energético del sistema, por lo que es otra variable a considerar dentro del modelo general de la plataforma de cálculo.

Si por añadido esta carga a repartir considera la posibilidad de llevar productos congelados, requiere considerar el consumo energético del contenedor así como el peso adicional del mismo. En el caso del peso del arcón se expresa su contribución en el peso o masa total del vehículo, m , según la Ec.8:

$$m = m_v + m_{load} + m_{cooler} \quad \text{Ec. 8}$$

Donde, m_v representa la masa del vehículo; m_{load} a la masa de la carga; y, m_{cooler} a la masa del arcón.

En función de si se utiliza el sistema de refrigeración en la red del vehículo se simula como un parámetro P_{frost} con 2 estados posibles descritos en la Ec. 9:

$$P_{frost} = \begin{cases} 0, & \text{off} \\ P_{cooler}, & \text{on} \end{cases} \quad \text{Ec. 9}$$

- Frenado Regenerativo

Los sistemas de frenado regenerativo en los EVs permiten la recuperación de energía durante el frenado. Específicamente, el motor eléctrico funciona como un generador mediante el envío de energía de las ruedas del vehículo al motor eléctrico que se almacena en el sistema de la batería. Estudios previos encontraron que los EVs eran mucho más eficientes cuando se conducía en rutas urbanas "intermitentes" en comparación con las autopistas ininterrumpidas porque el sistema de frenado regenerativo es capaz de regenerar mayor cantidad de energía [1] [5].

Por esto, resulta importante en el PMEC tomar en cuenta los efectos del frenado regenerativo para la estimación del consumo instantáneo de energía del V.E. El modelo incluye el rendimiento energético del frenado regenerativo instantáneo, como una función del nivel de desaceleración del vehículo. A partir de las mediciones de velocidad, las aceleraciones del vehículo se pueden determinar para cada ciclo de reloj la energía de frenado regenerativa instantánea capturada, usando como variables de entrada la velocidad y la aceleración. Para calcular el aporte de la energía de frenado para el sistema de frenado regenerativo (η_{rb}) se define la relación descrita en la Ec. 10 para cada ciclo de conducción:

$$\eta_{rb} [\%] = E_{Recv} / E_{Aval} \quad \text{Ec. 10}$$

Donde, η_{rb} es la eficiencia del frenado regenerativo (%); E_{Recv} es la energía (kWh) recuperada durante el frenado; y, E_{Aval} es la energía máxima (kWh) disponible para recuperar durante el frenado. Este parámetro se puede calcular empleando la Ec. 11:

$$E_{Aval} = \int_0^t P_{Brake}(t) dt \quad \text{Ec. 11}$$

En este caso, P_{Brake} corresponde a los casos donde la $P_{total} < 0$, que ocurre cuando el vehículo está frenando. En los casos en que la $P_{total} > 0$ el coche está en modo tracción, y se asigna valor cero a la P_{Brake} .

- Cambios de altitud (pendiente de elevación)

Los cambios de elevación a lo largo de una ruta contribuyen en el incremento del consumo energético característico para una distancia y velocidades tipo [3]. Mediante una aproximación trigonométrica sencilla (ver figura 9), descrita en la Ec. 12, se propone una metodología para obtener el gradiente de la carretera (α) debido a un cambio en la elevación del V.E. durante un viaje [19].

$$\alpha = \sin^{-1} \frac{\Delta E}{\Delta D} \quad \text{Ec. 12}$$

De esta manera el sistema de recolección de datos descrito en párrafos anteriores recoge en tiempo real los datos de altitud del V.E. en cada muestra. Este resultado se emplea como entrada de la PMEC del consumo energético de la batería descrita en la Ec. 9.

