



IMPACTO DE LA SIMULACIÓN MONTECARLO DE CARGA NO CONTROLADA DE VEHÍCULOS ELÉCTRICOS EN LA GENERACIÓN DISTRIBUIDA

MONTE CARLO SIMULATION OF UNCONTROLLED ELECTRIC VEHICLE CHARGING IMPACT ON DISTRIBUTED GENERATION

Carlos W. Villanueva-Machado^{1,*} , Jaime E. Luyo¹ , Alberto Ríos-Villacorta² ,

Recibido: 08-05-2023, Recibido tras revisión: 31-05-2023, Aceptado: 12-06-2023, Publicado: 01-07-2023

Resumen

La carga no controlada de vehículos eléctricos plantea un gran desafío para los operadores de redes de distribución y los planificadores de sistemas de potencia. En lugar de focalizarse en el control de esta carga no controlada, se propone un modelo que utiliza variables de análisis de contingencias para calcular la capacidad de potencia necesaria en el sistema de potencia. Se emplea la variable de potencia no servida para evaluar la cantidad de potencia de carga no cubierta en cada barra del sistema, seguido del cálculo de la capacidad de potencia adicional requerida, utilizando un sistema fotovoltaico y de almacenamiento y otra alternativa de generación constante en el sistema de potencia IEEE de 14 barras con información sobre algunos vehículos eléctricos y la carga diaria en el sistema de potencia de Perú. Los resultados obtenidos en el sistema de potencia con generación distribuida muestran que no hay presencia de potencia no servida, corroborando el éxito de la metodología utilizada. Este modelo brinda herramientas tanto a los operadores de redes de distribución como a los planificadores de sistemas de potencia, reduciendo el impacto en el sistema de potencia de los vehículos eléctricos y aportando una metodología aplicable a otros sistemas de distribución eléctrica con cargas no controladas.

Palabras clave: fuentes de energía renovable, potencia no servida, sistema de potencia, sistemas de almacenamiento de energía, simulación de Montecarlo, vehículos eléctricos

Abstract

The uncontrolled charging of electric vehicles poses a great challenge for distribution network operators and power system planners. Instead of focusing on controlling this uncontrolled load, a model that uses contingency analysis variables to calculate the power capacity needed in the power system is proposed. The unserved power variable is used to evaluate the amount of uncovered load power at each bus of the system, followed by the calculation of the additional power capacity required using a photovoltaic and storage system and another constant generation alternative in the 14-bus IEEE power system with information on some electric vehicles and daily load in the power system of Peru. The results obtained in the power system with distributed generation, the absence of unserved power, corroborate the success of the methodology used. This model provides tools to both distribution network operators and power system planners, reducing the impact on the power system of electric vehicles and providing a methodology applicable to other electric distribution systems with uncontrolled loads.

Keywords: Electric Vehicles, Energy Storage Systems, Monte Carlo Simulation, Not Served Power, Optimal Power Flow, Renewable Energy Sources, Power System

^{1,*}Facultad de Ingeniería Mecánica, Universidad Nacional de Ingeniería, Perú.

Autor para correspondencia ✉: cwvillanuevam@uni.pe.

²Facultad de Sistemas Electrónicos e Ingeniería Industrial, Universidad Técnica de Ambato, Ecuador.

Forma sugerida de citación: Villanueva-Machado, C. W.; Luyo, J. E. y Ríos-Villacorta, A. "Impacto de la simulación Montecarlo de carga no controlada de vehículos eléctricos en la generación distribuida," *Ingenius, Revista de Ciencia y Tecnología*, N.º 30, pp. 120-134, 2023. DOI: <https://doi.org/10.17163/ings.n30.2023.10>.

1. Introducción

Los vehículos eléctricos (EV, electric vehicles en inglés) han ganado popularidad debido a sus bajas emisiones, alta eficiencia y costos operativos más bajos [1]. Sin embargo, el aumento en el número de EV ha significado un reto para las redes eléctricas, principalmente debido a la carga no controlada que estresa las redes de distribución (RD). Este artículo propone un sistema constituido por generación fotovoltaica (PV, photovoltaic en inglés) y almacenamiento de energía en baterías (AE) que puede ser implementado para optimizar el uso de los sistemas PV y de baterías, minimizar el costo de carga de los EV, y reducir la carga sobre la red [1, 2].

Los vehículos eléctricos representan un reto para la capacidad de la red eléctrica, la infraestructura de carga y la tecnología de almacenamiento de energía [3, 4]. El *Vehicle-to-Grid* (V2G) y la generación distribuida (GD) se han propuesto como tecnologías de respaldo para abordar estos aspectos [1]. Desai, *et al.* [5] presenta, un modelo del impacto de la adopción local de EV sobre las redes de distribución, lo cual representa un reto para los operadores de estas redes. La simulación Montecarlo (MCS, Monte Carlo simulation en inglés) puede ayudar a los operadores a entender el impacto de sus políticas sobre el desempeño del sistema e identificar los riesgos potenciales de ciertas decisiones [6] como una manera de abordar estos aspectos.

De acuerdo con el estudio de Kumar, *et al.* [7], la MCS es una herramienta valiosa para evaluar el impacto de factores de incertidumbre sobre el desempeño de los sistemas de potencia (SP). La condición de operación de la red de distribución de electricidad puede mejorarse usando MCS. La presencia de la variable potencia no servida (PNS) muestra condiciones de operación de déficit de potencia o sobrecarga para el SP.

Se han propuesto las tecnologías de generación fotovoltaica y de almacenamiento de energía como soluciones potenciales para integrar los EV a la red eléctrica, como se sugiere en [1], [6], al igual que la optimización de la PNS como un método para monitorear el desempeño del SP. Este método cubre los costos operacionales durante contingencias, ya que la PNS se expulsará de la carga [8]. La tecnología V2G también es una solución para los retos de la carga no controlada de EV, porque puede ayudar a mitigar los aspectos negativos y a mejorar la sostenibilidad [9]. Se ha sugerido la MCS como una potente herramienta para analizar el impacto del suministro del excedente de carga requerido por los EV utilizando GD.

De igual forma, la descripción de análisis complementario examina la interacción con el uso de EV. Wang, *et al.* [2] describe, la interacción entre la intermitencia producida por los generadores renovables y

la capacidad de almacenamiento que se obtiene utilizando el proceso de carga V2G. Ahmadian, *et al.* [4] considera, una metodología estocástica asociada con el proceso de carga inteligente de EV, centrada en un análisis de la degradación de la batería. Por otra parte, Mahmud, *et al.* [3] se enfocan en la interacción entre las diferentes variables que se requieren para un proceso de carga inteligente. El entorno del Internet de la energía se ha adaptado de acuerdo con los futuros requerimientos de operación de una red inteligente.

Como proponen Lazarou, *et al.* [10], la GD puede ayudar a mitigar los impactos negativos de la carga no controlada de EV y mejorar la sostenibilidad. La GD puede suministrar energía a la red durante las horas pico para balancear la carga, reduciendo el impacto de la carga no controlada de EV sobre la red eléctrica. Es importante anticipar las deficiencias de energía para determinar las políticas energéticas apropiadas, [5] propone un modelo para caracterizar los patrones geográficos y de recorrido de los propietarios de EV para proporcionar información acerca de la conducta de viaje y demanda de energía.

El estudio propuso el uso de MCS para analizar los efectos de la carga no controlada de EV a mediano plazo. Esto contribuye a establecer políticas energéticas para satisfacer la demanda de energía de los propietarios de EV. La implementación de estas medidas mejoró la estabilidad y confiabilidad de las redes eléctricas distribuidas.

Este método proporciona un panorama de los escenarios potenciales con base en las tendencias globales y el mercado de transporte con EV en Perú, lo que resulta importante para optimizar las redes eléctricas distribuidas, utilizando modelado algebraico. El estudio apunta a asistir en el desarrollo de políticas para satisfacer la demanda energética, mientras garantiza condiciones de estabilidad y confiabilidad de la red eléctrica distribuida, [6] destaca la necesidad de estaciones de carga y de estrategias de GD debido a los requerimientos de carga de los EV.

2. Materiales y métodos

Se analizarán diferentes niveles de adopción de vehículos eléctricos para evaluar el impacto en la energía requerida de RD, utilizando información mundial y peruana. La proyección revisa la estratificación del parque vehicular actual e histórico del Perú.

