Algoritmo de Programación para Gestionar la Demanda de Cargadores de Baterías para Vehículos Eléctricos en un Esquema de Tarificación Variable

Miguel A. Dávila, Cesar L. Trujillo y Elvis E. Gaona

Facultad de Ingeniería, Universidad Distrital Francisco José de Caldas, Bogotá D.C.-Colombia
(e-mail: miadavilar@correo.udistrital.edu.co; cltrujillo@udistrital.edu.co; egaona@udistrital.edu.co)

Recibido Oct. 16, 2018; Aceptado Dic. 26, 2018; Versión final Mar. 15, 2019, Publicado Ago. 2019

Resumen

Se propone un algoritmo simple para programar el consumo de energía residencial de un cargador de baterías de vehículos eléctricos, minimizando el costo total de la energía eléctrica demandada por ciclo de carga en un escenario de tarificación en tiempo real. La duración total del ciclo de carga se divide en intervalos de tiempo de una hora de duración. Se consideran todas las combinaciones posibles a lo largo del intervalo de tiempo disponible para llevar a cabo el ciclo de carga, y se encuentra la combinación que minimiza el costo total por ciclo de carga. Con el fin de determinar el tiempo disponible para realizar el proceso de carga, para el escenario de simulación, la conducta del conductor se modela con variables aleatorias. Mediante un análisis estadístico de las simulaciones realizadas, se evalúa el ahorro potencial obtenido al incorporar el algoritmo propuesto. A pesar de la limitada flexibilidad operacional, el algoritmo propuesto encuentra satisfactoriamente una combinación de horas en el tiempo disponible, que reduce el costo total del ciclo de carga.

Palabras clave: respuesta a la demanda; vehículo eléctrico; respuesta automática a la tarifa; tarificación en tiempo real

A Schedule Algorithm to Manage Electric Vehicle Battery Charger Demand in a Variable Pricing Scheme

Abstract

A simple schedule algorithm for programming residential energy consumption of an electric vehicle battery charger is proposed, minimizing the total cost of electric power demanded per charge cycle in a real-time-pricing scenario. The total charge cycle duration is divided into time slots of one-hour-duration. All possible combinations throughout the available time interval to carry out the charge cycle are considered, and the combination that minimizes the total cost per charge cycle is found. To determine the available time to carry out the charge cycle, for the simulation scenario, the driver's behavior is modeled with random variables. Through a statistical analysis of the simulations carried out, the potential saving obtained by incorporating the proposed algorithm is evaluated. Despite the limited operational flexibility, it is shown that the proposed algorithm satisfactorily finds a combination of hours along the available time, which reduces the total cost of the charge cycle.

Keywords: demand response; electric vehicle; automatic pricing response; real time pricing

INTRODUCCIÓN

Actualmente, las redes de distribución de energía eléctrica operan con una filosofía inflexible de operación, la capacidad de generación está dada para suplir una demanda energética máxima con un nivel mínimo de confiabilidad; sin embargo, la demanda es variable en el tiempo (Albadi y El-Saadany, 2007); esta situación compromete la eficiencia operacional de la red de distribución, que es máxima cuando la energía eléctrica generada coincide con la energía eléctrica demandada. Los aumentos de la demanda de energía eléctrica imponen grandes desafíos para igualar la demanda con el suministro de energía disponible en la red de distribución. Las técnicas que usan el concepto de respuesta a la demanda son soluciones indirectas y viables porque introducen algunas ventajas para los usuarios (U.S. Department of Energy, 2009). Además, permiten aprovechar la flexibilidad operacional de varios dispositivos eléctricos en un ambiente residencial con el fin de lograr un balance entre la energía demandada y la energía disponible a través de mecanismos de respuesta.

Las estrategias basadas en la respuesta a la demanda consisten en esquemas de tarificación variable donde se incrementa o reduce el costo de la energía eléctrica para incentivar a los usuarios a modificar sus conductas de consumo. Desde el punto de vista del proveedor de energía es deseable que la cantidad de energía disponible sea demandada sin que se llegue a exceder la totalidad de la energía generada. En Hatton et al., (2016), se sugiere usar los datos disponibles de medidores inteligentes para seleccionar un grupo de control basado en perfiles de carga individuales y con estos datos generar una tarifa como respuesta a la demanda. Una de las ventajas de este método es que este grupo de control seleccionado se puede adaptar a cualquier número de individuos que participen del programa de reducción, sin importar cuantos ingresen o salgan del programa. En McKenna et al., (2016), se presenta un modelo de perfil de carga residencial como respuesta a la demanda basada en tarificación. Se generan modelos para la demanda y modelos variantes en el tiempo de cargas eléctricas. Se modela la respuesta a la tarifa a través de algoritmos de control para cargas controladas termostáticamente, la programación óptima de electrodomésticos y matrices de elasticidad de la tarifa para representar la inherente respuesta elástica del consumidor. El modelo desarrollado se utiliza en un caso de estudio para examinar el potencial impacto en la red de distribución al introducir esquemas de tarificación dinámica.