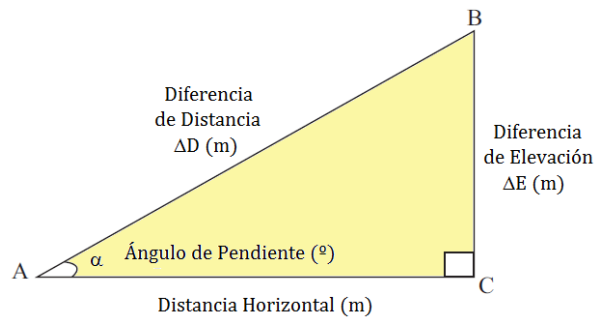


Figura 9.- Triángulo de distancia – elevación

- Comportamiento del Conductor

El estilo de conducción y el comportamiento de un individuo son difíciles de predecir. El comportamiento del conductor puede tener un impacto significativo en el alcance de un EV debido a las variaciones en el nivel de habilidad del conductor cuando se trata de utilizar el frenado regenerativo, la urgencia en la aceleración, la agresividad en el tráfico y el uso del equipo del vehículo, luces [3].

A pesar de que un coche eléctrico es capaz de mediante el frenado regenerativo de recuperar parte de la energía cinética y almacenarla en la batería, se pierde mucha energía como calor en los frenos de disco cuando se pisa fuertemente el pedal del freno. [1]

Por ejemplo, algunos conductores presionan el pedal de la aceleración agresivamente hasta que el vehículo alcance la velocidad deseada, pero otros gradualmente aumentan / disminuyen velocidad con un tiempo largo de la aceleración. El tiempo de reacción también depende del conductor. Mientras que los conductores con un largo tiempo de reacción tienden a mantener la velocidad de sus vehículos en lugar de aceleración o desaceleración, otros con un breve tiempo de reacción responden inmediatamente a una situación dada, por ejemplo, la desaceleración del coche delantero. [6]

Este parámetro es difícil de estimar o utilizar como entrada del sistema. Pero, dentro de una flota de vehículos de carga si resulta de utilidad caracterizar la tipología del conductor. Y a partir de esa identificación, utilizar como parte de la estrategia particular de predicción del consumo de cada vehículo.

- Grado de Ansiedad en la Conducción

El miedo de quedar varado a un lado de la carretera con un V.E. por falta de carga de la batería se ha denominado "Grado de Ansiedad". La incidencia que produce el Rango de Ansiedad dentro del consumo energético es especialmente problemática dado que afecta la velocidad de conducción, la agresividad en la conducción, así como en el control de la climatización del vehículo [1].

Se espera que un conductor de V.E. esté enterado de las limitaciones de la batería y de la situación de los puntos de recarga, sin embargo existen diversos niveles de comprensión de un conductor a otro. En situaciones en las que un EV se utiliza como un vehículo compartido, puede haber muchos conductores diferentes para un solo vehículo.

La incertidumbre sobre las capacidades de alcance de un V.E. para un viaje dado también puede ser mayor cuando el conductor no está familiarizado con la ruta que debe utilizar.

En los casos de alta incertidumbre, los conductores se basan en la estimación de alcance dada por el V.E. al planificar un viaje. Las grandes fluctuaciones del cálculo del SOC son comunes cuando se conduce un V.E. especialmente cuando se encuentran con situaciones intensivas de energía, como subir una pendiente o períodos de conducción a altas velocidades en la autopista. Esto puede dar lugar a que el conductor sobrestimar las capacidades del vehículo.

Por otro lado, la desconfianza en la estimación de la distancia probablemente cause a los conductores ser demasiado cautelosos en su uso del V.E. Esto puede manifestarse en forma de paradas de recarga excesivas durante un viaje. [3]

El grado de ansiedad se modela como una función de paso que se activa cuando el SOC de batería restante es menor que un porcentaje de umbral predeterminado. [8].

$$P_{anx} = \beta \Delta SOC$$

$$\begin{cases} \beta = \gamma; \forall \omega * \kappa \geq SOC \\ \beta = 0; \forall \omega * \kappa < SOC \end{cases} \quad \text{Ec. 13}$$

Dónde:

- γ es el coste de ansiedad predeterminado
 - ω es el umbral de ansiedad (%)
 - κ es la capacidad de la batería
 - $\Delta SOC(t)$ es el diferencial de SOC en un intervalo de tiempo
- Horarios de Conducción (Diurno/Nocturno)

Los faros de los vehículos y las luces traseras funcionan cuando el nivel de luz ambiente es bajo. Su uso está determinado por la hora del día en que se produce el accionamiento [3]. La potencia utilizada por la iluminación se expresa en la Ec. 17:

$$P_{luces} = \begin{cases} 0, & \text{diurno} \\ P_{luces}, & \text{nocturno} \end{cases} \quad \text{Ec. 14}$$