La metodología presentada en el artículo involucra un bucle que se inicia con la información del modelo de EV y llega hasta la etapa de ahorro de data, como se ilustra en la Figura 1. Este lazo se aplica a todos los modelos de EV y los tres escenarios de adopción de EVs mencionados en la sección “2.3 Múltiples Escenarios”.

Luego, la data resultante se procesa a través de dos procesos separados. El primer proceso es la MCS, para

reducir la cantidad de data. El segundo proceso es el análisis de la RD, explicado en la sección 2.6. La información recolectada en estos procesos se utiliza para comparar y evaluar el sistema diseñado que integra

la generación PV y el AE para abordar el excedente de demanda de energía sobre la RD causado por la carga no controlada de EVs. La Tabla 1 muestra la terminología empleada en este artículo.

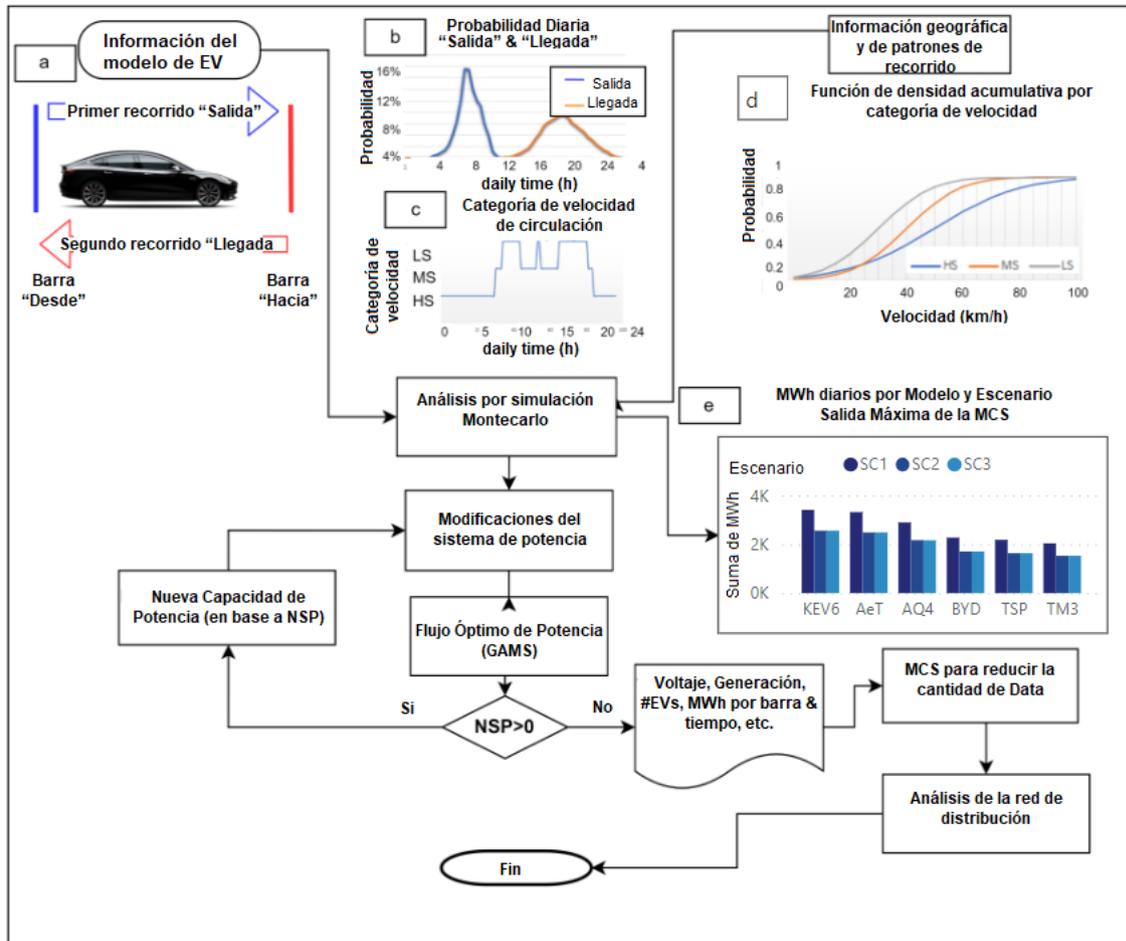


Figura 1. Metodología y data de entrada: (a) Entradas a la simulación Montecarlo acerca de modelos de vehículos eléctricos, y explicaciones de recorridos diarios. (b) Función de densidad de probabilidad (PDF) de las horas de los recorridos diarios. (c) Categoría de la velocidad de circulación diaria. (d) Función de densidad acumulativa del valor de velocidad por categoría de velocidad de circulación. (e) Resultados de la simulación Montecarlo, entrada para los próximos pasos.

Tabla 1. Terminología utilizada en este artículo

Terminología	Descripción
PS	Sistema de potencia
MCS	Simulación Montecarlo
V2G	Vehicle-to-Grid
GAMS	General Algebraic Modeling System
PNS	Potencia no servida
EVs	Vehículos eléctricos
CP	Capacidad de potencia
GD	Generación distribuida
RD	Red de distribución
PV	Fotovoltaico
AE	Almacenamiento de energía
FOP	Flujo óptico de potencia
ENS	Energía no servida

2.1. Descripción de proyección de carga descontrolada en Perú

Las importaciones peruanas de vehículos eléctricos han ido en aumento (según lo informado por el Departamento de Estudios Económicos de la AAP, 2019) desde 2016. Hasta agosto de 2019, se importaron 253 vehículos híbridos y 16 eléctricos. La cantidad global de vehículos eléctricos importados anualmente fue de 11 en 2016, 93 en 2017 y 165 en 2018. En total, se informaron 535 EV hasta agosto de 2019. El Gobierno peruano informó la cantidad de vehículos en circulación hasta 2018 de cada categoría: automóviles, SUV y camionetas.

2.2. Proceso de proyección de carga descontrolada en Perú

Se proyecta las tasas de adopción de vehículos eléctricos (EV) optimistas, pesimistas y habituales en Perú. Se estima la tasa de carga controlable, utilizando la participación en el mercado como punto de referencia y calcula la tasa de carga no controlable. La tasa de carga no controlable se calcula como un complemento de la tasa de carga controlable, que se supone que varía anualmente según las tendencias regionales y globales de adopción de vehículos eléctricos.

Los supuestos para las proyecciones pesimista y optimista se basan en las tendencias actuales. Es posible que no se mantengan en el futuro. Se espera que las ventas de vehículos eléctricos continúen aumentando debido a los incentivos gubernamentales, la reducción de los costos de las baterías y una mayor concienciación de los consumidores.

2.3. Escenarios múltiples

Este estudio examina el impacto potencial del uso de EVs sobre la demanda de energía en el SP de Perú. Se presentan tres escenarios de crecimiento en su uso: bajo (15 % por año), medio (25 % por año) y alto (40 % por año). Tres escenarios de 2000, 2500 y 3750 EVs estiman el número de cargas no controladas en el mediano plazo. Los escenarios fueron establecidos utilizando datas de Perú y mundiales [11].

Sobre la base de los escenarios, los autores evaluaron el impacto potencial del uso de EV sobre el SP de Perú, bajo diferentes condiciones. Los criterios de selección para los escenarios estuvieron basados en tasas de crecimiento realistas y variadas, análisis del peor caso, y data histórica y actual. También se hace una revisión de la estratificación actual e histórica de la flota vehicular de Perú.

Hasta agosto de 2019 se importaron a Perú 253 vehículos híbridos y 16 EV. El Gobierno peruano reportó el número de vehículos de cada categoría que circularon hasta 2018 [12]. La información se encuentra detallada en la sección 2.2.

2.4. Análisis por simulación Montecarlo

La Figura 1a muestra cómo los EV salen de y llegan a diferentes barras, con horas de salida y llegada según los patrones geográficos y de recorrido de los propietarios de los EVs [5]. El modelo utiliza muestras N_s (s), T períodos de tiempo (t) y NV EVs (v), caracterizados por medio de variables estocásticas [13].