Por otra parte, está el consumidor, para quien es deseable minimizar el costo total de la energía eléctrica. Sin embargo, en áreas con un gran número de clientes residenciales, el principal reto es gestionar efectivamente estos recursos con bajo costo computacional y con una infraestructura de comunicaciones de baja complejidad, de manera que pueda ser explotada la flexibilidad operacional que ofrecen algunos tipos de carga. Esta escena abre nuevas oportunidades para el desarrollo de dispositivos eléctricos inteligentes con el fin de implementar estrategias que mejoren el desempeño operacional de la red de distribución eléctrica. En Roh et al., (2016), se clasifican varios electrodomésticos en cinco conjuntos considerando su diferente consumo y características de operación, y se presentan modelos matemáticos para cada conjunto. Con estos modelos, se propone un algoritmo de programación de la demanda que controla el tiempo de operación y el nivel de consumo de energía de cada electrodoméstico adaptándose a la tarifa de tiempo de uso (TOU). En Safdarian et al., (2014, 2016), debido a que la respuesta no coordinada de los consumidores puede causar picos severos en periodos de tarifa baja, se propone un esquema coordinado de respuesta a la demanda. Se utilizan módulos de gestión de carga residencial embebidos en los medidores inteligentes de los consumidores como agentes autónomos asociados con el algoritmo propuesto. En el algoritmo los módulos optimizan la operación diaria de los electrodomésticos como respuesta a las tarifas anunciadas por el proveedor, y envían al proveedor los correspondientes perfiles de carga. Después el proveedor calcula el perfil total de carga y mediante la continua interacción entre el proveedor y los módulos se alcanza el punto en el cual no se puede ajustar o mejorar el perfil total de carga total. Se presenta un ejercicio similar (Konotop et al., 2015), donde se incluyen la gestión de recursos energéticos distribuidos.

En Adika y Wang (2014), se propone una estructura para la gestión inteligente de la demanda energética que se basa en la gestión de sistemas de almacenamiento de energía y la programación de la demanda energética de electrodomésticos. El sistema de almacenamiento permite a los consumidores comprar energía durante los picos de tarifa baja y usarla durante los picos de demanda alta, minimizando de esta manera el costo total de la energía consumida sin afectar los hábitos de consumo del usuario. En Fernandes et al., (2014), se propone un método de prioridad dinámica de carga para cambiar la prioridad de cada carga residencial durante un evento de respuesta a la demanda. Yoon et al., (2014) se enfocan en el desarrollo de una estrategia de control para aire acondicionado y sistemas de calefacción como respuesta a la tarificación en tiempo real. El controlador modifica el valor de la temperatura de control dependiendo de las tarifas de la energía eléctrica. La principal ventaja de este método es la incorporación de una función para comparar la tarifa actual con un valor de preferencia del usuario considerando el costo total que está dispuesto a costear. En Hu y Li, (2013), se presenta el diseño de un hardware para un sistema de gestión de energía con aplicaciones de comunicaciones, tecnología de censado y aprendizaje de máquinas; con este hardware, el consumidor es capaz de conseguir una respuesta en tiempo real a la tarifa, controlando sus cargas

residenciales. En Ozturk et al., (2013), se desarrolla un sistema de decisión para predecir la demanda eléctrica en el hogar, sistema que habilita al usuario para ahorrar energía recomendando una programación óptima del consumo energético de electrodomésticos inteligentes. En Yi et al., (2013), se propone un algoritmo no centralizado para programar el consumo de electrodomésticos inteligentes, el algoritmo determina el mejor momento de operación de los electrodomésticos con el fin de reducir el costo de la energía eléctrica.

Los vehículos alternativos como los híbridos o los eléctricos son cada vez más populares. Los ciclos de carga de las baterías de estos vehículos tienen un impacto considerable en la red de distribución de energía eléctrica debido a la enorme cantidad de energía eléctrica necesaria para cada ciclo de carga causando enormes e indeseables picos en la demanda de energía eléctrica. Por lo tanto, la gestión de la operación de los vehículos eléctricos en la red de distribución es un desafío para el lado de la demanda (Deilami et al., 2011). Es muy probable el escenario en el que la mayoría de los propietarios de vehículos eléctricos regresan a casa después del trabajo y conectan simultáneamente sus vehículos a la red eléctrica en una hora de demanda pico. Este perfil de carga descoordinado y aleatorio podría sobrecargar significativamente la red de distribución causando fluctuaciones de tensión, una oferta insuficiente de energía eléctrica y un incremento en la cantidad de cortes de la misma (Deilami et al., 2011). En este artículo se presenta una estrategia para gestionar la demanda de energía eléctrica de un cargador residencial de baterías para vehículos eléctricos con el fin de reducir el costo total de cada ciclo de carga en un escenario de tarificación variable; sin embargo, el enfoque adoptado se diferencia del encontrado en la literatura debido a que no se considerara el efecto que pueda tener la operación del dispositivo sobre el perfil de carga residencial del usuario, solamente se considera el costo de la energía eléctrica. El único objetivo es proponer un algoritmo que sea capaz de reducir el costo total de la energía demandada durante el proceso de carga bajo las condiciones de operación típicas del usuario; esto es, considerar el tiempo típico que podría destinar un usuario para realizar el proceso completo de carga sin modificar sus hábitos. En las siguientes secciones se presenta el escenario de simulación que se utiliza para probar el algoritmo propuesto. Posteriormente, se presenta el algoritmo y los resultados de simulación.

MODELOS ESTOCÁSTICOS PARA EL ESCENARIO DE SIMULACIÓN

El algoritmo de gestión de cada ciclo de carga considera tres variables: la señal de tarificación, el intervalo de tiempo disponible y el intervalo de tiempo necesario para llevar a cabo el ciclo de carga. Se utilizan datos reales de una señal de tarificación puesto que en un escenario de tarificación variable se publican las tarifas para que los usuarios puedan programar su consumo como respuesta a las tarifas. El intervalo de tiempo disponible para llevar a cabo el ciclo de carga es el intervalo de tiempo entre el momento de llegada a casa y el momento de partida del día siguiente para un usuario dado. La ventana de tiempo necesaria para llevar a cabo un ciclo de carga depende del estado de carga de la batería (SoC) en el momento de llegada a casa de un usuario dado, la potencia nominal de carga y la capacidad de la batería del vehículo eléctrico.

Distribución del modelo temporal para el intervalo de tiempo disponible

Con el fin de modelar los hábitos de uso de un usuario real, se consideran una serie de intervalos de tiempo de uso. Estos intervalos de tiempo se construyen a partir de un modelo estocástico propuesto para las distribuciones temporales de los instantes de tiempo de llegada y partida cotidianos del usuario (Lee et al., 2012). La distribución temporal de los tiempos de llegada depende de la distribución de los tiempos de partida. Por lo tanto, la distribución de los tiempos de llegada en un determinado tiempo de partida se expresa como una probabilidad condicional, ecuación (1).

$$P_{ARR}(t_{arr}) = \sum_{i=1}^N P_{ARR,DEP}(t_{arr}|t_{dep,i})f_{DEP}(t_{dep,i}) \quad (1)$$

Donde, $P_{ARR}(t_{arr})$ es la función de densidad de probabilidad (PDF) de los tiempos de llegada t_{arr} , $f_{DEP}(t_{dep,i})$ es la función de masa de probabilidad (pmf) de la i -ésima ventana de tiempo de partida $t_{dep,i}$, N es el número discreto de la ventana de tiempo de partida, $P_{ARR,DEP}(t_{arr}|t_{dep,i})$ es la PDF condicional del tiempo de llegada t_{arr} en $t_{dep,i}$. De la ecuación (1), la distribución del tiempo de llegada se obtiene sumando las distribuciones del tiempo de llegada para cada ventana de tiempo de partida. La Figura 1 muestra las funciones conjuntas de densidad de probabilidad (PDF) y distribución acumulativa (CDF) del modelo de distribución temporal reproducido para los tiempos de llegada y partida.

Fig. 1: PDF y CDF conjuntas del modelo de distribución temporal reproducido para los tiempos de llegada y partida.

En Lee et al., (2012), la distribución de los tiempos de partida es modelada como una distribución chi cuadrado (χ^2) como se muestra en la ecuación (2). Donde $\Gamma(\cdot)$ es la función Gamma definida como en la ecuación (2), $t_{dep,i}$ es el tiempo de partida normalizado en la i -ésima ventana de tiempo de partida y definido como $t_{dep,i}/\Delta t$, y Δt es el tamaño discreto de la ventana. Aquí como en Lee et al., (2012), se escoge $u=8$ para ajustar la distribución a los datos reales.

$$\Gamma(z) = \int_0^x \frac{t^{z-1}}{e} dt \quad (2)$$

$$f_{DEP}(t_{dep,i}) = \frac{t_{dep,i}^{(u-2)/2} e^{-t_{dep,i}/2}}{2^{u/2} \Gamma(u/2)} \quad (3)$$

La PDF de los tiempos de llegada se determina en forma de distribución Gaussiana para cada ventana de tiempo de partida. En este artículo, la distribución del tiempo de llegada para la i -ésima ventana de tiempo de partida se asume como una distribución Gaussiana como se muestra en la ecuación (4).

$$P_{ARR,DEP}(t_{arr}|t_{dep,i}) = \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(t_{arr}-\mu_i)^2}{2\sigma_i^2}} \quad (4)$$

Fig. 2: Ochocientas muestras (t_{dep}, t_{arr}) reproducidas con el modelo de distribución temporal de tiempos de llegada y partida.

Fig. 3: Distribuciones y CDFs de las duraciones T_{out} y T_{in} .

Donde μ_i es la media de los tiempos de llegada en la i -ésima ventana de tiempo de partida, σ_i es la desviación estándar de los tiempos de llegada en la i -ésima ventana de tiempo de partida. Entonces la media y la desviación estándar de los tiempos de llegada son usadas para modelar la distribución de los tiempos de llegada en cada ventana de tiempo de partida. En este artículo, la media y la desviación estándar de los tiempos de llegada son ajustadas como funciones lineales de la i -ésima ventana de tiempo de partida, como $\mu_i = i/2 + 14.5$ y $\sigma_i = -0.215i + 5.5$ con $N=24$, $i=0, 1, 2, \dots, N$.

El modelo de distribución temporal presentado arriba es útil para generar muestras aleatorias (t_{dep}, t_{arr}) de viajes diarios de duración $T_{out} = t_{arr} - t_{dep}$ horas; en la Figura 2 se muestra la distribución de 800 viajes (t_{dep}, t_{arr}) reproducidos a partir del modelo de distribución de tiempos de llegada y partida, en la Figura 3 se muestra la CDF de la duración de esos viajes. Sin embargo, para simular un escenario de carga de un vehículo eléctrico, se debe considerar la ventana de tiempo disponible para realizar el ciclo de carga, como el tiempo entre el instante de llegada a casa y el instante de partida del viaje siguiente. Aquí como en Verzijlbergh et al., (2011), se asume que los instantes de partida y llegada a casa reflejan los instantes de partida y llegada del día siguiente para un usuario dado. Entonces, las muestras en la Figura 2 son manipuladas de tal manera que no son consideradas las muestras en las cuales $t_{dep} \geq t_{arr}$, y la ventana de tiempo disponible para realizar un ciclo de carga T_{in} en horas es calculada para cada muestra en la Figura 2 como $T_{in} = t_{dep} + 24 - t_{arr}$. La Figura 3 también muestra la distribución y la CDF de las ventanas de tiempo disponibles para realizar ciclos de carga, datos que serán utilizados posteriormente en el escenario de simulación.

Modelo de distribución del estado de carga de la batería

La ventana de tiempo necesaria para realizar el ciclo de carga depende del estado de carga (SoC) de la batería en el instante en el que el usuario llega a casa, la potencia de carga y la capacidad de la batería del vehículo eléctrico. Para los vehículos eléctricos y los cargadores disponibles comercialmente, la capacidad de la batería y la potencia de carga respectivamente, son valores nominales. Por el contrario, el SoC depende de los hábitos o conducta de conducción de cada usuario. EL SoC en el instante de partida, las distancias conducidas y las características de conducción de cada usuario determinan el SoC de la batería del vehículo eléctrico en el instante de iniciar el ciclo de carga. Con el fin de modelar la conducta del usuario, se adoptan diferentes distribuciones para el SoC, escogidas según los datos de algunas investigaciones empíricas disponibles en la literatura (Rassaei et al., 2014); como se muestra en la Figura 4, se adoptan cuatro posibles casos para la distribución del SoC en el instante de llegada a casa: Uniforme, exponencial, Gaussiana y distribución de Rician, todas ellas soportadas para valores de SoC en el intervalo $[0, 1]$. A partir de estas distribuciones se reproducen cerca de 800 muestras del SoC para realizar el mismo número de escenarios de simulación para cada conducta de los usuarios.

Estado de carga con distribución uniforme

Asumiendo que el SoC tiene una distribución uniforme sobre el intervalo $[a, b]$, con $0 \leq a < b$ y $b < 1$. Con $a=0.2$ y $b=0.8$, como se muestra en la Figura 4, la PDF del SoC es $P(\text{SoC}) = 1/(b-a)$ para $a < \text{SoC} < b$, de lo contrario $P(\text{SoC}) = 0$. La CDF del SoC es $f(\text{SoC}) = 0$ si $\text{SoC} < a$, $f(\text{SoC}) = (T-a)/(b-a)$ para $a < \text{SoC} < b$ y $f(\text{SoC}) = 1$ si $b \leq \text{SoC} \leq 1$.

Fig. 4: PDFs y CDFs consideradas para el SoC en el instante de llegada a casa.

Estado de carga con distribución exponencial

Asumiendo que el SoC tiene una distribución exponencial con media μ y parámetro $\lambda = \mu^{-1}$, como se muestra en la Figura 4, la PDF del SoC es $P(\text{SoC}) = \lambda e^{-\lambda \text{SoC}}$. La CDF del SoC es $f(\text{SoC}) = 1 - e^{-\lambda \text{SoC}}$. Se asume una media $\mu = 0.5$ entonces $\lambda = 2$.

Estado de carga con distribución Gaussiana

Asumiendo que el SoC tiene una distribución Gaussiana con media μ y desviación estándar σ , la PDF del SoC está dada la forma presentada en la ecuación (4). Como se muestra en la Figura 4, se asume $\mu = 0.5$ y $\sigma = 0.1$.

Estado de carga con distribución de Rician

Asumiendo que el SoC tiene una distribución de Rician, su PDF está dada por la ecuación (5). Con parámetro de no centralidad $v \geq 0$ y parámetro de escala $\sigma > 0$, para $\text{SoC} > 0$. $I_0(\cdot)$ es la función de Bessel modificada de primera especie y orden cero. Como se muestra en la Figura 4, se asume un parámetro de no centralidad $v = 0$ y un parámetro de escala $\sigma = 0.3$.

$$P(\text{SoC}) = \frac{\text{SoC}}{\sigma^2} \left(e^{-\frac{\text{SoC}^2 + \sigma^2}{2\sigma^2}} \right) I_0 \left(\frac{v \text{SoC}}{\sigma^2} \right) \quad (5)$$

Señal de tarificación

En un esquema de tarificación variable, las tarifas son generadas como respuesta a la demanda de energía eléctrica con el propósito de modificar los hábitos de consumo de los usuarios regulando la demanda de energía eléctrica, que idealmente debería ser menor o igual a la oferta disponible. Usualmente, las tarifas son publicadas diariamente en los sitios web de los distribuidores para que los usuarios puedan programar su consumo de energía eléctrica. Se publica la tarifa de la energía eléctrica de cada hora para el día actual o el día siguiente, dependiendo del esquema de tarificación que puede ser intraday (tarificación en tiempo real) o del día siguiente.

En los sitios web de algunos distribuidores se encuentran disponibles datos históricos para ambos esquemas de tarificación (Nord Pool, 2018), por lo tanto, no es necesario construir un modelo estocástico para la señal de tarificación. El histórico de datos reales disponible en Nord Pool (2018) es utilizado como señal de tarificación en el escenario de simulación. Como se muestra en la Figura 5, cerca de veinte mil muestras de tarifas por hora en euros por kWh, correspondientes a cerca de ochocientos días, son utilizadas como señal de tarificación en el escenario de simulación.

Fig. 5: Señal de tarificación, datos históricos desde 01/01/2016 hasta 15/04/2018. (Datos tomados de Nord Pool, 2018).

ALGORITMO DE PROGRAMACIÓN DEL CONSUMO

Aquí se presenta el algoritmo propuesto para programar el consumo de energía eléctrica durante el ciclo de carga, cuya función principal es encontrar la manera más económica de realizar un ciclo de carga de un vehículo eléctrico en un escenario de tarificación variable. Primero, se debe determinar el tiempo en horas necesario para realizar el proceso de carga. Después, dado el número de horas necesario, se hallan todas las combinaciones posibles para realizar el ciclo de carga en la ventana de tiempo disponible. El costo total del ciclo de carga para cada combinación se calcula como la suma de todos los productos entre la energía demandada por hora y la tarifa de las horas respectivas. Finalmente, se determina la combinación de horas que minimiza el costo total del ciclo de carga.

Ventana de tiempo necesaria

La ventana de tiempo necesaria T depende del SoC del vehículo en el instante que el usuario llega a casa t_{arr} e inicia la ventana de tiempo disponible para realizar el ciclo de carga T_{in} , y la capacidad de la batería C (en Ah). También depende de las características del cargador de baterías, tales como: potencia nominal P_N en kW, máxima corriente de carga permitida I_{max} en amperios, máxima tensión de carga $V_{max} = 1000 P_N / I_{max}$ en voltios, así como el método de carga. Existen diferentes métodos de carga de baterías, los más populares de ellos son: corriente constante, tensión constante, una combinación de los anteriores y potencia constante. Con el fin de modelar la demanda de energía durante el proceso de carga, se asume únicamente el modo de carga de potencia constante para baterías de ácido-plomo con capacidad nominal C y tensión nominal V_N , la cual será cargada con carga lenta ($0.3C < I < 3C$) o carga rápida ($I = 3C$ en amperios) siempre que la potencia instantánea demandada $P = IV_N$ (en vatios) no exceda la potencia nominal P_N del cargador de baterías. La ventana de tiempo necesaria T es encontrada como se muestra en la ecuación (6).

$$T = \frac{C(1-SoC)}{I} = \frac{C(1-SoC)V_N}{P} \quad (6)$$

Donde el SoC del vehículo eléctrico es modelado como se muestra en la subsección: modelo de distribución del estado de carga de la batería, considerando cuatro diferentes distribuciones. DoD=1-SoC es la profundidad de descarga de la batería, $I=3C$ si $I_{max} \leq 3C$ o $I=1000P_N/V_N$ si $I_{max} > 3C$.

Posibles combinaciones y costo total de las combinaciones

Para encontrar la combinación adecuada de horas para realizar el ciclo de carga, se tiene un número T_{in} de horas disponibles y se tiene que encontrar las $S_{m,n}$ posibles combinaciones de horas necesarias T en el número de horas disponibles T_{in} ; la cantidad de combinaciones k dados T_{in} y T se presentan en la ec. (7).

$$k(T_{in}, T) = \frac{T_{in}!}{T!(T_{in}-T)!} \quad (7)$$

Una vez se han encontrado las k posibles combinaciones, el costo por hora de las T_{in} horas de cada combinación se encuentra calculando el producto entre la potencia instantánea demandada y la tarifa de las T hora consideradas en dicha combinación. Entonces, en cada combinación los costos por hora se suman para obtener el costo total por combinación. Este procedimiento se realiza para todas las combinaciones de

tal manera que se tiene k posibles costos totales correspondientes a cada combinación posible como se representa en la ecuación (8). Donde el índice $n=1, 2, \dots, k$ representa el número de combinación en las k posibles combinaciones, P_m es la tarifa de la energía eléctrica (en euros por kWh) en las T_{in} horas de cada combinación n , el índice $m=t_{arr}, \dots, t_{dep}$ es la hora considerada en las T_{in} horas disponibles; $S_{m,n}$ son las posibles combinaciones y puede verse como una matriz de k filas y T_{in} columnas cuyos valores son iguales a uno si la m -ésima hora de la n -ésima combinación es una de las T horas que se consideran en dicha combinación para realizar el ciclo de carga, de lo contrario es igual a cero. Y_n son los k posibles costos totales. P es la potencia instantánea demandada en el proceso de carga y está dada en kW. En la Figura 6 se muestra el diagrama de flujo del algoritmo descrito anteriormente para programar el consumo energético del cargador de baterías durante el tiempo disponible para realizar el ciclo de carga.

$$Y_n = \sum_{m=t_{arr}}^{t_{dep}} S_{m,n} P_m P \quad (8)$$

En la Figura 7 se muestra dos experimentos en los cuales $P_n = 5$ kW, $V_{max}=500$ V, $C = 100$ Ah, $V_n = 240$ V, SoC modelado con distribución Gaussiana y $t_{arr} < P_m < t_{dep}$ tomado del histórico de tarifas mostrado en la Figura 5. Para el experimento 1, la muestra obtenida del modelo del tiempo disponible es $(t_{dep}, t_{arr}) = (11/04/2016 \ 14:00, 12/04/2016 \ 06:00)$ entonces $T_{in} = 16$ Horas; el valor modelado del SoC es 48.55% lo que se ve reflejado en un tiempo necesario para el ciclo de carga $T = 6$ Horas. Para el experimento 2, $(t_{dep}, t_{arr}) = (09/02/2017 \ 15:00, 10/02/2017 \ 09:00)$ entonces $T_{in} = 18$ Horas; el valor modelado del SoC es 69.20% lo que se ve reflejado en un tiempo necesario para el ciclo de carga $T = 4$ Horas. En la Figura 7 se muestra para ambos experimentos la tarifa P_m , la combinación $S_{m,max} P_m P$ que resulta en el costo total máximo Y_{max} y la combinación $S_{m,min} P_m P$ que resulta en el costo total mínimo Y_{min} . También se muestran algunos valores correspondientes a cada experimento, entre ellos el ahorro porcentual definido como $A_p = 100\%(Y_{max} - Y_{min})/Y_{max}$.

RESULTADOS Y DISCUSIÓN

Para el experimento 1, mostrado en la Figura 7, $A_p=8.88\%$, $Y_{max}=0.324$ euros y $Y_{min}=0.295$ euros, mientras que para el experimento 2, $A_p=39.85\%$, $Y_{max}=0.519$ euros y $Y_{min}=0.312$ euros. Con el fin de describir el comportamiento de los costos totales máximo y mínimo, así como evaluar el algoritmo de gestión a través del ahorro porcentual, se realiza una serie de experimentos de simulación y se ajustan los datos obtenidos a algunas distribuciones conocidas.

Fig. 6: Diagrama de flujo del algoritmo propuesto.

Fig. 7: Dos experimentos para SoC con distribución Gaussiana.

Escenario de simulación

El escenario de simulación es el mostrado en la Figura 8, se utilizan las variables de entrada descritas en la sección: modelos estocásticos para el escenario de simulación. Los parámetros del cargador y batería son los mismo utilizados en los experimentos de la Figura 7 ($P_n = 5$ kW, $V_{max}=500$ V, $C = 100$ Ah, $V_n = 240$ V). Se generan 666 muestras (t_{dep}, t_{arr}) para realizar igual numero de experimentos. La señal de tarificación P_m para cada experimento se genera a partir del histórico de tarifas mostrado en la Figura 5. Teniendo en cuenta la conducta del usuario, se consideran cuatro casos: SoC con distribución uniforme, SoC con distribución Gaussiana, SoC con distribución exponencial y SoC con distribución Rician. Para cada uno de los cuatro casos de simulación se realizan 666 experimentos con los mismos valores para las variables P_n , V_{max} , C , V_n , (t_{dep}, t_{arr}) y P_m . Las variables de salida del algoritmo Y_{max} , Y_{min} y A_p son analizadas para evaluar los beneficios que ofrece el algoritmo propuesto.

Distribuciones de las medias de Y_{max} , Y_{min} y para A_p

Se ajusta una distribución Gaussiana para la media de las variables Y_{max} y Y_{min} en cada uno de los casos considerados; se escogieron las medias como variables aleatorias de interés porque según el teorema del límite central son variables aleatorias con distribución aproximadamente gaussiana como se muestra en la Figura 9. El ahorro porcentual A_p es de especial interés para mostrar las bondades del algoritmo propuesto; por lo tanto, para cada uno de los casos considerados se ajusta A_p a la distribución Burr tipo XII cuya PDF esta dada por la ecuación (9) con parámetro de escala $\alpha > 0$ y parámetros de forma $c > 0$ y $\kappa > 0$ como se muestra en la Figura 10. Los parámetros de todas las distribuciones se ajustan par aun intervalo de confianza de 95% y los rangos para cada parámetro se muestran en la Tablas 1 y 2.

$$P(A_p) = \frac{\frac{\kappa c}{\alpha} \left(\frac{A_p}{\alpha} \right)^{c-1}}{\left(1 + \left(\frac{A_p}{\alpha} \right)^c \right)^{\kappa+1}}, A_p > 0 \quad (9)$$

 Tabla 1: Rangos para los parámetros de las distribuciones de las medias de Y_{max} y Y_{min} . En euros, ajustados para un intervalo de confianza de 95% y redondeados a dos cifras decimales.

Caso SoC	μ de Y_{min}	σ de Y_{min}	μ de Y_{max}	σ de Y_{max}
Uniforme	0.31 < 0.33 < 0.34	0.07 < 0.08 < 0.09	0.39 < 0.41 < 0.44	0.12 < 0.14 < 0.16
Gaussiana	0.31 < 0.32 < 0.34	0.056 < 0.063 < 0.73	0.39 < 0.42 < 0.45	0.15 < 0.17 < 0.19
Exponencial	0.53 < 0.55 < 0.57	0.09 < 0.10 < 0.12	0.62 < 0.65 < 0.69	0.16 < 0.18 < 0.21
Rician	0.42 < 0.43 < 0.45	0.08 < 0.09 < 0.10	0.50 < 0.54 < 0.57	0.16 < 0.18 < 0.21

Tabla 2: Rangos para los parámetros de las distribuciones del ahorro porcentual A_p [%]. Ajustados para un intervalo de confianza de 95% y redondeados a dos cifras decimales.

Caso SoC	α	c	κ	μ
Uniforme	13.35 < 15.50 < 17.99	2.66 < 2.97 < 3.32	0.86 < 1.15 < 1.52	17.04
Gaussiana	14.48 < 16.91 < 19.74	2.55 < 2.84 < 3.15	1.00 < 1.33 < 1.77	17.09
Exponencial	10.04 < 12.18 < 14.78	2.20 < 2.44 < 2.72	1.04 < 1.41 < 1.93	12.14
Rician	11.87 < 13.86 < 16.18	2.50 < 2.77 < 3.09	0.93 < 1.23 < 1.63	14.79

Discusión de los resultados de simulación

Como se muestra en la Figura 9 y en la Tabla 1, el costo mínimo por ciclo de carga $Y_{\min}$ depende de los hábitos de conducción del usuario, cuando la conducta de conducción del usuario se modela como un SoC con una distribución uniforme o una Gaussiana, la media de la distribución de la media de $Y_{\min}$, es $\mu \approx 0.32$ euros mientras que para un SoC con distribución exponencial la media de la distribución de la media de $Y_{\min}$ es $\mu \approx 0.55$ euros; para un SoC con una distribución de Rician, la media de la distribución de la media de $Y_{\min}$ es $\mu \approx 0.43$ euros.

Adicionalmente, en la Figura 9 y en la Tabla 1, el costo máximo también depende de la conducta del usuario, para SoC modelado con distribuciones Uniformes o Gaussianas la media de la distribución de la media de $Y_{\max}$ es $\mu \approx 0.42$ euros; para SoC distribuidos exponencialmente, la media de la distribución de la media $Y_{\max}$ es $\mu \approx 0.65$ euros y para SoC con distribución de Rician es $\mu \approx 0.54$.

Para los cuatro casos, las desviaciones estándar σ de las distribuciones de la media de $Y_{\max}$ son mayores que las desviaciones estándar de las distribuciones de σ de las distribuciones de la media de $Y_{\min}$, esto implica que los valores de $Y_{\max}$ están más dispersos que los valores obtenidos de $Y_{\min}$. Por otro lado, se observa que en todos los casos las medias de las distribuciones de las medias de $Y_{\max}$ son mayores que las medias de las distribuciones de las medias de $Y_{\min}$, esto implica que los valores de $Y_{\max}$ son mayores que los valores obtenidos de $Y_{\min}$, y esto se debe a que en todos los experimentos se obtiene un ahorro al implementar el algoritmo para gestionar la demanda de energía eléctrica. Sin embargo, el ahorro porcentual $A_p = 100\%(Y_{\max} - Y_{\min})/Y_{\max}$, da una mejor valoración del ahorro derivado de la implementación del algoritmo propuesto. El ahorro porcentual es calculado para cada experimento en cada caso considerado y la distribución de los datos obtenidos se ajusta con una distribución Burr tipo XII en cada caso como se muestra en la Figura 10.

Fig. 8: Escenario de simulación.

En la Figura 10 y en la Tabla 2, el ahorro porcentual A_p , también depende de la conducta de manejo del usuario modelada a través de SoC en el instante de llegada a casa t_{arr} . Para usuarios cuya conducta se modela con un SoC distribuido uniformemente o Normalmente (Gaussiana) el promedio del ahorro porcentual es $\mu \approx 17\%$, con mayor probabilidad de que ocurran ahorros porcentuales de $A_p \approx 12\%$. Para los usuarios cuya conducta de manejo fue modelada con un SoC distribuido exponencialmente el promedio del ahorro porcentual es $\mu \approx 12.14\%$, con mayor probabilidad de que ocurra un ahorro porcentual $A_p \approx 7.29\%$. Para usuarios con conducta modelada con SoC con distribución Rician el promedio del ahorro porcentual es $\mu \approx 14.79\%$, con mayor probabilidad de que ocurra un ahorro porcentual $A_p \approx 9.72\%$.

Fig. 9: Distribución de las medias de $Y_{\max}$ y $Y_{\min}$

Fig. 10: Distribución del ahorro porcentual.

ANÁLISIS Y DISCUSIÓN FINAL

Para minimizar el costo total de la energía demandada durante el proceso de carga de un vehículo eléctrico en un esquema de tarificación variable, se puede gestionar la demanda de energía eléctrica programando las horas en las que se realiza cada ciclo de carga. Sin embargo, los procesos de carga de los vehículos eléctricos ofrecen una flexibilidad operacional limitada debido a que el costo mínimo posible por ciclo de carga depende fuertemente de los hábitos de manejo del usuario como se muestra en la sección de discusión de los resultados de simulación. La flexibilidad operacional se ve afectada por la conducta del usuario porque el número de horas necesarias para realizar el ciclo de carga depende del SoC en el instante de llegada a casa. En los casos cuando el SoC es muy bajo, el número de horas necesarias para realizar el proceso de carga es mucho mayor que en los casos cuando el SoC es mayor.

CONCLUSIONES

A pesar de la flexibilidad operacional limitada para gestionar la demanda de energética de un cargador de baterías durante el ciclo de carga, el algoritmo propuesto encuentra satisfactoriamente una combinación de horas durante el tiempo disponible para realizar el proceso de carga, que reduce el costo total del ciclo de carga. Aunque el ahorro porcentual se calcula respecto a la combinación de horas que causa el mayor costo total del proceso de carga, refleja un valor de ahorro que se podría presentar al adoptar el tipo de estrategias propuestas.

AGRADECIMIENTOS

Esta investigación es financiada por el Fondo Nacional para la financiación de la ciencia, la tecnología y la innovación "Fondo Francisco José de Caldas" del Departamento Administrativo de Ciencia, Tecnología e innovación - COLCIENCIAS (Contrato: FP44842 - 031 2016)."

REFERENCIAS

- Adika, C.O. y L. Wang, Smart Charging and Appliance Scheduling Approaches to Demand Side Management, doi: 10.1016/j.ijepes.2013.12.004, 57, International Journal of Electrical Power and Energy Systems, 232–240 (2014)
- Albadi, M.H. y E. F. El-Saadon, Demand Response in Electricity Markets: an Overview, doi: 10.1109/PES.2007.385728, IEEE Power Engineering Society General Meeting, 1–5 (2007)

- Deilami, S., A. S. Masoum, P. S. Moses y M. A. S. Masoum, Real-Time Coordination of Plug-in Electric Vehicle Charging in Smart Grids to Minimize Power Losses and Improve Voltage Profile, doi: 10.1109/TSG.2011.2159816, IEEE Transactions on Smart Grid, 2(3), 456–467 (2011)
- Deilami, S., A. S. Masoum, P. S. Moses y M. A. S. Masoum, Smart Load Management of Plug-in Electric Vehicles in Distribution and Residential Networks with Charging Stations for Peak Shaving and Loss Minimization Considering Voltage Regulation, doi: 10.1049/iet-gtd.2010.0574, IET Generation, Transmission & Distribution, 877–888 (2011)
- Fernandes, F., H. Morais, Z. Vale y C. Ramos, Dynamic Load Management in a Smart Home to Participate in Demand Response Events, doi: 10.1016/j.enbuild.2014.07.067, Energy and Buildings, 82, 592–906 (2014)
- Hatton, L., P. Charpentier y E. Matzner-løber, Statistical Estimation of the Residential Baseline, IEEE Transactions on Power Systems, 31(3), 1752–1759 (2016)
- Hu, Q., y F. Li, Hardware Design of Smart Home Energy Management System with Dynamic Price Response, doi: 10.1109/TSG.2013.2258181, IEEE Transactions on Smart Grid, 4(4), 1878–1887 (2013)
- Konotop, I., S. Waczowicz y otros cuatro autores, Investigation and Mathematical Modelling of the Impact of Incentive Signals to Consumers on their Consumption, Load Forecast and Network Operation, doi: 10.1049/iet-gtd.2015.1175, IET Generation, Transmission & Distribution, 10, 1–9 (2015)
- Lee, T. K., Z. Bareket, T. Gordon y Z. S. Filipi, Stochastic Modeling for Studies of Real-World PHEV Usage: Driving Schedule and Daily Temporal Distributions, doi: 10.1109/TVT.2011.2181191, IEEE Transactions on Vehicular Technology, 61(4), 1493–1502 (2012)
- Mckenna, K., S. Member, A. Keane y S. Member, Residential Load Modeling of Price-Based Demand Response for Network Impact Studies, IEEE Transactions on Smart Grid, 7(5), 2285–2294 (2016)
- Monteiro, V., H. Gonçalves y J. L. Afonso, Impact of Electric Vehicles on Power Quality in a Smart Grid Context, doi: 10.1109/EPQU.2011.6128861, Proceeding of the International Conference on Electrical Power Quality and Utilisation, 660–665 (2011)
- Nord Pool, See Hourly Day-Ahead Prices (2018)
- Ozturk, Y., D. Senthilkumar, S. Kumar y G. Lee, An Intelligent Home Energy Management System to Improve Demand Response, doi: 10.1109/TSG.2012.2235088, IEEE Transactions on Smart Grid, 4(2), 694–701 (2013)
- Rassaei, F., W.S. Soh y K. C. Chua, A Statistical Modelling and Analysis of Residential Electric Vehicles' Charging Demand in Smart Grids, 0–4 (2014)
- Roh, H., J. Lee y S. Member, Residential Demand Response Scheduling with Multiclass Appliances in the Smart Grid, IEEE Transactions on Smart Grid, 7(1), 94–104 (2016)
- Safdarian, A., M. Fotuhi-Firuzabad y M. Lehtonen, A Distributed Algorithm for Managing Residential Demand Response in Smart Grids, doi: 10.1109/TII.2014.2316639, IEEE Transactions on Industrial Informatics, 10(4), 2385–2393 (2014)
- Safdarian, A., M. Fotuhi-Firuzabad y M. Lehtonen, Optimal Residential Load Management in Smart Grids: a Decentralized Framework, doi: 10.1109/TSG.2015.2459753, IEEE Transactions on Smart Grid, 7(4), 1836–1845 (2016)
- U.S. Department of Energy, The Smart Grid: An Introduction (2009)
- Verzijlbergh, R. A., Z. Lukszo, E. Veldman, J. G. Slootweg y M. Ilic, Deriving Electric Vehicle Charge Profiles from Driving Statistics, doi: 10.1109/PES.2011.6039609, IEEE Power and Energy Society General Meeting, 1–6 (2011)
- Yi, P., X. Dong, A. Iwayemi, C. Zhou y S. Li, Real-Time Opportunistic Scheduling for Residential Demand Response, doi: 10.1109/TSG.2012.2225155, IEEE Transactions on Smart Grid, 4(1), 227–234 (2013)
- Yoon, J.H., R. Baldick y A. Novoselac, Dynamic Demand Response Controller Based on Real-Time Retail Price for Residential Buildings, doi: 10.1109/TSG.2013.2264970, IEEE Transactions on Smart Grid, 5(1), 121–129 (2014)