Dónde P_{luces} es la potencia necesaria para hacer funcionar las luces del vehículo

5.1.6 Modelo y procedimiento para reajuste offline de forma periódica

Tal como se ha expuesto en los apartados anteriores el modelo desarrollado para la predicción de consumos está basado en el conocimiento de las características propias del vehículo y de las distintas fuerzas que definen la dinámica de un vehículo en movimiento. Así mismo el modelo integra los distintos consumos previsibles de los servicios auxiliares del V.E. y de las características del transporte de carga refrigerada. Y a través de un EKF se realiza la predicción y corrección del SOC/SOH de la batería basado en un modelo matemático del proceso electroquímico de la misma. De esta manera se diseña y desarrolla un modelo de estimación que presenta un compromiso razonable entre la precisión y la complejidad de la misma. Este tipo de solución puede denominarse del tipo *caja gris* (grey box), como alternativa factible al típico modelo de *caja negra* (black box) [20].

Esta solución requiere el conocimiento experto de muchas de las constantes físicas implicadas en la determinación de la potencia a consumir tanto por el vehículo como por los sistemas auxiliares del mismo. La determinación de los parámetros se basa en las características típicas del modelo de V.E. Por lo que para que el desempeño de la plataforma de cálculo de consumo se adapte lo mejor posible a las particularidades de cada vehículo donde es implementada, se considera necesario aplicar un proceso de reajuste. Este proceso de aprendizaje estaría basado en la información recolectada en cada trayecto/viaje realizado por el vehículo.

En este caso si se emplearía un modelo de *caja negra* para que sea capaz de modelar las complejas relaciones no lineales entre las entradas y salidas del sistema [9]. Los modelos de caja negra emplean herramientas de inteligencia artificial, como redes neuronales [14], máquinas vectoriales soportadas [13], algoritmos genéticos [9], etc., para construir un modelo invisible capaz de simular el desempeño del modelo de predicción de consumos, los cuales basados en una gran cantidad de datos experimentales pueden entrenar la salida del modelo, es decir, la capacidad de la batería (SOC).

Para simplificar la implementación del aprendizaje se ha decidido implementar una técnica de redes neuronales basada en el algoritmo de backpropagation que permite modificar las conexiones de arquitecturas multicapas. El objetivo del algoritmo backpropagation es propagar los errores cometidos por las unidades de salida hacia atrás, ya que, en un sistema de este tipo, el error cometido por una unidad intermedia depende del error cometido por las unidades de salida a las que dicha unidad intermedia está conectada. Tras conocerse el error cometido por las unidades intermedias, pueden entonces modificarse las conexiones entre unidades de entrada y unidades intermedias. De forma similar a la regla delta, la base matemática del algoritmo backpropagation es la técnica de gradiente decreciente, basa-

da en modificar los pesos en la dirección opuesta al gradiente, esto es $-\frac{\partial E_p}{\partial w_{ij}}$, en la dirección que determina el decremento más rápido del error (ver figura 10)




Figura 10.- Ejemplo de Red Neural con Backpropagation

Este entrenamiento se realizaría con un período a determinar en función del número de viajes diarios/semanales que realice el vehículo. Ya que la red neuronal requiere un gran número de muestras para asegurar la precisión del algoritmo.

5.2 Modelado y simulación

El modelo es implementado en Matlab 12 y compilado posteriormente en una dll que contiene las funciones requeridas para su integración en la plataforma de cálculo de consumo desarrollada en C#.