La Figura 1b muestra las variables estocásticas [9] $dep_{v,s}$ y $arr_{v,s}$ a las que se le ajustan distribuciones de probabilidad [2], con variables binarias que representan los estados ($deps_{t,v,s}$ y $arrs_{t,v,s}$). Las Figuras 1c y 1d muestran las caracterizaciones probabilísticas

de la variable velocidad del EV ($sv_{t,v,s}$) y la distancia entre barras corregida usando $tdcf_{v,s}$ y longitud $L(Fr_{v,s} : To_{v,s})$.

$$td_{v,s} = L(Fr_{v,s}; To_{v,s}) \times tdcf_{v,s} \quad (1)$$

La ecuación (1) combina los parámetros estocásticos $Fr_{v,s}$ y $To_{v,s}$ del estado de la ubicación del EV con $tdcf_{v,s}$, para determinar la distancia final recorrida $td_{v,s}$. Para el análisis MCS se requiere data específica del EV, como capacidad de la batería (BCES), consumo específico durante la conducción ($SC_{v,s}$), estado de carga (SoC_{min} y SoC_{max}), máxima potencia de carga (Pv_{max}), eficiencia de carga y descarga (n_{chg} y n_{dsg}), valor de consumo en circulación ($R_{t,v,s}$), e índice de variable binaria ($X_{t,v,s}$).

2.4.1. Pseudocódigo – modelado del recorrido

1. Definir la hora de salida, hora de llegada, y las variables distancia temporal recorrida en circulación $t = dep_{v,s}$ y la distancia recorrida en circulación, $rdt_{v,s} = 0$ para el caso de salida, y $t = arr_{v,s}$ y $rdt_{v,s} = 0$ para el caso de llegada.
2. Iniciar el bucle para llenar la distancia recorrida en circulación hasta sobrepasar la distancia recorrida, como se indica en las ecuaciones (2) y (3).

$$\text{while } rdt_{v,s} \leq td_{v,s} \{ \quad (2)$$

$$rdt_{v,s} = +sv_{v,s} \times 24/T \quad (3)$$

3. Condicional para verificar si se alcanza la última etapa del recorrido de salida, como en las ecuaciones (4) y (5).

$$\text{if } rdt_{v,s} \leq td_{v,s} \{ \quad (4)$$

$$R_{t,v,s} = sv_{v,s} \times SC_{v,s}/n_{dsg} \times 24/T \quad (5)$$

4. Asignar un valor al consumo en circulación para etapas diferentes a la última en el recorrido de salida, como en la ecuación (6).

$$\text{else} \{ R_{t,v,s} = (sv_{v,s} + td_{v,s} - rdt_{v,s}) \times SC_{v,s}/n_{dsg} \} \quad (6)$$

5. Finalizar el bucle asignando el valor de hora de finalización de la salida u hora de inicio de la llegada, y estado binario en circulación, tal como se muestra en la ecuación (7) para uno de salida y en la ecuación (8) para un recorrido de llegada.

$$X_{t,v,s} = 1 \wedge t = +1\} de_{v,s} = t \quad (7)$$

$$X_{t,v,s} = 1 \wedge t = -1\} ai_{v,s} = t \quad (8)$$

Las variables tales como $de_{v,s}$ y $ai_{v,s}$ marcan el fin del recorrido de salida y la hora a la que el EV está listo para iniciar el recorrido de retorno, respectivamente.

La variable binaria $CS_{b,t,v,s}$ hace un seguimiento del estado de la barra de carga para el EV ubicado en la barra b. Las ecuaciones (9) y (10) fuerzan el cumplimiento de restricciones asociadas al estado de la barra de carga.

$$CS_{Fr_{v,s,t,v,s}} = 1 \forall arr_{v,s} < t < dep_{v,s} \quad (9)$$

$$CS_{To_{v,s,t,v,s}} = 1 \forall de_{v,s} < t < ai_{v,s} \quad (10)$$

Las variables $ChR_{v,s}$ y CC se definen como la energía total requerida por el EV en circulación y la carga completa, respectivamente. Estas variables se calculan en las ecuaciones (11) y (12).

$$ChR_{v,s} = \sum_t R_{t,v,s} \quad (11)$$

$$CC = Pv_{max} \times 24/T \times n_{chg} \quad (12)$$

2.4.2. Pseudo código – modelado de la carga no controlada

1. Colocar 0 el valor de $tch_{v,s}$, como en la ecuación (13).

$$tch_{v,s} = 0; \forall v \in NV \wedge s \in Ns \quad (13)$$

2. Establecer el tiempo de carga: salida y llegada, como en la ecuación (14).

$$t = de_{v,s} \wedge t = arr_{v,s} + 1 \quad (14)$$

3. Aumentar y asignar el valor de la carga no controlada del vehículo $UC_{b,t,v,s}$, de acuerdo con la carga temporal $tch_{v,s}$, midiendo la carga no controlada en la barra correspondiente, sin alcanzar la energía requerida, como en las ecuaciones (15) y (16).

$$tch_{v,s} = +CC \quad (15)$$

$$if \ tch_{v,s} \leq ChR_{v,s} \{ UC_{b,t,v,s} = CS_{b,t,v,s} \times CC \} \quad (16)$$

4. Asignar carga no controlada al tiempo mientras se llega a la energía requerida, como en la ecuación (17).

$$else \{ UC_{b,t,v,s} = (ChR_{v,s} + CC - tch_{v,s}) \times CS_{b,t,v,s} \} \quad (17)$$

5. Finalizar el bucle como en la ecuación (18).

$$t = +1\} \quad (18)$$

La ecuación (19) se utiliza para obtener la información de la carga pico requerida, PLR_s , que se reporta como la salida final de la MCS. La carga en la barra b del SP se representa como $Pdps_{b,t}$. La Figura 1e muestra un resumen de esta información, con el acumulado diario de la energía requerida por la RD para todos los modelos y escenarios. La Figura 1e compara las salidas máximas de la MCS que producen más carga sobre la RD durante las horas pico. Por otra parte, las salidas mínimas de la MCS representan el mínimo impacto en el estado de carga en la hora pico.

$$PLR_s = \max \left(t, \sum_b \left(\sum_v UC_{b,t,v,s} + Pdps_{b,t} \right) \right) \quad (19)$$

2.5. Interacción entre la MCS y el flujo óptimo de potencia

Las ecuaciones (21) y (22) muestran cómo se eligen las salidas de la MCS. El excedente de carga se agrega a la carga del SP y se denota como $Pd_{b,t,s}$. La información obtenida del análisis con la MCS (ecuaciones (21) y (22)) es una entrada importante para optimizar la operación de la red eléctrica de distribución, específicamente de la subsección de transmisión, utilizando el modelado algebraico.

$$[PLR_{smax}, smax] = \max(s, PLR_s) \quad (20)$$

$$[PLR_{smin}, smin] = \min(s, PLR_s) \quad (21)$$

$$Pd_{b,t,s} = Pdps_{b,t,s} + \sum UC_{b,t,v,s} \quad (22)$$

2.6. Flujo óptimo de potencia

El FOP eléctrica se modela en el software GAMS, utilizando la minimización de la función objetivo (fo) CONOPT de la ecuación (24) para cada uno de los seis casos (tres escenarios, dos salidas de la MCS). Este proceso suministra la cantidad de PNS requerida en cada barra de la RD para cada período analizado, como se muestra en la ecuación (25). Los enfoques de optimización GAMS y el análisis complementario con la MCS tendrían la capacidad de superar los retos de integrar EVs y GD en los SP [14].

2.6.1. Función objetivo

La salida principal es la energía asignada a la energía no servida (ENS) diaria, con información reportada cada media hora. Esto involucra evaluar ecuaciones para todo $t \in T \wedge s \in \{s_{min}, s_{max}\}$. La ENS se utiliza para asignar la cantidad de PNS durante este período de tiempo, según la ecuación (23).

La PNS se utiliza como variable auxiliar para identificar áreas y la cantidad de energía requerida para cubrir el excedente debido a la carga de EVs, y también puede representar la cantidad de potencia requerida como excedente de generación en su barra para evitar fallas del SP [8].

La función objetivo (*of*) para optimizar las pérdidas de energía asociadas a la operación de la red se expresa en la ecuación (24), donde también se evalúa la generación de potencia en la barra auxiliar Pg_{slack} . Según se menciona en [15], el precio de penalización por ENS en Perú es $C_{pen} = \$6000$. El uso de la PNS como fuente de datos puede ayudar a los planificadores a comparar las fuentes alternativas de generación, ajustar la energía requerida en el modelado espacio-tiempo, y dimensionar las condiciones de GD en el SP.

$$NSE_k = 24/T \times NSP_k \quad (23)$$

$$of = \sum (C_{pen}NSE_k) + Pg_{slack} \quad (24)$$

2.6.2. Restricciones para el flujo óptimo de potencia

Las restricciones para el FOP son el balance de potencia activa y reactiva. Las ecuaciones (25) y (26) definen el balance de potencia, donde Pg_k y NSP_k denotan la potencia de generación y las reservas no rotativas, mientras que Pd_k representa la potencia requerida por la carga.

$$Pg_k + NSp_k = Pd_k + \sum P_{km} \quad (25)$$

$$Qg_k = Qd_k + Qsh_k + \sum Q_{km} \quad (26)$$

Las variables Qg_k , Qd_k están relacionadas con la potencia reactiva de generación y carga en cada barra. Las ecuaciones (27) y (28) calculan la potencia activa y reactiva por línea (P_{km} y Q_{km}) y la potencia aparente S_{km} en la ecuación (29) controla la sobrecarga en la línea de potencia correspondiente.

$$P_{km} = V_k V_m Y_{km} \cos(th_{km} + d_{km}) - V_k^2 \cos(t_{km}) \quad (27)$$

$$Q_{km} = -V_k V_m Y_{km} \sin(th_{km} + d_{km}) + V_k^2 \sin(t_{km}) \quad (28)$$

$$S_{km} = \sqrt{P_{km}^2 + Q_{km}^2} \leq S_{kmupper} \quad (29)$$

Las variables V_i , d_i , Qg_i , Pg_i tienen límites inferior y superior, denotados por x_{lower} y x_{upper} en la ecuación (30). La sección se refiere a [8] para los detalles sobre los parámetros de voltaje (V y d) y los parámetros de la matriz de admitancia (Y y t).

$$x_{lower} \leq x \leq x_{upper} \quad (30)$$

2.7. Capacidad del nuevo sistema de potencia para garantizar operación normal

Se consideraron dos opciones para el modelo desarrollado para determinar el momento y la barra de falla. La primera opción involucra un incremento lineal de la capacidad de potencia (CP) en una barra específica. La segunda opción es una combinación de generación PV y un sistema de AE.

La ecuación (31) describe la primera opción, la cual modela la nueva CP ($PNg_{k,t}$) para operar durante el día y recuperar los costos de inversión. La segunda opción apunta a minimizar la función objetivo de costos adicionales, con costos agregados x_{cost} de acuerdo con la PNS calculada ($NSP_{c,k,t}$).

$$PNg_{k,t} = Pg_{k,t} + NSP_{c,k,t} \quad (31)$$

Las ecuaciones (32), (33) y (34) describen el proceso de la segunda opción, la cual cubre la nueva CP requerida, incluyendo la dimensión de la potencia ($PhPC_b$) y el almacenamiento de energía ($SSEC_b$), y se ajusta según la variación de la disponibilidad solar (Saf_t) y del estado de carga ($SoCv_{k,t}$) para redistribuir la energía almacenada cada media hora (Dt). La fuente de la capacidad de generación excedente no se analiza debido a su variedad.

$$fo = PhPC_{cost} \times PhPC_k + SSEC_{cost} \times SSEC_k \quad (32)$$

$$PhPC_k \times Saf_t \geq NSP_{c,k,t} + SoCv_{k,t} \quad (33)$$

$$SoC_{k,t} = SoC_{k,t-1} + SoCv_{k,t-1} \times Dt \quad (34)$$

2.8. Impacto sobre la red de distribución

Los estudios indican que los vehículos eléctricos tienen un impacto sobre las redes de distribución. Los requerimientos diarios de energía son independientes del modelo de EV. La data de voltaje y la energía requerida por los EV se recopila y se procesa mediante ciencia de datos, obteniendo información estadística utilizando MCS. La carga de los EV puede causar caídas de voltaje e inestabilidad en la red, lo cual puede ser abordado usando sistemas de almacenamiento de energía y estrategias inteligentes de carga [2], [5].

2.9. Caso de estudio

2.9.1. Carga no controlada de vehículos eléctricos (datos proyectados 2023–2031)

Las suposiciones y las fuentes de información utilizan la participación de mercado como un punto de referencia para las tasas regionales y globales de carga controlada. Las ventas acumuladas de EV se consideran como el total de EV en circulación, y se espera que las ventas de los mismos continúen incrementándose debido a incentivos gubernamentales, costos reducidos de baterías y aumento en la conciencia del consumidor.

La proyección optimista supone un aumento anual

de 25 % en las ventas de EV, y supone que la tasa de carga controlada es 70 %. La proyección pesimista supone un aumento anual de 10 % en las ventas de EV, y supone que la tasa de carga controlada es 50 %. Estas suposiciones se utilizaron para proyectar la adopción de EV en Perú.

La Tabla 2 presenta los rangos de la proyección de la adopción de EV en Perú entre 2023 y 2031. Esto incluye las ventas acumuladas, las tasas de carga controlada y no controlada, y el número de EV en circulación. La data se presenta en los escenarios optimista, pesimista y normal.

Tabla 2. Carga no controlada de vehículos eléctricos (data proyectada 2023–2031)

Año	Total de vehículos N.º	Ventas acumuladas de EV N.º EV	Participación de mercado %	Tasa de carga no controlada %	Carga no controlada de EV N.º EV
2023	366 900-372 700	2 450-2 930	6.67-7.85	85.30-86.70	2 120-2 490
2024	375 800-385 900	3 180-4 170	8.45-10.81	84.30-85.80	2 719-3 460
2025	384 000-399 800	4 200-5 750	10.94-14.39	83.30-84.90	3 606-4 880
2026	392 300-414 500	5 480-7 770	13.97-18.74	82.30-84.00	4 760-7 070
2027	400 800-430 000	7 190-10 350	17.95-24.07	81.30-83.10	6 455-9 060
2028	409 400-446 400	9 370-13 500	22.84-30.21	80.30-82.20	8 485-11 978
2029	418 200-463 700	12 030-17 350	28.73-37.40	79.30-81.30	10 963-16 652
2030	427 100-482 100	15 220-22 020	35.63-45.65	78.30-80.40	14 372-17 494
2031	436 100-501 600	18 920-27 650	43.31-55.31	77.30-79.50	15 390-24 768

2.9.2. Múltiples escenarios

El artículo presenta tres escenarios para el crecimiento de la venta de EV en Perú: optimista, normal y pesimista, con estimaciones de tasas de carga controladas para cada escenario. Basándose en esta información y al análisis de la carga no controlada de los EV, el estudio proyecta que el número de EV circulando en Perú para 2023 variará entre 2450 y 2940. El artículo

también compara las características técnicas de diferentes modelos de EV y sus efectos sobre la RD, como se muestra en la Tabla 3; se encontró que el KIA EV6 es el vehículo que requiere más energía entre los EV estudiados. Sin embargo, los escenarios presentados se basan en suposiciones generales, y puede que no reflejen de manera precisa las condiciones específicas del mercado peruano. Ver la Tabla 2 para mayor información.

Tabla 3. Modelos de vehículos eléctricos (data del 2021)

EV	BCES kWh	SCv,smin kWh/km	SCv,smax kWh/km	Pvmax kW	SoCmin %	SoCmax %
TSP	100	0.18	0.21	250	5	80
AQ4	82	0.181	0.181	125	15	95
KEV6	77.4	0.21	0.227	228	10	80
BHEV	76.9	0.164	0.207	360	30	80

2.9.3. Análisis por simulación Montecarlo

El estudio analizó tres escenarios con microescenarios estocásticos. El escenario 1 consistió en 2000 EV con 200 muestras. El escenario 2 tuvo 2500 EV con 120 muestras. El escenario 3 tuvo 3750 EV con 80 muestras. El análisis incluyó 1.0×10^6 escenarios microestocásticos con incertidumbre. En la sección 2.2 se ajustó una distribución normal a las variables $dep_{v,s}$ y $arr_{v,s}$. La Figura 1b ilustra las diferencias significativas entre las funciones de distribución de probabilidad de las horas de salida y llegada. Las horas de llegada tienen una desviación estándar que engloba horas después del trabajo cuando los individuos pueden atender tareas del hogar o socializar, lo cual no ocurre durante las horas de la mañana antes del trabajo.

De acuerdo con [13], el Tesla Model 3 tiene una BCES de $2.88 \times 10^{+8}$ J (80 kWh). El consumo específico de energía para este vehículo está dentro del rango de $SC_{v,s} \in < 684; 900 > J/m (< 0.19; 0.25 > KWh/Km)$. La máxima potencia de carga del EV

es aproximadamente $P_{v,max} = 1.5 \times 10^{+5}$ W with $n_{chg} = 90 \%$ y $n_{dsg} = 90 \%$. Para modelar las baterías del EV, se establece el estado de carga mínimo SoC_{min} en 15 % de la capacidad de la batería, mientras que el estado de carga máximo SoC_{max} se establece en 95 % de la capacidad de la batería.

2.9.4. Interacción entre la MCS y el FOP

La caracterización de la incertidumbre del recorrido y geográfica involucra categorizar el número de EV por barra como “desde” o “hacia” según el recorrido de salida. La Figura 2 muestra diagramas de caja de la energía total requerida por la RD en cada hora, comparando el KIA EV6, que requiere la mayor cantidad de energía, con el Tesla Model 3, que requiere la menor cantidad de energía (como se muestra en la Figura 1e). Los valores reportados en la Figura 2 muestran que el KIA EV6 es el modelo que consume más energía, provocando un mayor requerimiento de energía para la RD.

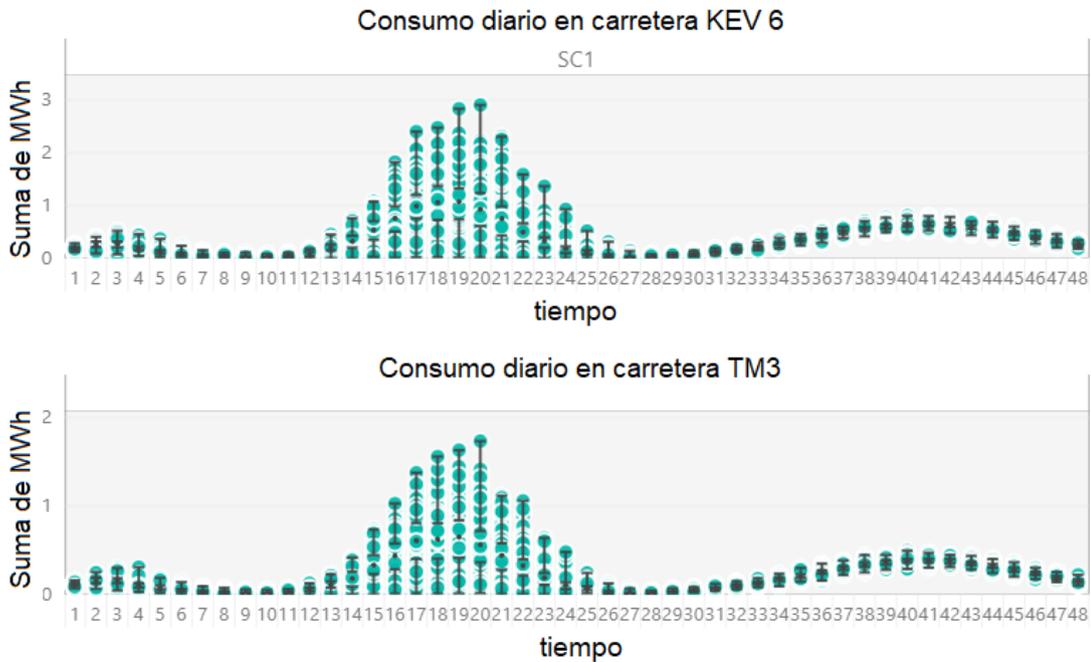


Figura 2. Consumo diario en circulación requerido por escenario y hora

2.9.5. Uso del flujo óptimo de potencia

El sistema de potencia IEEE de 14 barras [16] representa el SP de la clase socioeconómica A en Perú, con variaciones en la longitud de la línea de potencia. La data de carga del mercado eléctrico de febrero de 2020 se utiliza como el factor de carga diario. Los efectos de las categorías de circulación de alta, media y baja velocidad se reportan en [13]. Google Maps suministró data histórica de tráfico para las tres categorías re-

presentadas por distribuciones normales. La primera categoría es velocidad alta con un valor promedio de 13.89 m/s (50 km/h) y una desviación estándar de 5.56 m/s (20 km/h). La segunda categoría es velocidad media, con un valor promedio de 9.72 m/s (35 km/h) y una desviación estándar de 4.17 m/s (15 km/h). La tercera categoría es velocidad baja, con un valor promedio de 5.56 m/s (20 km/h) y una desviación estándar de 2.78 m/s (10 km/h).

2.9.6. Capacidad del nuevo sistema de potencia para garantizar operación normal

La opción del primer CP excedente no necesita data adicional, pero la opción del sistema con generación PV y almacenamiento de energía requiere un factor de disponibilidad solar, obtenido de [17] con data de costos de [18]. La subsección 2.5 presenta las restricciones y la función de la interacción de potencia con PNS. Las restricciones (32) a (34) son complementadas por la ecuación (35), manteniendo la variable $SoC_{k,t}$ entre los límites de 0 y la capacidad del sistema de almacenamiento, $SSEC_k$.

$$0 \leq SoC_{k,t} \leq SSEC_k \quad (35)$$

Las variables de la función objetivo en la ecuación (33) incluyen un $PhPC_{cost}$ de 1.30 \$/W para el costo de CP fotovoltaica y un $SSEC_{cost}$ de 1.11×10^{-4} \$/J (400 \$/kWh) para la capacidad del sistema de almacenamiento de energía.

2.9.7. Análisis de la red de distribución

Finalmente, se obtienen dos síntesis muy similares a la data global. La primera representó el 4 % de los

casos, y la otra correspondió al 10 % de los casos. Estas reducciones son evaluadas en una red de distribución comúnmente utilizada (el sistema IEEE de 14 barras) mediante la herramienta Simulink del software MATLAB. El efecto de todas las simulaciones realizadas en la RD se reporta en la siguiente sección.

3. Resultados y discusión

3.1. Análisis por simulación Montecarlo

La Figura 3 muestra el número de EV en el SP y dos figuras para cada escenario, ilustrando los patrones geográfico y de recorrido de los EV. La Tabla 4 proporciona información adicional sobre el número de EV saliendo de y llegando a cada barra en su primer recorrido, junto con la incertidumbre de los patrones geográficos. Los encabezados en la Tabla 4 están clasificados como “Min MCS” y “Max MCS”, representando los escenarios mínimos y máximos de carga pico diaria reportados en las salidas de la MCS. Estos clasificadores pueden ayudar a evaluar los potenciales impactos de los EV sobre el SP.

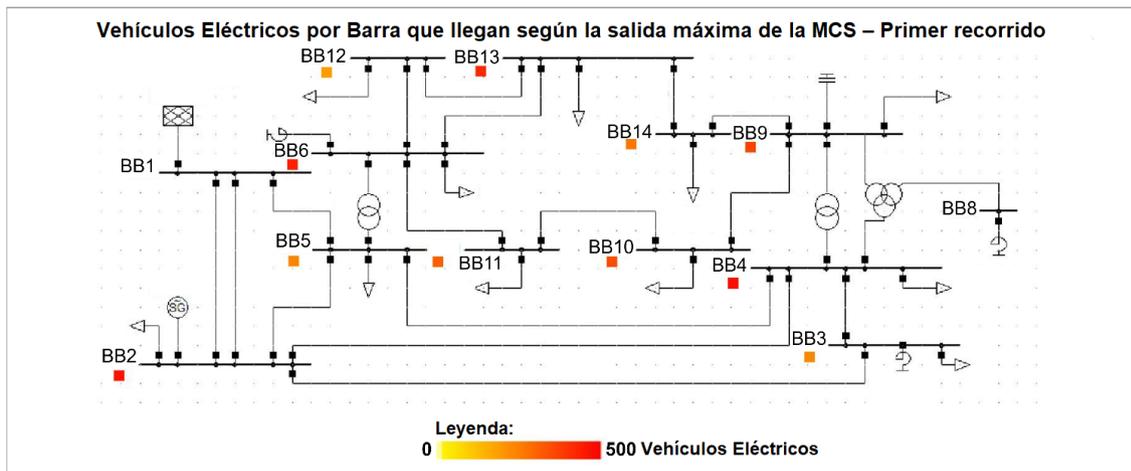


Figura 3. Número de vehículos eléctricos que llegan según la salida máxima de la simulación Montecarlo - escenario 1

Tabla 4. Número de vehículos eléctricos desde y hacia cada barra por escenario según las salidas de la simulación Montecarlo

EVs Bus	Escenario 1				Escenario 2				Escenario 3			
	Min MCS		Max MCS		Min MCS		Max MCS		Min MCS		Max MCS	
	Desde	Hacia	Desde	Hacia	Desde	Hacia	Desde	Hacia	Desde	Hacia	Desde	Hacia
1	0	0	0	0	0	0	0	0	0	0	0	0
2	180	242	171	269	227	265	224	288	325	460	307	424
3	186	132	197	117	208	151	240	149	337	219	333	227
4	179	255	177	256	215	296	223	336	360	454	342	502
5	204	120	200	103	214	152	227	141	328	217	380	209
6	186	225	188	222	208	339	232	286	320	463	352	440
7	0	0	0	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0	0	0
9	191	179	166	188	229	256	224	264	358	341	360	342
10	172	196	204	157	244	227	257	242	340	353	322	344
11	172	131	153	164	240	183	232	197	343	287	329	274
12	188	132	201	119	234	150	234	147	357	202	341	221
13	170	244	167	260	249	290	196	280	324	467	337	468
14	172	144	176	145	232	191	211	170	358	287	347	299

3.2. Interacción entre la MCS y el FOP

La Figura 4 compara la aplicación para el Tesla Model 3, que tiene el consumo específico más bajo. La primera aplicación es el PS_{MCS} , que se muestra en la sección derecha. Los valores también están relacionados con la salida máxima de la MCS. Mientras tanto, la Tabla 5 presenta las características promedio de carga diaria para diferentes escenarios con salidas mínimas y máximas de la MCS.

La energía de la carga Ed_s se calcula mediante la ecuación (36). La carga pico $Pd_{max,s}$ representa la carga máxima diaria suministrada por el SP para cada escenario analizado, como se expresa en la ecuación (37).

Finalmente, el factor de carga LF_s se determina dividiendo la potencia promedio de la carga por la potencia máxima de la carga, como se muestra en la ecuación (38).

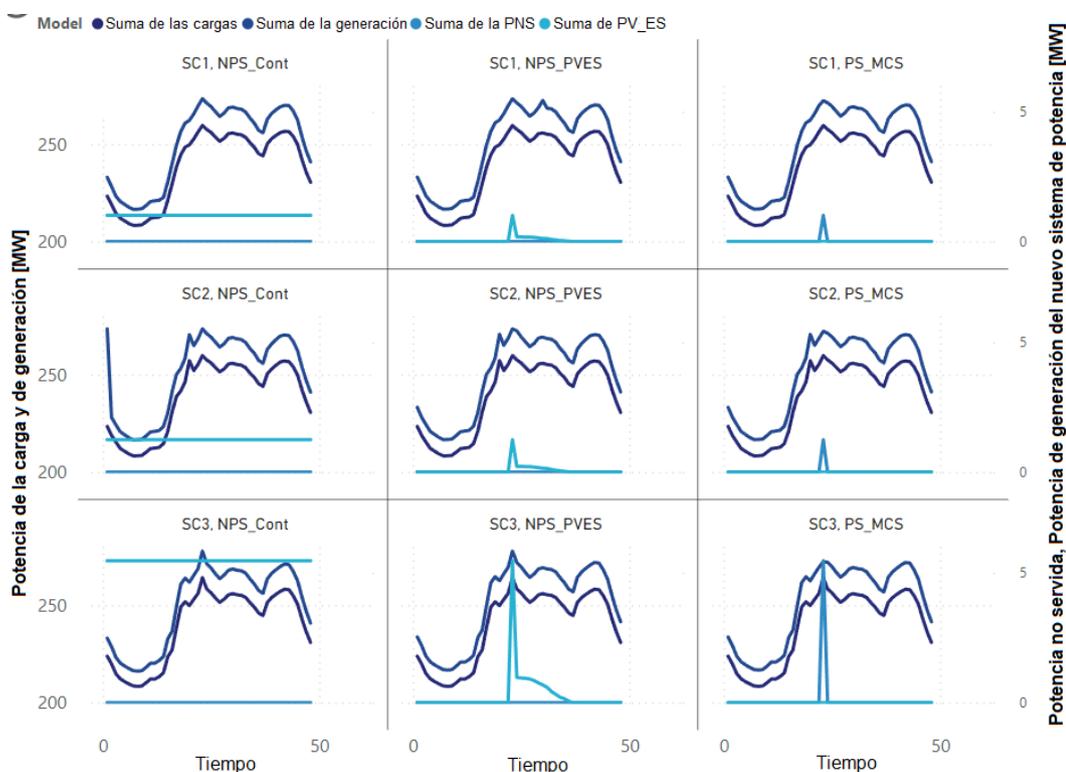


Figura 4. Comparación del desempeño del sistema de potencia: flujo óptimo de potencia (PS_MCS), fotovoltaico y almacenamiento de energía (NPS_PVES) y generación continua (NPS_Cont)

Tabla 5. Data de carga por escenario para el vehículo eléctrico Tesla (2018) y desempeño del flujo óptimo de potencia para todos los escenarios

Carga diaria	BAU	Escenario 1		Escenario 2		Escenario 3	
	sin EV	Min MCS	Max MCS	Min MCS	Max MCS	Min MCS	Max MCS
Ed_s (MWh)	5,704.6	5710.58	5724.82	5711.51	5729.43	5715.56	5742.4
$Pd_{max,s}$ (MW)	257.2	257.25	259.66	257.31	259.91	257.51	264.23
LF_s	0.906	0.906	0.907	0.905	0.906	0.910	0.906
Eg_s (MWh)	5,979.1	5985.82	6000.95	5986.67	6005.91	5991.1	6017.9
Los_s (MWh)	274.5	275.24	276.12	275.17	276.48	275.54	275.5
NSE (MWh)			0.5		0.62		2.74
Max NSP (MW)			1.01		1.25		5.47
NSP bus			14		14		14

$$Ed_s = \sum \sum Pd_{b,t,s} \times 24/T; s = \{s_{min}, s_{max}\} \quad (36)$$

$$Pd_{max,s} = \max \left(\sum Pd_{b,t,s} \right); s = \{s_{min}, s_{max}\} \quad (37)$$

$$LF_s = \frac{\sum \sum \frac{Pd_{p,t,s}}{T}}{Pd_{max,s}}; s = \{s_{min}, s_{max}\} \quad (38)$$

Se observa un incremento en la diferencia en la carga pico entre las salidas máximas y mínimas de la MCS, lo cual indica el efecto estocástico del análisis. Para el escenario 1, la brecha entre las salidas de la MCS es $2.41 \times 10^{+6} W$. Para el escenario 2, la diferencia entre las salidas de la MCS es $2.60 \times 10^{+6} W$. Para el escenario 3, la brecha entre las salidas de la MCS es $6.72 \times 10^{+6} W$. A continuación, se reporta la diferencia en la energía diaria de la carga entre las salidas máximas y mínimas de la MCS para cada escenario. El escenario 1 tiene una diferencia en la energía diaria de $5.13 \times 10^{+10} J$ (14.24 MWh). El escenario 2 tiene una diferencia en la energía diaria de $6.45 \times 10^{+10} J$ (17.92 MWh). El escenario 3 tiene una diferencia en la energía diaria de $9.66 \times 10^{+10} J$ (26.84 MWh). El incremento en la brecha se debe al número de EV en los escenarios evaluados.

3.3. Uso del flujo óptimo de potencia

Comúnmente, el modelo emplea el FOP para evaluar el desempeño del SP para los diferentes escenarios de

carga de EV. La Figura 4 muestra el desempeño de la CP y la PNS requerida para mantener la operación normal, donde se especifica la salida más alta de la MCS para el EV Tesla 3 Model. La Tabla 5 resume los hallazgos del flujo óptimo de potencia, incluyendo variables tales como Eg_s y $Loss_s$, que representan energía generada, brechas de energía y NSE_s asignando PNS a todas las barras durante el día. Las ecuaciones (39) a (41) definen estas variables.

$$Eg_s = \frac{\sum \sum Pg_{b,t,s} \times 24}{T}; s = \{s_{min}, s_{max}\} \quad (39)$$

$$Loss_s = Eg_s - Ed_s; s \in \{s_{min}, s_{max}\} \quad (40)$$

$$NSE_s = \frac{\sum \sum NSP_{b,t,s} \times 24}{T}; s = \{s_{min}, s_{max}\} \quad (41)$$

El modelo evaluado permite identificar la barra que requiere mayor capacidad y cuál es la opción más apropiada para suministrarla. La cantidad de PNS determinará la capacidad requerida para nuevas plantas eléctricas. La Tabla 6 reporta información para el Tesla 3 Model (2018).

El estudio encontró que se expulsó ENS de la última barra del SP, que es la que está más alejada de las barras de generación (#14). La cantidad de ENS se incrementó a medida que aumentó el número de EV en cada escenario.

Tabla 6. Capacidad del nuevo sistema de potencia (NSP) para garantizar la operación normal, dada como un valor fijo a lo largo del día: opción fotovoltaica – sistema de almacenamiento (PVSA)

OPF	Escenario 1			Escenario 2			Escenario 3		
	BAU sin EV	Min MCS	Max MCS	BAU sin EV	Min MCS	Max MCS	BAU sin EV	Min MCS	Max MCS
E_{gNPS} (MWh)	5975.91	5982.49	5998.33	5975.16	5982.75	6002.67	5962.67	5974.66	6004.41
$Loss_{NPS}$ (MWh)	271.36	271.91	273.51	270.62	271.25	273.25	258.12	259.1	262.01
Max P_{gNPS} (MW)	270.7	270.72	273.41	270.67	270.75	273.65	270.08	270.38	277.87
Capacidad de NPS (MW)		1.01			1.25			5.47	
E_{gPSS} (MWh)	5978.9	5985.49	6001.34	5978.86	5986.45	6007.05	5978.13	5990.15	6020.07
$Loss_{PSS}$ (MWh)	274.36	274.91	276.52	274.31	274.95	277.63	273.58	274.59	277.67
Max P_{gPSS} (MW)	270.82	270.83	273.41	270.82	270.84	273.65	270.71	270.72	277.87
Capacidad PV (MW)		0.177687			0.219993			0.965943	
Almacenamiento (MWh)		0.419278			0.519105			2.279288	
Barra (#)		14			14			14	
Costo PVSA (\$) (\$)		345,397.68			427,634.56			1,877,658.44	

3.4. Capacidad del nuevo sistema de potencia para garantizar operación normal

El SP requiere capacidad adicional de generación para abordar el problema identificado. La sección de metodología ofrece opciones para obtener capacidad extra de generación usando microturbinas, máquinas de combustión interna, generación PV en conjunto con un sistema de almacenamiento, etc. La Figura 4 muestra el desempeño del SP y la potencia suministrada por el sistema PV-AE para la salida máxima de la MCS para el Tesla 3 Model. La Tabla 5 proporciona información acerca de la capacidad requerida del nuevo sistema de potencia (NSP). El costo del sistema PV-AE se reporta para cada escenario en las Figuras 5a, 5b, y 5c, variando desde \$ 0 a $\$7.40 \times 10^5$ para el escenario 1, $\$2.22 \times 10^5$ a $\$7.81 \times 10^5$ para el escenario 2 y $\$5.88 \times 10^5$ to $\$3.41 \times 10^6$ para el escenario 3. El costo de la primera opción para agregar capacidad para un día completo no se evalúa en este estudio, pero su CP se establece como constante, tal como la PNS del SP FOP.

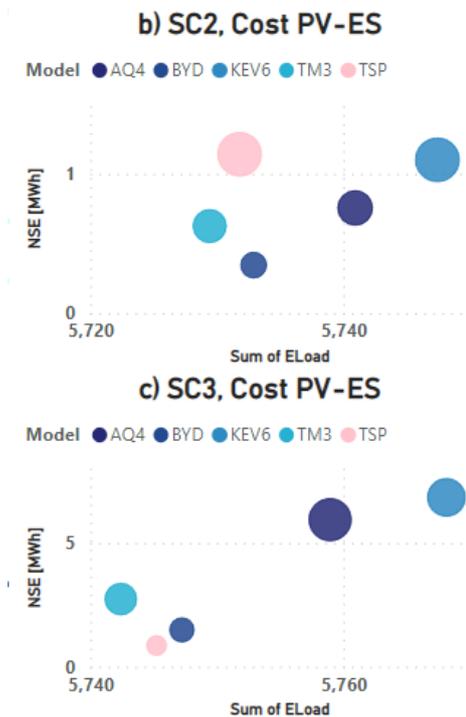
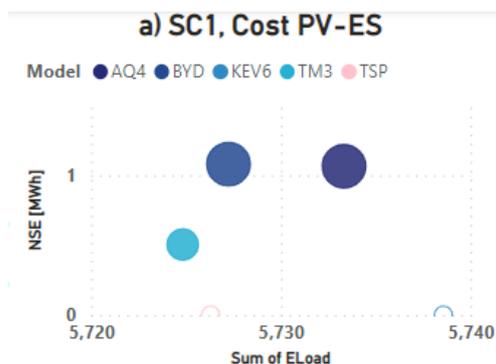


Figura 5. Comparación de la energía no servida (NSE) y costos fotovoltaico-almacenamiento de energía para los tres escenarios: (a) escenario 1, (b) escenario 2 y (c) escenario 3.

3.5. Resultados de la red de distribución

La sección 3.4 del estudio examina la relación entre carga y capacidad del SP. Se encontró que un aumento en la carga general no necesariamente requiere mayor

capacidad del SP o incrementa el costo de generación PV y AE. Este estudio también muestra que la carga requerida por los modelos de EV no resulta en mayor PNS. Estos hallazgos sugieren que los requerimientos del SP y del modelo de EV son independientes.

Se utilizan técnicas de reducción de datos para sintetizar la gran cantidad de información procesada. Se realizaron dos reducciones en los datos, con errores de 1.24 % y 0.85 % en comparación con la data global. La reducción de 4 % de la data se utiliza para procesar la data en MATLAB mediante la herramienta Simulink. La data de la red de distribución se utiliza para redistribuir los EV entre los alimentadores del sistema de potencia IEEE de 14 barras, y el desempeño resultante de los alimentadores se muestra en la Figura 6. Los resultados indican que los valores de voltaje permanecen dentro del rango para todas las barras del sistema de potencia IEEE de 14 barras, aún bajo suposiciones de carga no controlada.

4. Conclusiones

En este estudio se muestra el efecto de la presencia de carga no controlada de EV en los mercados eléctricos, como puede verse en la Tabla 5 y en la Figura 2. Las salidas mínimas y máximas de las simulaciones Montecarlo dependen del consumo específico de los modelos de EV, cuyos valores se reportan en la Tabla 3. El modelo de EV que requirió más energía de la red de distribución fue el KIA EV6, mientras que el modelo que requirió menos energía fue el Tesla Model 3, como se muestra en la Figura 1e. El mayor consumo

del escenario 3 fue para el modelo KIA EV6, con 31.8 MWh, mientras que el menor consumo del escenario 1 fue para el Tesla Model 3, con 10.14 MWh.

Para los modelos específicos de EVs que requieren más energía, no se garantiza que la variable PNS sea necesaria. La Figura 5a muestra que los modelos que no tuvieron PNS fueron el KIA EV6 (que tiene el mayor requerimiento de energía) y el Tesla S Plaid. Las Figuras 5b y 5c también soportan este hecho debido a la intermitencia de las PNS máximas y mínimas que se presentan en las ejecuciones de FOP.

Por otra parte, la dependencia que se observa en la Figura 5 es la relación entre los costos de sistemas de generación PV – almacenamiento de energía de diferentes dimensiones y la cantidad de ENS diaria presente en la ejecución del FOP. Esta relación no es estrictamente lineal, pero para valores similares de ENS el costo del sistema diseñado es similar. Por ejemplo, en el escenario 3, el valor más alto de ENS es 6.84 MWh. El modelo de EV correspondiente es el KIA EV6. El costo relacionado con este punto es \$ $2.84 \times 10^{+6}$. Sin embargo, el costo más alto entre los sistemas diseñados es \$ $3.41 \times 10^{+6}$, con un valor de energía no servida de 5.94 MWh.

El impacto de la carga no controlada no es relevante en la distribución, como lo muestra la estabilidad de voltaje en el modelo ejecutado. Aún las barras más alejadas tienen valores de voltaje que cumplen con los límites de las normas peruanas de distribución eléctrica. Las barras 632, 645, 646 y 633 tienen niveles de voltaje bien distribuidos. Los restantes también tienen valores de acuerdo con las normas.

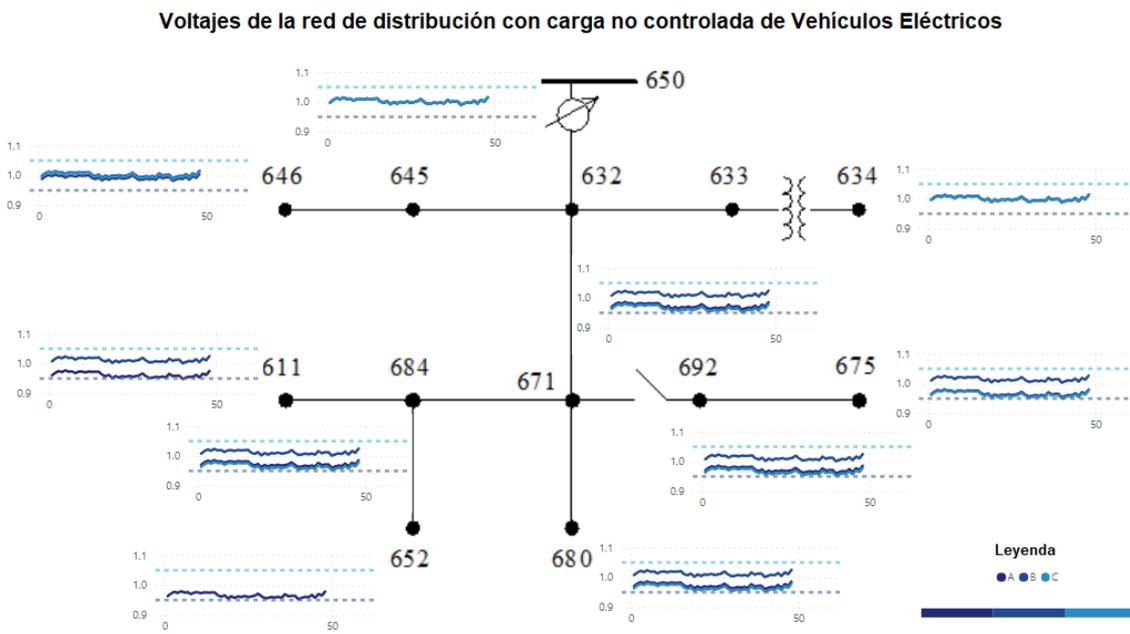


Figura 6. Voltaje Diario de la Red de Distribución para cada fase

Agradecimientos

Un agradecimiento especial al “Programa de Doctorados en la Universidad Peruana”, promovido por el Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica (CONCYTEC) a través del Fondo Nacional para el Desarrollo Científico, Tecnológico e Innovación Tecnológica (FONDECYT).

Referencias

- [1] V. Vita and P. Koumides, “Electric vehicles and distribution networks: Analysis on vehicle to grid and renewable energy sources integration,” in *2019 11th Electrical Engineering Faculty Conference (BulEF)*, 2019, pp. 1–4. [Online]. Available: <https://doi.org/10.1109/BulEF48056.2019.9030787>
- [2] L. Wang, S. Sharkh, and A. Chipperfield, “Optimal decentralized coordination of electric vehicles and renewable generators in a distribution network using a search,” *International Journal of Electrical Power & Energy Systems*, vol. 98, pp. 474–487, 2018. [Online]. Available: <https://doi.org/10.1016/j.ijepes.2017.11.036>
- [3] K. Mahmud, G. E. Town, S. Morsalin, and M. Hossain, “Integration of electric vehicles and management in the internet of energy,” *Renewable and Sustainable Energy Reviews*, vol. 82, pp. 4179–4203, 2018. [Online]. Available: <https://doi.org/10.1016/j.rser.2017.11.004>
- [4] A. Ahmadian, M. Sedghi, B. Mohammadi-ivatloo, A. Elkamel, M. Aliakbar Golkar, and M. Fowler, “Cost-benefit analysis of V2G implementation in distribution networks considering PEVs battery degradation,” *IEEE Transactions on Sustainable Energy*, vol. 9, no. 2, pp. 961–970, 2018. [Online]. Available: <https://doi.org/10.1109/TSTE.2017.2768437>
- [5] R. R. Desai, R. B. Chen, and W. Armington, “A pattern analysis of daily electric vehicle charging profiles: Operational efficiency and environmental impacts,” *Journal of Advanced Transportation*, vol. 2018, p. 6930932, Jan 2018. [Online]. Available: <https://doi.org/10.1155/2018/6930932>
- [6] J. H. Angelim and C. de Mattos Affonso, “Probabilistic assessment of voltage quality on solar-powered electric vehicle charging station,” *Electric Power Systems Research*, vol. 189, p. 106655, 2020. [Online]. Available: <https://doi.org/10.1016/j.epsr.2020.106655>
- [7] S. Kumar, R. Saket, D. K. Dheer, J. B. Holm-Nielsen, and P. Sanjeevikumar, “Reliability enhancement of electrical power system including impacts of renewable energy sources: a comprehensive review,” *IET Generation, Transmission & Distribution*, vol. 14, no. 10, pp. 1799–1815, 2020. [Online]. Available: <https://doi.org/10.1049/iet-gtd.2019.1402>
- [8] C. W. Villanueva Machado, M. F. Bedriñana Aronés, and J. E. Luyo Kuong, *Planificación de expansión de transmisión bajo condiciones de máxima generación con recursos energéticos renovables*. Universidad Nacional de Ingeniería, 2018. [Online]. Available: <https://bit.ly/3XfQZ8b>
- [9] S. Pirouzi, J. Aghaei, T. Niknam, H. Farahmand, and M. Korpås, “Exploring prospective benefits of electric vehicles for optimal energy conditioning in distribution networks,” *Energy*, vol. 157, pp. 679–689, 2018. [Online]. Available: <https://doi.org/10.1016/j.energy.2018.05.195>
- [10] S. Lazarou, V. Vita, C. Christodoulou, and L. Ekonomou, “Calculating operational patterns for electric vehicle charging on a real distribution network based on renewables’ production,” *Energies*, vol. 11, no. 9, 2018. [Online]. Available: <https://doi.org/10.3390/en11092400>
- [11] D. Schmerler Vainstein, J. C. Velarde Sacio, and B. Rodríguez González, Abel Solís Sosa, *Electromovilidad. Conceptos, políticas y lecciones aprendidas para el Perú*. Osinergmin, 2019. [Online]. Available: <https://bit.ly/3NBY53W>
- [12] AAP, *Los protagonistas de la nueva era automotriz: Vehículos eléctricos e híbridos en el Perú*. Asociación Automotriz del Perú, 2019. [Online]. Available: <https://bit.ly/465w2kl>
- [13] C. Villanueva, J. Luyo, A. Delgado, and C. Carbajal, “Electric vehicle aggregator participation in energy markets considering uncertainty travel patterns,” *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, vol. 8, no. 12, pp. 4994–4998, 2019. [Online]. Available: <https://doi.org/10.35940/ijitee.L3747.1081219>
- [14] R. Jing, M. Wang, Z. Zhang, X. Wang, N. Li, N. Shah, and Y. Zhao, “Distributed or centralized? designing district-level urban energy systems by a hierarchical approach considering demand uncertainties,” *Applied Energy*, vol. 252, p. 113424, 2019. [Online]. Available: <https://doi.org/10.1016/j.apenergy.2019.113424>
- [15] A. Dammert, R. García Carpio, and F. Molinelli, *Regulación y supervisión del sector eléctrico*. Fondo Editorial Pontificia Universidad

- Católica del Perú, 2013. [Online]. Available: <https://bit.ly/3p7rIQW>
- [16] PSCAD, *IEEE 14 Bus System*. Manitoba HVDC Research Centre, 2014. [Online]. Available: <https://bit.ly/3CxmAZt>
- [17] T. Khatib and W. Elmenreich, “A model for hourly solar radiation data generation from daily solar radiation data using a generalized regression artificial neural network,” *International Journal of Photoenergy*, vol. 2015, p. 968024, Oct 2015. [Online]. Available: <https://doi.org/10.1155/2015/968024>
- [18] A. Babajide and M. C. Brito, “Solar PV systems to eliminate or reduce the use of diesel generators at no additional cost: A case study of Lagos, Nigeria,” *Renewable Energy*, vol. 172, pp. 209–218, 2021. [Online]. Available: <https://doi.org/10.1016/j.renene.2021.02.088>