El programa consiste en una función o programa principal que realiza la estimación online del SOC final a partir de los datos enviadas por la PTCR y la PTRD:

function [Outjson,version]= Ptcc(Jstring,SOCo,tmc,consigna,TarcE,Tarcl,IDv)

Outjson : Vector de salida que entrega los valores predecibles del SOC para cada punto de paso (waypoint) del trayecto estimado por la plataforma de cálculo de rutas

version : Número de versión del algoritmo, sirve como control de cambios en las modificaciones del programa y permitir la revisión de estos cambios dentro del software de la plataforma de cálculo de consumos

Jstring : String que contiene la información de la PTCR sobre los waypoints y los intervalos de tiempo estimados entre cada uno de ellos. El string está definido en formato JSON

SOCo : Dato actual del SOC de la batería del vehículo con la que iniciaría la ruta de reparto sugerida

tmc : Temperatura exterior estimada durante el inicio del trayecto

consigna : Temperatura de consigna para la climatización de la cabina del conductor

TarcE : Temperatura exterior del contenedor/arcón de carga refrigerada

Tarcl : Temperatura de consigna en que se desea llevar la carga refrigerada

IDv : Identificación del vehículo

Los pasos del programa consisten en:

1. Comprobación de entradas de la función: *En caso que el vector de datos de entrada esté incompleto el programa asume valores tipo para realizar la predicción.*
2. Consulta de la Base de Datos (MySQL) de los parámetros actualizados del vehículo específico.
3. Asignación de las variables iniciales a utilizar en el modelo electroquímico de la batería.
4. Lectura datos de recorrido: *De las rutas propuestas por la PTRD se extraen los waypoints y tiempos de viaje.*
5. Se ejecuta el Algoritmo de Cálculo rápido de SOC.

- a) Cálculo de las Fuerzas involucradas en la dinámica del vehículo
- b) Estimación de la Potencia Consumida en cada tramo del trayecto
- c) Definición de entradas a la rutina EKF
6. Actualización de variables
7. Ejecución de pasos 5 y 6 para el nuevo tramo del trayecto propuesto
8. Fin del Algoritmo de Cálculo rápido de SOC
9. Salida de la PTCC : *vector de Consumos Estimados para cada tramo del trayecto*
10. Fin

5.2.1 Ejemplo

Como entrada del sistema desde la PTRD se recibe el arreglo (Jstring) en formato Json :

Esta información estructurada contiene el siguiente trayecto comprendido en 4 tramos:

- 1) De *Carrer Colón, 24, 46004 València*, hasta *Gran Via de Ferran el Catòlic, 15, 46008 València*., se estima un tiempo de recorrido de *392 segundos y una distancia de conducción de 1962 mts*
- 2) De *Gran Via de Ferran el Catòlic, 15, 46008 València*, hasta *Av. de Portugal, 14, 46009 València*; se estima un tiempo de recorrido de *582 segundos y una distancia de conducción de 4219 mts*
- 3) De *Av. de Portugal, 14, 46009 València*, hasta *Av. de Blasco Ibáñez, 25, 46010 València*; se estima un tiempo de recorrido de *640 segundos y una distancia de conducción de 3373 mts*
- 4) De *Av. de Blasco Ibáñez, 25, 46010 València*, hasta *Carrer Colón, 24, 46004 València*; se estima un tiempo de recorrido de *360 segundos y una distancia de conducción de 2361 mts*

Por otro lado para este ejemplo se asumen los siguientes datos:

- SOC inicial del vehículo : 85%
- Temperatura ambiente : 26 °C
- Temperatura deseada en cabina : 22.5 °C
- Temperatura actual del arcón : 8 °C
- Consigna de refrigeración para la carga : 4 °C
- Nº Identificación del vehículo : 2

Se realiza el llamado de la función como:

```
[Outjson,version]= Ptcc(Jstring,Soc,Tamb,Tcab,Tact_arcon,Tcons_arcon,ID_V)
```

Y el resultado del ejemplo de ejecución del programa es el siguiente:

Outjson = [85.0000 82.8625 78.0715 73.9027 71.4406] (*Esta es la predicción del SOC en al final de cada tramo del trayecto a realizar a partir del dato inicial*)

version = PTCC con BBDD v05 (*Dato de verificación de actualizaciones o modificaciones del algoritmo*)

5.2.2 Recomendaciones

Para contrastar el desempeño de la PTCC es recomendable realizar exhaustivas pruebas de campo que permitan verificar la caracterización y adaptación de la plataforma a la mayor cantidad de modelos de V.E. de reparto y dotarla de una versatilidad que el sistema de aprendizaje offline pueda terminar de reajustar al usuario específico.

Por ello, también se requieren una gran cantidad de pruebas para que el reajuste offline por aprendizaje tenga la suficiente fiabilidad.

El algoritmo combinado de estimación de potencia consumida por el sistema dinámico del vehículo aunado a la estimación de temperaturas y modelado de la batería, hacen de la PTCC una herramienta efectiva. Sin embargo, justo el modelado de consumo por sistemas de climatización y del modelo electroquímico, son susceptibles de mejora. Por lo que se recomienda la posibilidad de estudiar otras posibles implementaciones menos empíricas que se aproximen más al comportamiento real de estos subsistemas.

La ventaja de la PTCC tal como está definida le permita una gran flexibilidad para incorporar más variables parametrizadas que permitan hacer una estimación más fina y ajustable al consumidor. Tanto en el algoritmo de cálculo como el diseño de la BBDD. Un ejemplo sería la caracterización de los modos de conducción específica de cada usuario, para ello habría que determinar un modelo fiable que contribuya en la estimación.

6 Conclusiones

En base a toda la información se desarrollará una herramienta de alta precisión de cálculo de consumos. En primer lugar se realizará un planteamiento del modelo teórico que permitirá identificar los parámetros de entrada con un sistema dinámico del vehículo eléctrico.

Como resultado de los trabajos llevados a cabo en el paquete de trabajo “PT5. Plataforma de cálculo de consumos” se han completado las siguientes tareas:

- Diseño de un prototipo funcional de la plataforma de cálculo de consumos en la nube.
- Desarrollo de la interfaz de comunicaciones con el servicio web disponible bajo demanda a petición de la Plataforma de Recogida de Datos (PTRD) y la PTR desarrollada en el PT4.
- Diseño y desarrollo de modelo de predicción de consumo energético. El algoritmo desarrollado dentro de la plataforma tiene en cuenta el modelo de la batería a emplear, los parámetros que condicionan la conducción del V.E., y los datos recogidos por el CAN Bus (PT2)
- Definición del procedimiento para reajuste offline de forma periódica de los parámetros del modelo de predicción.

De esta manera los diferentes trabajos desarrollados en los PT 2, 3 y 4 (detallados en sus correspondientes entregables) permiten proveer a la PTCC de las entradas necesarias para el cálculo del SOC, mediante la interfaz de comunicaciones y mediante un algoritmo de cálculo basado en el modelo de la batería del coche y las características dinámicas del coche, permite una estimación efectiva y contrastada con otras plataformas de simulación de cálculo de consumo similares [21], [22], [23], [24]. Las pruebas realizadas de manera aislada. (Pruebas de laboratorio) para la validación de la PTCC se presentarán en el entregable E5.2. En el que se describirán las simulaciones realizadas antes de ser integrada con el resto de componentes en el PT6 con rutas y el vehículo eléctrico sensorizado.

7 Referencias

- [1] R. Van Haaren, «Assessment of electric cars' range requirements and usage patterns based on driving behavior recorded in the National Household Travel Survey of 2009,» Earth and Environmental Engineering Department, Columbia University, Fu Foundation School of Engineering and Applied Science, New York (USA), 2011.
- [2] X. Wu, D. Freese, A. Cabrera y W. A. Kitch, «Electric vehicles' energy consumption measurement and estimation,» *Transportation Research Part D: Transport and Environment*, vol. 34, pp. 52-67, 2015.
- [3] V. R. Tannahill, K. M. Muttaqi y D. Sutanto, «Driver alerting system using range estimation of electric vehicles in real time under dynamically varying environmental conditions,» *IET Electrical Systems in Transportation*, vol. 6, nº 2, pp. 107-116, 2016.
- [4] J. C. Ferreira, V. Monteiro y J. L. Afonso, «Dynamic range prediction for an electric vehicle,» de *World Electric Vehicle Symposium and Exhibition (EVS27)*, Barcelona (Spain), 2013.
- [5] C. Fiori, K. Ahn y H. A. Rakha, «Power-based electric vehicle energy consumption model: Model development and validation,» *Applied Energy*, nº 168, pp. 257-268, 2016.
- [6] E. Kim, J. Lee y K. G. Shin, «Real-time prediction of battery power requirements for electric vehicles,» de *Proceedings of the ACM/IEEE 4th International Conference on Cyber-Physical Systems*, Philadelphia, Penn. (USA), 2013.
- [7] J. A. K. S. Jayasinghe y K. K. K. D. Nadishan, «Neural Network Based State of Charge (SOC) Estimation of Electric Vehicle Batteries,» *International Journal of Scientific and Research Publications*, vol. 4, nº 12, 2014.
- [8] S. Agrawal, H. Zheng, S. Peeta y A. Kumar, «Routing aspects of electric vehicle drivers and their effects on network performance,» *Transportation Research Part D: Transport and Environment*, vol. 46, pp. 246-266, 2016.
- [9] R. Ahmed, Modeling and State of Charge Estimation of Electric Vehicle Batteries, Hamilton, Ontario (Canada): PhD. diss. - McMaster University, 2014.
- [10] J. Li, J. Klee Barillas, C. Guenthe y M. A. Danzer, «A comparative study of state of charge estimation algorithms for LiFePO₄ batteries used in electric vehicles,» *Journal of power sources*, nº 230, pp. 244-250, 2013.
- [11] B. S. Bhangu, P. Bentley, D. A. Stone y C. M. Bingham, «Observer techniques for estimating the state-of-charge and state-of-health of VRLABs for hybrid electric vehicles,» de *IEEE Vehicle Power and Propulsion Conference*, Chicago, IL, USA, 2005.
- [12] Y. Zou, X. Hu, H. Ma y S. E. Li, «Combined state of charge and state of health estimation over lithium-ion battery cell cycle lifespan for electric vehicles,» *Journal of Power Sources*, nº 273, pp. 793-803, 2015.
- [13] W. He, N. Williard, C. Chen y M. Pecht, «State of charge estimation for electric vehicle batteries using unscented Kalman filtering,» *Microelectronics Reliability*, vol. 53, nº 6, pp. 840-847, 2013.
- [14] J. Lee, D. Lee y G. Park, «State-of-Charge stream processing and modeling for electric vehicle-based trips,» *International Journal of Control and Automation*, vol. 7, nº 9, pp. 399-410, 2014.
- [15] L. Qian, Y. Si y L. Qiu, «SOC estimation of LiFePO₄ Li-ion battery using BP Neural Network,» de *28th International Electric Vehicle Symposium and Exhibition (EVS28)*, Goyang (Korea), 2015.
- [16] B. Jun, S. Sai, G. Wei y W. Lu, «State of charge estimation of Li-ion batteries in an electric vehicle based on a radial-basis-function neural network,» *Chinese Physics B*, vol. 21, nº 11, pp. 118801: 1-5, 2012.

- [17] S. A. Al-Assadi y A. A. Marouf, «Optimal discrete-time models for continuous-time control systems,» *Applied Mathematical Modelling*, vol. 12, nº 5, pp. 533-542, 1988.
- [18] C. De Cauwer, J. Van Mierlo y T. Coosemans, «Energy consumption prediction for electric vehicles based on real-world data,» *Energies*, vol. 8, nº 8, pp. 8573-8593, 2015.
- [19] K. W. Chew y C. K. Leong, «Contour Data Acquisition System for Electric Vehicle Distance Estimation System,» *Journal of Marine Science and Technology*, vol. 22, nº 6, pp. 700-704, 2014.
- [20] M. El Lakkis, O. Sename, M. Corno y D. Bresch Pietri, «Combined battery SOC/SOH estimation using a nonlinear adaptive observer,» de *14th European Control Conference (ECC15)*, , pp. 1522-1527., 2015, Linz (Austria), 2015.
- [21] B. Hannel, «EV Trip Planner,» 2015-2016. [En línea]. Available: <https://www.evtriplanner.com/index.php>. [Último acceso: 2016-2017].
- [22] L. J. Test, «GreenRace 5.2,» [En línea]. Available: <http://www.jurassictest.ch/GR/>. [Último acceso: 2017].
- [23] C. Software, «e.go Intelligent Travel Evolved,» [En línea]. Available: <http://egomap.eu/>.
- [24] C. Ltd, «EV Route,» 2017. [En línea]. Available: <http://evroute.controtex.com/>.

* En este proyecto han colaborado por parte del ITE: Ignacio Benítez, Christian Conca, Julio César y Caterina Tormo; Por parte de ITENE: