



Universidad de Jaén

Escuela de Doctorado

TESIS DOCTORAL

**PLANIFICACIÓN ÓPTIMA DE UNA  
COMUNIDAD ENERGETICA CON ENERGÍAS  
RENOVABLES EMPLEANDO SISTEMAS  
FOTOVOLTAICOS**



# Resumen

Este trabajo presenta una nueva herramienta para la planificación óptima de paneles fotovoltaicos en comunidades energéticas (CE). La propuesta desarrollada aborda la complejidad de este problema al representar el espacio de decisión para cada año y día durante la vida útil del proyecto, que normalmente se extiende entre 25 y 30 años. Este enfoque resulta en un problema de optimización a gran escala que podría ser inasequible para los solucionadores y máquinas convencionales.

Para superar este desafío, se han propuesto dos contramedidas. En primer lugar, se aplicó una técnica de reducción de datos para disminuir el número de días considerados a lo largo de un año. Esto resultó en un conjunto mínimo de perfiles representativos. En segundo lugar, el problema se descompuso en una estructura esclava que con la ayuda del algoritmo de descomposición de Benders. La nueva metodología ofrece varias ventajas, incluida la reducción de la carga computacional, la filosofía natural de múltiples cortes y la capacidad de incorporar parámetros de degradación e inflación a largo plazo.

Además, en este estudio se empleó un enfoque híbrido para calcular el estado de carga (SoC) de las baterías de iones de litio. En primer lugar, se modeló la batería con precisión utilizando el optimizador de African Vultures (AVOA), una técnica de optimización eficaz para modelar sistemas no lineales como las baterías de iones de litio. Luego, se utilizó un método híbrido que combina el conteo de Coulomb (CCM) con el Filtro de Kalman No Lineal Adaptativo (AUKF) para la estimación del SoC.

El AUKF se empleó inicialmente para corregir el valor inicial y eliminar cualquier error en las primeras lecturas, y luego el CCM continuó estimando el SoC durante un largo período de trabajo. Este método híbrido se comparó con otros métodos similares, como el CCM con un Filtro de Kalman Extendido (EKF), el CCM con un Filtro de Kalman No Lineal (UKF) y el CCM con un Filtro de Kalman Extendido Adaptativo (AEKF). Los resultados de la simulación mostraron que la combinación propuesta de CCM con AUKF demostró una validación dinámica excepcional y una capacidad sobresaliente en todas las situaciones.

# Astract

This paper presents a new tool for the optimal planning of photovoltaic panels in energy communities (EC). The developed proposal addresses the complexity of this problem by representing the decision space for each year and day during the useful life of the project, which typically extends between 25 and 30 years. This approach results in a large-scale optimization problem that could be unaffordable for conventional solvers and machines.

To overcome this challenge, two countermeasures have been proposed. First, a data reduction technique was applied to decrease the number of days considered over the course of a year. This resulted in a minimal set of representative profiles. Second, the problem was broken down into a slave structure that with the help of the Benders decomposition algorithm. The new methodology offers several advantages, including reduced computational load, the natural philosophy of multiple slices, and the ability to incorporate long-term degradation and inflation parameters.

In addition, a hybrid approach was employed in this study to calculate the state of charge (SoC) of lithium-ion batteries. First, the battery was modeled accurately using the African Vultures Optimizer (AVOA), an effective optimization technique for modeling nonlinear systems such as lithium-ion batteries. Then, a hybrid method combining the Coulomb count (CCM) with the Adaptive Nonlinear Kalman Filter (AUKF) was used for SoC estimation.

The AUKF was initially employed to correct the initial value and eliminate any errors in the first readings, and then the MCC continued to estimate the SoC over a long period of work. This hybrid method was compared with other similar methods, such as MCC with an Extended Kalman Filter (EKF), MCC with a Nonlinear Kalman Filter (UKF), and MCC with an Adaptive Extended Kalman Filter (AEKF). The results of the simulation showed that the proposed combination of CCM with AUKF demonstrated exceptional dynamic validation and outstanding capability in all situations.

# Contenidos

Lista de Figuras.....	x
Lista de Tablas .....	xii
Chapter 1: Introduction, Objectives, and Thesis structure.....	14
1.1 Context and Motivation .....	14
1.2 Thesis Objectives .....	17
1.3 Thesis Layout.....	18
Capítulo 2: Energías renovables .....	20
2.1 Antecedente.....	20
2.2 Energía sustentable global .....	23
2.3 Desarrollo y aplicación de tecnologías fotovoltaicas.....	26
2.4 Comunidades eléctricas fotovoltaicas.....	27
2.5 Estudios realizados de sistemas de arreglos fotovoltaicos.....	29
2.6 Estimacion del SoC en baterías de Litio .....	33
2.7 Sistemas híbridos de estimación del Soc .....	35
2.8 Conclusiones .....	37
Capítulo 3: Planificación Óptima de Paneles Fotovoltaicos en Comunidades Energéticas .....	38
3.1 Descripción del sistema .....	39
3.2 Caracterización de datos .....	40
3.3 Modelo matemático del sistema.....	42
3.3.1 Función objetivo .....	42
3.3.2 Restricciones de planificación .....	43
3.3.3 Limitaciones a nivel comunitario.....	49
3.3.4 Variación de parámetros a largo plazo.....	50
3.4 Propuesta de estrategia de solución .....	51
3.4.1 Descomposición de Benders .....	53
3.4.2 Problema maestro.....	55
3.4.3 Subproblemas.....	55
3.4.4 Simulación del algoritmo .....	57
3.5 Caso de estudio .....	58
3.5.1 Datos de entrada.....	58
3.5.2 Algoritmo de análisis .....	60
3.5.- Conclusiones .....	63

---

Capítulo 4: Estimation of Lithium-Ion Battery.....	65
4.1  Introducción.....	65
4.2  Modelado de la batería de Iones de Litio.....	66
4.2.1  Ecuaciones de estado de carga.....	67
4.2.2  Objetivos y limitaciones del problema de estimación del SoC del modelo de batería de iones de litio.....	69
4.2.3  Método híbrido: conteo de Coulomb y filtro de Kalman adaptativo no centrado.....	70
4.2.4  Filtro de Kalman no lineal adaptativo.....	72
4.2.5  Covarianza del ruido del sistema adaptativo ( $Q_j$ ).....	75
4.2.6  Covarianza del ruido de observación del sistema adaptativo ( $R_j$ ).....	76
4.3  Simulación y resultados.....	77
4.3.1  Simulación de aproximación 1.....	79
4.3.2  Simulación de aproximación 2.....	81
4.3.3  simulación de aproximación 3.....	82
4.3.4  Simulación de aproximacion 4.....	83
4.4  Conclusiones.....	85
Capítulo 5: Resultados.....	86
5.1  Resultados de la planificación optima de paneles fotovoltaicos en comunidades energéticas.....	86
5.1.1  Coste del proyecto.....	90
5.1.2  Limitaciones y posibles aplicaciones.....	95
5.2  Resultados de cálculo de SoC.....	96
Capítulo 6: Conclusiones y Futuros trabajos.....	100
6.1  Conclusiones.....	100
6.2  Futuros trabajos.....	103
Apéndice A: Curriculum Vitae.....	104
Apéndice B: Contribuciones.....	105
Bibliografía.....	106

## Nomenclatura

<b>Simbolo</b>	<b>Descripción</b>
SoC	Estado de carga de la batería
ESS	Sistemas de almacenamiento de energía
BMS	Sistema de gestión de la batería
ISE	Error cuadrado integral
ECM	Modelo de circuito equivalente
OCV	Voltaje de circuito abierto
CCM	Método de conteo de Coulomb
EKF	Filtro de Kalman extendido
UKF	Filtro Kalman no lineal
AKF	Filtro de Kalman adaptativo
AEKF	Filtro de Kalman extendido adaptativo
AUKF	Filtro Kalman no lineal adaptativo
AVOA	Algoritmo de optimización African Vultures
EMF	Fuerza electromotriz
UB	Límite superior
LB	Límite inferior
SEI	Interfaces de electrolitos sólidos
Ah	Amperios-hora
$SoC_0$	El valor inicial del estado de carga
$V_{ocv}$	Voltaje de circuito abierto de la batería
$R_o$	Resistencia de la batería en serie
$R_{tr}$	Resistencia transitoria de la batería
$C_{tr}$	Capacitancia transitoria de la batería
$V_{tr}$	El voltaje a través de la rama de polarización de la batería
$I_{Ctr}$	Flujos de corriente en la capacitancia de polarización de la batería
$I_{batt}$	Corriente del terminal de la batería
$\tau_s$	Sampling time
$\tau_{tr}$	Constante de tiempo transitoria
$V_{nom}$	Battery nominal voltage
$V_{dis}$	Voltaje de descarga de la batería

$Q$	Capacidad nominal de la batería
$Q_{dis}$	Capacidad de descarga de la batería
$V_t$	Voltaje del terminal de la batería
$n$	Número total de ciclos de descarga
$N$	Número de ciclos de descarga
$F_i(U)$	Función objetivo
$nob f$	Número de funciones de objetivo
$U_{min}, U_{max}$	Límites de parámetros para el factor de la variable de control
$SoC_{measured}$	Estado de carga esperado del modelo de batería
$SoC_{experimental}$	Estado de carga de la batería experimental registrado
$Q_{min}, Q_{max}$	Valores máximos y mínimos de ( $Q$ )
$R_{o_{min}}, R_{o_{max}}$	Valores máximos y mínimos de ( $R_o$ )
$R_{tr_{min}}, R_{tr_{max}}$	Valores máximos y mínimos de ( $R_{tr}$ )
$\tau_{tr_{min}}, \tau_{tr_{max}}$	Valores máximos y mínimos de ( $\tau_{tr}$ )
$\eta$	Eficiencia del conteo de Coulomb
$\alpha$	El coeficiente alfa controla la aparición de puntos sigma y minimiza el error de aproximación.
$\beta$	El coeficiente beta controla la aparición de puntos sigma y minimiza el error de aproximación.
W	Ventana de longitud móvil
Y	Año
R	Día representativo
N	Par
t	Tiempo
a (A I/NI)	Aparato controlable interrumpible/no interrumpible
$\Omega_r$	Cluster del $r$ th día representativo
$\Theta$	Ventana de tiempo de un aparato controlable o vehículo eléctrico
PV	Fotovoltaico
inv	Inversor
M	administrador
G, i/e	Importado/exportado desde/hacia la red de distribución
D	Demanda no flexible
B, c/d	Baterías en modo de carga/descarga



$EV, c/d$	Vehículo eléctrico en modo de carga/descarga
$H, heat/cool$	Sistema de calefacción-ventilación-aire acondicionado en modo calefacción/refrigeración
$H, sp/db$	Punto de asiento/banda muerta de la calefacción-ventilación-aire
$Air\_in/out$	Aire interior/exterior
$(\cdot)/\overline{(\cdot)}$	Valor mínimo/máximo de una variable o parámetro
$\overline{(\cdot)}$	Valor dado/calculado
$\Delta\tau$	Intervalo de tiempo (h)
$C$	Costos de capital e instalación (€/kWp)
$c^{inv}$	Vector auxiliar cuyo $y^{th}$ es igual a 1 si el inversor tiene que ser reemplazado durante el $y^{th}$ año
$o^{PV}$	Coste de operación y mantenimiento de paneles fotovoltaicos (pu/kWp-año)
$r$	Tipo de interés (pu)
$\Pi$	Presupuesto disponible (€)
$inf$	Tasa de inflación (pu)
$LG$	Tasa de crecimiento de la carga (pu)
$deg^{PV}$	Tasa de degradación de los paneles (pu)
$g^{PV}$	Potencial fotovoltaico en función de los parámetros meteorológicos
$\eta$	Eficiencia
$\delta$	Ciclo de trabajo de los aparatos controlables (h)
$m$	Masa (kg)
$\gamma$	Capacidad térmica (kJ/kg °C)
$R$	Resistencia térmica del edificio (J/°C) COP
$\mu$	Sensibilidad (€/kWp)
$p^{PV}$	Potencia máxima de la matriz fotovoltaica (kWp)
$p$	Potencia (kW)
$u$	Estado del compromiso (binary) SOC
$\alpha$	Auxiliary variable to model costs (€)

# LISTA DE FIGURAS

Fig. 1. 1 - Sketch of the considered cooperative EC.....	15
Fig. 1. 2 - Thesis Layout .....	18
Fig. 2. 1 – a) sistema híbrido conectado a la red b) sistema híbrido sin conexión a la red. .....	23
Fig. 2. 2 - Generación eléctrica mundial 2022 por subregiones [ TWh, %] .....	24
Fig. 2. 3 - Generación eléctrica renovable en relación a la generación total [ %] .....	25
Fig. 2. 4 – Capacidad eléctrica instalada para generación eléctrica [ MW; %] .....	25
Fig. 2. 5 – Capacidad anual de energía fotovoltaica instalada mundial.....	27
Fig. 3. 1 - Esquema de la CE considerada cooperativa.....	39
Fig. 3. 2 - Diagrama de flujo conceptual de la descomposición de los dobladores multicorte. ....	54
Fig. 3. 3 - Tiempo medio de iteración para diferentes tamaños de problemas. ....	61
Fig. 3. 4 - Validación del modelo de campo. ....	63
Fig. 4. 1 – Modelo de batería de Iones de Litio .....	66
Fig. 4. 2 - Diagrama de la estimación del SoC .....	68
Fig. 4. 3 Diagrama de flujo de AUKF. ....	77
Fig. 4. 4 - Curvas de convergencia para la aproximación de la batería de iones de litio (1). .....	81
Fig. 4. 5 - Curvas de convergencia para la aproximación de la batería de iones de litio (2). .....	82
Fig. 4. 6 - Curvas de convergencia para la aproximación de la batería de iones de litio (3). .....	83
Fig. 4. 7 - Curvas de convergencia para la aproximación de la batería de iones de litio (4). .....	84
Fig. 5. 1 – Precio de la energía según el horario.....	87
Fig. 5. 2 – Temperatura exterior según el horario.....	88
Fig. 5. 3 Potencial PV en relación al horario. ....	88

Fig. 5. 4 – Demanda no flexible de potencia en kWh de cada par de la comunidad. ....	89
Fig. 5. 5 - Validación del modelo de campo. ....	90
Fig. 5. 6 - Energía total importada (arriba) y exportada (abajo) por la comunidad para diferentes presupuestos. ....	91
Fig. 5. 7 - Energía total importada (arriba) y exportada (abajo) por la comunidad anualmente a lo largo de la vida útil del proyecto.. ....	92
Fig. 5. 8 - Distribución de costos para diferentes presupuestos. ....	93
Fig. 5. 9 - Resultado de la programación para diferentes presupuestos (en esta figura, potencia negativa significa potencia exportada). ....	94
Fig. 5. 10 - Resultado de programación para diferentes años (en esta figura, potencia negativa significa potencia exportada).....	95
Fig. 5. 11 - SoC estimado y SoC experimental antes de usar un modelo y una estimación precisos .....	98
Fig. 5. 12 - SoC estimado y SoC experimental después de utilizar un modelo preciso y una técnica de estimación. ....	99

## LISTA DE TABLAS

Tabla 3. 1 – Datos de usuarios .....	59
Tabla 3. 2 – Datos del proyecto. ....	60
Tabla 4. 1 – Constantes de la batería de iones de litio .....	78
Tabla 4. 2 – Constantes de la batería de iones de litio .....	79
Tabla 4. 3 Límites de los parámetros de la batería de iones de litio. ....	79
Tabla 4. 4 – Enfoque (1): parámetros optimizados de la batería de iones de litio a diferentes valores de SoC.....	80
Tabla 4. 5 – Aproximación (1): Error del SoC de la batería de iones de litio utilizando técnicas híbridas comparativas. ....	80
Tabla 4. 6 – Enfoque (2): parámetros optimizados de la batería de iones de litio a diferentes valores de SoC.....	81
Tabla 4. 7 – Aproximación (2): Error del SoC de la batería de iones de litio utilizando técnicas híbridas comparativas. ....	81
Tabla 4. 8 – Enfoque (3): parámetros optimizados de la batería de iones de litio a diferentes valores de SoC.....	82
Tabla 4. 9 – Enfoque (3): Error de SoC de batería de iones de litio utilizando técnicas híbridas comparativas.. ....	83
Tabla 4. 10 – Enfoque (4): parámetros optimizados de la batería de iones de litio a diferentes valores de SoC.....	84
Tabla 4. 11 – Enfoque (4): Error de SoC de batería de iones de litio utilizando técnicas híbridas comparativas.. ....	84
Tabla 5. 1– Datos de cada par de la comunidad .....	89
Tabla 5. 2 – Valor objetivo de la batería de iones de litio utilizando técnicas comparativas híbridas para el enfoque (1). ....	96
Tabla 5. 3 – Valor objetivo de la batería de iones de litio utilizando técnicas comparativas híbridas para el enfoque (2). ....	97
Tabla 5. 4 – Valor objetivo de la batería de iones de litio utilizando técnicas comparativas híbridas para el enfoque (3). ....	97
Tabla 5. 5 – Valor objetivo de la batería de iones de litio utilizando técnicas comparativas híbridas para el enfoque (4). ....	97

Tabla 5. 6 – Valores de error de SoC en todos los enfoques que utilizan métodos de estimación individuales.....97

# **CHAPTER 1: INTRODUCTION, OBJECTIVES, AND THESIS STRUCTURE**

## ***1.1 Context and Motivation***

The deregulation of the electricity sector calls for new business opportunities and cooperative structures that seek for a more active participation of end users. In this context, energy communities (ECs) arise as a regulatory framework that empower end-users to actively engage in local trading with other users as well as promoting a coordinated participation in electricity markets [1]. In essence, an EC can be conceived as an aggregation of residential installations which engage in energy trading and, in consequence, are seen as a unique entity by the upscale distribution network [2]. From the point of view of end-users, partaking in ECs might bring notable advantages. For instance, individual resources can be shared in order to improve the economy and efficiency of the group. In this sense, resources such as local renewable generation and storage can be shared in a coordinated way with the objective of reducing the energy cost of the entire community in a practise commonly known as peer-to-peer (P2P) [3]

Other practise consists in installing collective assets which can be used by the entire community according to pre-established sharing rules [4]. For instance, different cooperative rules are proposed in Guedes et al. (2023) to regulate the access to collective

storage and photovoltaic (PV) in ECs. However, collective assets must be properly designed in order to maximize their social benefit, which ad-vocates for developing optimization techniques devoted on planning collective assets in ECs. Intuitively, the particularities of ECs should be taken into account when properly designing such collective assets. This way, P2P trading, the presence of individual assets and interaction with the distribution network should be considered. In this regard, planning tools for ECs differ from others methods available for other systems such as microgrids or virtual power plants. Indeed, some concepts like P2P or management of individual assets are irrelevant in such systems, but important in ECs. This work focuses on this issue, more precisely, a novel methodology for optimal planning collective PV arrays in ECs is proposed. The Fig 1.1 shows the schematic of a cooperative energy community.




Fig. 1. 1 - Sketch of the considered cooperative EC.

This work focuses on energy communities powered by a collective array of photovoltaic panels, a community manager, peers and the power distribution network in this context the detailed modeling of all the features intrinsic to the planning problems in the ECs requires stating a large number of variables. For example, the modeling of PV panel degradation or load growth. In addition, the inclusion of binary variables is required to model some components. Therefore, community planning problems are often posed as large-scale MILP frameworks, which are challenging for conventional methodologies, especially if the number of prosumers within the community is large and their behavior is modeled in detail.

By the circumstances exposed above, novel planning methodologies for ECs should focus on alleviating the intrinsic computational burden of the problem, without lying in oversimplifications that may lead to inaccurate results. For example, optimal managing of HVAC systems and CAs directly impact on the economy of the community [5]. However, properly modelling the characteristic functioning of such devices need detailed mathematical models, which cannot be ignored or simplified to attain accurate results.

To address these issues, it is proposed a solution methodology based on the Benders' decomposition for planning problems in ECs. Good results reported for similar problems lead us to think that the application of this methodology in ECs is promising. For example, the Benders' decomposition, or some of its variants, have been applied to transmission network expansion [6] or unit commitment problems, which typically involve a large number of continuous and binary variables [7] [8].

On the other hand the measuring the SoC of a Li-ion battery has proven to be a significant obstacle to correctly estimating it. Due to the intricate electrochemical processes taking place inside a Li-ion battery [9], SoC is not directly measurable due to the nonlinear connection between the SoC and OCV of the battery. It must be measured using voltage, current, and temperature measurements; hence why the precise calculation of SoC for battery simulation is a current research topic [10]. Accurate SoC estimation is a primary task in BMS by helping to improve the system implementation and precision and lengthening the service life of the battery [11]. It can also prevent unexpected system outages, keep the Li-ion battery from being overcharged or under-charged, which might permanently harm the battery's internal structure, and it enables the development of logical control schemes for energy conservation [12].

Before estimating the State of Charge (SoC), it is essential to accurately model the characteristics of the Li-ion battery using an Equivalent Circuit Model (ECM). This modeling includes various parameters such as the battery's series resistance, the transient branch (comprising polarization resistance and capacitance), and the Open Circuit Voltage (OCV) of the battery at different SoC values, temperatures, and loading conditions, considering battery fading effects. Once the battery is adequately modeled, SoC estimation involves predicting the state of charge and then refining this estimation using measurements of voltage, current, and temperature [13]. This meticulous process ensures a precise assessment of the state of charge and an accurate representation of battery behavior, thereby facilitating research into the dynamic response of Li-ion batteries..



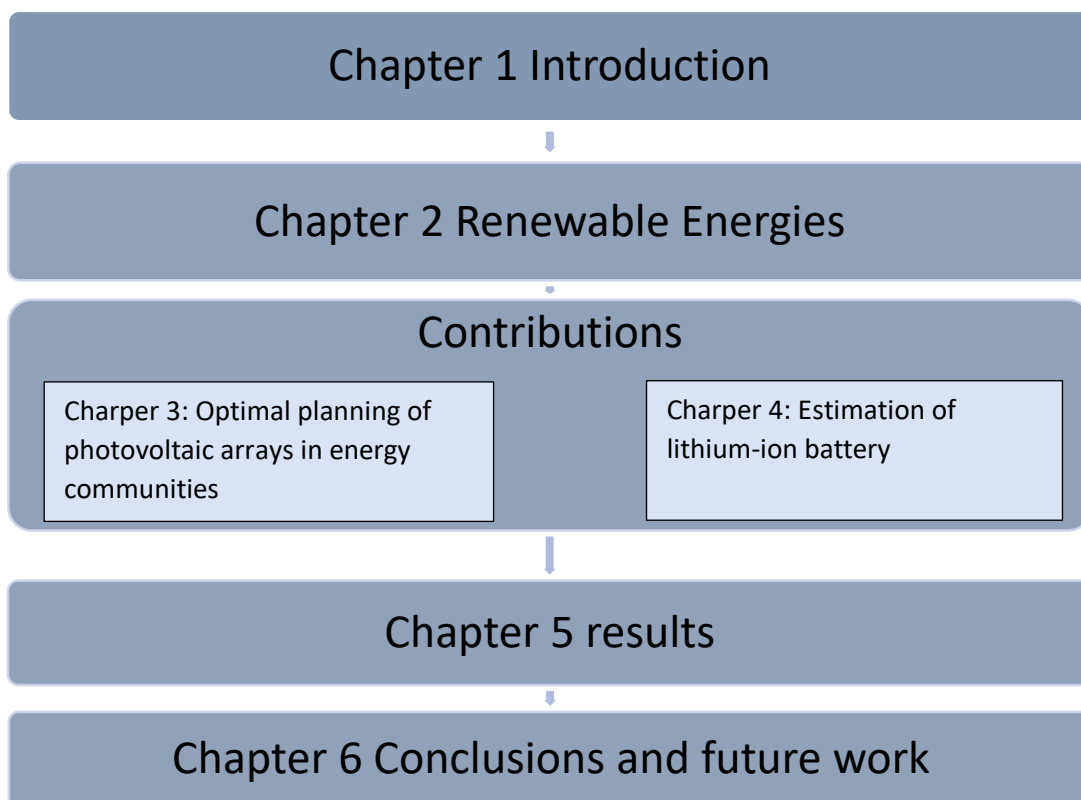
## **1.2 Thesis Objectives**

- Develop methodologies for the optimal planning of photovoltaic systems in order to improve the efficiency and sustainability of community energy communities considering a long-term planning horizon.
- Research and apply data reduction techniques to address large-scale optimization problems, reducing computational complexity and facilitating the implementation of optimal planning of collective photovoltaic systems.
- Implement a reliable state-of-charge (SoC) estimation technique for lithium-ion batteries, using an accurate battery model to prevent damage and extend battery life.
- Improve the sizing models and algorithms of hybrid energy systems, allowing simulations to validate their efficiency before implementation in the field.

## 1.3 Thesis Layout

This thesis is structured as follows. After the introduction, a review of the use of renewable energies in community energy communities and the use of techniques to determine the SoC of lithium batteries in Section 2. Section 3 shows optimal planning of photovoltaic panels in energy communities. In Section 4, a hybrid method for obtaining the state of charge of lithium-ion batteries is proposed. Finally, the results and conclusions of the paper are presented.

The present thesis is composed of several chapters, each one with a specific purpose. A brief explanation of the content and objective of each chapter is given below, and the layout of the thesis is presented in Figure 1.2.



*Fig. 1. 2 - Thesis Layout*

Chapter 2 - Renewable Energy: This chapter describes the application of renewable energy in energy communities and how the SoC of a battery is calculated.

Chapter 3 – Optimal Planning of Photovoltaic Panels: This section presents the equations and mathematical models necessary for the efficient long-term planning of energy communities. In addition, it presents the results of the validation.

Chapter 4 – Estimation of the state of charge: this chapter presents an efficient model to determine the SoC of lithium-ion batteries from the battery simulation and validates the results by comparing other methods.

Chapter 5 – Results: This section discusses the main results of the research by analyzing the different optimization techniques and algorithms for obtaining the SoC.

Chapter 6 – Conclusions and future work: This chapter presents the main conclusions and possible future lines of research.

## **CAPÍTULO 2: ENERGÍAS RENOVABLES**

### **2.1 Antecedente**

En las últimas décadas, el notable aumento en la concentración de gases de efecto invernadero, principalmente debido a las actividades humanas, ha generado una creciente preocupación por el cambio climático. A la par, el aumento en el consumo mundial de energía ha impulsado el uso de fuentes no renovables, como los combustibles fósiles, el gas natural, la energía nuclear y el carbón. Sin embargo, se ha observado un crecimiento significativo en el uso de energías renovables, como la solar, eólica, hidroeléctrica, biomasa, geotérmica y mareomotriz. Estas energías son inagotables, respetuosas con el medio ambiente y contribuyen al desarrollo sostenible, mitigando las emisiones de gases de efecto invernadero y promoviendo la seguridad energética. Este capítulo explora la importancia de las energías renovables, sus beneficios y su papel fundamental en el desarrollo sostenible, así como sus limitaciones y perspectivas futuras.

La utilización de estas fuentes de energía renovable ofrece una amplia variedad de beneficios notables, ya que son fiables, rentables, producen un mínimo de residuos secundarios y, en última instancia, conducen al desarrollo sostenible. Estas fuentes pueden cubrir dos tercios de la demanda energética mundial y, por lo tanto, pueden contribuir

significativamente a mitigar las emisiones de gases de efecto invernadero y, en última instancia, el calentamiento global. Por lo tanto, la importancia de las fuentes renovables no puede ser subestimada [14].

El principal objetivo de la planificación energética es satisfacer la demanda de una ciudad, región o país a corto, mediano o largo plazo, en forma continua, con determinados parámetros de calidad y precios aceptables. Inicialmente, esta planificación se centraba exclusivamente en criterios económicos para el dimensionamiento de la estructura energética, priorizando los costos asociados a la producción e implantación de la infraestructura energética. Sin embargo, con el tiempo, han emergido aspectos sociales y ambientales como prioritarios. Los avances tecnológicos han permitido considerar las energías renovables como una opción para cambiar el modelo de aprovisionamiento energético. Los esfuerzos por satisfacer la demanda energética y disminuir el consumo de las fuentes no renovables se reflejan en varios países alrededor del mundo, como se evidencia en la firma del Protocolo de Kioto. Este protocolo establece objetivos para reducir las emisiones de gases de efecto invernadero, promoviendo la investigación, desarrollo e implementación de sistemas basados en fuentes de energías renovables [15] [16].

Las energías renovables variables, como la energía solar fotovoltaica y la energía eólica, son tecnologías clave para lograr la descarbonización del sector energético. Sin embargo, difieren significativamente de las fuentes convencionales de generación de energía. A medida que aumenta la proporción de energías renovables variables, estas diferencias generan numerosos desafíos en los sistemas eléctricos. La falta de abordar estos desafíos puede poner en peligro la fiabilidad del sistema eléctrico o el logro de los objetivos de descarbonización. Existen diversas tecnologías de solución disponibles para mitigar estos desafíos como los sistemas híbridos que incorporan energías renovables en los sistemas actuales de generación eléctrica. Sin embargo, factores como las condiciones meteorológicas, incluida la luz solar, la fuerza del viento y la temperatura ambiente, dificultan el dimensionamiento de los equipos que componen estos sistemas híbridos. Esto, a su vez, afecta a los costos de inversión necesarios para satisfacer de manera sostenible la demanda de energía [17] [18].

Una de las aplicaciones más prometedoras de la tecnología de energías renovables es la instalación de sistemas híbridos de energía en áreas remotas, donde la extensión de la red eléctrica es costosa y el costo del combustible aumenta drásticamente con la lejanía del

lugar. Estos sistemas, que integran fuentes de energía renovable como la fotovoltaica, la energía eólica o la hidroeléctrica a pequeña escala, ofrecen una alternativa realista a los generadores impulsados por motores para la generación de electricidad en tales áreas. Las investigaciones recientes en fuentes de energía renovable ha demostrado un excelente potencial como contribución complementaria a los sistemas convencionales de generación de energía, y se ha observado que los sistemas híbridos pueden reducir significativamente el costo total del ciclo de vida de las fuentes de alimentación autónomas, al mismo tiempo que proporcionan un suministro de electricidad más confiable mediante la combinación de diferentes fuentes de energía [19]. Estos sistemas, conocidos como sistemas de energía híbrida o sistemas integrados de energía renovable, combinan fuentes de energía renovable y convencionales con baterías de plomo-ácido para almacenamiento químico, equipos de acondicionamiento de energía y un controlador, lo que permite mantener la calidad de la energía de la red y utilizar el sistema convencional, ya sea un generador diésel o la red eléctrica, como generador de respaldo según sea necesario. Además los sistemas híbridos mitigan significativamente los problemas de intermitencia energética y mejoran la estabilidad de la red lo que los vuelve más rentables debido a la infraestructura compartida. Sin embargo un factor en contra de los sistemas de energía híbridos es el sistema de almacenamiento que si no tiene una buena optimización y gestión de energía, presenta inconvenientes por lo que se han desarrollado innovaciones tecnológicas como algoritmos de aprendizaje automático e inversores avanzados que podrían superar estos obstáculos por ende los sistemas híbridos de energía renovable tienen el potencial de satisfacer de manera sostenible las demandas energéticas futuras, siempre y cuando haya un esfuerzo concertado en investigación, inversión y formulación de políticas [20].

La tendencia actual en energías renovables se centra en la integración de sistemas fotovoltaicos (PV) y eólicos (WT) como un escenario híbrido prometedor tanto para aplicaciones conectadas a la red como desconectadas de ella. El objetivo principal es aprovechar la naturaleza complementaria de los recursos solares y eólicos para mejorar la confiabilidad, eficiencia y sostenibilidad del sistema. Estos sistemas híbridos son particularmente efectivos en ubicaciones remotas o aisladas donde la red eléctrica es inestable o no está disponible. Se desarrollan modelos matemáticos y simulaciones para evaluar el rendimiento del sistema bajo condiciones climáticas variables y requisitos de carga. Estos modelos suelen incluir ecuaciones para la producción y distribución de

energía, a menudo incorporando algoritmos de control avanzados para gestionar el flujo de energía entre las diferentes fuentes y unidades de almacenamiento [21].

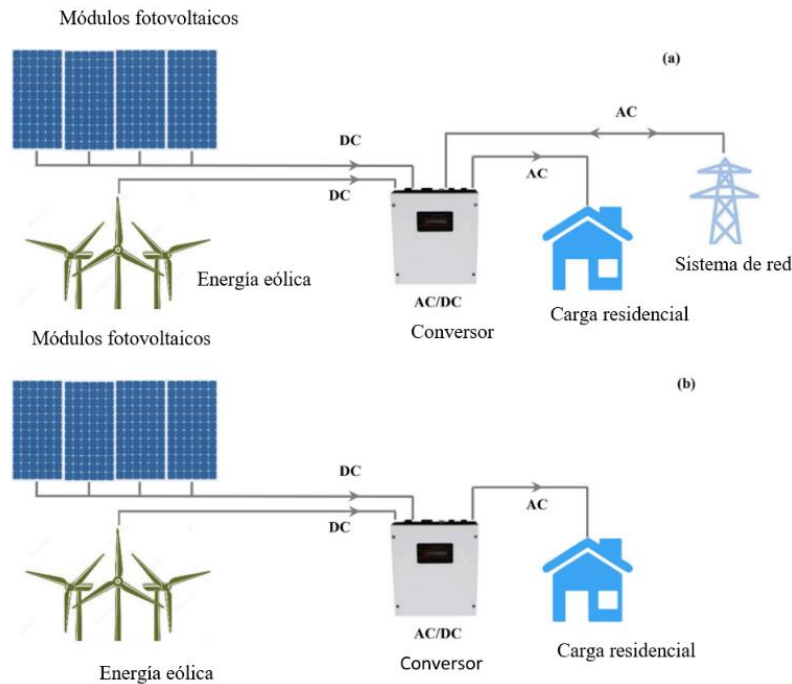


Fig. 2. 1 – a) sistema híbrido conectado a la red b) sistema híbrido sin conexión a la red.

## 2.2 Energía sustentable global

El aumento en el uso de sistemas de generación de energías sostenibles y renovables es una preocupación creciente en la mayoría de los países. En el año 2022, la generación eléctrica a nivel mundial alcanzó los 28,728 TWh, lo que representa un aumento del 1.15% en comparación con el año anterior. China fue el país que más energía eléctrica produjo, con un total de 13,994 TWh. En la Figura 2.1 se muestra la producción de energía a nivel mundial en 2022, incluyendo los datos correspondientes a América Latina y el Caribe (ALC) y sus respectivas subregiones [22] [23].

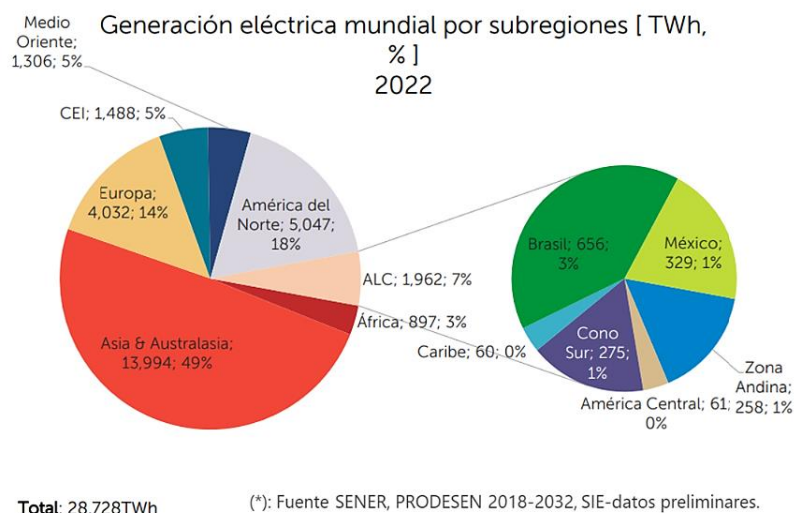


Fig. 2. 2 - Generación eléctrica mundial 2022 por subregiones [ TWh, %]

En la Unión Europea, se espera que la penetración de energías renovables variables (VRE, por sus siglas en inglés) en 2028 supere el 50% en nueve países, con más del 90% de la generación de energía de Dinamarca prevista para provenir de sistemas eólicos y fotovoltaicos solares. Sin embargo, esta transición hacia una mayor penetración de VRE también presenta desafíos, como la creciente congestión de la red eléctrica y la posibilidad de recortes de energía. Se proyecta que en 2028, los países de la Unión Europea alcancen una penetración de VRE de casi el 65% en España y más del 70% en Portugal. A pesar de las interconexiones de mercado de la UE que ayudan a integrar la generación de energía solar fotovoltaica y eólica, los cuellos de botella en la red eléctrica presentarán cada vez más desafíos y podrían resultar en recortes de energía. El recorte de la generación de energía fotovoltaica y eólica en España se triplicó en 2023 en comparación con 2022, principalmente debido a bajos precios. Se espera que el recorte de energía también aumente en países como Alemania, Irlanda, Reino Unido y Grecia, ya que la expansión de la red eléctrica no puede mantenerse al ritmo del crecimiento de las energías renovables variables. En la Figura 2.3 se muestra las proyecciones perdas de generación eléctrica de diferentes países [24].



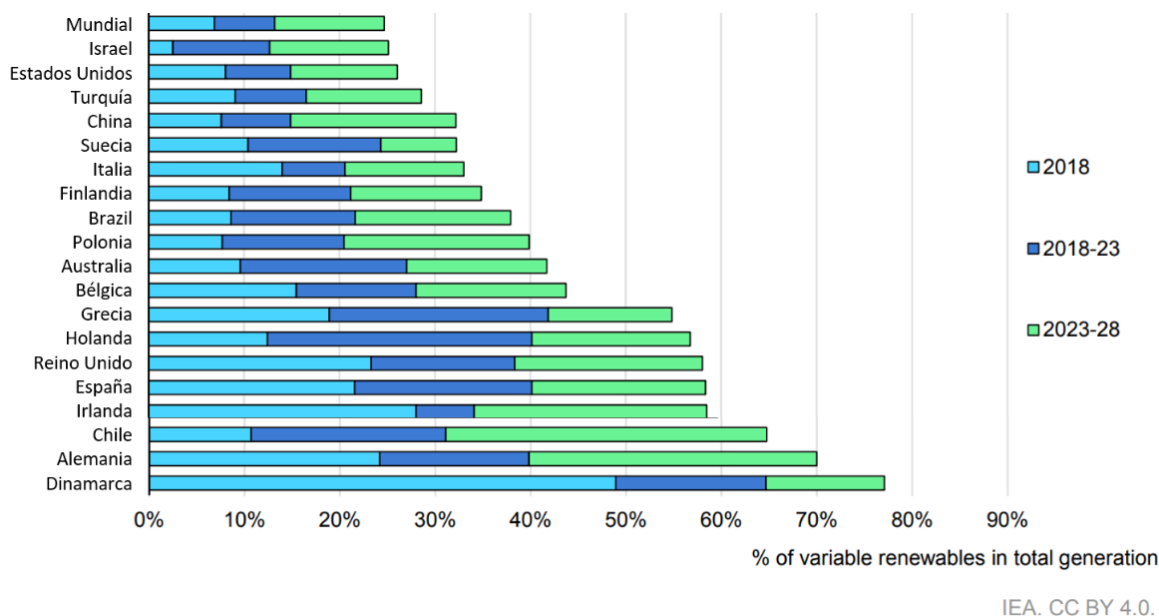


Fig. 2.3 - Generación eléctrica renovable en relación a la generación total [%]

La generación de electricidad a nivel mundial (Figura 2.4) sigue dependiendo en gran medida de recursos no renovables, los cuales representan el 62.8% de la electricidad producida. Los recursos hídricos son responsables del 15.63%, la energía nuclear del 10.39%, la energía eólica del 5.31%, la térmica renovable del 3.16%, la energía solar del 2.67% y la energía geotérmica del 0.04%. Por tanto a pesar de que algunos países siguen implementando generación eléctrica con fuentes renovables, la Figura 2.4 muestra que actualmente la matriz eléctrica mundial sigue dependiendo de fuentes de energía no renovables.

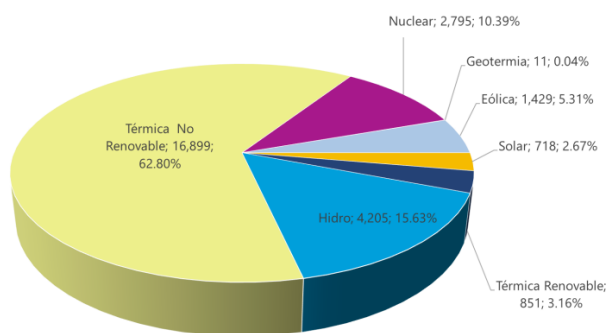


Fig. 2.4 - Capacidad eléctrica instalada para generación eléctrica [MW; %]

Con el crecimiento del uso de energía renovable generada por pequeñas unidades de generación distribuida, surgen algunos problemas recurrentes relacionados con la fiabilidad del sistema y la calidad de la energía generada. Las fuentes de energía renovable, como el sol y el viento, son intermitentes y generan variaciones que pueden causar

fluctuaciones impredecibles en el sistema de energía. El hecho de que la generación de energía a partir de fuentes renovables no esté sujeta a la demanda puede causar desequilibrios en el sistema de generación. Una forma de evitar este problema es mediante la incorporación de formas intermedias de almacenamiento de energía, como baterías, supercondensadores y volantes de inercia, lo que ayuda a minimizar los efectos de las variaciones inherentes al proceso de generación de este tipo de energía [25] [26].

## **2.3 Desarrollo y aplicación de tecnologías fotovoltaicas**

En el contexto de la diversidad de fuentes de energía renovable, la energía fotovoltaica es una de las tecnologías que está siendo estudiada para la generación de electricidad y aplicaciones industriales. La energía fotovoltaica aprovecha la radiación solar para generar electricidad de forma directa mediante el uso de paneles solares. Esta tecnología tiene el potencial de proporcionar una fuente de energía limpia y sostenible, especialmente en regiones con altos niveles de radiación solar. En este sentido, este estudio se centra en la evaluación de sistemas fotovoltaicos para la generación de electricidad y calor en zonas áridas, con el objetivo de maximizar la eficiencia y la sostenibilidad de la energía solar en estas regiones [27].

En los últimos años, la tecnología fotovoltaica solar ha experimentado avances significativos en eficiencia, costos y capacidad de almacenamiento de energía, lo que la ha convertido en una opción más viable para la generación de energía renovable y el almacenamiento. A pesar de estos avances, la intermitencia sigue siendo una limitación importante de la energía solar, y los sistemas de almacenamiento de energía son la solución preferida para estos desafíos en la generación de energía eléctrica. La necesidad creciente de fuentes de energía renovable y soluciones energéticas a largo plazo ha impulsado la investigación en materiales novedosos para sistemas fotovoltaicos solares, con un enfoque en aumentar la eficiencia de las células solares mediante la creación de materiales innovadores capaces de recolectar y convertir la luz solar en energía eléctrica [28].

Según la Agencia Internacional de Energía (AIE) la energía solar fotovoltaica ha tenido grandes crecimientos en los últimos años logrando incrementos de hasta 37% y se espera para el 2030 lograr incrementar la generación en 348 GW para reducir las emisiones contaminantes por el uso de combustibles fósiles.




Fig. 2. 5 – Capacidad anual de energía fotovoltaica instalada mundial.

Los países que más potencia instalada y con visión para futuros proyectos en generación de energía fotovoltaica son:

China es el líder mundial en generación fotovoltaica, con 414,5 GW, la Unión Europea 209,3 GW, Estados Unidos es el tercer país con más generación de energía fotovoltaica con 141,6 GW. Japón tiene instalada una capacidad de 84,9 GW, India dispone de 79,1GW, Alemania 67,2 GW, Australia 30GW, España 26,6 GW y dentro de América Latina Brasil es el país con mayor generación con 23,6 GW [29]

## 2.4 Comunidades eléctricas fotovoltaicas

Los sistemas de energía comunitaria, también conocidos como distritos inteligentes, son una configuración ideal para prevenir problemas locales y, al mismo tiempo, maximizar el potencial de respuesta a la demanda a partir de recursos locales, lo que está generando un interés creciente. Las fuentes de energía renovable, en particular aquellas basadas en la radiación solar, están creciendo rápidamente y se planea que jueguen un papel fundamental en la construcción de sistemas energéticos para alcanzar los objetivos de mitigación climática y energética para 2030 y 2050. Sin embargo, nuevos actores han sido introducidos en el campo energético, resaltando la importancia del papel de los ciudadanos y las comunidades en la construcción de dichos sistemas energéticos [30]. En particular, muchos

enfoques de modelado ahora reconocen explícitamente la importancia de modelar la generación, almacenamiento y consumo de energía, en lugar de simplemente la electricidad, tanto para la operación como para la inversión, en un contexto de sistemas multienergéticos. Los recursos de respuesta a la demanda en general, y los sistemas de energía comunitaria en particular, suelen incorporar múltiples vectores de energía, por lo que pueden considerarse sistemas multienergéticos a pequeña escala que pueden aprovechar su flexibilidad multienergética intrínseca [31] [32].

Desde un punto de vista mercantilista, las ECs, pueden clasificarse ampliamente en competitivas y cooperativas [5]. Las primeras aplican algunos arreglos de mercado local mediante los cuales el comercio de energía local se realiza bajo precios locales, revelados de manera distribuida o centralizada, de acuerdo con algunas reglas de mercado preestablecidas [33]. Por el contrario, las comunidades cooperativas buscan colectivizar el comercio de energía sin imponer mecanismos de fijación de precios locales. De esta manera, los prosumidores intercambian energía dentro de la comunidad sin esperar una contraparte monetaria, asumiendo así que el comercio de energía local mejorará la economía de la comunidad y, por lo tanto, cada miembro se beneficiará individualmente del intercambio de energía local [34].

Las ECs son reconocidas por la UE y el paquete de Energía Limpia como "acciones energéticas colectivas que fomentan la participación de los ciudadanos en todo el sistema energético". Actualmente, hay aproximadamente 5000 ECs en la UE en el año 2023, con alrededor de 4848 en Alemania y 73 en España. Además, existen varias iniciativas y proyectos de investigación sobre comunidades energéticas, entre los que se encuentra IEletrix. Las ECs suelen formarse en base a objetivos sociales y/o ambientales, y los participantes comparten o intercambian recursos energéticos de manera no comercial. En este trabajo, nos enfocamos en las Comunidades de Energía Renovable (RECs), que utilizan energía renovable producida localmente y sistemas de almacenamiento de energía con baterías (BESS). Dado el gran número de ECs existentes, la descentralización de la red y los objetivos de aumentar las ER, es natural concluir que estas RECs tendrán un impacto cada vez mayor en el sistema energético [35] [36].

Además, en la Unión Europea (UE), una comunidad de energía renovable se define como una entidad legal autónoma que gestiona activos energéticos y comparte la energía

generada localmente entre sus miembros. Estas comunidades presentan una gobernanza abierta y participativa, controlada por ciudadanos, autoridades locales y pequeñas y medianas empresas (PYMEs). Los responsables políticos europeos reconocen que las comunidades energéticas tienen numerosos beneficios, como la mitigación del cambio climático, el aumento de la seguridad del suministro energético local, la reducción de las pérdidas en la transmisión de energía y el apoyo a la economía local. Además, consideran que estas comunidades pueden aumentar la conciencia energética de los ciudadanos, facilitar la aceptación social de la infraestructura limpia y acelerar las inversiones privadas en la transición hacia la energía limpia [37]. Por último, los responsables políticos consideran que las comunidades energéticas son fundamentales para una transición energética justa e inclusiva, ya que permiten la participación activa de actores no tradicionales, como los hogares, las autoridades locales y las PYMEs, en la transición energética y, por lo tanto, disfrutar de mayores beneficios [38].

## **2.5 Estudios realizados de sistemas de arreglos fotovoltaicos**

Existe una serie de investigaciones que tratan de la gestión óptima de los activos colectivos en las comunidades energéticas. Estos trabajos asumen que los activos colectivos e individuales fueron diseñados antes del problema en cuestión, que normalmente se realiza diariamente durante un período de tiempo de 24 horas (programación diaria). En este sentido, el tamaño de los componentes se considera un parámetro fijo en lugar de una variable a calcular dentro del problema. Así, en [32], propusieron un programa de optimización lineal entero mixto estocástico para un sistema de energía comunitaria que deriva la flexibilidad a partir de diferentes factores energéticos como la calefacción y la electricidad [32]. También se han propuesto estudios que se centran en proporcionar reservas de frecuencia a la red de distribución a través de activos de almacenamiento local, formados por baterías estacionarias y vehículos eléctricos (VE) y estos se llevan a cabo en dos etapas: una planificación a futuro para estimar las capacidades flexibles disponibles y una programación en tiempo real para maximizar el beneficio de la comunidad. Los resultados muestran que los parámetros de control propuestos afectan significativamente la rentabilidad en tiempo real de la comunidad energética local (LEC) y que participar en el mercado como recursos energéticos flexibles puede aumentar sus ganancias. [39]. En [34],

se propuso una estrategia de programación diaria distribuida para las comunidades energéticas cooperativas, la cual preserva la privacidad de los usuarios. Los resultados confirman que, dentro del marco de la comunidad energética local y considerando a cada uno de los prosumidores, es posible reducir costos o aumentar ingresos al participar en la comunidad energética, en comparación con la situación en la que solo pueden realizar transacciones con un proveedor de energía externo.

Centrándose en el reparto del poder en las CE, se han propuesto plataformas para colectivizar la generación y el almacenamiento local. Sin embargo, solo un par debe actuar como agente activo, mientras que el resto de la comunidad sigue participando como consumidores pasivos [40]. Por otro lado, el acceso al almacenamiento y la negociación de riesgo se trataron en [33], [41] respectivamente. Para ello, se propusieron modelos innovadores de mercado local con el fin de permitir el almacenamiento colectivo y los intercambios de riesgo a través de los denominados valores Arrow-Debreu. También se han comparado diferentes esquemas peer-to-x en CE con cero emisiones netas. En particular, se han desarrollado diferentes modelos de comercio de energía que involucran una variedad de tecnologías de almacenamiento, lo que demuestra que se pueden lograr mejoras sustanciales mediante la implementación de estrategias P2P [42].

En [43], se desarrolló una novedosa estrategia operativa basada en reglas para las CE con cero emisiones netas, prestando especial atención a la gestión de los sistemas de almacenamiento híbridos (electricidad, calefacción y refrigeración). Con este fin, se propuso un marco multiobjetivo que incorpora tanto el coste de la energía como las emisiones de carbono, además que se optimiza la configuración del sistema de energía distribuida (DES) en relación con su entorno, economía e interacción neta, y se comparan y analizan sus características de rendimiento y operación. Del mismo modo, Doroudchi et al. [44], estudiaron la posibilidad de aumentar la autosuficiencia a través del almacenamiento térmico común, comparando el rendimiento general para diferentes tamaños de almacenamiento. También se ha desarrollado herramientas de gestión de la energía en varias etapas para compartir de forma óptima los recursos propios, como las baterías y la energía fotovoltaica, pero también la flexibilidad proporcionada por cargas elásticas como los aparatos controlables (CA) y los sistemas de calefacción, ventilación y aire acondicionado (HVAC) [5]. En [45], desarrollaron un modelo de negociación conjunta para la participación de prosumidores en CE que incorporan una demanda flexible a través

de dispositivos controlables. Para ello, se propuso un modelo de optimización multiobjetivo, que involucra el coste de la comercialización de energía con la red y otros pares, pero también un índice de incomodidad por el funcionamiento de las AC, mientras que en [46], se centran en gestionar de forma óptima las reservas de energía proporcionadas por los vehículos eléctricos agrupados en estaciones de carga. Además, se determinan los niveles óptimos de reserva hacia arriba y hacia abajo capaces de cubrir las fluctuaciones aleatorias en la generación fotovoltaica dentro de cada microrred basada en vehículos eléctricos mediante un conjunto de restricciones de probabilidad específicas. Las comunidades energéticas permiten una estrecha cooperación entre sus miembros (consumidores, productores y prosumidores), donde los edificios, recursos energéticos y cargas pueden ser gestionados a nivel de los miembros mientras colaboran con la comunidad. Para fomentar las interacciones entre los miembros de la comunidad, se pueden aplicar modelos de intercambio de energía. En [47], se plantea un modelo de distribución cooperativo para distribuir de manera óptima los costos dentro de una comunidad. Para ello, el valor de Shapley se utiliza como matriz para distribuir el coste energético. Otros estudios se centran en la gestión óptima del almacenamiento colectivo en las CE. Más específicamente, proponiendo una estrategia de licitación y programación basada en el riesgo, donde los límites inciertos del estado de carga (SOC) determinan la estrategia de gestión de la comunidad [48]. De manera similar en [49], estudiaron diferentes estrategias de compartición para el almacenamiento colectivo y la energía fotovoltaica. En particular, se desarrollaron y compararon mecanismos de reparto equitativo y proporcional como una forma de proporcionar acceso y derechos equitativos sobre el almacenamiento colectivo y la energía fotovoltaica. Las comunidades energéticas locales están surgiendo como una forma para los prosumidores y consumidores de invertir en fuentes de energía renovable distribuida, almacenamiento comunitario y compartir electricidad, en [50], estudiaron la cooperación entre las CE y las redes de distribución, centrándose en los beneficios que proporcionan los recursos flexibles locales para mejorar la estabilidad de la tensión. La importancia de los próximos vectores energéticos como el hidrógeno se estudió en [51], [52], donde se desarrolla una programación diaria de comunidades energéticas con sistemas integrados de almacenamiento de hidrógeno colectivo. También se creó una metodología de tres etapas que aborda la gestión energética individual en el hogar, el comercio de energía entre prosumidores y la interacción con la red eléctrica, teniendo en cuenta la cadena de hidrógeno. También se ha propuesto una estructura jerárquica donde una entidad central coordina un grupo de prosumidores con cargas y almacenamiento de

hidrógeno. El carácter reactivo al riesgo de los prosumidores se gestiona a través de precios locales en tiempo real y optimización estocástica [51]. Por otro lado en [53], se considera una cadena central de hidrógeno que proporciona almacenamiento colectivo a la comunidad.

Los estudios mencionados anteriormente se centran en el funcionamiento de los CE en lugar de planificar o diseñar sus componentes. En este sentido, el comercio de energía eléctrica (power trading) es la variable más típica que se tiene en cuenta, mientras que el dimensionamiento de los componentes se trata como un parámetro, asumiendo que los diferentes activos fueron diseñados previamente. La literatura sobre la planificación óptima de sistemas renovables híbridos es rica y abarca diferentes perspectivas. Por ejemplo, en [54], se analiza un estudio de caso que involucra diferentes generadores renovables, motores diésel y almacenamiento para el suministro de energía de un sistema aislado remoto. En este caso, los diferentes componentes se dimensionan utilizando HOMER® (Givler. HOMER Software, 2005), que busca la configuración que minimice el valor presente neto siguiendo diferentes lógicas de programación preestablecidas. En [55], se aborda la planificación óptima de la expansión de una central eléctrica virtual de fijación de precios, para la que se desarrolló un modelo exacto de Programación Lineal Entera Mixta (MILP). También se ha propuesto modelos de optimización multiobjetivo para el diseño de plantas renovables, mediante los cuales se minimiza tanto el coste energético como la autosuficiencia, utilizando como optimizador una hibridación de metaheurísticas y técnicas de ramificación y límites [56]. De manera similar en [57], se desarrolla un modelo de planificación MILP para la planificación óptima de una microrred rural respaldada por vehículos eléctricos a través de la capacidad de vehículo a red.

Las referencias [57], [54], [55] [56], abordan de manera efectiva la planificación óptima de generadores renovables o sistemas de almacenamiento. Sin embargo, estas referencias se centraron en las microrredes o centrales eléctricas virtuales en lugar de las EC. En las CE, considerar el comercio P2P entre prosumidores es de vital importancia. En este sentido, la literatura sobre la planificación óptima de activos colectivos en las CE es más escasa en comparación con los documentos que tratan sobre la operación óptima. También en esta categoría, la metodología propuesta por [35], considera un modelo de optimización lineal para el dimensionamiento óptimo de los sistemas de baterías fotovoltaicas en las CE. Para gestionar de forma óptima el funcionamiento del sistema de almacenamiento, se proponen y prueban diferentes estrategias. En consecuencia, el problema general de optimización se



reformula como un marco de optimización multiobjetivo, que se resuelve utilizando la metodología de restricción  $\epsilon$ . Del mismo modo, en [58], se propuso un enfoque de planificación multicriterio, que necesita calcular el frente de Pareto resolviendo el problema de optimización muchas veces para diferentes pesos.

Aunque los modelos de programación lineal son fáciles de resolver, algunas características de los EC requieren el uso de variables binarias (estado de encendido/apagado). Por ejemplo, los modos de carga y descarga de las baterías requieren el uso de estados de compromiso binarios para evitar la aceptación de soluciones físicamente irrealizables [59].

## **2.6 Estimación del SoC en baterías de Litio**

Los sistemas de almacenamiento de energía (ESS) se están volviendo esenciales en las redes eléctricas modernas debido al creciente uso de fuentes de energía renovable, caracterizadas por su incertidumbre y fluctuación. Además de su papel fundamental en el almacenamiento y la recuperación de energía, los componentes de almacenamiento de energía son cruciales para proporcionar servicios auxiliares al sistema anfitrión [60]. En numerosas aplicaciones, incluidas aquellas que involucran dispositivos electrónicos portátiles, automóviles eléctricos, componentes de satélites y sistemas de energía, las baterías de varios tipos desempeñan un papel crucial y determinar su estado de carga (SoC) es importante por lo tanto se han diseñado sistemas como el de inferencia neurodifusos adaptativos (ANFIS), que considera las características no lineales de las celdas, proporcionadas por el fabricante, para establecer la relación entre el SoC de la celda y el voltaje de circuito abierto (OCV) a diferentes temperaturas [61].

El desarrollo vigoroso de la tecnología de almacenamiento de energía ha llevado a que los vehículos eléctricos (EVs) se conviertan en una de las soluciones más representativas. Se prevé que para el 2030 habrá 117.6 millones de EVs en las carreteras de todo el mundo, lo que resultará en una reducción de 262 Mt. de emisiones de CO<sub>2</sub>. Las baterías de iones de litio, son ampliamente utilizadas en vehículos eléctricos puros e híbridos debido a su larga vida útil, alta densidad de energía, bajo índice de autodescarga, alta densidad de potencia, alta seguridad y alta confiabilidad. El Sistema de Gestión de Baterías (BMS) supervisa los parámetros de la batería, como el voltaje, la corriente, la temperatura y otros, para estimar el Estado de Carga (SOC) en tiempo real, y luego formula una estrategia de carga y descarga equilibrada para evitar la sobrecarga y la descarga

excesiva de la batería, y soluciona problemas del sistema para garantizar la salud de la batería y extender su vida útil. Como parámetro de estado interno de la batería, el SOC no puede ser obtenido directamente por el sensor, solo a través de sus parámetros característicos como corriente, voltaje, temperatura y otros, estimados por algunos algoritmos. La estimación precisa del SOC es la función más importante y compleja del BMS, y su método de estimación ha recibido una amplia atención por parte de académicos de todo el mundo [62].

En comparación con otros tipos comunes de baterías, las baterías de iones de litio tienen una alta densidad de energía, una baja tasa de autodescarga y una larga vida útil, lo que las convierte en una tecnología flexible y prometedora [63]. Sin embargo, la sobrecarga o la subcarga de las baterías de iones de litio pueden dañar permanentemente las celdas de la batería, reduciendo su vida útil y degradando su rendimiento. Por lo tanto, uno de los puntos críticos del Sistema de Gestión de Baterías (BMS, por sus siglas en inglés) es estimar con precisión SoC para reducir los riesgos de seguridad y prolongar la salud de la batería. Es así que, el método, denominado DSAR-UKF, utiliza un algoritmo de filtrado de Kalman adaptativo de raíz cuadrada dinámica. Se basa en un modelo de circuito equivalente de Thevenin de segundo orden y utiliza un método de mínimos cuadrados recursivos de ventana rectangular para identificar adaptativamente los parámetros de la batería en línea. Además, se introduce un método de coincidencia de covarianza de ruido basado en un filtro adaptativo para eliminar las incertidumbres e inexactitudes causadas por el ruido de medición del sistema variable en el tiempo [64]. Para determinar el SoC de la batería en tiempo real, el BMS observa las mediciones de la batería, como el voltaje, la corriente, la temperatura y otras variables. Luego, para evitar la sobrecarga y la sobre-descarga de la batería, preservar la salud de la batería y extender su vida útil, diseña un enfoque razonable para los fenómenos de carga y descarga de la batería de iones de litio. En la actualidad se han desarrollado nuevos métodos híbridos para estimar el SoC de la batería de manera precisa, como el método de aprendizaje incremental y la máquina de vectores relevantes (movIRVM), que integra técnicas como el promedio móvil, el aprendizaje incremental y la máquina de vectores relevantes, junto con el método de conteo de Coulomb. Esta combinación permite estimaciones precisas y robustas del SOC, evitando problemas de acumulación de errores y mejorando el rendimiento general del algoritmo [65].

## 2.7 Sistemas híbridos de estimación del SoC

El enfoque de estimación híbrido basado en distintos modelos para baterías de iones de litio combina varios algoritmos de estimación del estado de carga (SoC). Uno de los métodos de estimación más esenciales es el de los sistemas ajustables [66]. Estos son sistemas autoajustables, también conocidos como observadores, que pueden modificarse espontáneamente para adaptarse a cualquier cambio en el sistema. Uno de los sistemas ajustables más comúnmente utilizados en baterías es el EKF [67], que utiliza el enfoque de expansión de Taylor para extender el Filtro de Kalman tradicional a modelos no lineales para estimar las primeras y segundas derivadas. Estima los estados de tiempo discreto tomando dos puntos (media y aproximada). Este método proporciona buenos resultados, pero debido a que solo utiliza el primer término de la expansión, las soluciones en sistemas altamente no lineales no son precisas; por lo tanto, se utiliza otro filtro llamado UKF [68]. Es un miembro de la clase más importante de filtros conocidos como Filtros de Kalman de Puntos Sigma, que emplean una linealización estadística, y estima estados de tiempo discreto utilizando una colección de puntos llamados puntos sigma y puntos aproximados. Luego, utiliza transformaciones no lineales en el conjunto de puntos sigma que se eligen de manera determinista, con soluciones muy precisas en sistemas altamente no lineales. Para el EKF y UKF estándar, asumen incertidumbres fijas en los parámetros de error, y estas incertidumbres se propagan a través del filtro, lo que limita su efectividad. Por lo tanto, se utiliza el Filtro de Kalman Adaptativo (AKF) [69], [70]. Este filtro se adapta a cualquier cambio en los datos o en las incertidumbres del error mediante la definición de algunos parámetros del modelo que son desconocidos, lo que lo hace más preciso. Además este, utiliza dos modelos independientes para estimar el estado de un sistema dinámico: un modelo de observación que establece una relación entre las mediciones y el vector de estado, y un modelo dinámico que define el comportamiento del vector de estado. Los sistemas adaptativos proporcionan una opción valiosa para la estimación del SoC, ya que las baterías de iones de litio tienen relaciones no lineales de SoC y están influenciadas por varios efectos químicos .

Los métodos híbridos son modelos que se sitúan entre diferentes técnicas de estimación del SoC. Dado que la cantidad de información que se puede obtener de un solo enfoque de estimación está limitada, los modelos híbridos tienen como objetivo combinar los beneficios de cada método y lograr una estimación óptima [71]. Un enfoque híbrido

entre varios algoritmos de estimación puede aprovechar los beneficios más significativos de diferentes enfoques de estimación de SoC, combinar las entradas de modelos individuales y maximizar la información disponible, aumentando la precisión de la estimación. Hay varios tipos de métodos híbridos, uno de ellos combina del Método de Conteo de Coulomb (CCM) y el método Estructura de Fuerza Electroquímica (EMF), una técnica innovadora de estimación de SoC que ha sido diseñada y aplicada en sistemas reales de estimación de SoC con resultados satisfactorios. El método combina el uso de mediciones directas, mediciones de la FEM de la batería durante la etapa de equilibrio y estimaciones de contabilidad utilizando el enfoque CCM durante la condición de descarga [72].

Otro método es una combinación entre CCM y el Filtro de Kalman para la estimación SoC donde el Filtro de Kalman corrige el valor inicial utilizado para el CCM, y luego el CCM estima el SoC durante un largo período de trabajo [73]. También se utiliza el sistema híbrido entre el Sistema de Unidades Per-Unit y el Filtro de Kalman Extendido (EKF), esta combinación para caracterizar los parámetros del modelo de batería con una estimación muy precisa de SoC, utilizando los parámetros de la batería que son afectados por el efecto del envejecimiento, según el sistema PU. En el modelo de circuito equivalente, el voltaje terminal de la batería y la corriente, así como los valores absolutos de los parámetros, se modifican en magnitudes adimensionales en relación con un conjunto de magnitudes base. Las magnitudes modificadas se aplican luego a los modelos dinámicos y de observación en el método EKF [74]. Los enfoques mencionados anteriormente han dado buenos resultados pero presentan limitaciones en precisión y consistencia. En la actualidad también se utilizan sistemas con integración de inteligencia artificial para abordar el desafío de la estimación del SoC, estos modelos combinan las capacidades de cómputo paralelo de las redes convolucionales temporales con las sólidas habilidades de aprendizaje de las unidades recurrentes gateadas. Este modelo incorpora un mecanismo de atención para asignar dinámicamente pesos y centrarse en características relevantes basadas en correlaciones en la información histórica. Además, se emplea una función de pérdida de regresión de cuantiles durante el entrenamiento de la red, lo que dota al modelo de redes neuronales con la capacidad de generar directamente estimaciones de intervalos. El análisis comparativo con otros métodos de estimación de SOC demuestra su excepcional precisión en la estimación puntual y su alta fiabilidad en la estimación del intervalo de confianza [75].

## **2.8 Conclusiones**

En esta sección fueron descritos los funcionamientos de los sistemas de energías renovables y las comunidades energéticas que buscan avanzar hacia una matriz energética más sostenible y descentralizada. Además, se ha explicado el uso de la tecnología de arreglos fotovoltaicos en comunidades energéticas y el uso otras energías renovables. Los avances en la tecnología de estimación de baterías ofrecen una mayor precisión en la planificación y gestión de la energía, optimizando su uso y contribuyendo a la reducción de emisiones de gases de efecto invernadero. Estos sistemas juegan un papel crucial en la transición hacia una economía baja en carbono y son clave para alcanzar los objetivos de descarbonización y mitigación del cambio climático a nivel local y global.

## **CAPÍTULO 3: PLANIFICACIÓN ÓPTIMA DE PANELES FOTOVOLTAICOS EN COMUNIDADES ENERGÉTICAS**

---

Desde un punto de vista mercantilista, las comunidades energética (CE) se pueden clasificar a grandes rasgos en competitivas y cooperativas (Tostado-V'eliz et al., 2022). Los primeros aplican algunos acuerdos de mercado local en virtud de los cuales el comercio local de energía se realiza bajo precios locales, revelados de manera de distribución o centralmente (Vespermann et al., 2021a), de acuerdo con algunas reglas de mercado preestablecidas. Por el contrario, las comunidades cooperativas buscan colectivizar el comercio de energía sin imponer mecanismos locales de fijación de precios. De esta manera, los prosumidores intercambian energía dentro de la comunidad sin esperar una contrapartida monetaria (Lilla et al., 2020), asumiendo así que el comercio local de energía mejorará la economía de la comunidad y, por lo tanto, cada par se beneficiará individualmente del intercambio local de energía. Este documento se centra en las EC cooperativas que involucran a pares que eventualmente poseen activos locales, como almacenamiento a pequeña escala, CA y EV. Tenga en cuenta que no se tienen en cuenta los paneles individuales de los tejados, ya que este documento se centra en la planificación

óptima de los paneles fotovoltaicos colectivos. En este sentido, se asume que la instalación de un sistema fotovoltaico colectivo carece de sentido en presencia de instalaciones fotovoltaicas individuales.

### 3.1 Descripción del sistema

En la Fig 3.1 se muestra la CE estudiada, así como las interacciones que se producen entre los agentes participantes. El sistema está conformado por los miembros de la comunidad o pares iguales, un sistema de paneles solares común y se dispone de una entidad central, llamada administrador de la comunidad, esta es responsable de coordinar el comercio de energía con la red de distribución de energía (a través de un minorista) y los intercambios locales de energía entre iguales (P2P). Este agente recibe señales de precios del minorista y actúa en consecuencia. En el presente documento, se establece que las CE acuerdan una tarifa de fijación de precios en tiempo real (RTP), pero podrían considerarse otros mecanismos de fijación de precios, como el tiempo de uso. El RTP revela los precios locales de acuerdo con las señales del mercado y, por lo tanto, refleja efectivamente el estado del mercado mayorista. Cabe destacar que el RTP es incierto y varía cada día y hora [45]. Por lo tanto, se considera el RTP como un parámetro dinámico en la planificación.

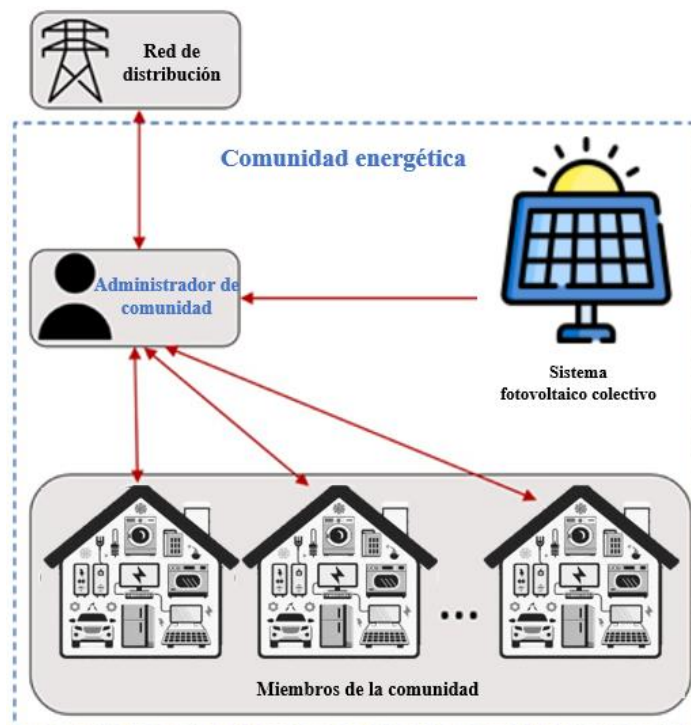


Fig. 3. 1 - Esquema de la CE considerada cooperativa.

Después de intercambiar energía con la red local y derivar el costo para toda la comunidad, dichos gastos se asignan a cada par siguiendo un mecanismo preestablecido por Mustika et al. [76], que presenta una estrategia de dos etapas con el objetivo de desvincular el cálculo de la factura de la gestión de activos a nivel comunitario, de esta manera, se asume que al minimizar el costo total de la comunidad también se reduce cada factura individual y por lo tanto conduce a maximizar el bienestar colectivo.

## **3.2 Caracterización de datos**

Los problemas de planificación energética requieren considerar una gran cantidad de datos para capturar todos los posibles eventos futuros a lo largo de la vida útil del proyecto. Por lo general, las instalaciones fotovoltaicas tienen una vida útil que oscila entre los 20 y 30 años [69], lo que coincide con la vida útil garantizada de los paneles fotovoltaicos comerciales. Esto implica que la planificación debe ser lo suficientemente flexible como para tener en cuenta los cambios en las condiciones ambientales, de mercado y tecnológicas a lo largo de este extenso período [70].

Sin embargo, tener en cuenta todos estos datos a lo largo de la vida útil del proyecto puede resultar inasequible en la práctica. En consecuencia, se han realizado esfuerzos de investigación encomiables para reducir esta carga sin incurrir en inexactitudes inaceptables. Dichas técnicas de reducción engloban estrategias de agregación o metodologías de aversión al riesgo, entre otras. Los primeros se centran en reducir el conjunto original de datos a un conjunto reducido de escenarios representativos, que se consideran una representación precisa del conjunto original [77]. Estos escenarios representativos se seleccionan cuidadosamente para cubrir una amplia gama de posibles condiciones futuras, minimizando así la pérdida de información significativa, por ende, el problema de optimización debe resolverse solo para el conjunto reducido en lugar de para todo el conjunto de datos, aliviando así notablemente la carga computacional.

Por otro lado, las metodologías de aversión al riesgo buscan desarrollar estrategias de planificación que sean robustas frente a la incertidumbre, reduciendo al mínimo el impacto de los eventos adversos que puedan surgir a lo largo de la vida útil del proyecto. Estas técnicas combinan análisis de riesgos y criterios de decisión para garantizar que las decisiones tomadas sean sólidas y efectivas a lo largo del tiempo.



Por su simplicidad, interpretabilidad y aplicabilidad, se adopta en esta investigación una caracterización de datos basada en días representativos [78]. En este sentido, se asume que ya se dispone de mediciones locales relevantes, como el potencial fotovoltaico y los precios de la energía en tiempo real (RTP), recopiladas durante un período de tiempo razonable, generalmente al menos un año, con una resolución horaria. Este conjunto de datos históricos sirve como entrada para la técnica de agregación, que tiene como objetivo reducir el conjunto completo de datos a un número mínimo de días representativos. El proceso de agregación selecciona minuciosamente un conjunto reducido de días que capturan de manera precisa la variabilidad estacional y diaria de las condiciones de generación y demanda de energía, minimizando así la pérdida de información significativa. De esta manera, se simplifica el análisis y la planificación de sistemas energéticos complejos, manteniendo al mismo tiempo un alto nivel de precisión en las predicciones.

En este trabajo, se emplea el método k-medoids para llevar a cabo la agregación de datos. Esta técnica de agrupación es ampliamente reconocida por ofrecer resultados efectivos en la reducción de conjuntos de datos complejos [79]. El método k-medoids agrupa el espacio de escenarios original en clústeres, cada uno representado por un único miembro llamado medoide, que actúa como el día representativo del clúster. Sin embargo, una limitación importante de este método es que el número total de medoides debe fijarse de antemano, lo que puede resultar complicado en la práctica, ya que puede ser difícil determinar el número óptimo de medoides que se deben considerar para una representación precisa de los datos.

En este sentido, se ha aplicado el método del codo, que busca encontrar un equilibrio entre precisión y eficiencia en la determinación del número óptimo de medoides [80]. Este método evalúa la variación de la suma de las distancias al cuadrado de cada punto respecto a su medoide más cercano en función del número de medoides seleccionados. La idea principal es identificar el punto en el que la adición de un medoide adicional no proporciona una mejora significativa en la reducción de la suma de las distancias. Este punto se conoce como "codo" y representa el número óptimo de medoides para la representación eficiente de los datos.

### 3.3 Modelo matemático del sistema

En esta sección, se presenta el modelo matemático para el dimensionamiento óptimo de la energía fotovoltaica colectiva en CE cooperativas. Estos modelos describen los principios de funcionamiento tanto de los usuarios como del administrador de la comunidad, detallando su interacción para mejorar la economía y eficiencia energética de la comunidad. Mediante estos modelos, se busca optimizar el tamaño y la distribución de los sistemas fotovoltaicos dentro de la comunidad, teniendo en cuenta las necesidades energéticas, los recursos disponibles y los objetivos económicos de los participantes.

#### 3.3.1 Función objetivo

El modelo de planificación propuesto busca minimizar el costo total del proyecto, el cual puede expresarse como, la función de costo mostrada a continuación:

$$Costo = CAP \sum_{y \in Y} \left\{ \rho_y (REP_y^{inv} + OM^{PV}) + \sum_{r \in R} |\Omega r| E_{yr}^M \right\} \quad (3.1)$$

Donde:

$\rho_y$ : representa la tasa de interés al año del proyecto, la cual puede calcularse de la siguiente manera [81]

$$\rho_y = (1 + r)^{y-1} \quad (3.2)$$

La ecuación 3.1 engloba los costes de capital, de sustitución, de mantenimiento y de comercialización de energía, que se definen respectivamente con las siguientes ecuaciones como:

$$CAP = p^{-PV} (C^{PV} + C^{inv}) \quad (3.3)$$

$$REP_y^{inv} = p^{-PV} C_y^{inv} C^{inv} \quad (3.4)$$

$$OM^{PV} = p^{-PV} C^{PV} + O^{PV} \quad (3.5)$$

$$E_{yr}^M = \Delta\tau \sum_{t \in T} \lambda_{yrt}^{G,i} p_{yrt}^{G,i} - \lambda_{yrt}^{G,e} p_{yrt}^{G,e} \quad (3.6)$$

Los costes de capital (3.3) son una función de la potencia máxima fotovoltaica e incluyen también los costes de los inversores. Se tienen en cuenta los costes de sustitución (3.4) de los inversores, suponiendo una vida útil más corta para estos dispositivos en comparación con los paneles fotovoltaicos [82]. Cabe reclamar que esta formulación asume que la vida útil del proyecto coincide con la vida útil garantizada de los paneles fotovoltaicos, como es habitual, por lo que no se consideró el costo de reemplazo de los paneles fotovoltaicos. Los costes de explotación y mantenimiento (3.5) también se consideran proporcionales a los costes de capital inicial, mientras que el comercio de energía (3.6) refleja el coste del intercambio de energía con el minorista local en el marco de la fijación de precios RTP.

Vale la pena señalar que (3.1) abarca diferentes costos evaluados en diferentes horizontes temporales. Por lo tanto, el proyecto incurre en costos de capital una vez a lo largo de la vida útil del proyecto, mientras que los costos de reemplazo y mantenimiento se evalúan anualmente. Por último, el comercio de energía revela los gastos diarios. Esta formulación particular permite descomponer el problema en diferentes escalas de tiempo, como se comenta más adelante, e incluir variaciones detalladas a largo plazo de los parámetros originales, como la degradación de los paneles o el crecimiento de la carga (ver Sección 3.3.4).

Tenga en cuenta que los costes diarios de comercialización de energía se ponderan por  $|\Omega_r|$ , que representa el número total de días dentro del conjunto correspondiente al  $r$ -ésimo día representativo. De esta manera, los costos diarios de comercialización de energía se evalúan a lo largo de un año y se pueden considerar adecuadamente durante toda la vida útil del proyecto sin la necesidad de incluir todos los días en el conjunto de datos original.

### 3.3.2 Restricciones de planificación

Los problemas de planificación están restringidos por las condiciones del entorno, como el presupuesto disponible ( $\Pi$ ). En este apartado se asume que los costos de capital

están limitados por un tope presupuestario disponible, de acuerdo a (3.7), por lo tanto el presupuesto debe ser menor o igual al capital disponible como lo indica la ecuación 3.7.

$$CAP \leq \Pi \quad (3.7)$$

En relación a las restricciones a nivel de usuario, el problema de planificación propuesto incluye la modelización detallada de los usuarios. En primer lugar, cada par asegura su propio equilibrio de poder, establecido en (3.8).

$$p_{yrnt} + p_{yrnt}^{PV} + p_{yrnt}^{B,d} + p_{yrnt}^{EV,d} = p_{yrnt}^D + p_{yrnt}^{B,c} + p_{yrnt}^{EV,c} + p_{yrnt}^{H,heat} + p_{yrnt}^{H,cool} + \sum_{a \in A_n^I \cup A_n^{NI}} u_{yrnt}^a p_a^n; \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in T \quad (3.8)$$

En la ecuación (3.8) se incluye la energía intercambiada con la comunidad, así como el flujo de energía bidireccional en baterías y vehículos eléctricos. De esta manera, se considera todo el potencial de las baterías a bordo a través del vehículo al hogar [5]. En (3.8) también se incluye el consumo de sistemas de climatización y la central de aire acondicionado, cuyos modelos se describirán más adelante.

$$-\bar{p}_n \leq p_{yrnt} \leq \bar{p}_n; \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in T \quad (3.9)$$

El acceso individual a los bienes colectivos se habilita siguiendo reglas previamente acordadas. Existen diferentes enfoques para determinar las cuotas de acceso de cada par (véase [49]). En este documento, se asume que la comunidad acuerda un acceso distributivo a los activos fotovoltaicos colectivos y, por lo tanto, el potencial fotovoltaico se comparte equitativamente entre los pares dentro de la comunidad, lo que se modela mediante las siguientes restricciones (3.10)(3.11).

$$p_{yrnt}^{PV} \leq \frac{\bar{P}_y^{PV}}{|N|}; \forall y \in Y \wedge r \in R \wedge t \in T \wedge n \in N \quad (3.10)$$

$$p_{yrnt}^{PV} \leq \frac{\bar{P}_y^{PV}}{|N|} \vartheta_{yrnt}^{PV}; \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in \quad (3.11)$$

Vale la pena señalar que el parámetro es diferente a la potencia pico instalada, debido a que el primero considera la degradación anual del panel (ver Sección 3.3.4). Cada par proporciona capacidad de almacenamiento a través de baterías estacionarias e integradas. En cualquier caso, el SOC instantáneo de los activos de almacenamiento está determinado por (3.12) y limitado por (3.13).

$$soc_{yrnt}^i = soc_{yrnt}^i + \Delta\tau(p_{yrnt}^{B,c}n_n^j - p_{yrnt}^{B,d}/n_n^j); \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in T \setminus t = 1 \wedge j \in \{B, EV\} \quad (3.12)$$

$$\underline{soc}_{yrnt}^j \leq soc_{yrnt}^j \leq \overline{soc}_{yrnt}^j; \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in T \wedge j \in \{B, EV\} \quad (3.13)$$

La energía intercambiada por las baterías en los modos de carga y descarga está en el límite superior. En el caso de las baterías estacionarias, este límite superior viene determinado por la capacidad total y la llamada relación energía-potencia [83]. Mientras que, en el caso de las baterías de a bordo, la potencia intercambiada está limitada por la potencia nominal de los cargadores comerciales, que es de unos 3,7 kW para los usuarios domésticos, hoy en día (Electrical Installation wiki, 2023). Además, tanto el modo de carga como el de descarga deben ser complementarios, evitando así carga y descarga simultáneas. Para cumplir con estas premisas, se imponen las siguientes restricciones.

$$p_{yrnt}^{j,c} \leq p_{yrnt}^j \bar{P}_n^j; \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in T \wedge j \in \{B, EV\} \quad (3.14)$$

$$p_{yrnt}^{j,d} \leq (1 - u_{yrnt}^j) \bar{P}_n^j; \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in T \wedge j \in \{B, EV\} \quad (3.15)$$

A diferencia de las baterías estacionarias, las baterías de los vehículos eléctricos no están disponibles en cualquier momento y solo se puede acceder a ellas cuando el vehículo eléctrico está enchufado. De acuerdo con [5], se establece la disponibilidad de vehículos eléctricos por su correspondiente ventana de tiempo  $\theta_n^{EV}$ , y la siguiente restricción evita programarlo durante las franjas horarias desconectadas.

$$p_{yrnt}^{EV,j} = 0; p_{yrnt}^j \leq \bar{P}_n^j; \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in / \theta_n^{EV} \wedge j \in \{c, d\} \quad (3.16)$$

Por último, vale la pena señalar que (3.12) no está definido en  $t = 1$  y, por lo tanto, el SOC inicial debe ser fijo. Como es habitual, el estado de carga inicial de las baterías estacionarias se fija igual a su capacidad límite inferior en (3.17), donde también se define el estado de carga final para mantener la coherencia del modelo.

$$soc_{yrn1}^B = soc_{yrn|T}^B = \underline{soc}_n^B; \forall y \in Y \wedge r \in R \wedge n \in N \quad (3.17)$$

Por otro lado, suponemos que el SOC inicial de los vehículos eléctricos es un parámetro dependiente del usuario fijado por (3.18), mientras que (3.19) garantiza que las baterías de a bordo estén completamente cargadas en el momento de la salida.

$$soc_{yrn1}^{EV} = soc_n^{EV,0}; \forall y \in Y \wedge r \in R \wedge n \in N \quad (3.18)$$

$$SOC_{yrn|\theta_n^{EV}}^{EV} = \overline{SOC}_n^{EV}; \forall y \in Y \wedge r \in R \wedge n \in N \quad (3.19)$$

De acuerdo con con las investigaciones realizadas, sobre las herramientas de gestión de la energía en el hogar, las unidades de aire acondicionado se clasifican en interrumpibles y no interrumpibles. Los primeros pueden interrumpir su funcionamiento por comodidad, mientras que los segundos deben funcionar de forma continua hasta completar sus ciclos de trabajo. En cualquier caso, se exige que los ciclos de trabajo se completen dentro de las ventanas de tiempo preestablecidas por (3.20), mientras que (3.21) y (3.22) aseguran el correcto funcionamiento de los aparatos no interrumpibles.

$$\sum_{t \in \theta_n^{EV}} u_{yrnt}^a = \frac{\delta_a}{\Delta \tau}; \forall y \in Y \wedge r \in R \wedge n \in N \wedge a \in A_n^I \cup A_n^{NI} \quad (3.20)$$

$$\begin{aligned} u_{yrnt}^a - u_{yrnt-1}^a &= on_{yrnt}^a - off_{yrnt}^a; rnt; \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in T \setminus t \\ &= 1 \ A_n^{NI} \end{aligned} \quad (3.21)$$

$$\sum_{t \in T} on_{yrnt}^a = 1; \forall y \in Y \wedge r \in R \wedge n \in N \wedge a \in A_n^{NI} \quad (3.22)$$

También queda por modelar el sistema HVAC. Esta unidad está dedicada a mantener la temperatura interior dentro de límites cómodos. Con este fin, la temperatura interior se declara una variable de decisión y se determina mediante

$$\begin{aligned} \theta_{yrnt}^{Air,in} &= (1 - A_n^{Air,in}) \theta_{yrnt-1}^{Air,in} + A_n^{Air,in} \theta_{yrnt-1}^{Air,out} + B_n^{Air,in} (p_{yrnt}^{H,heat} - p_{yrnt}^{H,cool}); \forall y \\ &\in Y \wedge r \in R \wedge t \in T \setminus t = 1 \wedge n \in N \end{aligned} \quad (3.23)$$

Donde:

$$A_n^{Air,in} = \frac{\Delta\tau}{1000m_n^{Air,in}\gamma^{Air}R}; \forall n \in N \quad (3.24)$$

$$B_n^{Air,in} = \frac{\Delta\tau COP_n^H}{0.000277m_n^{Air,in}\gamma^{Air}}; \forall n \in N \quad (3.25)$$

El modelo (3.23) se deriva después de linealizar las ecuaciones diferenciales que gobiernan la evolución de la temperatura en función de la temperatura exterior y el modelo térmico del hogar. En este sentido, se supone que el edificio tiene una planta rectangular y los dispositivos de climatización instalados en el interior del edificio. Este modelo se considera aceptable para los problemas de gestión energética del hogar y ha sido probado en múltiples referencias [84]. En esta investigación, solo se consideran las viviendas, quedando fuera del alcance de este trabajo analizar más a fondo el impacto de otros modelos de construcción en los resultados finales (se remite al lector a [70] para una discusión más detallada sobre este tema).

Como se mencionó, el sistema HVAC mantiene la temperatura interior dentro de límites cómodos, que se describen mediante un punto de ajuste de temperatura y bandas muertas en (3.26). Por otra parte, la temperatura interior inicial debe definirse mediante (3.27) de acuerdo con el modelo adoptado para las baterías estacionarias. Por último, (28) y (29) evitan activar simultáneamente los modos de calefacción y refrigeración ya que no sería coherente activar los dos al mismo tiempo.



$$\theta_n^{H,sp} - \theta_n^{H,sp} \leq \theta_n^{H,sp} + \theta_n^{H,db}; \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in T \quad (3.26)$$

$$\theta_{yrn1}^{Air,in} = \theta_{yrnt|T}^{Air,in} = \theta_n^{H,sp}; \forall y \in Y \wedge r \in R \wedge n \in N \quad (3.27)$$

$$\theta_{yrnt}^{H,heat} \leq u_{yrnt}^H u_n^P; \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in T \quad (3.28)$$

$$P_{yrnt}^{H,heat} \leq (1 - u_{yrnt}^H) P_n^H; \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in T \quad (3.29)$$

### 3.3.3 Limitaciones a nivel comunitario

Estas limitaciones se centran en la parte del administrador de la comunidad (community manager) que es responsable de coordinar los intercambios P2P y el comercio de energía con la red para que exista el balance de potencia comunitaria dado por (3.30), mientras que (3.31) y (3.32) limiten la potencia importable/exportable.

$$\sum_{t \in T} p_{yrnt} + P_{yrt}^{G,e} - P_{yrt}^{G,i} = 0; \forall y \in Y \wedge r \in R \wedge t \in T \quad (3.30)$$

$$P_{yrt}^{G,e} \leq P_{yrt}^G p^{-G}; \forall y \in Y \wedge r \in R \wedge t \in T \quad (3.31)$$

$$P_{yrt}^{G,e} \leq (1 - u_{yrt}^G) p^{-G}; \forall y \in Y \wedge r \in R \wedge t \in T \quad (3.32)$$

### 3.3.4 Variación de parámetros a largo plazo

Los problemas de planificación se evalúan en horizontes temporales largos. En este contexto, es razonable pensar que algunos parámetros variarán a lo largo de la vida útil del proyecto [69]. Por ejemplo, se espera que la demanda local crezca [70], mientras que la producción fotovoltaica puede verse degradada debido a la degradación de los paneles y al envejecimiento de los componentes.

El modelo en particular adoptado en este trabajo denota cada variable a lo largo de un año, lo que permite modelar adecuadamente las variaciones a largo plazo. Además en esta investigación, se asume las variaciones pesimistas de algunos parámetros, a saber, los precios de la energía, la demanda no flexible y la degradación fotovoltaica, que se modelan a lo largo de un año, como se indica a continuación.

$$\lambda_{yrt}^j = \lambda_{yrt}^j (1 + \text{inf.}(y - 1)); \forall y \in Y \wedge r \in R \wedge t \in T \wedge j \in \{i, e\} \quad (3.33)$$

$$P_{yrt}^D = P_{1rnt}^D (1 + \text{LG.}(y - 1)); \forall y \in Y \wedge r \in R \wedge n \in N \wedge t \in T \quad (3.34)$$

$$P_y^{-PV} = p^{-PV} (1 - \text{deg}^{PV} \cdot (y - 1)); \forall y \in \quad (3.35)$$

### 3.4 Propuesta de estrategia de solución

Para mayor comodidad en el modelado, se escribe el modelo de planificación desarrollado en forma compacta, de la siguiente manera

$$\text{Costo} = f(p^{-PV}) + \sum_{y \in Y} \sum_{r \in R} |\Omega_r| g(x_{yr}^M, u_{yr}^M, x_{yrn}, u_{yrn}) \quad (3.36a)$$

La función de costo esta sujeta a:

$$\text{CAP} \leq \text{II} \quad (3.36b)$$

$$h^M(x_{yr}^M, u_{yr}^M) = 0; \forall y \in Y \wedge r \in R \wedge n \in N \quad (3.36c)$$

$$k^M(x_{yr}^M, u_{yr}^M) \leq d^M; \forall y \in Y \wedge r \in R \quad (3.36d)$$

$$h_n(x_{yrn}, u_{yrn}) = b_{yrn}; \forall y \in Y \wedge r \in R \wedge n \in N \quad (3.36e)$$

$$k_n(x_{yrn}, u_{yrn}) \leq d_{yrn}; \forall y \in Y \wedge r \in R \wedge n \in N \quad (3.36f)$$

$$q_n(p_{yrnt}^{PV}) \leq \bar{P}_y^{PV}; \forall y \in Y \wedge r \in R \wedge n \in N \quad (3.36g)$$

$$u_y^M \in \{0,1\}; \forall y \in Y \wedge r \in R \quad (3.36h)$$

$$u_{yrn} \in \{0,1\}; \forall y \in Y \wedge r \in R \wedge n \in N \quad (3.36i)$$

Donde:  $x_{yr}^M$  son  $u_{yr}^M$  son los vectores de variables de decisión continuas y binarias del administrador para el año  $y^{th}$  y día representativo  $r^{th}$  en el horizonte de planificación, respectivamente; mientras  $x^{yrn}$  y  $u^{yrn}$  son los vectores correspondientes de variables continuas y binarias para la participación de pares iguales  $n^{th}$  en la comunidad.

En las ecuaciones (3.36), (3.36a) que representan la función objetivo, y esta a su vez se descompone en costes de planificación y estos se pueden ver afectados por la potencia pico fotovoltaica y costes energéticos diarios determinados por las decisiones de programación y comercialización de energía. La ecuación (3.36b) muestra la restricción presupuestaria (3.7), mientras que (3.36d)-(3.36f) son la representación matricial de las restricciones de igualdad y desigualdad de los modelos comunitario y a nivel de usuario, respectivamente, con la excepción de (3.10) y (3.11), que se representan en (3.36g). Finalmente, (3.36h) y (3.36i) declaran formalmente variables binarias.

El problema (3.36) representa una Programación Lineal Entera Mixta (MILP), que puede resolverse utilizando solucionadores estándar y garantizar la optimización global si las brechas de enteros y optimización se establecen igual a cero. Sin embargo, se espera que (3.36) sea a gran escala debido a los siguientes factores:

- El tamaño de  $\mathbf{Y}$ , que normalmente abarca de 25 a 30 elementos.
- El tamaño de  $\mathbf{R}$ , cuyo número de elementos varía según el conjunto de datos original y la técnica de agrupación empleada, pero normalmente abarca más de 5 elementos.
- El número de pares que participan en la comunidad, que son representados por el conjunto  $N$ . De acuerdo con [41], los CE suelen abarcar unos pocos pares (~3-6), pero no se pueden descartar comunidades más grandes.

Debido a las razones anteriores, el problema (3.36) es difícilmente manejable por los solucionadores y máquinas promedio. Sin embargo, se puede ver fácilmente que (3.36) presenta una estructura claramente descomponible. En efecto, si  $\bar{p}PV$  se considera como una «variable de complicación», (3.36) puede descomponerse directamente, lo que aboga por la aplicación de técnicas de descomposición para aliviar el coste computacional de resolver este problema sin incurrir en simplificaciones excesivas. En las siguientes

secciones, se detalla la aplicación de la técnica de descomposición de dobladores multicorte al problema (3.36).

### **3.4.1 Descomposición de Benders**

En la teoría de la optimización, las técnicas de descomposición se han empleado ampliamente para tratar problemas de optimización a gran escala. Existe una variedad de técnicas de descomposición y su idoneidad depende normalmente del tamaño del problema, las variables involucradas y otras características (ver [87]) para más información).

Entre el estado del arte de las técnicas de descomposición, la descomposición de los Benders es, sin duda, una de las más populares y ampliamente aplicadas, encontrando múltiples aplicaciones en sistemas de potencia y energía [88]. Esta técnica descompone el problema original en una estructura maestro-esclavo, en la que las llamadas variables de complicación se fijan después de resolver el problema maestro, mientras que el subproblema (o subproblemas) agrega cortes para acercarse al valor de la función objetivo de manera iterativa.

Una de las principales preocupaciones al aplicar la descomposición de los Benders es el número total de iteraciones necesarias para lograr la solución. Esto se debe a que, en algunos problemas, el algoritmo convencional necesita muchas iteraciones para converger o la solución oscila durante un gran número de iteraciones, convirtiendo así el algoritmo en computacionalmente costoso [89], para superar este problema, se han propuesto en la literatura diferentes variantes de la descomposición de los Benders [90]. En particular, se aplica la descomposición de los dobladores multicorte al problema (3.36). A diferencia del algoritmo convencional de descomposición-posición, el enfoque de corte múltiple agrega un número (tantos como subproblemas) de cortes al problema maestro para abordar la función de costo rápidamente, lo que generalmente requiere menos iteraciones.

Esencialmente, la variante de corte múltiple del algoritmo de Benders sigue los pasos a continuación (ver Fig. 3.2):

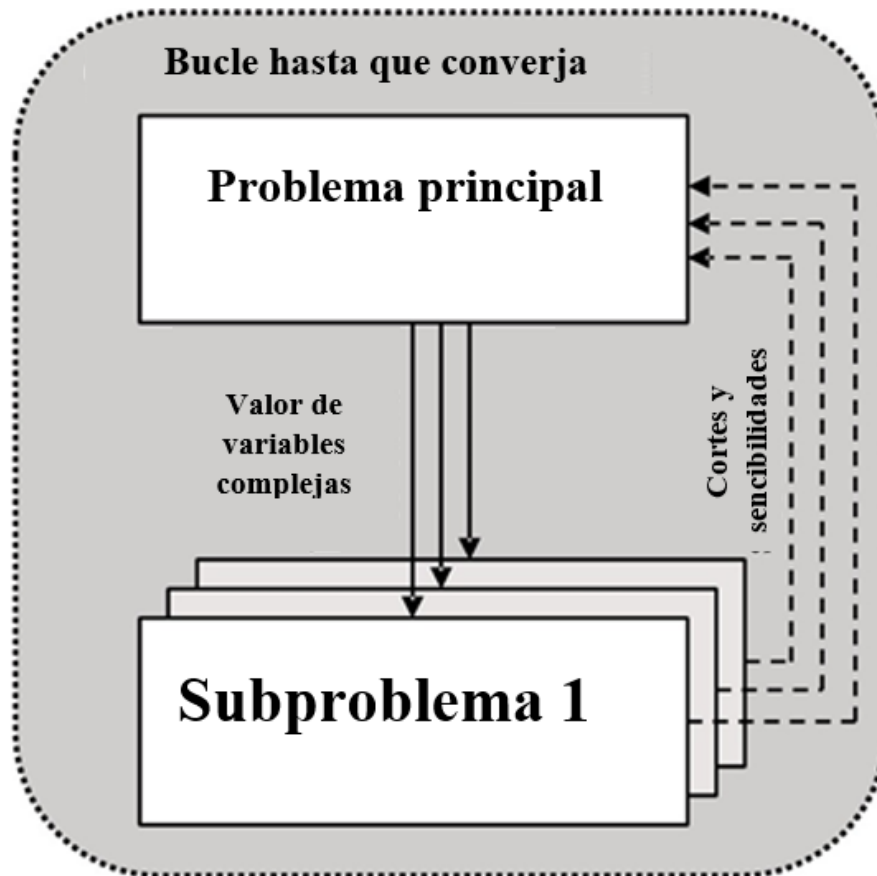


Fig. 3. 2 - Diagrama de flujo conceptual de la descomposición de los dobladores multicorte.

- Descompone el problema de optimización original en un problema maestro y varios subproblemas.
- Resuelve el problema maestro y el valor de las variables complicadas.
- Resuelve los subproblemas para un valor dado de variables complicadas.
- Cada subproblema contribuye con un corte, que sirve como retroalimentación para el problema maestro.
- Busca la solución final repitiendo iterativamente los pasos anteriores.

De acuerdo a lo descrito anteriormente la descomposición de los dobladores multicorte se alinea con la estructura de (3.36). De hecho, este problema puede descomponerse en un problema maestro, de el valor de  $\overline{p^{PV}}$  y una serie de subproblemas (uno por año y día representativo) que añaden cortes al problema maestro para abordar el segundo término en (36a). Dado que la estructura particular del problema de planificación se adapta perfectamente a la filosofía de los Benders multicorte, se aplica esta técnica para

resolver el problema con el fin de aliviar la carga computacional del problema de planificación original.

### 3.4.2 Problema maestro

Después de descomponer (3.36), el problema maestro resultante para la iteración se lee como  $m^{th}$

$$\min f(p^{-PV,(m)}) + \sum_{y \in Y} \sum_{r \in R} |\Omega_r| \alpha_{yr}^M \quad (3.37a)$$

$$\bar{p}^{PV,(m)}, \alpha_{yr}^{(m)}$$

Sujeto a:

$$CAP \leq \Pi \quad (3.37b)$$

$$\alpha_{yr}^{(m)} \geq \underline{\alpha}; \forall y \in Y \wedge r \in R \quad (3.37c)$$

$$\alpha_{yr}^{(m)} \geq g(x_{yr}^{M,(v)}, u_{yr}^{M,(v)}, x_{yrn}^{(v)}, x_{yrn}^{(v)}) + u_{yr}^{(v)}(\bar{p}^{PV,(m)} - \bar{p}^{PV,(v)});; \forall y \in Y \wedge r \in R \wedge v \in \{1, 2, \dots, m-1\} \quad (3.37d)$$

El problema (3.37) conserva el primer objetivo de (3.36a), que es de hecho una función de la variable principal (i.e.). Mientras que el resto de la función objetivo es aproximada por la variable auxiliar  $\alpha$ . En el resto de las restricciones, (3.37b) es el mismo que (3.36b), (3.37c) define un límite inferior en  $\alpha$  para acelerar la convergencia y (3.37d) describe los cortes provenientes de subproblemas. Como se puede observar, (3.37d) agrega un corte para cada iteración (hasta  $m - \bar{p}^{PV} - 1$ ), año y día representativo, lo que da como resultado un espacio de corte más denso que eventualmente conduce a una mejor aproximación de  $\alpha$  y, en consecuencia, a una convergencia más rápida.

Cabe mencionar que cada corte requiere información de las iteraciones anteriores, así como sensibilidades  $\mu$ , que se obtienen después de resolver los subproblemas. Además el problema maestro es una programación lineal ligera y fácilmente resoluble.

### 3.4.3 Subproblemas

Los subproblemas se representan como la descomposición del problema original en términos de  $|Y| \cdot |R|$  subproblemas, que modelan el comportamiento de los pares para un

valor dado de variables complicadas en el  $y$  –ésimo año y el  $r$  –ésimo día representativo, de la siguiente manera.

$$\tilde{\mathbf{u}}_{yr}^{M,(m)}, \tilde{\mathbf{u}}_{yrn}^{(m)} \in \operatorname{argmin} g(x_{yr}^{M,(m)}, u_{yr}^{M,(m)}, x_{yrn}^{(m)}, u_{yrn}^{(m)}) \quad (3.38a)$$

Sujeto a:

$$h^M(x_{yr}^{M,(m)}, x_{yrn}^{(m)}) = 0; \forall n \in N \quad (3.38b)$$

$$k^M(x_{yr}^{M,(m)}, u_{yr}^{M,(m)}) \leq d^M \quad (3.38c)$$

$$h_n(x_{yrn}^{(m)}, u_{yr}^{(m)}) = b_{yrn}; \forall n \in N \quad (3.38d)$$

$$k_n(x_{yrn}^{(m)}, u_{yr}^{(m)}) \leq d^M; \forall n \in N \quad (3.38e)$$

$$q_n(p_{yrnt}^{PV,(m)}) \leq \bar{P}_y^{PV,(m)}; \forall n \in N \quad (3.38f)$$

$$u_{yr}^{M,(m)} \in \{0, 1\} \quad (3.38g)$$

$$u_{yr}^{(m)} \in \{0, 1\}; \forall n \in N \quad (3.38h)$$

El subproblema (3.38) es MILP y, por lo tanto, puede ser manejado por solucionadores estándar. Sin embargo, las sensibilidades en los problemas de MILP no se pueden derivar con precisión, por lo tanto supone un problema ya que las sensibilidades sirven de retroalimentación para añadir recortes en el problema maestro. Para resolver este problema, de acuerdo con [91], cada subproblema se resuelve en dos etapas. En primer lugar, (3.38) se resuelve para derivar el valor óptimo de las variables binarias (i.e.



$\tilde{\mathbf{u}}_{yr}^{M,(m)}$ ,  $\tilde{\mathbf{u}}_{yrn}^{(m)}$  y Luego, con dichas variables fijas, se aborda una versión lineal de (3.38), de la siguiente manera.

$$\min g(x_{yr}^{M,(m)}, u_{yr}^{M,(m)}, x_{yrn}^{(m)}, u_{yrn}^{(m)}) \quad (3.39a)$$

Sujeto a:

$$h^M(x_{yr}^{M,(m)}, x_{yrn}^{(m)}) = 0; \forall n \in N \quad (3.39b)$$

$$k^M(x_{yr}^{M,(m)}, \tilde{\mathbf{u}}_{yr}^{M,(m)}) \leq d^M \quad (3.39c)$$

$$h_n(x_{yrn}^{(m)}, \tilde{\mathbf{u}}_{yr}^{(m)}) = b_{yrn}; \forall n \in N \quad (3.39d)$$

$$k_n(x_{yrn}^{(m)}, u_{yr}^{(m)}) \leq d_{yrn}; \forall n \in N \quad (3.39e)$$

$$q_n(p_{yrnt}^{PV,(m)}) \leq \bar{P}_y^{PV,(m)}; \forall n \in N \quad (3.39f)$$

$$\bar{P}^{PV} = \bar{P}^{PV,(m)} : u_{yr}^{(m)} \quad (3.39g)$$

Por lo tanto, las sensibilidades se pueden derivar fácilmente como los multiplicadores de Lagrange asociados con (39g).

### 3.4.4 Simulación del algoritmo

Para la simulación del algoritmo de optimización se sigue el siguiente procedimiento para resolver el dimensionamiento fotovoltaico colectivo propuesto utilizando el enfoque de descomposición de dobladores multicorte propuesto:

1. Se inicializa los valores de  $UB = \infty$ ,  $LB = -\infty$  y  $m = 0$ .
2. Si  $m = 0$ , se resuelve (3.37) sin incluir (3.37d). De lo contrario, resuelva el problema completo.
3. Actualizar  $LB = \sum_{y \in Y} \sum_{r \in R} |\Omega_r| \alpha_{yr}^M$
4. Resolver la versión MILP de cada subproblema (3.38) para calcular el valor óptimo de las variables binarias.
5. Con valores fijos de variables binarias, se resuelve cada subproblema lineal (3.39) para derivar sensibilidades.
6. Actualizar  $UB = g(x_{yr}^{M,(m)}, u_{yr}^{M,(m)}, x_{yrn}^{(m)}, u_{yrn}^{(m)})$  y revisando la convergencia como
  - a.  $\frac{UB-LB}{UB} \leq \varepsilon$
  - b. Donde  $\varepsilon = 0.05$  en el estudio
7. Si el algoritmo converge, se detiene. De lo contrario,  $m = m + 1$ , e ir al paso 2.

## 3.5 Caso de estudio

En esta sección, se presenta un estudio de caso con un doble propósito. Por un lado, se busca demostrar que la aplicación del algoritmo de descomposición de Benders hace que el problema de planificación propuesto sea manejable, de lo contrario este problema podría resultar inasequible para las máquinas convencionales. Por otro lado, se pretende validar la nueva propuesta, con el objetivo de demostrar su aplicabilidad a problemas reales y su capacidad para proporcionar soluciones eficientes y prácticas.

### 3.5.1 Datos de entrada

A lo largo de esta sección, se presentan una variedad de resultados en diferentes escenarios. En concreto se presenta, resultados para diferentes tamaños de problemas, variando el número de pares y escenarios considerados. Además, se tomará un caso de referencia considerado que involucre pares de tamaño con fines ilustrativos. Con este fin, los datos relativos a los pares se toman aleatoriamente dentro de los rangos típicos para las instalaciones domésticas, que se detallan en la Tabla 3.1.

Tabla 3. 1 – Datos de usuarios

---

<b>Elementos</b>
Número de aparatos controlables $\in [0, 3]$
Ciclo de trabajo de cada aparato controlable $\in [2, 6]$ horas
Potencia nominal de cada aparato controlable $\in [0.5, 2]$ kW
Ventana de tiempo de cada aparato controlable $\in [2 : 00 \text{ h}, 23 : 00 \text{ h}]$
Capacidad de la batería $\in [2.5, 5]$ kWh
Límite de descarga de la batería $\in [40, 80]$ %
Potencia nominal de la batería $\in [0.6, 3.3]$ kW
Eficiencia de la batería = 95 %
HVAC Potencia nominal $\in [1.5, 2]$ kW
HVAC Consigna $\in [23, 25]$ °C
HVAC Banda muerta $\in [0.5, 1.5]$ °C
HVAC coeficiente de rendimiento $\in [1, 2]$
AnAir,in $\in [0.1, 0.2]$
BnAir,in $\in [2, 4]$
EV total capacity $\in [10, 22]$ kWh
EV Estado de carga inicial $\in [0.4, 0.8]$ de la capacidad total
EV Potencia nominal de carga = 3.7 kW
EV Hora de salida $\in [6 : 00 \text{ h}, 10 : 00 \text{ h}]$

---

Por otro lado, considera los datos de entrada para generar escenarios de RTP, que consideran la demanda individual no flexible, temperatura exterior y potencial fotovoltaico. Para los precios de la energía se toma en cuenta los precios comerciales en tiempo real en España en 2023 de la Comisión Nacional de los Mercados y la Competencia . Los datos no flexibles se tomaron de mediciones reales reportadas en [69], mientras que el potencial fotovoltaico se construyó considerando la temperatura y la irradiancia solar en Madrid en

[2], que se convirtieron a potencial fotovoltaico utilizando el modelo fotovoltaico de [45]. Dichos datos se consideraron como el conjunto de datos del escenario original y posteriormente se redujeron utilizando la metodología descrita en la Sección 3.2. Por último, se considera que cada par puede intercambiar 10 kW con la comunidad y la comunidad puede importar/exportar 12 kW para cada usuario, mientras que otros datos relacionados con el proyecto se recogen en la Tabla 3.2.

Tabla 3. 2 – Datos del proyecto.

Parametro	Valor	Referencia
Capital	1200 €/kWp	[93]
Inversor	100 €/kWp	[82]
Mantenimiento celdas PV	1% del capital de costo	[82]
Degradación	0.5% por año	[82]
Horizonte del proyecto	30 años	[82]
Vida útil invertir	15 años	[82]
Tasa de interés	1.5%/año	[94]
Tasa de crecimiento de turismo	2%/año	[82]
Tasa de crecimiento de demanda	0.1%/año	[35]

### 3.5.2 Algoritmo de análisis

En primer lugar, se denota que el algoritmo de Benders multicorte propuesto hace que el problema de planificación propuesto sea manejable. Para ello, en primer lugar se ejecuta el problema original (3.36), en el que se resuelve el problema de planificación planteado sin aplicar técnicas de descomposición. Se ejecuto el problema considerando solo tres pares y cinco días representativos en un Intel® Core™ i7- 10700K con 32.00 GB de RAM, en un horizonte de tiempo de 24 h con una resolución de tiempo de 1 h (con 24 franjas horarias en total), utilizando Gurobi como optimizador [95] en el software MatlabR2021a. Con los ajustes iniciales, los resultados no fueron satisfactorios y, la simulación se detuvo después de dos días de ejecución, asumiendo que el modelo es inasequible al tardar tanto tiempo.

A continuación, se aplicó la técnica de descomposición propuesta y se ejecutó la herramienta de planificación para diferente número de pares y días representativos. Los

resultados para este experimento se muestran en la Fig. 3.3 donde se detalla el tiempo promedio de iteración. Como era de esperar, el tiempo total de cómputo crece con el número de días representativos y pares. Pero, incluso con un alto número de pares y días considerados, los resultados informados pueden considerarse razonables, especialmente después de observar que el algoritmo desarrollado generalmente converge después de dos o tres iteraciones. Esta rápida convergencia obedece indudablemente a la aplicación de una estrategia multicorte, que con frecuencia conduce a propiedades de convergencia más rápidas.




Fig. 3.3 - Tiempo medio de iteración para diferentes tamaños de problemas.

Cabe reclamar, que el tiempo de iteración que se indica en la Fig. 3.3 en lugar del tiempo total de ejecución se debe a las siguientes razones:

- El número total de iteraciones varía en función del número de pares o días representativos. En consecuencia, el tiempo total de ejecución no da una visión clara sobre cómo varía el tiempo de cómputo de un escenario a otro. Obsérvese que, dado que los datos relativos a los usuarios se generaron aleatoriamente dentro de los límites indicados en la Tabla 3.1, el número total de iteraciones varió de una simulación a otra. El proceso es altamente paralelizable. De hecho, los subproblemas pueden ejecutarse en paralelo, lo que reduce significativamente el

tiempo total de cálculo. Para verificar esta afirmación, se utiliza la función 'parfor' en Matlab, la cual ejecuta bucles 'for' en paralelo. Al emplear esta función en una máquina de seis núcleos, se logró reducir el tiempo total de cálculo en un 20-30 %, lo que resultó en tiempos de cálculo aceptables incluso para problemas de gran escala.

También se compara la metodología de corte múltiple desarrollada con el algoritmo tradicional de Benders, que incluye un corte por iteración. En este caso, el número total de iteraciones aumentó notablemente de *dos-tres* a *cinco-siete* en promedio, con el consiguiente incremento en el tiempo de cálculo. Estos resultados se alinean con las conclusiones extraídas en múltiples artículos (véase, por ejemplo [96]), en los que los resultados demuestran que las versiones multicorte del algoritmo de Benders conducen a cortes densos y más fuertes que finalmente conducen a una mejor aproximación del costo de los subproblemas y, por lo tanto, a una convergencia más rápida.

Es aún más interesante ver cómo el coste total del proyecto varía con el número de pares y días representativos, que se muestra en la Fig. 3.4 (para  $\Pi = 60.000$  €). Como se observa, el costo total se estabiliza durante  $\sim 10$  días representativos, lo que demuestra que la técnica de reducción considerada es confiable y, por lo tanto, no es necesario considerar todo el conjunto de datos original. En realidad, después de aplicar el procedimiento de agrupamiento descrito en la Sección 3.2, el algoritmo selecciona ocho escenarios representativos, considerándolo así como la configuración más óptima. Como se observa en la Fig. 3.4, este valor es coherente con los resultados de esta figura.

Sin embargo, para demostrar aún más la confiabilidad de la técnica de agrupamiento considerada, se llevaron a cabo algunos experimentos preliminares utilizando conjuntos de datos completos. Se observó que el costo total del proyecto varió marginalmente en comparación con los resultados reportados en este documento. Por lo tanto, los beneficios en simplicidad y rendimiento computacional proporcionados por la metodología desarrollada justifican ampliamente su aplicación en problemas de planificación, donde el nivel de detalle puede ser relajado.

Los resultados de la Fig. 3.4 validan aún más la herramienta desarrollada desde un punto de vista computacional. De hecho, la Fig. 3.4 justifica el uso de pocos clústeres ( $\sim 10$ ) en este problema en particular. Para tal número de días representativos, se puede ver en la Fig. 3.3 que el tiempo de iteración sigue siendo de 3000 s incluso para comunidades de gran escala (24 pares en total). Teniendo en cuenta que el algoritmo suele converger en 2 o

tres iteraciones, el tiempo total de la metodología desarrollada se mantiene por debajo de los 9000 s incluso en comunidades a gran escala, lo cual es razonable para las herramientas de planificación que normalmente se realizan fuera de línea.




Fig. 3. 4 - Validación del modelo de campo.

### 3.5.- Conclusiones

Se ha desarrollado una nueva herramienta para la planificación óptima de los paneles fotovoltaicos colectivos en las CE. La nueva propuesta representa el espacio de decisión para cada año y día durante la vida útil del proyecto, que suele durar entre 25 y 30 años. Este enfoque da como resultado un problema de optimización a gran escala que puede resultar inasequible para los solucionadores y máquinas convencionales.

Para eludir este problema, se han propuesto dos contramedidas. Por un lado, se ha aplicado una técnica de reducción de datos para reducir el número de días que realmente se consideran a lo largo de un año. De esta manera, el número total de días se agrupa en un conjunto mínimo de perfiles representativos. Por otro lado, el problema se descompone en un estructura esclava que se resuelve utilizando el algoritmo de descomposición de Benders.

La nueva metodología presenta algunas ventajas notables, como la reducción de la carga computacional, la filosofía natural de múltiples cortes y la capacidad de incorporar parámetros de degradación e inflación a largo plazo.



# **CAPÍTULO 4: ESTIMATION OF LITHIUM-ION BATTERY**

---

## ***4.1 Introducción***

La medición del SoC de una batería de iones de litio ha demostrado ser un obstáculo importante para estimarlo. Debido a los intrincados procesos electroquímicos que tienen lugar dentro de una batería de iones de litio [10], el SoC no se puede medir directamente debido a la conexión no lineal entre el SoC y el OCV de la batería. Debe medirse mediante mediciones de voltaje, corriente y temperatura; por lo tanto, el cálculo preciso de SoC para la simulación de baterías es un tema de investigación actual [9]. La estimación precisa del SoC es una tarea primordial en BMS, ya que ayuda a mejorar la implementación y la precisión del sistema y a alargar la vida útil de la batería [11]. También puede evitar interrupciones inesperadas del sistema, evitar que la batería de iones de litio se sobrecargue o se cargue poco, lo que podría dañar permanentemente la estructura interna de la batería, y permite el desarrollo de esquemas de control lógicos para la conservación de energía [12].

Antes de estimar el SoC, es necesario modelar con precisión las características de la batería de iones de litio, se lleva a cabo un modelo de circuito equivalente (ECM), que incluye la resistencia en serie de la batería, la rama transitoria, que consiste en la resistencia de polarización y la capacitancia, y el OCV de la batería a diferentes valores de SoC tomando en consideración las diferentes temperaturas y diferentes condiciones de carga y desvanecimiento de la batería, luego se estima el SoC prediciendo el valor del estado de carga y corrigiendo el valor del estado utilizando las mediciones de voltaje, corriente y temperatura [13]. Esto dará como resultado una evaluación precisa del estado de carga y el modelado de la batería, lo que ayuda en el proceso de investigación de la reacción dinámica de la batería de iones de litio .

## 4.2 Modelado de la batería de Iones de Litio

Se presentaron y evaluaron varios modelos de baterías de iones de litio, considerando su complejidad y precisión. Entre los modelos evaluados, se encontró que el modelo de circuito equivalente (ECM) para baterías, con parámetros concentrados para ramas de polarización simple y doble, ofrece la mejor combinación de precisión y también de simplicidad. Este modelo resulta ser una opción óptima para la estimación del estado de carga (SoC) y el rendimiento de las baterías de iones de litio.

El modelo más comúnmente utilizado es el modelo de rama de un solo orden, también conocido como el modelo de constante de tiempo único para las baterías de iones de litio. Este modelo se representa en la Figura 4.1 [69].

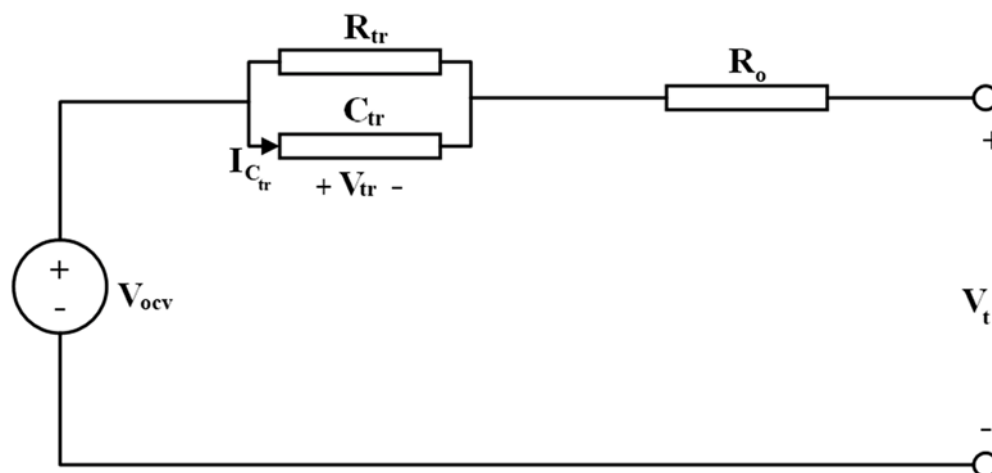


Fig. 4. 1 – Modelo de batería de Iones de Litio

El comportamiento eléctrico del modelo de constante de un solo tiempo puede caracterizarse mediante las ecuaciones (4.1) y (4.2):

$$V_{tr} = \frac{-1}{R_{tr} * C_{tr}} V_{tr} + \frac{1}{C_{tr}} I_{bat} \quad (4.1)$$

$$V_t = V_{OCV} - V_{tr} - R_o * I_{bat} \quad (4.2)$$

La explicación del tiempo discreto puede verse en las ecuaciones (4.3) y (4.4) de la siguiente manera:

$$V_{tr,k+1} = V_{tr,k} e^{\frac{\tau_s}{\tau_{tr}}} + R_{tr} \left(1 - e^{\frac{-\tau_s}{\tau_{tr}}}\right) I_{bat,k} \quad (4.3)$$

$$V_{t,k} = V_{OCV}(SoC, k) - V_{tr,k} - R_o * I_{bat,k} \quad (4.4)$$

Donde  $\tau_s$  es el tiempo e muestreo y  $\tau_{tr}$  constante de tiempo tau de la rama transitoria

### 4.2.1 Ecuaciones de estado de carga

El SoC de la celda de la batería revela cuánta energía todavía está disponible en la celda en comparación con su capacidad, como se muestra en la ecuación (4.5).

$$SoC = SoC_0 - \frac{1}{Q} \int_0^t I_{bat} dt \quad (4.5)$$

Donde: Q es la capacidad de batería de iones de litio, (SoCO) es el valor inicial del estado de carga y (Ibat) es la corriente de carga. La ecuación (4.5) se utiliza para calcular el SoC para determinar el voltaje ( $V_{ocv}$ ) la ecuación (4.3) y para calcular el voltaje terminal ( $V_t$ ) con la ecuación (4.4). La discretización de la ecuación (4.5) se muestra en la ecuación (4.6):

$$SoC_k = SoC_{k-1} - 100 \frac{I_{bat,k-1}}{3600 * Q} \quad (4.6)$$

Ahora, usando las ecuaciones (4.1)-(4.4), se presentan las ecuaciones del espacio de estados de la batería de iones de litio en las ecuaciones (7) y (8).

$$\begin{bmatrix} SoC_k \\ V_{tr,k} \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & e^{\frac{-\tau s}{R_{tr}C_{tr}}} \end{bmatrix} \begin{bmatrix} SoC_{k-1} \\ V_{tr,k-1} \end{bmatrix} + \begin{bmatrix} 100 \frac{I_{bat,k-1}}{3600 * Q} \\ R_{tr} \left[ 1 - e^{\frac{-\tau s}{R_{tr}C_{tr}}} \right] \end{bmatrix} I_{bat,k-1} \quad (4.7)$$

$$V_t = \begin{bmatrix} -1 \\ 0 \end{bmatrix}^T V_{tr,k} - I_{bat,k} R_0 + V_{OCV,k} \quad (4.8)$$

Para resumir el proceso de estimación de SoC, la Figura 4.2 muestra el marco de estimación de SoC.

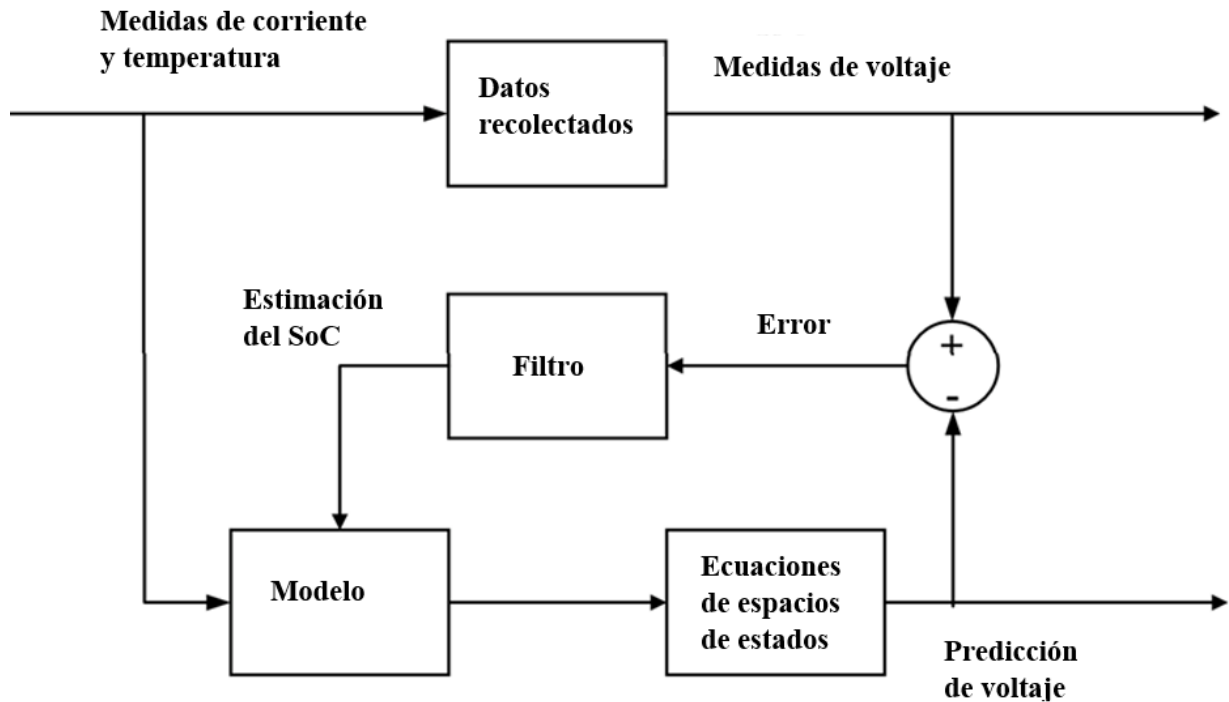


Fig. 4. 2 - Diagrama de la estimación del SoC

#### 4.2.2 Objetivos y limitaciones del problema de estimación del SoC del modelo de batería de iones de litio

El modelo de batería de iones de litio de una sola rama, como se menciona anteriormente, proporciona una descripción de las características de la batería. Para garantizar que el estado de carga predicho (SoC) coincida con el estado de carga observado durante los experimentos, es necesario desarrollar una función objetivo. Además, se requiere un método de estimación preciso y confiable para calcular el SoC con precisión. Esto garantiza que la batería de iones de litio funcione dentro de un rango seguro, evitando problemas de sobrecarga o descarga excesiva que puede provocar daños permanentes en la batería como pérdida de capacidad o inestabilidad química. La función objetivo desarrollada tiene como objetivo minimizar la discrepancia entre el SoC experimental y el SoC obtenido de la simulación. Esta función objetivo se expresa en la ecuación 4.9.

$$\begin{aligned} \text{Min}_u Fi(u), i = 1, 2, \dots, n_{obj} \\ U_{min} \leq U \leq U_{max} \end{aligned} \quad (4.9)$$

La función objetivo  $Fi(u)$  se desarrolla con los parámetros estimados  $(i, u)$  de la batería. Aquí,  $U_{min}$  y  $U_{max}$  representan las variables de control de los parámetros, mientras que  $n_{obj}$  comprende todas las posibles funciones objetivo.

El objetivo principal es reducir la discrepancia media entre el estado de carga simulado de la batería  $Fi(u)$  y el estado de carga experimentado, como se muestra en la ecuación (4.10). Esto se logra utilizando los resultados del experimento con la batería de iones de litio para establecer los parámetros del modelo de la batería.

$$F_i(u) = \sum (SoC_{Estimado} - SoC_{experimental})^2 \quad (4.10)$$

Donde:

$SoC_{Estimado}$ : Estado de carga estimado

$SoC_{experimental}$ : Estado de carga experimental

Para todo el sistema se establecen parámetros de restricción iniciales:

El valor del estado de carga debe estar en los rangos de  $0 \leq SoC \leq 1$

$$\begin{array}{ll}
 V_{OCVmin} \leq V_{OCV} \leq V_{OCVmax} & \text{Con } T_1 = 25^\circ \text{ y } T_2 = 45^\circ\text{C} \\
 R_0min \leq R_0 \leq R_0max & \text{Con } T_1 = 25^\circ \text{ y } T_2 = 45^\circ\text{C} \\
 R_{trmin} \leq R_{tr} \leq R_{trmax} & \text{Con } T_1 = 25^\circ \text{ y } T_2 = 45^\circ\text{C} \\
 \tau_{trmin} \leq \tau_{tr} \leq \tau_{trmax} & \text{Con } T_1 = 25^\circ \text{ y } T_2 = 45^\circ\text{C}
 \end{array}$$

Donde los valores *min* y *max* son los parámetros que restringen la operación

### 4.2.3 Método híbrido: conteo de Coulomb y filtro de Kalman adaptativo no centrado

De acuerdo a Kiarash et al. [97], el método de conteo de Coulomb se presenta en la ecuación 4.11.

$$SoC(t) = SoC(0) - \frac{1}{360 Q} \int_0^t i(t) dt \quad (4.11)$$

Donde:

$n$  = eficiencia del método de Coulomb

la eficiencia del método de conteo de Coulomb se determinan con la fórmula 4.12.

$$n = \begin{cases} n_{carga}, & i(t) > 0 \\ n_{descarga}, & i(t) < 0 \end{cases} \quad (4.12)$$

Donde:

$t$  = tiempo en segundos

$i(t)$  = corriente de la batería en amperios en el tiempo

$SoC(t)$  = estado de carga de batería en el tiempo

$SoC(0)$  = estado de carga en el instante  $t=0$

$Q$  = capacidad de la batería en Ahr

Luego de transformar la función del conteo de Coulomb en discreta se obtiene la ecuación 4.13

$$SoC(j) = SoC(j-1) - \frac{1}{360 Q} \int_{t(j-1)}^{t(j)} i(\tau) d\tau \quad (4.13)$$

Donde:

$SoC(j)$  = estado de SoC en instante de tiempo ( $t(j)$ )

$SoC(j-1)$  = estado de carga en el instante ( $t(j-1)$ )

$i(\tau)$  = corriente medida en el instante  $\tau$

La integración en la ecuación (14) se aproxima utilizando el enfoque del rectángulo (diferencia hacia atrás) en la ecuación (13).

$$\int_{t(j-1)}^{t(j)} i(\tau) d\tau \approx \Delta_j i(t(j)) = \Delta_j(j) \quad (4.14)$$

Donde:

$$\Delta_j i = t(j) - t(j-1)$$

La ecuación 4.15 es una versión simplificada del conteo de Coulomb

$$SoC(j) = SoC(j-1) - \frac{n \Delta_j i(j)}{360 Q} \quad (4.15)$$

El estado de carga que se estima con el conteo de Coulomb de la ecuación (15), tiene las siguientes imprecisiones:

1. Inexactitud de la medición de corriente  $i(j)$ ;
2. Un error resultante de la aproximación de la integración en la ecuación (14);
3. El conocimiento de la capacidad de la batería ( $Q$ ) no es fiable;
4. La falta de comprensión sobre la eficiencia del conteo de Coulomb  $\eta$ ;

5. Error de medición del tiempo de muestreo ( $\Delta$ ).

Por lo tanto, para limitar estos errores, el Filtro de Kalman adaptativo no centrado (AUKF) se emplea inicialmente para llevar el valor inicial al valor real.

#### 4.2.4 Filtro de Kalman no lineal adaptativo

Para mejorar la precisión del Filtro de Kalman No Lineal (UKF) al convertir un sistema no lineal en uno lineal, es crucial emplear la transformación sin muestreo en lugar de la aproximación de Taylor. Aunque en el método UKF se especifica el ruido del modelo del sistema y de las observaciones como constantes, estas no pueden representar con precisión el impacto real del ruido en el filtro. Esto a menudo conduce a un aumento o incluso a una divergencia en el error de estimación del SoC. Para abordar estos problemas, se desarrolló el algoritmo AUKF, una versión mejorada del UKF. El AUKF calcula la varianza de la innovación y la varianza residual utilizando el enfoque de ventana móvil, y monitorea continuamente la evolución de la innovación y el residuo en el filtro. Mientras que la varianza residual ajusta instantáneamente la covarianza del ruido de observación, la varianza de la innovación ajusta la covarianza del ruido del sistema de forma dinámica [13].

El proceso a seguir para el AUKF se presenta de la siguiente manera:

Paso 1: Definir el valor del estado inicial ( $\hat{x}_0$ ) y el valor inicial de estado de error de la covarianza ( $P_0$ ) de acuerdo a las ecuaciones (4.16) y (4.17).

$$z\hat{x}_0 = E[x_0] \quad (4.16)$$

$$P_0 = E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)]^T \quad (4.17)$$

Paso 2: calcular el punto Sigma a través de la ecuación (4.18)

$$\left\{ \begin{array}{l} x_j^0 = \hat{x}_{j-1} \\ x_{j-1}^i = \hat{x}_{j-1} + \sqrt{(L + \lambda)P_{j-1}}, i = 1, 2, \dots, L \\ x_{j-1}^i = \hat{x}_{j-1} - \sqrt{(L + \lambda)P_{j-1}}, i = L + 1, L + 2, \dots, 2L \end{array} \right. \quad (4.18)$$



Donde:

$L$ = la longitud del vector de estado.

El cálculo del valor de los pesos se lo realiza con la ecuación 4.19

$$\begin{cases} \lambda = \alpha^2(L + j_i) - L \\ W_m^0 = \frac{\lambda}{L + \lambda}, W_m^i = \frac{1}{2(L + \lambda)}, i = 1, 2, \dots, 2L \\ W_c^0 = \frac{\lambda}{L + \lambda} + 1 - \alpha^2 + \beta, W_c^i = \frac{1}{2(L + \lambda)}, i = 1, 2, \dots, 2L \end{cases} \quad (4.19)$$

Paso 3: actualizar el tiempo

1. Actualizar el valor del estado predicho ( $\bar{x}_j$ ) con la ecuación 4.20 y 4.21

$$x_{j|j-1}^i = F(x_{j-1}^i) \quad (4.20)$$

$$\bar{x}_{j|j-1}^i = \sum_{i=0}^{2L} W_m^i x_j^i \quad (4.21)$$

2. Actualizar el valor de la predicción observada ( $\bar{y}_j$ ) con la ecuación 4.22 y 4.23

$$y_{j|j-1}^i = G(x_{j-1}^i) \quad (4.22)$$

$$\bar{y}_j = \sum_{i=0}^{2L} W_m^i [G(x_{j-1}^i) + v] = \sum_{i=0}^{2L} W_m^i y_{j|j-1}^i \quad (4.23)$$

3. Actualizar el valor predicho de la covarianza del sistema  $P_{xx|j}$  con la ecuación 4.24

$$P_{xx|j} = \sum_{i=0}^{2L} (W_c^i (x_{j|j-1}^i - \bar{x}_j)(x_{j|j-1}^i - \bar{x}_j)^T) + Q_{j-1} \quad (4.24)$$

4. Calcular el valor innovador  $d_j$  y el valor de varianza innovativo  $C_{dj}$  con la ecuación 4.25 y 4.26

$$d_j = y_j - \bar{y}_j \quad (4.25)$$

$$C_{dj} = \begin{cases} \frac{j-1}{j} C_{dj-1} + \frac{1}{j} d_j d_j^T, j \leq W \\ \frac{1}{W} \sum_{i=j-W+1}^j d_i d_i^T, j > W \end{cases} \quad (4.26)$$

5. Actualizar la covarianza de ruido del sistema  $Q_j$  con la ecuación 4.27

$$Q_j = K_{j-1} C_{dj} K_{j-1}^T \quad (4.27)$$

Paso 4: Actualizar estados

1. Actualizar el valor de observación de covarianza  $P_{yy|j}$  con la ecuación 4.28

$$P_{yy|j} = \sum_{i=0}^{2L} (W_c^i (y_{j|j-1}^i - \bar{y}_j)(y_{j|j-1}^i - \bar{y}_j)^T) + R_{j-1} \quad (4.28)$$

2. Actualizar la covarianza  $P_{xy|j}$  con la ecuación 4.29

$$P_{xy|j} = \sum_{i=0}^{2L} W_c^i (x_{j|j-1}^i - \bar{x}_j)(y_{j|j-1}^i - \bar{y}_j)^T \quad (4.29)$$

3. Calcular la ganancia de Kalman con la ecuación 4.30

$$K_j = \frac{P_{xy|j}}{P_{yy|j}} \quad (4.30)$$

4. Actualizar el valor de la estimación de estado  $\hat{x}_j$  con la ecuación 4.31

$$\hat{x}_j = \bar{x}_j + K_j (y_j - \bar{y}_j) \quad (4.31)$$

5. Actualizar el valor del estado observado  $\hat{y}_j$  con la ecuación 4.32

$$\hat{y}_j = H_j \hat{x}_j \quad (4.32)$$

6. Actualizar el valor de error de la covarianza  $P_j$  con la ecuación 4.33

$$P_j = P_{xx|j} - K_j P_{yy|j} K_j^T \quad (4.33)$$

7. Calcular el valor residual  $r_j$  y el valor residual de la varianza  $C_{rj}$  con las ecuaciones 4.34 y 4.35.

$$r_j = y_j - \hat{y}_j \quad (4.34)$$

$$C_{rj} = \begin{cases} \frac{j-1}{j} C_{dr-1} + \frac{1}{j} r_j r_j^T, j \leq W \\ \frac{1}{W} \sum_{i=j-W+1}^j r_i r_i^T, j > W \end{cases} \quad (4.35)$$

8. Actualizar el valor del ruido de la observación  $R_j$  con la ecuación 4.36

$$R_j = C_{rj} - H_j P_j H_j^T \quad (4.36)$$

#### 4.2.5 Covarianza del ruido del sistema adaptativo ( $Q_j$ )

Las ecuaciones anteriores demuestran que cuando  $Q_j$  es muy grande, la predicción de la covarianza del sistema  $P_{xx|j}$  aumenta, por lo tanto, aumenta el valor del estado  $\overline{x_{j+1}}$ , lo que conduce a un valor alto del estado predicho  $\widehat{x_{j+1}}$ , aumentando así el error del estado de carga estimado.

La covarianza del sistema de ruido  $Q_j$  se actualizará instantáneamente para corregir el efecto de errores del sistema en los resultados estimados.

La diferencia entre el valor real de observación  $y_j$  y el valor de la observación predicha  $\bar{y}_j$  se denota como innovación  $dj$  en el momento ( $j$ ), que se muestra en la ecuación (4.25). En el método ventana móvil, la varianza de la innovación  $C_{dj}$  se denota en la ecuación (4.26).

Donde ( $W$ ) es la longitud de la ventana móvil de la ecuación  $C_{dj}$  de varianza innovadora, y la covarianza de ruido del sistema  $Q_j$  se calcula a partir de la ecuación (4.37)

$$Q_j = K_{j-1} C_{dj-1} K_{j-1}^T \quad (4.37)$$

Después de calcular el valor de innovación  $dj$  y actualizar el valor  $Q_j$  instantáneamente se corrige el error de covarianza  $P_j$ , el valor de ruido del sistema corregido y  $Q_j$  debe llegar a cero

### 4.2.6 Covarianza del ruido de observación del sistema adaptativo ( $R_j$ )

Las ecuaciones anteriores indican que ( $R_j$ ) determina la importancia del valor de la observación en el resultado estimado. A medida que ( $R_j$ ) aumenta, la ganancia del filtro de Kalman ( $K_j$ ) disminuye, lo que reduce el impacto del valor observado en la predicción del estado. Del mismo modo, cuando ( $R_j$ ) disminuye, la ganancia del filtro ( $K_j$ ) aumenta, lo que aumenta el impacto del valor observado en la predicción del estado. Por lo tanto, la covarianza del ruido de observación ( $R_j$ ) ajusta la ganancia de Kalman ( $K_j$ ) instantáneamente para modificar el impacto del valor predicho en la observación. El residuo ( $r_j$ ) en un momento ( $j$ ), que se muestra en la ecuación (4.34), es la divergencia entre el valor real ( $y_j$ ) y el valor estimado de la observación  $\hat{y}_j$ . En el método de la ventana móvil, el valor de la varianza del residuo ( $C_{rj}$ ) se indica en la ecuación 4.38

$$C_{rj} = \begin{cases} \frac{j-1}{j} C_{rj-1} + \frac{1}{j} r_j r_j^T, & j \leq W \\ \frac{1}{W} \sum_{i=j-W+1}^j r_i r_i^T, & j > W \end{cases} \quad (4.38)$$

A partir del valor de la ecuación de la varianza residual ( $C_{rj}$ ), el valor de la covarianza del ruido de observación ( $R_j$ ) se calcula a partir de la ecuación (39). (4.39)

$$R_j = C_{rj} + H_j P_{j-1} H_j^T$$

Por lo tanto, calculando el valor residual  $r_j$  y actualizando  $R_j$  en tiempo real y ajustando la ganancia de Kalman ( $K_j$ ), podemos lograr una estimación óptima.

La Fig. 4.3 detalla todo el procedimiento para el AUKF, donde se realizan iteraciones para ir actualizando el valor hasta obtener el valor aproximado del SoC de la batería.

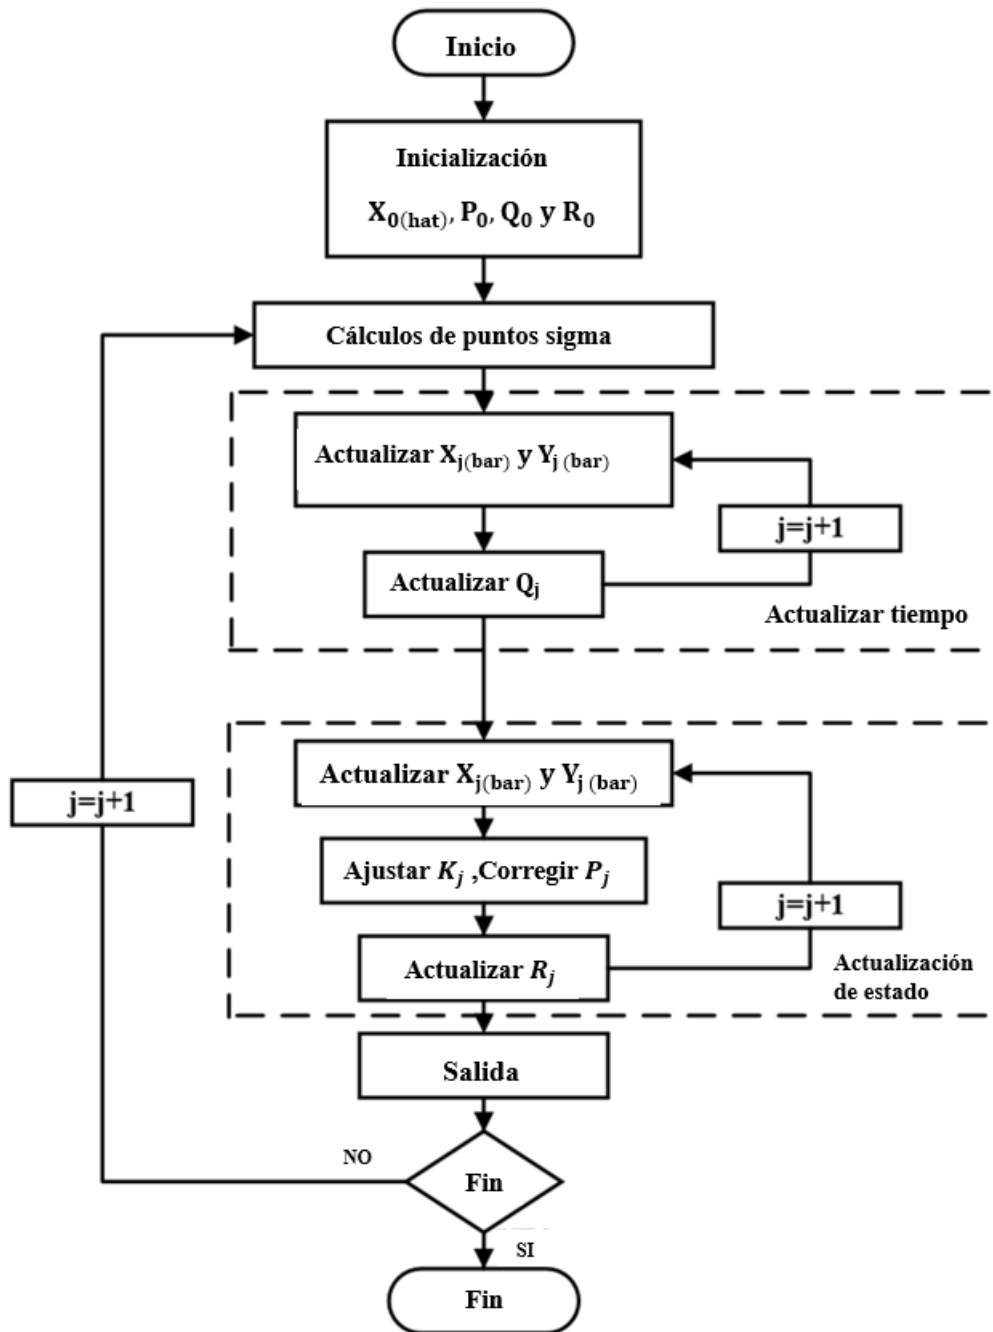


Fig. 4. 3 Diagrama de flujo de AUKF.

### 4.3 Simulación y resultados

La simulación de la obtención del SoC se realiza bajo diferentes condiciones y tomando en cuenta algunas características de una batería de iones de litio de 3,7 V y 2,6 Ah, ya que tiene un gran rendimiento y fiabilidad. Sus características incluyen se detallan en las Tablas 4.1-4.3 [98]. También se consideran otras constantes al simular la batería de iones de litio, representadas en Tabla 4.2

Se aplican cuatro enfoques para las baterías de iones de litio de la siguiente manera:

1. **Enfoque (1):** no se consideran la carga resistiva y el desvanecimiento de la batería;
2. **Enfoque (2):** se considera el desvanecimiento de la batería, pero no la carga resistiva;
3. **Enfoque (3):** se incluye la carga resistiva; el desvanecimiento no se considera
4. **Enfoque (4):** se consideran el desvanecimiento resistivo y de la batería.

*Tabla 4. 1 – Constantes de la batería de iones de litio*

<b>Batería</b>	<b>Valor</b>
Voltaje promedio ( $V_{nom}$ )	3.7
Menor capacidad (Ah)	2.45
Capacidad ideal (Ah)	2.6
Resistencia en serie ( $\Omega$ )	0.05
Corriente máxima de carga/descarga (A)	2/2
Carga CC/CV (mA, V)	1750, 4.20
Tiempo de carga (h)	3
Temperatura ambiente ( $^{\circ}\text{C}$ )	Temperature de carga: (0~+45 $^{\circ}\text{C}$ ) Temperatura de descarga: (-20~+60 C)
Peso (g)	48

Tabla 4. 2 – Constantes de la batería de iones de litio

Parametro	Valor
Capacidad de descarga (Qdis ) (Ahr)	1.4
Sin ciclos de descarga (N)	100
Capacidad Qf de acuerdo con (N) ciclos de descarga (Ahr)	2
(Ro ) despues (N) ciclos de descarga ( $\Omega$ )	0.15
(Vdis ) despues (N) ciclos de descarga (V)	3
Tamaño de la población	20
Nº de iteraciones	500
Estado inicial de carga (SoC0)	0.5
Tiempo de carga y descarga (s)	21,600
Valor inicial de resistencias en serie (usadas para AUKF) ( $\Omega$ )	0.05
Covarianza de error de estado inicial (P0)	$[1 \times 10^{-6} \ 0; \ 0 \ 1]$
Covarianza del ruido de medición (R)	0.25
Covarianza del ruido de proceso (Q)	$[1 \times 10^{-1} \ 0; \ 0 \ 1 \times 10^{-1}]$
Alpha ( $\alpha$ )	1
Beta ( $\beta$ )	1
Kappa ( $\kappa$ )	0

Tabla 4. 3 Límites de los parámetros de la batería de iones de litio.

Parametro	LB	UB	Parametro	LB	UB
	At $T_1 = 25$ °C			At $T_2 = 45$ °C	
$V_{nom}$ (V)	3	4	$V_{nom}$ (V)	3	4
$R_o T_1$ ( $\Omega$ )	0.045	0.06	$R_o T_2$ ( $\Omega$ )	0.07	0.085
$R_{tr} T_1$ ( $\Omega$ )	0.005	0.015	$R_{tr} T_2$ ( $\Omega$ )	0.007	0.01
$\tau_{tr} T_1$ (s)	100	200	$\tau_{tr} T_2$ (s)	150	250

### 4.3.1 Simulación de aproximación 1

En este enfoque, se excluyen tanto los efectos de carga como los de desvanecimiento de la batería. La Tabla 4.4 representa los valores de los parámetros

optimizados mediante el Algoritmo de Optimización de African Vultures (AVOA) a diferentes valores de estado de carga a temperaturas de 25 °C y 45 °C; luego, después de estimar el SoC, la Tabla 4.5 representa el error del SoC (ISE) que se utiliza en las curvas entre los enfoques híbridos contrastados en la Figura 4.

Tabla 4. 4 – Enfoque (1): parámetros optimizados de la batería de iones de litio a diferentes valores de SoC.

	SoC = 0	SoC = 0.1	SoC = 0.25	SoC = 0.5	SoC = 0.75	SoC = 0.9	SoC = 1
$V_{nom} T_1$	3	3.06	3.13	3.22	3.42	3.58	3.7
$R_o T_1$	0.0515	0.0508	0.0512	0.0519	0.0519	0.0525	0.0528
$R_{tr} T_1$	0.0137	0.0097	0.0075	0.0062	0.0061	0.0061	0.0056
$\tau_{tr} T_1$	104.65	115.36	193.45	120.54	143.71	124.36	109.71
$V_{nom} T_2$	3.2109	3.2812	3.3409	3.4269	3.6409	3.7954	3.9009
$R_o T_2$	0.0801	0.0801	0.0803	0.0798	0.0799	0.08	0.08
$R_{tr} T_2$	0.0083	0.0078	0.008	0.0079	0.0086	0.0081	0.008
$\tau_{tr} T_2$	157	166	226	150	198	154	160

Tabla 4. 5 – Aproximación (1): Error del SoC de la batería de iones de litio utilizando técnicas híbridas comparativas.

	CC + EKF	CC + UKF	CC + AEKF	CC + AUKF
ISE	0.000285955	$8.58843 \times 10^{-5}$	$5.80235 \times 10^{-5}$	$1.72978 \times 10^{-6}$

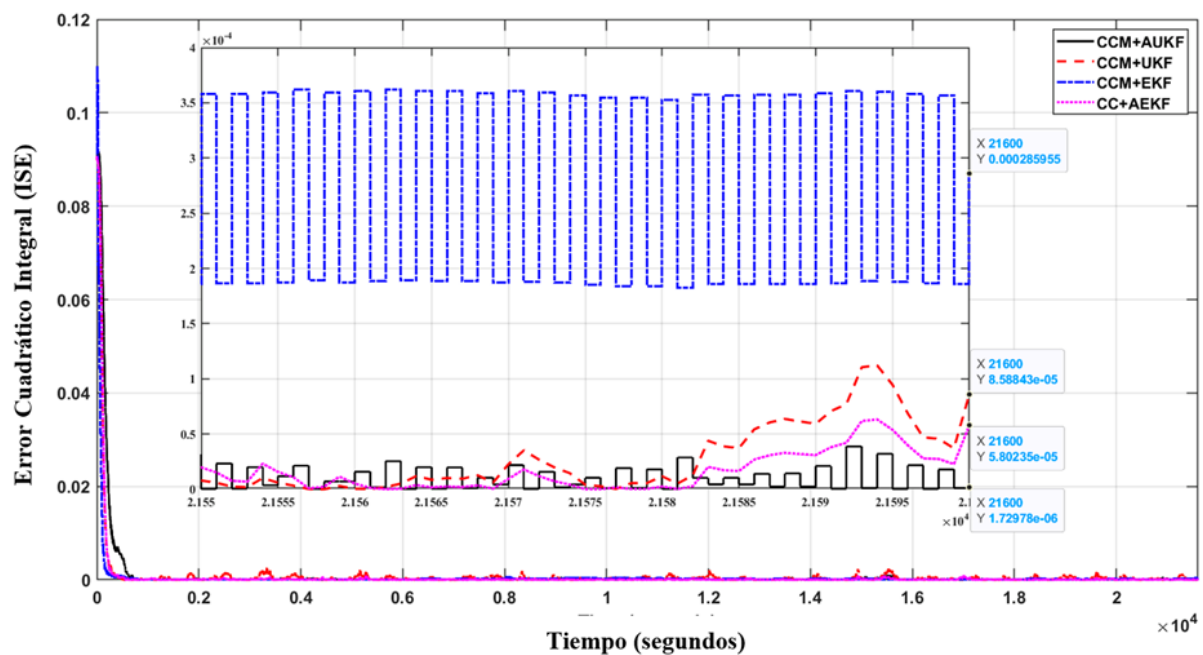




Fig. 4. 4 - Curvas de convergencia para la aproximación de la batería de iones de litio (1).

La Figura 4.4 muestra las curvas de convergencia entre el error cuadrado integral (ISE) y el tiempo en segundos.

### 4.3.2 Simulación de aproximación 2

En este enfoque, se incluye el efecto del desvanecimiento de la batería, mientras que la carga no está incluida. Tanto la capacidad de la batería como la resistencia de la serie de la batería se ven afectadas por el envejecimiento. Los aumentos de resistencia son causados por varias causas, incluido el desarrollo (SEI) de la corrosión del ánodo, el cátodo y las interfaces del colector actual. Estos mecanismos provocan el desvanecimiento de la batería y están influenciados por la temperatura, el estado de carga y el tiempo de almacenamiento. En la Tabla 4.6 se representan los valores de los parámetros optimizados mediante el algoritmo de optimización de African Vultures (AVOA) a diferentes valores de estado de carga a temperaturas de 25 °C y 45 °C; luego, después de estimar el SoC, la Tabla 4.7 representa el error del SoC (ISE), que se utiliza en las curvas entre los enfoques híbridos contrastados en la Figura 4.5.

Tabla 4. 6 – Enfoque (2): parámetros optimizados de la batería de iones de litio a diferentes valores de SoC.

	SoC = 0	SoC = 0.1	SoC = 0.25	SoC = 0.5	SoC = 0.75	SoC = 0.9	SoC = 1
$V_{nom} T_1$	3.024	3.084	3.154	3.244	3.444	3.604	3.724
$R_o T_1$	0.0496	0.0489	0.0493	0.050	0.052	0.0526	0.0529
$R_{tr} T_1$	0.00992	0.00952	0.00732	0.00602	0.00592	0.00592	0.00542
$\tau_{tr} T_1$	104.568	115.984	193.4587	120.364	143.5681	124.5847	109.2108
$V_{nom} T_2$	3.231	3.301	3.361	3.441	3.661	3.811	3.9210
$R_o T_2$	0.08436	0.08436	0.08456	0.08406	0.08416	0.08426	0.08426
$R_{tr} T_2$	0.00885	0.00835	0.00855	0.00845	0.00915	0.00865	0.00855
$\tau_{tr} T_2$	157.412	166.785	226.457	150.251	198.473	154.785	160.251

Tabla 4. 7 – Aproximación (2): Error del SoC de la batería de iones de litio utilizando técnicas híbridas comparativas.

	CC + EKF	CC + UKF	CC + AEKF	CC + AUKF
ISE	0.000297115	0.000260252	$4.28443 \times 10^{-5}$	$2.78046 \times 10^{-5}$

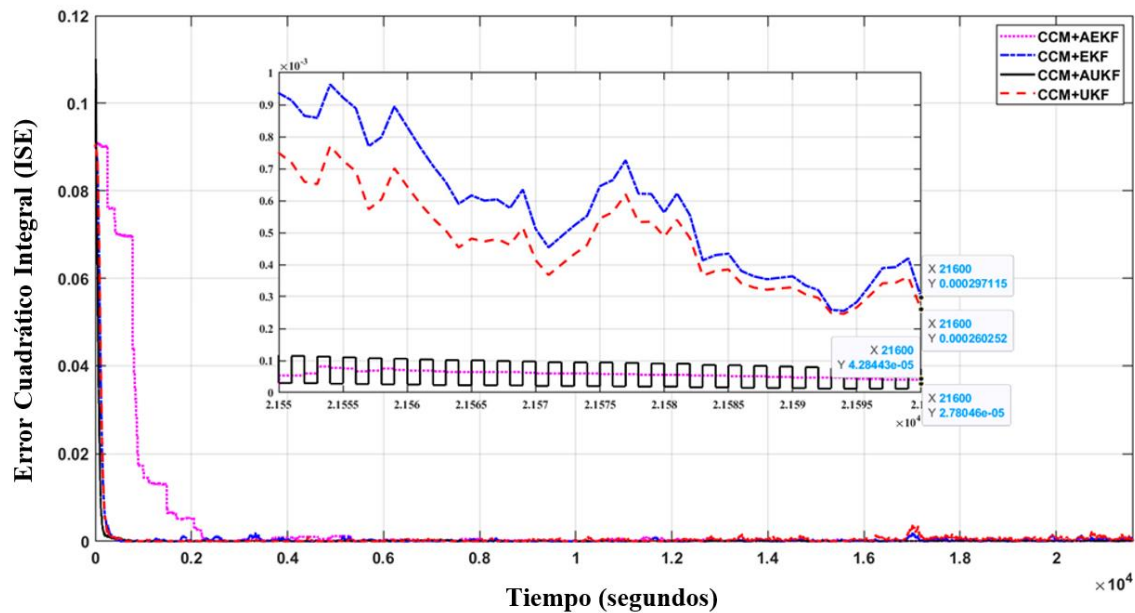


Fig. 4. 5 - Curvas de convergencia para la aproximación de la batería de iones de litio (2).

La Figura 4.5 muestra las curvas de convergencia entre el error cuadrado integral (ISE) y el tiempo en segundos.

### 4.3.3 simulación de aproximación 3

En este enfoque, se estudia una carga resistiva igual a 1 k $\Omega$  mientras que el desvanecimiento de la batería no lo es. En la Tabla 4.8 se representan los valores de los parámetros optimizados mediante el algoritmo de optimización de los African Vultures (AVOA) a diferentes valores de SoC a temperaturas de 25 °C y 45 °C; luego, después de estimar el SoC, la Tabla 4.9 representa el error del SoC (ISE) que se utiliza en las curvas entre los enfoques híbridos contrastados en la Figura 6.

Tabla 4. 8 – Enfoque (3): parámetros optimizados de la batería de iones de litio a diferentes valores de SoC.

	SoC = 0	SoC = 0.1	SoC = 0.25	SoC = 0.5	SoC = 0.75	SoC = 0.9	SoC = 1
$V_{nom}/T_1$	3.0115	3.0715	3.1415	3.2315	3.4315	3.5915	3.7115
$R_o/T_1$	0.0511	0.05045	0.05085	0.05155	0.05155	0.05215	0.05245
$R_{tr}/T_1$	0.0098	0.00942	0.00722	0.00592	0.00572	0.00572	0.00522
$\tau_{tr}/T_1$	104.5129	115.321	193.2314	120.478	143.9845	124.9541	109.1172
$V_{nom}/T_2$	3.2213	3.2913	3.3513	3.4313	3.6513	3.8013	3.9113
$R_o/T_2$	0.0842	0.0846	0.0848	0.0843	0.0844	0.08450	0.08452
$R_{tr}/T_2$	0.0089	0.00841	0.00861	0.00861	0.00931	0.00881	0.00871
$\tau_{tr}/T_2$	157.86	166.873	226.1234	150.364	198.4155	154.2844	160.8211

Tabla 4. 9 – Enfoque (3): Error de SoC de batería de iones de litio utilizando técnicas híbridas comparativas..

	CC + EKF	CC + UKF	CC + AEKF	CC + AUKF
ISE	$5.82592 \times 10^{-5}$	0.000256599	$8.53238 \times 10^{-5}$	$1.52231 \times 10^{-6}$

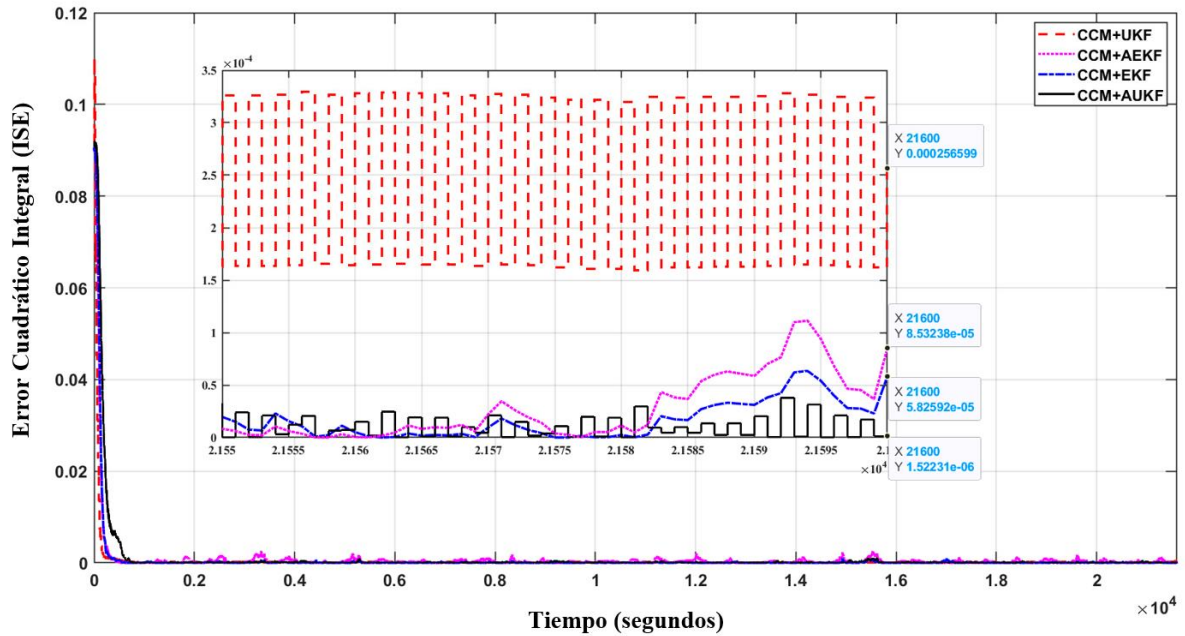


Fig. 4. 6 - Curvas de convergencia para la aproximación de la batería de iones de litio (3).

La Figura 6, muestra las curvas de convergencia entre el error cuadrado integral (ISE) y el tiempo en segundos.

#### 4.3.4 Simulación de aproximación 4

En este enfoque, se tienen en cuenta tanto la carga resistiva como el desvanecimiento de la batería. En la Tabla 4.10 se representan los valores de los parámetros optimizados mediante el Algoritmo de Optimización de African Vultures (AVOA) a diferentes valores de estado de carga a temperaturas de 25 °C y 45 °C; luego, después de estimar el SoC, la Tabla 4.11 representa el error del SoC (ISE) que se utiliza en las curvas entre los enfoques híbridos contrastados en la Figura 4.7.

Tabla 4. 10 – Enfoque (4): parámetros optimizados de la batería de iones de litio a diferentes valores de SoC.

	SoC = 0	SoC = 0.1	SoC = 0.25	SoC = 0.5	SoC = 0.75	SoC = 0.9	SoC = 1
$V_{nom} T_1$	3.011	3.071	3.141	3.231	3.431	3.591	3.711
$R_o T_1$	0.0523	0.0514	0.0517	0.0522	0.0522	0.0528	0.0531
$R_{tr} T_1$	0.00891	0.00931	0.00711	0.00581	0.00571	0.00561	0.00521
$\tau_{tr} T_1$	104.3675	115.2178	193.3245	120.6478	143.86321	124.9541	109.1131
$V_{nom} T_2$	3.2101	3.2801	3.3401	3.4201	3.6401	3.7901	3.9001
$R_o T_2$	0.0858	0.0858	0.086	0.0855	0.0857	0.0858	0.0861
$R_{tr} T_2$	0.008275	0.007875	0.008075	0.007975	0.008675	0.008275	0.008175
$\tau_{tr} T_2$	157.3211	166.3222	226.3144	150.3644	198.2345	154.2387	160.7111

Tabla 4. 11 – Enfoque (4): Error de SoC de batería de iones de litio utilizando técnicas híbridas comparativas..

	CC + EKF	CC + UKF	CC + AEKF	CC + AUKF
ISE	0.000259489	0.000298199	$5.85516 \times 10^{-5}$	$4.44024 \times 10^{-5}$

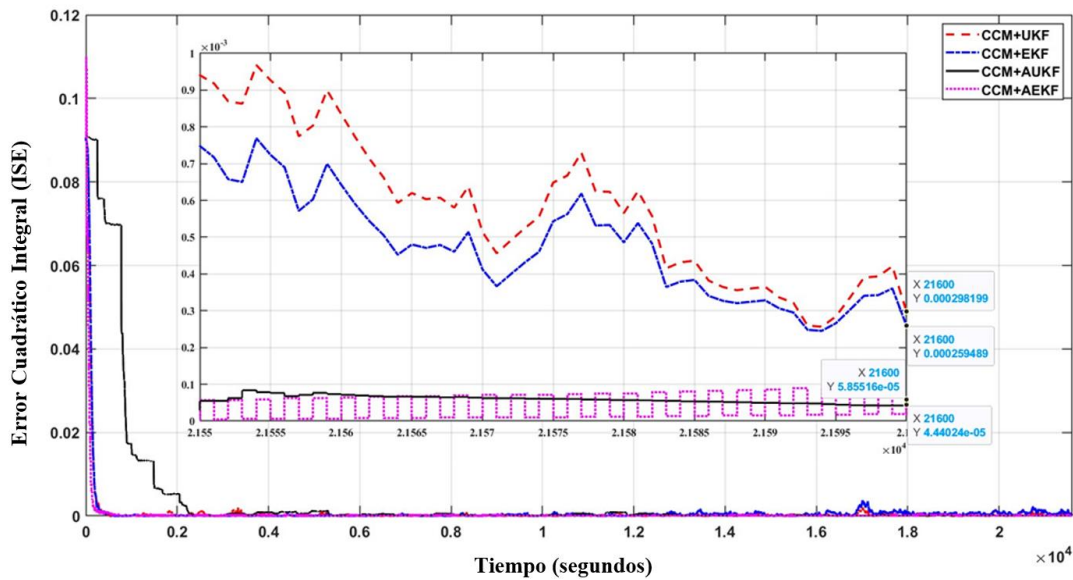


Fig. 4. 7 - Curvas de convergencia para la aproximación de la batería de iones de litio (4).

La Figura 7, muestra las curvas de convergencia entre el error cuadrático integral (ISE) y el tiempo en segundos.

## **4.4 Conclusiones**

Este trabajo empleó un enfoque híbrido para calcular el SoC de las baterías de iones de litio. En primer lugar, la batería se modela con precisión para una estimación precisa del SoC mediante el uso del optimizador de African Vultures (AVOA), que se considera una de las técnicas de optimización más eficaces para modelar un modelo no lineal como la batería de iones de litio. A continuación, se utiliza el método híbrido que consiste en el CCM con el AUKF para la estimación del SoC.

AUKF se emplea inicialmente para llevar el valor inicial al valor real y eliminar cualquier error en las primeras lecturas, y luego Coulomb Counting continúa estimando SoC durante un largo tiempo de trabajo. Este método híbrido se compara con otros métodos híbridos, como el CCM con un EKF, el CCM con un UKF y el CCM con un AEKF. En el caso de la batería de iones de litio de 2,6 Ahr, los resultados de la simulación muestran que la combinación propuesta de CCM con AUKF tiene una validación dinámica y una capacidad excepcionales en todas las situaciones.

## CAPÍTULO 5: RESULTADOS

---

### ***5.1 Resultados de la planificación óptima de paneles fotovoltaicos en comunidades energéticas***

La implementación de sistemas de energía renovable, como la energía solar fotovoltaica, en comunidades energéticas es una estrategia prometedora para reducir las emisiones de CO<sub>2</sub> y promover la sostenibilidad energética [99]. En este contexto, se ha desarrollado una herramienta de planificación para optimizar la instalación de paneles fotovoltaicos en CE, considerando diferentes presupuestos disponibles.

En este apartado, se presentan los resultados de la aplicación de esta herramienta de planificación para diferentes presupuestos, representados por  $\Pi$ . Para ilustrar estos resultados, se considera el caso de referencia de una CE compuesta por seis pares, cuyos datos se detallan a continuación.

La Fig 3.5 muestra los resultados del precio de la energía planificada en función de las diferentes franjas horarias. Se observa que las horas con mayor precio están comprendidas entre las 17:00 h y las 22:00 h. Esta información es crucial para la toma de decisiones estratégicas relacionadas con la gestión de la energía en la comunidad. La planificación adecuada de la generación de energía fotovoltaica durante estas horas de alto

precio puede tener un impacto significativo en la reducción de los costos de energía para los miembros de la comunidad.

Además del precio de la energía, se analizarán otros resultados importantes, como la cantidad de energía generada por los paneles fotovoltaicos en diferentes momentos del día, el nivel de autoconsumo de la comunidad y la cantidad de energía comprada o vendida a la red eléctrica. Estos resultados proporcionarán una visión detallada de la eficacia y la viabilidad económica de la planificación de paneles fotovoltaicos en comunidades energéticas.

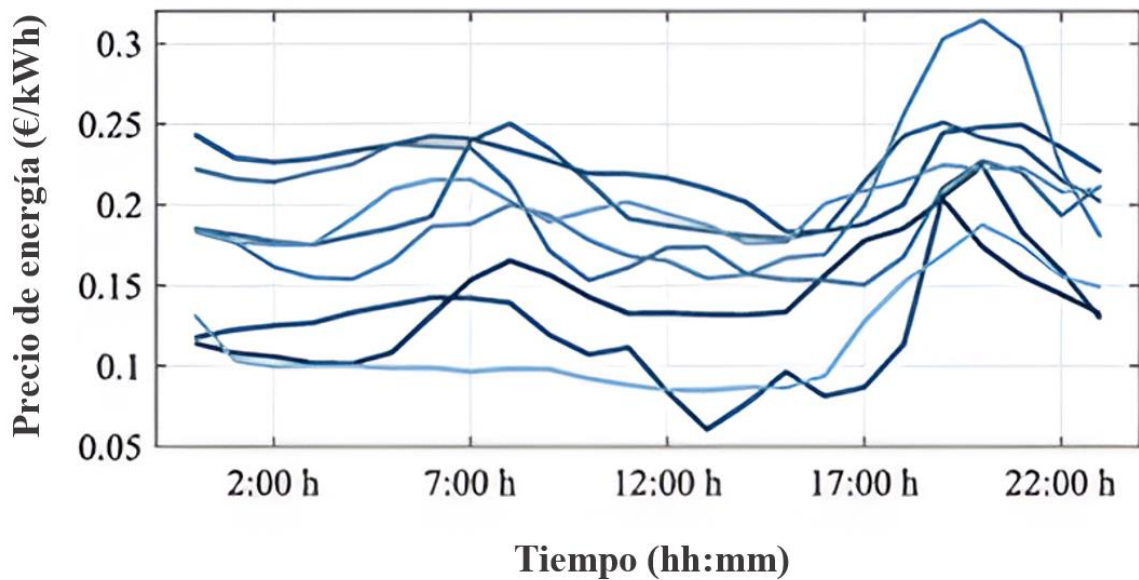


Fig. 5.1 – Precio de la energía según el horario.

La Fig 5.2, indica la temperatura exterior que estaría relacionada con el potencial PV y es mayor en la franja horaria desde las 12:00h hasta las 17:00h.

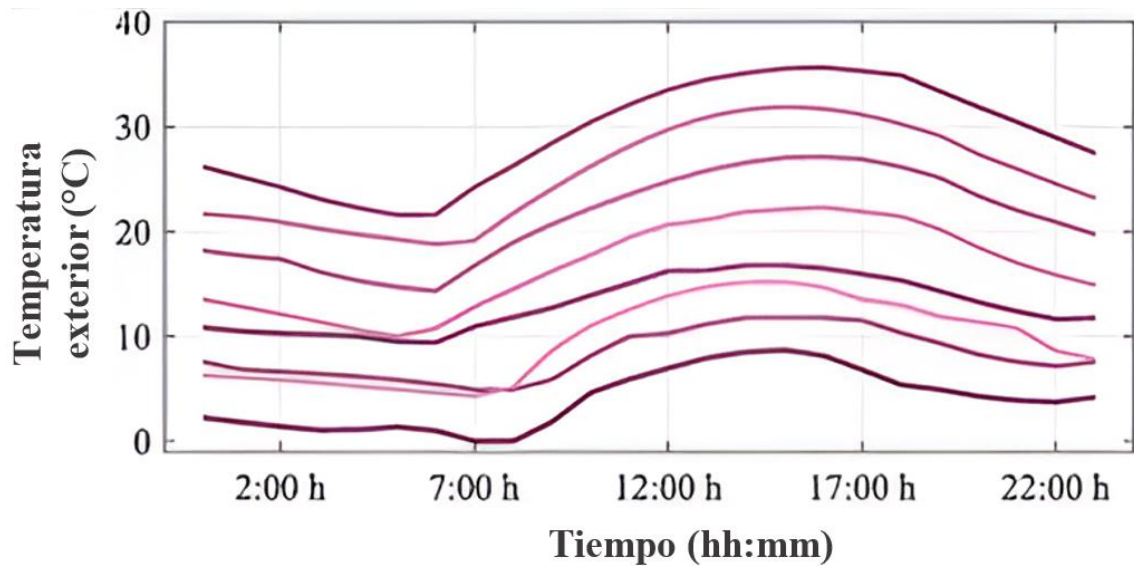


Fig. 5. 2 – Temperatura exterior según el horario.

En la Fig 5.3 se muestra el potencial de generación fotovoltaica de acuerdo al horario, donde se observa que los valores más altos se dan alrededor del medio día.

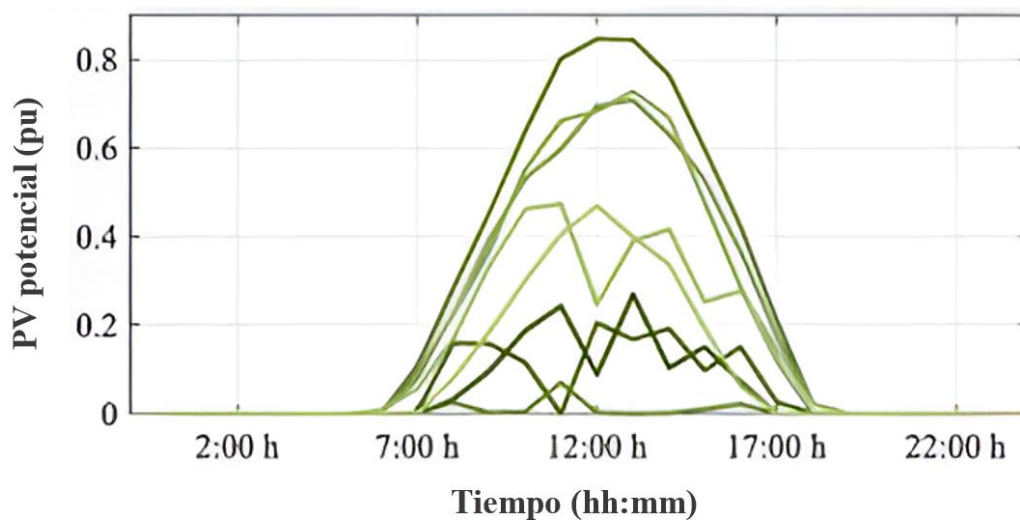


Fig. 5. 3 Potencial PV en relación al horario.

La Fig 5.4 indica demandada de potencia en kWh de los seis pares de la comunidad, que representa el perfil individual de consumo.



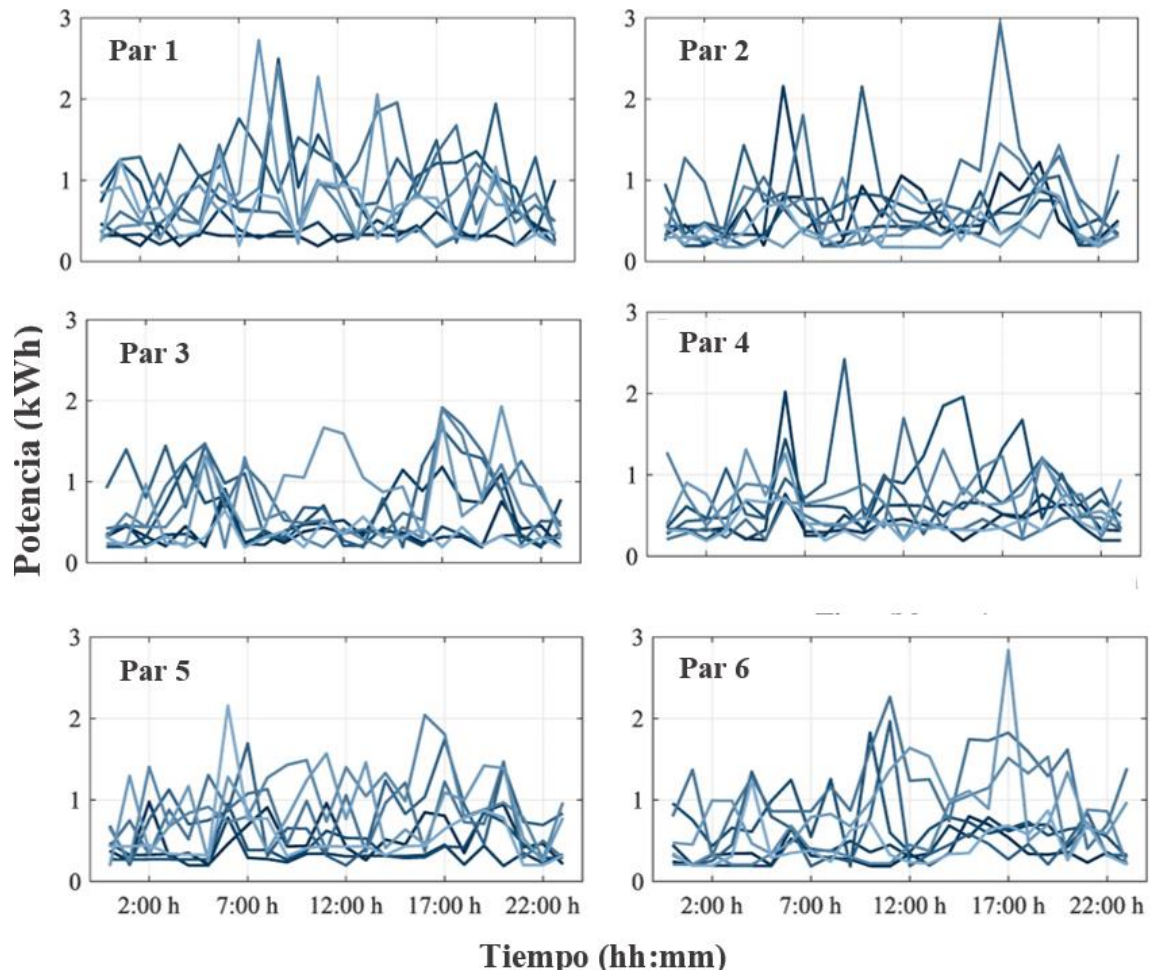


Fig. 5. 4 – Demanda no flexible de potencia en kWh de cada par de la comunidad.

La Tabla 5.1 muestra los datos de referencia de los pares de la comunidad, donde se indica estados de carga, potencia, eficiencia entre otros factores.

Tabla 5. 1– Datos de cada par de la comunidad

Parametro	Par # 1	2	3	4	5	6
$SOC^B$	2.5	2.5	4	4.5	4	4
$\underline{SOC}^B$	1	1.25	2.4	1.8	1.2	0.8
$SOC^{EV}$	10	19	22	22	10	16
$\underline{SOC}^{EV}$	3	3.8	4.4	5.5	1.5	1.6
$p^B$	0.625	2.5	1.33	2.25	1	2
$p^{EV}$	3.7	3.7	3.7	3.7	3.7	3.7
$\eta^B$	0.92	0.97	0.92	0.9	0.94	0.94
$\eta^{EV}$	0.9	0.96	0.97	0.95	0.93	0.98
$p^H$	2.5	4	3	2.5	4	2.5
$A_{Air,in}$	0.19	0.16	0.15	0.16	0.14	0.14
$B_{Air,in}$	2.9	3.4	3	2.8	2.6	3.2
$\theta^{H,sp}$	23.5	23	24	25	24	23
$\rho_{H,db}$	0.5	0.5	0.5	1.5	0.5	1.5
$SOC^{EV,0}$	5	12.35	8.8	14.3	6.5	11.2
EV Depart.	9:00	6:00 h	10:00 h	9:00 h	7:00 h	8:00 h

### 5.1.1 Coste del proyecto

La relación del coste total del proyecto y la capacidad fotovoltaica instalada se muestra en la Fig. 5.5. Como era de esperar, la instalación de generación fotovoltaica colectiva tiene un impacto notable en la economía del sistema, permitiendo la autogeneración local que ayuda a reducir la energía importada de la red de distribución. Como se puede observar, el coste total del proyecto (es decir, la energía más los costes de capital y mantenimiento) disminuye linealmente con el presupuesto disponible.

En particular, el coste total disminuye en un 19 % (~100.000 €) cuando el presupuesto disponible aumenta de 0 a 100.000 € en el estudio de caso. También vale la pena señalar que la energía fotovoltaica instalada aumenta linealmente con el presupuesto disponible, lo que indica que el resultado óptimo se logra cuando todo el presupuesto disponible se dedica realmente a la instalación de energía fotovoltaica (en otras palabras, la restricción (3.7) siempre se activa en el momento óptimo).




Fig. 5.5 - Validación del modelo de campo.

Para obtener una mejor visión general de los resultados de las Figs. 5.6 y 5.7, se representa la energía total importada/exportada por la economía para diferentes presupuestos. Es decir, la Fig. 5.6 muestra el balance energético de la CE para diferentes tamaños fotovoltaicos. Los resultados muestran que, la energía que debe importarse de la red disminuye drásticamente con el tamaño del sistema fotovoltaico. Más concretamente, la energía importada se redujo en este caso en un 32 % (casi 1200 MWh menos) cuando la capacidad fotovoltaica total aumentó de 0 a 80 kWp. Por el contrario, la energía exportada a la red con el tamaño fotovoltaico. Este resultado obedece a una coherencia lógica, de hecho, cuando la capacidad fotovoltaica es alta, la comunidad observa un

excedente de energía renovable que eventualmente puede exportarse a la red para obtener un ingreso monetario adicional. En el caso de estudio, la energía exportada aumentó un 96 %. Es importante ver que la energía exportada no es nula ni siquiera con . En este caso, la energía fotovoltaica no está instalada y la capacidad exportable única proviene de sistemas de almacenamiento, que son capaces de proporcionar arbitraje de energía. No obstante, cabe señalar que las importaciones de energía fueron muy superiores a las exportaciones en todos los casos, lo que indica que la exportación de energía es en realidad una actividad secundaria en las CE, más bien dedicada a satisfacer su demanda local.




Fig. 5.6 - Energía total importada (arriba) y exportada (abajo) por la comunidad para diferentes presupuestos.

En la Fig. 5.7 se analiza el balance energético anual de la comunidad (importaciones y exportaciones). En particular, la Fig. 5.7 representa el caso con  $\Pi = 60.000\text{€}$ , mientras que se pueden extraer conclusiones similares para diferentes presupuestos.

Además el objetivo es analizar cómo afectan los parámetros a largo plazo, como la degradación de los paneles solares y el crecimiento de la carga eléctrica, impactan en el rendimiento global del sistema. Como se ha presentado, el total de la energía importada sigue una tendencia clara creciente. Este aumento se debe a que se ha considerado que la capacidad fotovoltaica se reduce progresivamente debido a la degradación de los paneles,

mientras que la demanda eléctrica aumenta. Estos dos factores conllevan inevitablemente a un incremento en la energía importada desde la red de distribución, ya que los paneles solares pierden capacidad para abastecer la creciente demanda energética de la comunidad.




Fig. 5. 7 - Energía total importada (arriba) y exportada (abajo) por la comunidad anualmente a lo largo de la vida útil del proyecto..

Por otro lado, la energía exportada sigue un patrón oscilante y poco claro. Esto se debe, además de a la degradación de los paneles, al aumento de los precios que hace atractiva la venta de energía a la red. Por lo tanto, los parámetros a largo plazo en este caso son contradictorios. De hecho, los precios más altos fomentan la venta de energía, sin embargo, la capacidad fotovoltaica se degrada cada año, lo que limita la capacidad exportadora de la comunidad. De hecho, resulta interesante observar que la tendencia creciente de la energía importada se invierte en el mismo año en que la comunidad exporta menos energía. Esto demuestra que la generación y el almacenamiento local permiten un arbitraje de energía que resulta beneficioso para toda la comunidad. Cuando la exportación de energía resulta económicamente atractiva, la comunidad opta por extraer más energía de la red de distribución para cargar las baterías. Esta energía almacenada se exporta posteriormente durante las horas punta, aprovechando los altos precios de venta durante este período.

Los resultados de Fig 5.7 sirven para validar el enfoque propuesto e incluir la degradación a largo plazo y los términos de inflación dentro del marco de optimización. En este sentido, el algoritmo de Benders propuesto proporciona un marco para incorporar estos parámetros de una manera sencilla, a diferencia de otras formulaciones que no reflejan fielmente estas características.

La Fig 5.18 se centra en los aspectos económicos. En particular, esta cifra compara el saldo monetario en dos casos extremos (es decir,  $\Pi = 0$  y  $\Pi = 100.000$  €). Como se ve, cuando el presupuesto disponible es cero, prácticamente todos los gastos provienen de la importación de energía. De hecho, en este escenario, la capacidad fotovoltaica es nula y, por lo tanto, la comunidad se convierte en una carga pura. Solo hay un beneficio marginal de la exportación de energía a través de las baterías. Por el contrario, con  $\Pi=100.000$  €, la energía importada se reduce, la energía exportada crece y los costes de capital y mantenimiento se vuelven importantes. Bajo este escenario, si bien los costos de importación de energía aún representan un porcentaje importante de los costos totales del proyecto, las otras actividades monetarias cobran importancia y no pueden ser ignoradas en el análisis. En este sentido, la herramienta desarrollada permite incorporar fácilmente una variedad de costos relacionados con el proyecto y la energía, lo que permite obtener resultados confiables que ayudan en el proceso de toma de decisiones.




Fig. 5. 8 - Distribución de costos para diferentes presupuestos.

A continuación, nos centramos en el papel de los aparatos controlables. Para ello, comparamos en la Fig. 5.9 el resultado de la programación para un día representativo del primer año en el horizonte temporal del proyecto con y sin instalación fotovoltaica ( $\Pi = 60.000$  € frente a  $\Pi = 0$  €). Como se ha observado, en ausencia de paneles fotovoltaicos,

los aparatos controlables (CA) se programan principalmente por la noche, coincidiendo con los bajos precios de la energía y la eventual baja demanda no flexible. En este caso, cabe destacar que la comunidad no puede exportar energía y, por lo tanto, se demanda energía de la red de distribución durante todo el día. Por el contrario, con la energía fotovoltaica instalada, la comunidad puede exportar energía al mediodía. Cabe recalcar que en ambos casos los CA se programaron por la noche, esto demuestra que, en el caso de la instalación de paneles fotovoltaicos colectivos, la herramienta propuesta prioriza el alto potencial fotovoltaico durante el mediodía para exportar energía, mientras que las CA están programadas aprovechando los bajos precios de la energía. Siguiendo esta estrategia, el resultado de la programación busca explotar estas dos ventajas con el fin de mejorar la economía de la comunidad.




Fig. 5. 9 - Resultado de la programación para diferentes presupuestos (en esta figura, potencia negativa significa potencia exportada).

Finalmente, se muestra los efectos de la degradación del panel en la Fig. 5.10. En esta figura, comparamos los resultados de la programación para el mismo día representativo en el 1er y último año de vida del proyecto. Como se puede observar, la potencia exportada se reduce ligeramente a los 30 años debido a que la potencia nominal de los paneles fotovoltaicos se reduce por efecto de la degradación. También es interesante mencionar que algunas CA se desplazan a las horas centrales a los 30 años. Esto se debe a que la herramienta de programación propuesta tiene como objetivo compensar la reducción de la potencia exportable desplazando parte de la demanda a las horas centrales del día, cuando los precios de la energía son bajos. De esta manera, la reducción de los ingresos por la exportación de energía se compensa con menores gastos por las importaciones de energía.

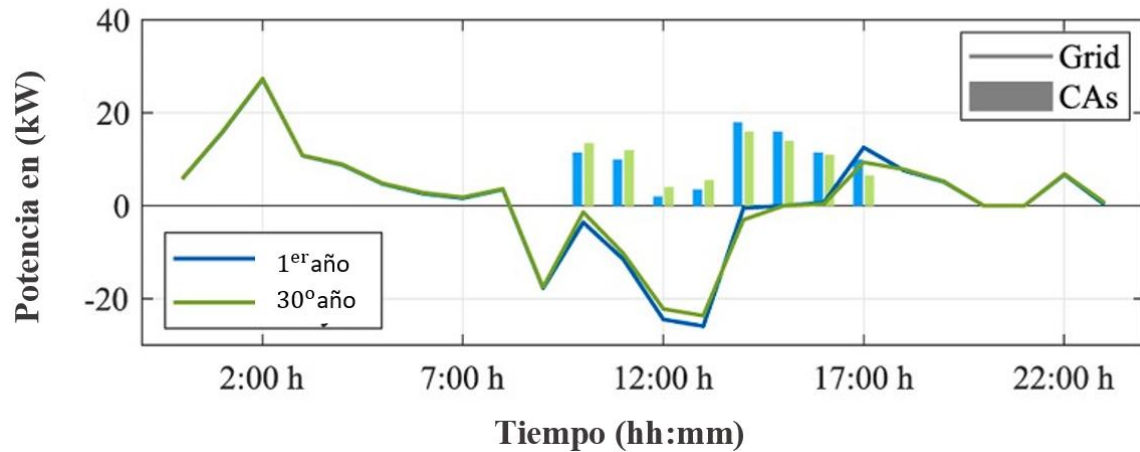


Fig. 5.10 - Resultado de programación para diferentes años (en esta figura, potencia negativa significa potencia exportada).

## 5.1.2 Limitaciones y posibles aplicaciones

El modelo de optimización desarrollado se presenta como un MILP que se puede resolver utilizando máquinas promedio en un tiempo razonable, como se ha demostrado a lo largo de la presente sección. Además, el modelo desarrollado es adaptable a diferentes diseños y componentes. De hecho, vale la pena señalar que, por ejemplo, la inclusión de dispositivos adicionales o la modificación de los principios de funcionamiento de los componentes individuales resulta tan simple como introducir escasas modificaciones en el modelo (3.8)-(3.29). Del mismo modo, se pueden omitir otros componentes individuales de una manera sencilla. Por ejemplo, en caso de que no se instalen baterías individuales, el modelo se puede adaptar simplemente omitiendo sus correspondientes restricciones.

Por otro lado, el modelo asegura alcanzar el óptimo global. De hecho, el problema MILP se puede resolver utilizando algoritmos estándar de ramificación y límites, que alcanzan el óptimo global si la optimización y las brechas de enteros se establecen igual a cero. De la misma manera, el algoritmo de descomposición de Benders propuesto es óptimo si los parámetros de tolerancia  $\epsilon$  se ajustan a un nivel bajo en comparación con el costo total del proyecto.

Por lo tanto, la metodología presentada presenta pocas limitaciones a nivel de codificación y resolución. Tal vez su principal limitación radique en el hecho de que, en su forma actual, solo es aplicable a las comunidades cooperativas. En este sentido, su

aplicación a comunidades competitivas con mercado local habilitado (ver e.g. [100] ), requeriría modificar considerablemente el modelo. Sin embargo, se plantea la hipótesis de que se podría aplicar la misma técnica de descomposición y se estudiará en futuros trabajos.

Vale la pena señalar que la herramienta desarrollada es versátil y se puede adaptar a cualquier otro problema en el que los paneles fotovoltaicos deban dimensionarse correctamente. En este sentido, su aplicación en microrredes, centrales eléctricas virtuales y otro tipo de sistemas energéticos es sencilla. Por otro lado, la nueva propuesta puede encontrar aplicaciones en diversos campos, como los sistemas de riego (véase ([101])). El sector agroalimentario es otro de los potenciales de aplicación. Por ejemplo, en ([102]) los autores examinan el impacto de la energía solar en dicho sector, mostrando que las tecnologías fotovoltaicas se encuentran entre los líderes en el sector agroalimentario. Por otro lado, la producción de petróleo ([103]) y otras actividades conexas ([103] ; [104]) también podrían beneficiarse. En estos casos, la herramienta desarrollada podría suponer un valioso aporte que será evaluado en futuros trabajos.

## 5.2 Resultados de cálculo de SoC

En esta sección, se presentan los resultados obtenidos del cálculo del Estado de Carga (SoC) de las baterías. Este estudio explora la relación entre las características de la batería y el estado de carga (SoC) bajo diversas condiciones de carga, temperatura y envejecimiento. En comparación con investigaciones previas, los resultados demuestran una notable reducción en el error entre el SoC estimado y el SoC real. Esto se logra mediante la aplicación de un novedoso método híbrido que combina el conteo de Coulomb (CCM) con el Filtro de Kalman No Lineal Adaptativo (AUKF). Este enfoque integrado ha demostrado ser más preciso y confiable para estimar el SoC de las baterías de iones de litio en diversas condiciones operativas . Las Tablas 5.2 a 5.5 muestran el valor objetivo alcanzado por la batería de iones de litio con técnicas de contraste, donde se puede evidenciar una disminución del error y del rango en todos los casos de cálculo realizados con diferentes condiciones.

Tabla 5. 2 – Valor objetivo de la batería de iones de litio utilizando técnicas comparativas híbridas para el enfoque (1).

	CC + EKF	CC + UKF	CC + AEKF	CC + AUKF
ISE	0.000285955	$8.58843 \times 10^{-5}$	$5.80235 \times 10^{-5}$	$1.72978 \times 10^{-6}$



Rango	4 (Max.)	3	2	1 (Min.)
-------	----------	---	---	----------

Tabla 5. 3 – Valor objetivo de la batería de iones de litio utilizando técnicas comparativas híbridas para el enfoque (2).

	CC + EKF	CC + UKF	CC + AEKF	CC + AUKF
ISE	0.000267115	0.000260252	$4.28443 \times 10^{-5}$	$2.78046 \times 10^{-5}$
Rango	4 (Max.)	3	2	1 (Min.)

Tabla 5. 4 – Valor objetivo de la batería de iones de litio utilizando técnicas comparativas híbridas para el enfoque (3).

	CC + EKF	CC + UKF	CC + AEKF	CC + AUKF
ISE	$5.82592 \times 10^{-5}$	0.000256599	$8.53238 \times 10^{-5}$	$1.52231 \times 10^{-6}$
Rango	2	4 (Max.)	3	1 (Min.)

Tabla 5. 5 – Valor objetivo de la batería de iones de litio utilizando técnicas comparativas híbridas para el enfoque (4).

	CC + EKF	CC + UKF	CC + AEKF	CC + AUKF
ISE	0.000259489	0.000298199	$5.85516 \times 10^{-5}$	$4.44024 \times 10^{-5}$
Rango	3	4 (Max.)	2	1 (Min.)

De acuerdo con los resultados de las Tablas 5.2-5.5, con base en el valor de la error y convergencia, el MCP con AUKF da el mínimo (ISE) y el mejor comportamiento para la curva de convergencia en todos los enfoques. Para una mayor confirmación de que el método híbrido se ajusta como la mejor técnica de estimación de SoC y tiene el menor error, el uso de cada método de estimación como un individuo sin incluir ninguna técnica híbrida da un error mayor que el uso de la técnica híbrida. La Tabla 5.6 muestra los resultados de la aplicación de varios métodos de estimación de SoC en baterías de iones de litio para todos los enfoques.

Tabla 5. 6 – Valores de error de SoC en todos los enfoques que utilizan métodos de estimación individuales.

	Aproximación (1)	Aproximación (2)	Aproximación (3)	Aproximación (4)
CCM	0.0924891	0.0959956	0.0979244	0.101549
EKF	0.000537848	0.00036549	0.000543256	0.000453648
UKF	$1.23475 \times 10^{-4}$	$3.24046 \times 10^{-4}$	0.000235487	0.000397456
AEKF	$2.47858 \times 10^{-5}$	0.000215894	$4.23578 \times 10^{-5}$	$8.34568 \times 10^{-5}$
AUKF	$3.47268 \times 10^{-5}$	$5.47866 \times 10^{-5}$	$1.5431 \times 10^{-5}$	$8.82024 \times 10^{-5}$

A medida que comparamos los resultados, el método híbrido proporciona una estimación más óptima para el SoC. Otra verificación para determinar si técnica de estimación es óptima es comparar las curvas SoC reales y estimadas, como se muestra en la Figura 5.11.

Como se evidencia en la Figura 5.11, la batería sufrió una sobrecarga ( $\pm 0.2$ ), lo que afectará la vida útil de la batería y, en largas distancias, la vida útil de las partes internas disminuirá y dañará.




Fig. 5. 11 - SoC estimado y SoC experimental antes de usar un modelo y una estimación precisos

Como se muestra en la Figura 5.12, al usar un modelo de batería preciso mediante una técnica de optimización precisa para modelar la batería con precisión y, a continuación, usar una técnica de estimación de SoC de batería confiable, los datos están muy cerca unos de otros, es decir no existe una diferencia significativa.




Fig. 5. 12 - SoC estimado y SoC experimental después de utilizar un modelo preciso y una técnica de estimación.

# **CAPÍTULO 6: CONCLUSIONES Y FUTUROS TRABAJOS**

---

## **6.1 Conclusiones**

De acuerdo con el estudio mostrado, la correcta planificación es esencial para la implementación de una comunidad energética comunitaria, convirtiéndose en una alternativa para la gestión de energías limpias. Sobre todo, en los escenarios donde se pretende exportar energía. También es cierto que es necesario tomar en consideración la vida útil de elementos utilizados en el proyecto y un administrador que se encargue de gestión de toda la comunidad para obtener el mayor beneficio de la inversión.

Implementar o complementar con tecnologías fotovoltaicas una comunidad energética es una opción para disminuir el uso de generadores de combustión interna o centrales eléctricas de ciclo combinado. Estos sistemas emplean combustibles fósiles o gases naturales, lo que resulta en la emisión de CO<sub>2</sub> a la atmósfera. Esto contribuye al aumento de los gases de efecto invernadero y al calentamiento global.

Según los resultados obtenidos del estudio de caso de referencia en el que participan seis prosumidores para validar la nueva herramienta se concluye que:

- La herramienta de optimización desarrollada supera al problema original no descompuesto en términos de eficiencia computacional gracias a la caracterización de los datos por medio de días representativos ya que, el problema original resultaba inasequible para algunos equipos convencionales.
- La instalación de paneles fotovoltaicos contribuyó a reducir notablemente los costes totales del proyecto (19 %), a reducir la energía importada de la red (32 %) y a aumentar la energía exportada (96 %) con una correcta gestión de la comunidad energética.

El estudio del papel de las baterías en las Comunidades Energéticas (CE) merece una atención más detallada. Los resultados obtenidos en este documento sugieren que las baterías desempeñan un papel crucial al ofrecer arbitraje de energía y capacidad exportable según la capacidad instalada, incluso en ausencia de la generación de los paneles fotovoltaicos. Estos hallazgos destacan la importancia de considerar las baterías como una pieza fundamental en la planificación y gestión de las Comunidades Energéticas.

La obtención precisa del estado de carga (SoC) de las baterías de litio es fundamental para garantizar su funcionamiento seguro, eficiente y fiable. Una estimación precisa del SoC no solo permite una gestión óptima de la energía almacenada y una maximización de la vida útil de la batería, sino que también contribuye a la seguridad del sistema al prevenir situaciones peligrosas como la sobrecarga o la descarga excesiva.

El método híbrido del CCM con el AUKF desarrollado proporciona una estimación óptima del estado de carga de la batería proporcionando un control adecuado del SoC, lo que también facilita el desarrollo de esquemas de control lógicos para la conservación de energía y proporciona una estimación fiable de la autonomía restante de la batería, lo que resulta crucial para aplicaciones como los vehículos eléctricos y comunidades energéticas. Además en comparación con otros enfoques híbridos, logra el valor más bajo de error con una alta precisión.

Los aparatos controlables desempeñan un papel clave en la reducción de la energía exportada de la red. En el presente estudio de caso, los CA se programaron principalmente por la noche, aprovechando los bajos precios de la energía. Sin embargo, es importante destacar que esta estrategia puede variar dependiendo de la disponibilidad de almacenamiento y generación local de energía en cada comunidad.

Los parámetros de degradación e inflación a largo plazo desempeñan un papel crucial en la precisión y confiabilidad de los resultados obtenidos en los problemas de planificación, como el dimensionamiento óptimo de sistemas fotovoltaicos en comunidades energéticas. En este estudio, se observó un impacto notable de estos parámetros en el rendimiento del sistema y en los resultados obtenidos. Por lo tanto, es fundamental tenerlos en cuenta y no ignorarlos durante la planificación, ya que pueden afectar significativamente la viabilidad y eficiencia de las soluciones propuestas.

## **6.2 Futuros trabajos**

Los trabajos futuros podrían centrarse en la aplicación de la técnica desarrollada a diferentes problemas de planificación relacionados con los sistemas energéticos, así como en la mejora de la propuesta incluyendo más funcionalidades.

Realizar una planificación con diferentes sistemas de generación de energía renovables, como la eólica y la fotovoltaica.

Investigar cómo las tecnologías de almacenamiento de energía, como las baterías de iones de litio, pueden afectar la eficiencia, la sostenibilidad y la rentabilidad de las comunidades energéticas, y cómo pueden integrarse de manera óptima en los sistemas energéticos existentes.

Continuar investigando y desarrollando algoritmos híbridos para la estimación precisa del estado de carga (SoC) de las baterías de iones de litio bajo diversas condiciones operativas de la batería.

# APÉNDICE A: CURRICULUM VITAE

---

**Name:** Maldonado Ortega José Luis

**Birthday:** November 11, 1992

**Nationality:** Ecuadorian

## Education and qualifications:

- **Graduate Degree:** Automotive Mechanic Engineering by the Universidad Politécnica Salesiana in 2018.
- **Master's Degree:** Industry 4.0 by the Universidad Internacional de la Rioja in 2021.

## Experience

- Mar. 2020 – jul 2023: Professor at the Juan Bautista Stiehle, Cuenca – Ecuador
- Aug. 2023 - Until now: Research professor at the Tecnológico Seis de Octubre
- Mar 2024 - Until now: Researcher in the Transport Engineering Research Group, Universidad Politécnica Salesiana



## **APÉNDICE B: CONTRIBUCIONES**

---

As result of the contributions of this Thesis, the following papers have been published or accepted for publication in international journals.

- J. L. Maldonado, M. Tostado-Véliz, H. M. Hasanien, N. Khosravi, y F. Jurado, «Optimal planning of collective photovoltaic arrays in energy communities through a multi-cut benders' decomposition strategy», *Sustainable Cities and Society*, vol. 104, p. 105307, may 2024, doi: 10.1016/j.scs.2024.105307. }
- H. M. Fahmy, R. A. Swief, H. M. Hasanien, M. Alharbi, J. L. Maldonado, y F. Jurado, «Hybrid State of Charge Estimation of Lithium-Ion Battery Using the Coulomb Counting Method and an Adaptive Unscented Kalman Filter», *Energies*, vol. 16, n.º 14, Art. n.º 14, ene. 2023, doi: 10.3390/en16145558.

## BIBLIOGRAFÍA

---

- [1] N. Vespermann, T. Hamacher, y J. Kazempour, «Access Economy for Storage in Energy Communities», *IEEE Trans. Power Syst.*, vol. 36, n.º 3, pp. 2234-2250, may 2021, doi: 10.1109/TPWRS.2020.3033999.
- [2] European Parliament and Council, «JRC Photovoltaic Geographical Information System (PVGIS) - European Commission». Accedido: 30 de abril de 2024. [En línea]. Disponible en: [https://re.jrc.ec.europa.eu/pvg\\_tools/en/tools.html](https://re.jrc.ec.europa.eu/pvg_tools/en/tools.html)
- [3] M. Gough *et al.*, «Blockchain-Based Transactive Energy Framework for Connected Virtual Power Plants», *IEEE Transactions on Industry Applications*, vol. 58, n.º 1, pp. 986-995, ene. 2022, doi: 10.1109/TIA.2021.3131537.
- [4] P. Mehta y V. Tiefenbeck, «Solar PV sharing in urban energy communities: Impact of community configurations on profitability, autonomy and the electric grid», *Sustainable Cities and Society*, vol. 87, p. 104178, dic. 2022, doi: 10.1016/j.scs.2022.104178.
- [5] M. Tostado-Véliz, S. Kamel, H. M. Hasanién, R. A. Turkey, y F. Jurado, «Optimal energy management of cooperative energy communities considering flexible demand, storage and vehicle-to-grid under uncertainties», *Sustainable Cities and Society*, vol. 84, p. 104019, sep. 2022, doi: 10.1016/j.scs.2022.104019.
- [6] Á. García-Cerezo, L. Baringo, y R. García-Bertrand, «Robust transmission network expansion planning considering non-convex operational constraints», *Energy Economics*, vol. 98, p. 105246, jun. 2021, doi: 10.1016/j.eneco.2021.105246.
- [7] G. E. Constante-Flores y A. J. Conejo, «Security-constrained unit commitment: A decomposition approach embodying Kron reduction», *European Journal of Operational Research*, jun. 2023, doi: 10.1016/j.ejor.2023.06.013.
- [8] A. Nasri, S. J. Kazempour, A. J. Conejo, y M. Ghandhari, «Network-Constrained AC Unit Commitment Under Uncertainty: A Benders' Decomposition Approach», *IEEE*

- Transactions on Power Systems*, vol. 31, n.º 1, pp. 412-422, ene. 2016, doi: 10.1109/TPWRS.2015.2409198.
- [9] H. F. Khan, A. Hanif, M. U. Ali, y A. Zafar, «A Lagrange multiplier and sigma point Kalman filter based fused methodology for online state of charge estimation of lithium-ion batteries», *Journal of Energy Storage*, vol. 41, p. 102843, sep. 2021, doi: 10.1016/j.est.2021.102843.
- [10] P. Nian, Z. Shuzhi, y Z. Xiongwen, «Co-estimation for capacity and state of charge for lithium-ion batteries using improved adaptive extended Kalman filter», *Journal of Energy Storage*, vol. 40, p. 102559, ago. 2021, doi: 10.1016/j.est.2021.102559.
- [11] Y. Khawaja *et al.*, «Battery management solutions for li-ion batteries based on artificial intelligence», *Ain Shams Engineering Journal*, vol. 14, n.º 12, p. 102213, dic. 2023, doi: 10.1016/j.asej.2023.102213.
- [12] X. Hao, S. Wang, Y. Fan, Y. Xie, y C. Fernandez, «An improved forgetting factor recursive least square and unscented particle filtering algorithm for accurate lithium-ion battery state of charge estimation», *Journal of Energy Storage*, vol. 59, p. 106478, mar. 2023, doi: 10.1016/j.est.2022.106478.
- [13] Z. Chen, H. Zhao, X. Shu, Y. Zhang, J. Shen, y Y. Liu, «Synthetic state of charge estimation for lithium-ion batteries based on long short-term memory network modeling and adaptive H-Infinity filter», *Energy*, vol. 228, p. 120630, ago. 2021, doi: 10.1016/j.energy.2021.120630.
- [14] S. Agrawal y R. Soni, «Renewable Energy», en *Energy*, John Wiley & Sons, Ltd, 2021, pp. 131-150. doi: 10.1002/9781119741503.ch7.
- [15] E. Barragán-Escandón *et al.*, «Factores que influyen en la selección de energías renovables en la ciudad», *EURE (Santiago)*, vol. 45, n.º 134, pp. 259-277, ene. 2019, doi: 10.4067/S0250-71612019000100259.
- [16] M. C. Romero Pereira y A. M. Higinio Pulido, «Energías renovables no convencionales para satisfacer la demanda energética: análisis de tendencias entre 1990 y 2018», may 2021, Accedido: 30 de abril de 2024. [En línea]. Disponible en:

<https://repository.eia.edu.co/entities/publication/7e03141c-4625-475a-bc5e-acc7c676f947>

- [17] S. R. Sinsel, R. L. Riemke, y V. H. Hoffmann, «Challenges and solution technologies for the integration of variable renewable energy sources—a review», *Renewable Energy*, vol. 145, pp. 2271-2285, ene. 2020, doi: 10.1016/j.renene.2019.06.147.
- [18] P. Nema, R. K. Nema, y S. Rangnekar, «A current and future state of art development of hybrid energy system using wind and PV-solar: A review», *Renewable and Sustainable Energy Reviews*, vol. 13, n.º 8, pp. 2096-2103, oct. 2009, doi: 10.1016/j.rser.2008.10.006.
- [19] M. K. Deshmukh y S. S. Deshmukh, «Modeling of hybrid renewable energy systems», *Renewable and Sustainable Energy Reviews*, vol. 12, n.º 1, pp. 235-249, ene. 2008, doi: 10.1016/j.rser.2006.07.011.
- [20] Q. Hassan, S. Algburi, A. Z. Sameen, H. M. Salman, y M. Jaszczur, «A review of hybrid renewable energy systems: Solar and wind-powered solutions: Challenges, opportunities, and policy implications», *Results in Engineering*, vol. 20, p. 101621, dic. 2023, doi: 10.1016/j.rineng.2023.101621.
- [21] E. N. Nyeche y E. O. Diemuodeke, «Modelling and optimisation of a hybrid PV-wind turbine-pumped hydro storage energy system for mini-grid application in coastline communities», *Journal of Cleaner Production*, vol. 250, p. 119578, mar. 2020, doi: 10.1016/j.jclepro.2019.119578.
- [22] O. L. de E. [31], «Generación eléctrica mundial y para América Latina y el Caribe (ALC)». Accedido: 12 de abril de 2024. [En línea]. Disponible en: <https://sielac.olade.org/>
- [23] «World Electricity Generation». Accedido: 1 de abril de 2024. [En línea]. Disponible en: <https://www.worldenergydata.org/world-electricity-generation/>
- [24] «Renewables 2023 – Analysis», IEA. Accedido: 1 de mayo de 2024. [En línea]. Disponible en: <https://www.iea.org/reports/renewables-2023>

- [25] D. Anderson y M. Leach, «Harvesting and redistributing renewable energy: on the role of gas and electricity grids to overcome intermittency through the generation and storage of hydrogen», *Energy Policy*, vol. 32, n.º 14, pp. 1603-1614, sep. 2004, doi: 10.1016/S0301-4215(03)00131-9.
- [26] C. Zhang, Y.-L. Wei, P.-F. Cao, y M.-C. Lin, «Energy storage system: Current studies on batteries and power condition system», *Renewable and Sustainable Energy Reviews*, vol. 82, pp. 3091-3106, feb. 2018, doi: 10.1016/j.rser.2017.10.030.
- [27] Y. Han, J. Jin, F. Lin, D. Li, y J. Wu, «Application Research of Photovoltaic Power Generation Technology in Railway System», en *Proceedings of the 6th International Conference on Electrical Engineering and Information Technologies for Rail Transportation (EITRT) 2023*, L. Jia, Y. Qin, J. Yang, Z. Liu, L. Diao, y M. An, Eds., Singapore: Springer Nature, 2024, pp. 157-169. doi: 10.1007/978-981-99-9307-9\_18.
- [28] M. Dada y P. Popoola, «Recent advances in solar photovoltaic materials and systems for energy storage applications: a review», *Beni-Suef Univ J Basic Appl Sci*, vol. 12, n.º 1, p. 66, jul. 2023, doi: 10.1186/s43088-023-00405-5.
- [29] P. Molina, «España es el país con mayor penetración fotovoltaica del mundo y líder en potencia instalada en Europa en 2022», *pV magazine España*. Accedido: 3 de mayo de 2024. [En línea]. Disponible en: <https://www.pv-magazine.es/2023/04/24/espana-es-el-pais-con-mayor-penetracion-fotovoltaica-del-mundo-y-lider-en-potencia-instalada-en-europa-en-2022/>
- [30] R. Lazdins, A. Mutule, y D. Zalostiba, «PV Energy Communities—Challenges and Barriers from a Consumer Perspective: A Literature Review», *Energies*, vol. 14, n.º 16, Art. n.º 16, ene. 2021, doi: 10.3390/en14164873.
- [31] E. A. Martínez y P. Mancarella, «Energy Systems Integration in Smart Districts: Robust Optimisation of Multi-Energy Flows in Integrated Electricity, Heat and Gas Networks», *IEEE Transactions on Smart Grid*, vol. 10, n.º 1, pp. 1122-1131, ene. 2019, doi: 10.1109/TSG.2018.2828146.
- [32] N. Good, E. Karangelos, A. Navarro-Espinosa, y P. Mancarella, «Optimization Under Uncertainty of Thermal Storage-Based Flexible Demand Response With

- Quantification of Residential Users' Discomfort», *IEEE Transactions on Smart Grid*, vol. 6, n.º 5, pp. 2333-2342, sep. 2015, doi: 10.1109/TSG.2015.2399974.
- [33] N. Vespermann, T. Hamacher, y J. Kazempour, «Access Economy for Storage in Energy Communities», *IEEE Transactions on Power Systems*, vol. 36, n.º 3, pp. 2234-2250, may 2021, doi: 10.1109/TPWRS.2020.3033999.
- [34] S. Lilla, C. Orozco, A. Borghetti, F. Napolitano, y F. Tossani, «Day-Ahead Scheduling of a Local Energy Community: An Alternating Direction Method of Multipliers Approach», *IEEE Transactions on Power Systems*, vol. 35, n.º 2, pp. 1132-1142, mar. 2020, doi: 10.1109/TPWRS.2019.2944541.
- [35] T. Weckesser, D. F. Dominković, E. M. V. Blomgren, A. Schledorn, y H. Madsen, «Renewable Energy Communities: Optimal sizing and distribution grid impact of photo-voltaics and battery storage», *Applied Energy*, vol. 301, p. 117408, nov. 2021, doi: 10.1016/j.apenergy.2021.117408.
- [36] B. Petrovich y M. Kubli, «Energy communities for companies: Executives' preferences for local and renewable energy procurement», *Renewable and Sustainable Energy Reviews*, vol. 184, p. 113506, sep. 2023, doi: 10.1016/j.rser.2023.113506.
- [37] I. López *et al.*, «European energy communities: Characteristics, trends, business models and legal framework», *Renewable and Sustainable Energy Reviews*, vol. 197, p. 114403, jun. 2024, doi: 10.1016/j.rser.2024.114403.
- [38] C. E. Hoicka, J. Lowitzsch, M. C. Brisbois, A. Kumar, y L. Ramirez Camargo, «Implementing a just renewable energy transition: Policy advice for transposing the new European rules for renewable energy communities», *Energy Policy*, vol. 156, p. 112435, sep. 2021, doi: 10.1016/j.enpol.2021.112435.
- [39] H. Firoozi, H. Khajeh, y H. Laaksonen, «Optimized Operation of Local Energy Community Providing Frequency Restoration Reserve», *IEEE Access*, vol. 8, pp. 180558-180575, 2020, doi: 10.1109/ACCESS.2020.3027710.

- [40] G. Di Lorenzo, S. Rotondo, R. Araneo, G. Petrone, y L. Martirano, «Innovative power-sharing model for buildings and energy communities», *Renewable Energy*, vol. 172, pp. 1087-1102, jul. 2021, doi: 10.1016/j.renene.2021.03.063.
- [41] N. Vespermann, T. Hamacher, y J. Kazempour, «Risk Trading in Energy Communities», *IEEE Transactions on Smart Grid*, vol. 12, n.º 2, pp. 1249-1263, mar. 2021, doi: 10.1109/TSG.2020.3030319.
- [42] J. Liu, H. Yang, y Y. Zhou, «Peer-to-peer trading optimizations on net-zero energy communities with energy storage of hydrogen and battery vehicles», *Applied Energy*, vol. 302, p. 117578, nov. 2021, doi: 10.1016/j.apenergy.2021.117578.
- [43] J. Liu, Y. Zhou, H. Yang, y H. Wu, «Uncertainty energy planning of net-zero energy communities with peer-to-peer energy trading and green vehicle storage considering climate changes by 2050 with machine learning methods», *Applied Energy*, vol. 321, p. 119394, sep. 2022, doi: 10.1016/j.apenergy.2022.119394.
- [44] E. Doroudchi, H. Khajeh, y H. Laaksonen, «Increasing Self-Sufficiency of Energy Community by Common Thermal Energy Storage», *IEEE Access*, vol. 10, pp. 85106-85113, 2022, doi: 10.1109/ACCESS.2022.3195242.
- [45] M. S. Javadi, M. Gough, A. E. Nezhad, S. F. Santos, M. Shafie-khah, y J. P. S. Catalão, «Pool trading model within a local energy community considering flexible loads, photovoltaic generation and energy storage systems», *Sustainable Cities and Society*, vol. 79, p. 103747, abr. 2022, doi: 10.1016/j.scs.2022.103747.
- [46] F. Marasciuolo, C. Orozco, M. Dicorato, A. Borghetti, y G. Forte, «Chance-Constrained Calculation of the Reserve Service Provided by EV Charging Station Clusters in Energy Communities», *IEEE Transactions on Industry Applications*, vol. 59, n.º 4, pp. 4700-4709, jul. 2023, doi: 10.1109/TIA.2023.3264965.
- [47] L. Gomes y Z. Vale, «Costless renewable energy distribution model based on cooperative game theory for energy communities considering its members' active contributions», *Sustainable Cities and Society*, vol. 101, p. 105060, feb. 2024, doi: 10.1016/j.scs.2023.105060.

- [48] M. Dolanyi, K. Bruninx, J.-F. Toubeau, y E. Delarue, «Risk-Based Constraints for the Optimal Operation of an Energy Community», *IEEE Transactions on Smart Grid*, vol. 13, n.º 6, pp. 4551-4561, nov. 2022, doi: 10.1109/TSG.2022.3185310.
- [49] W. Guedes, C. Oliveira, T. A. Soares, B. H. Dias, y M. Matos, «Collective Asset Sharing Mechanisms for PV and BESS in Renewable Energy Communities», *IEEE Transactions on Smart Grid*, vol. 15, n.º 1, pp. 607-616, ene. 2024, doi: 10.1109/TSG.2023.3288533.
- [50] K. Berg, R. Rana, y H. Farahmand, «Quantifying the benefits of shared battery in a DSO-energy community cooperation», *Applied Energy*, vol. 343, p. 121105, ago. 2023, doi: 10.1016/j.apenergy.2023.121105.
- [51] W. Feng y C. Ruiz, «Risk management of energy communities with hydrogen production and storage technologies», *Applied Energy*, vol. 348, p. 121494, oct. 2023, doi: 10.1016/j.apenergy.2023.121494.
- [52] M. Tostado-Véliz, A. Rezaee Jordehi, D. Icaza, S. A. Mansouri, y F. Jurado, «Optimal participation of prosumers in energy communities through a novel stochastic-robust day-ahead scheduling model», *International Journal of Electrical Power & Energy Systems*, vol. 147, p. 108854, may 2023, doi: 10.1016/j.ijepes.2022.108854.
- [53] M. Tostado-Véliz, S. A. Mansouri, A. Rezaee-Jordehi, D. Icaza-Alvarez, y F. Jurado, «Information Gap Decision Theory-based day-ahead scheduling of energy communities with collective hydrogen chain», *International Journal of Hydrogen Energy*, vol. 48, n.º 20, pp. 7154-7169, mar. 2023, doi: 10.1016/j.ijhydene.2022.11.183.
- [54] M. M. Kamal, I. Ashraf, y E. Fernandez, «Optimal energy management and capacity planning of renewable integrated rural microgrid», *Environ Sci Pollut Res*, vol. 30, n.º 44, pp. 99176-99197, sep. 2023, doi: 10.1007/s11356-023-28792-3.
- [55] S. Maiz, L. Baringo, y R. García-Bertrand, «Expansion planning of a price-maker virtual power plant in energy and reserve markets», *Sustainable Energy, Grids and Networks*, vol. 32, p. 100832, dic. 2022, doi: 10.1016/j.segan.2022.100832.



- [56] C. Roldán-Blay, G. Escrivá-Escrivá, C. Roldán-Porta, y D. Dasí-Crespo, «Optimal sizing and design of renewable power plants in rural microgrids using multi-objective particle swarm optimization and branch and bound methods», *Energy*, vol. 284, p. 129318, dic. 2023, doi: 10.1016/j.energy.2023.129318.
- [57] G. Er, G. Soykan, y E. Canakoglu, «Stochastic optimal design of a rural microgrid with hybrid storage system including hydrogen and electric cars using vehicle-to-grid technology», *Journal of Energy Storage*, vol. 75, p. 109747, ene. 2024, doi: 10.1016/j.est.2023.109747.
- [58] E. Dal Cin, G. Carraro, G. Volpato, A. Lazzaretto, y P. Danieli, «A multi-criteria approach to optimize the design-operation of Energy Communities considering economic-environmental objectives and demand side management», *Energy Conversion and Management*, vol. 263, p. 115677, jul. 2022, doi: 10.1016/j.enconman.2022.115677.
- [59] J. M. Arroyo, L. Baringo, A. Baringo, R. Bolaños, N. Alguacil, y N. G. Cobos, «On the Use of a Convex Model for Bulk Storage in MIP-Based Power System Operation and Planning», *IEEE Transactions on Power Systems*, vol. 35, n.º 6, pp. 4964-4967, nov. 2020, doi: 10.1109/TPWRS.2020.3020730.
- [60] I. Dagal, B. Akin, y E. Akboy, «A novel hybrid series salp particle Swarm optimization (SSPSO) for standalone battery charging applications», *Ain Shams Engineering Journal*, vol. 13, n.º 5, p. 101747, sep. 2022, doi: 10.1016/j.asej.2022.101747.
- [61] M. A. Awadallah y B. Venkatesh, «Accuracy improvement of SOC estimation in lithium-ion batteries», *Journal of Energy Storage*, vol. 6, pp. 95-104, may 2016, doi: 10.1016/j.est.2016.03.003.
- [62] Z. Li, J. Huang, B. Y. Liaw, y J. Zhang, «On state-of-charge determination for lithium-ion batteries», *Journal of Power Sources*, vol. 348, pp. 281-301, abr. 2017, doi: 10.1016/j.jpowsour.2017.03.001.

- [63] C. Sheng *et al.*, «Energy management strategy based on health state for a PEMFC/Lithium-ion batteries hybrid power system», *Energy Conversion and Management*, vol. 271, p. 116330, nov. 2022, doi: 10.1016/j.enconman.2022.116330.
- [64] S. Liu *et al.*, «Dynamic adaptive square-root unscented Kalman filter and rectangular window recursive least square method for the accurate state of charge estimation of lithium-ion batteries», *Journal of Energy Storage*, vol. 67, p. 107603, sep. 2023, doi: 10.1016/j.est.2023.107603.
- [65] C. Wang, X. Zhang, X. Yun, y X. Fan, «A novel hybrid machine learning coulomb counting technique for state of charge estimation of lithium-ion batteries», *Journal of Energy Storage*, vol. 63, p. 107081, jul. 2023, doi: 10.1016/j.est.2023.107081.
- [66] Y. Ye, Z. Li, J. Lin, y X. Wang, «State-of-charge estimation with adaptive extended Kalman filter and extended stochastic gradient algorithm for lithium-ion batteries», *Journal of Energy Storage*, vol. 47, p. 103611, mar. 2022, doi: 10.1016/j.est.2021.103611.
- [67] Y. Tian, R. Lai, X. Li, L. Xiang, y J. Tian, «A combined method for state-of-charge estimation for lithium-ion batteries using a long short-term memory network and an adaptive cubature Kalman filter», *Applied Energy*, vol. 265, p. 114789, may 2020, doi: 10.1016/j.apenergy.2020.114789.
- [68] R. Zhu, B. Duan, J. Zhang, Q. Zhang, y C. Zhang, «Co-estimation of model parameters and state-of-charge for lithium-ion batteries with recursive restricted total least squares and unscented Kalman filter», *Applied Energy*, vol. 277, p. 115494, nov. 2020, doi: 10.1016/j.apenergy.2020.115494.
- [69] N. Shi, Z. Chen, M. Niu, Z. He, Y. Wang, y J. Cui, «State-of-charge estimation for the lithium-ion battery based on adaptive extended Kalman filter using improved parameter identification», *Journal of Energy Storage*, vol. 45, p. 103518, ene. 2022, doi: 10.1016/j.est.2021.103518.
- [70] Y. Miao y Z. Gao, «Estimation for state of charge of lithium-ion batteries by adaptive fractional-order unscented Kalman filters», *Journal of Energy Storage*, vol. 51, p. 104396, jul. 2022, doi: 10.1016/j.est.2022.104396.

- [71] D. Liu, L. Li, Y. Song, L. Wu, y Y. Peng, «Hybrid state of charge estimation for lithium-ion battery under dynamic operating conditions», *International Journal of Electrical Power & Energy Systems*, vol. 110, pp. 48-61, sep. 2019, doi: 10.1016/j.ijepes.2019.02.046.
- [72] V. Pop, H. J. Bergveld, P. H. L. Notten, J. H. G. Op het Veld, y P. P. L. Regtien, «Accuracy analysis of the State-of-Charge and remaining run-time determination for lithium-ion batteries», *Measurement*, vol. 42, n.º 8, pp. 1131-1138, oct. 2009, doi: 10.1016/j.measurement.2008.03.009.
- [73] J. Wang, B. Cao, Q. Chen, y F. Wang, «Combined state of charge estimator for electric vehicle battery pack», *Control Engineering Practice*, vol. 15, n.º 12, pp. 1569-1576, dic. 2007, doi: 10.1016/j.conengprac.2007.03.004.
- [74] J. Kim y B. H. Cho, «State-of-Charge Estimation and State-of-Health Prediction of a Li-Ion Degraded Battery Based on an EKF Combined With a Per-Unit System», *IEEE Transactions on Vehicular Technology*, vol. 60, n.º 9, pp. 4249-4260, nov. 2011, doi: 10.1109/TVT.2011.2168987.
- [75] H. Li, L. Fu, X. Long, L. Liu, y Z. Zeng, «A hybrid deep learning model for lithium-ion batteries state of charge estimation based on quantile regression and attention», *Energy*, vol. 294, p. 130834, may 2024, doi: 10.1016/j.energy.2024.130834.
- [76] A. D. Mustika, R. Rigo-Mariani, V. Debusschere, y A. Pachurka, «A two-stage management strategy for the optimal operation and billing in an energy community with collective self-consumption», *Applied Energy*, vol. 310, p. 118484, mar. 2022, doi: 10.1016/j.apenergy.2021.118484.
- [77] A. Sangadiev, A. Gonzalez-Castellanos, y D. Pozo, «A review on recent advances in scenario aggregation methods for power system analysis», arXiv.org. Accedido: 30 de abril de 2024. [En línea]. Disponible en: <https://arxiv.org/abs/2207.09557v1>
- [78] A. Baringo, L. Baringo, y J. M. Arroyo, «Robust virtual power plant investment planning», *Sustainable Energy, Grids and Networks*, vol. 35, p. 101105, sep. 2023, doi: 10.1016/j.segan.2023.101105.

- [79] E. S. Pinto, L. M. Serra, y A. Lázaro, «Evaluation of methods to select representative days for the optimization of polygeneration systems», *Renewable Energy*, vol. 151, pp. 488-502, may 2020, doi: 10.1016/j.renene.2019.11.048.
- [80] M. Tostado-Véliz, H. M. Hasanien, A. R. Jordehi, R. A. Turkey, y F. Jurado, «Risk-averse optimal participation of a DR-intensive microgrid in competitive clusters considering response fatigue», *Applied Energy*, vol. 339, p. 120960, jun. 2023, doi: 10.1016/j.apenergy.2023.120960.
- [81] M. Tostado-Véliz, D. Icaza-Alvarez, y F. Jurado, «A novel methodology for optimal sizing photovoltaic-battery systems in smart homes considering grid outages and demand response», *Renewable Energy*, vol. 170, pp. 884-896, jun. 2021, doi: 10.1016/j.renene.2021.02.006.
- [82] A. A. R. Mohamed, R. J. Best, X. Liu, y D. J. Morrow, «A Comprehensive Robust Techno-Economic Analysis and Sizing Tool for the Small-Scale PV and BESS», *IEEE Transactions on Energy Conversion*, vol. 37, n.º 1, pp. 560-572, mar. 2022, doi: 10.1109/TEC.2021.3107103.
- [83] I. Alsaidan, A. Khodaei, y W. Gao, «A Comprehensive Battery Energy Storage Optimal Sizing Model for Microgrid Applications», *IEEE Transactions on Power Systems*, vol. 33, n.º 4, pp. 3968-3980, jul. 2018, doi: 10.1109/TPWRS.2017.2769639.
- [84] N. G. Paterakis, O. Erdinç, A. G. Bakirtzis, y J. P. S. Catalão, «Optimal Household Appliances Scheduling Under Day-Ahead Pricing and Load-Shaping Demand Response Strategies», *IEEE Transactions on Industrial Informatics*, vol. 11, n.º 6, pp. 1509-1519, dic. 2015, doi: 10.1109/TII.2015.2438534.
- [85] O. Mussawar, R. R. Urs, A. Mayyas, y E. Azar, «Performance and prospects of urban energy communities conditioned by the built form and function: A systematic investigation using agent-based modeling», *Sustainable Cities and Society*, vol. 99, p. 104957, dic. 2023, doi: 10.1016/j.scs.2023.104957.
- [86] IEA, «Electricity consumption – Electricity Information: Overview – Analysis», IEA. Accedido: 7 de mayo de 2024. [En línea]. Disponible en:

- <https://www.iea.org/reports/electricity-information-overview/electricity-consumption>
- [87] A. J. Conejo, E. Castillo, R. Minguez, y R. Garcia-Bertrand, *Decomposition Techniques in Mathematical Programming: Engineering and Science Applications*. Springer Science & Business Media, 2006.
- [88] Y. Wan, J. Qin, Y. Shi, W. Fu, y D. Zhang, «Privacy-Preserving Operation Management of Battery Swapping and Charging System With Dual-Based Benders Decomposition», *IEEE Transactions on Smart Grid*, vol. 14, n.º 5, pp. 3899-3912, sep. 2023, doi: 10.1109/TSG.2023.3236329.
- [89] L. Mitridati, J. Kazempour, y P. Pinson, «Heat and electricity market coordination: A scalable complementarity approach», *European Journal of Operational Research*, vol. 283, n.º 3, pp. 1107-1123, jun. 2020, doi: 10.1016/j.ejor.2019.11.072.
- [90] R. Rahmaniani, T. G. Crainic, M. Gendreau, y W. Rei, «The Benders decomposition algorithm: A literature review», *European Journal of Operational Research*, vol. 259, n.º 3, pp. 801-817, jun. 2017, doi: 10.1016/j.ejor.2016.12.005.
- [91] S. J. Kazempour y A. J. Conejo, «Strategic Generation Investment Under Uncertainty Via Benders Decomposition», *IEEE Transactions on Power Systems*, vol. 27, n.º 1, pp. 424-432, feb. 2012, doi: 10.1109/TPWRS.2011.2159251.
- [92] Singh, «Smart Home Dataset with weather Information». Accedido: 7 de mayo de 2024. [En línea]. Disponible en: <https://www.kaggle.com/datasets/taranvee/smart-home-dataset-with-weather-information>
- [93] «Solar photovoltaic (PV) cost data», GOV.UK. Accedido: 30 de abril de 2024. [En línea]. Disponible en: <https://www.gov.uk/government/statistics/solar-pv-cost-data>
- [94] M. Tostado-Véliz, R. S. León-Japa, y F. Jurado, «Optimal electrification of off-grid smart homes considering flexible demand and vehicle-to-home capabilities», *Applied Energy*, vol. 298, p. 117184, sep. 2021, doi: 10.1016/j.apenergy.2021.117184.
- [95] «The Leader in Decision Intelligence Technology - Gurobi Optimization». Accedido: 30 de abril de 2024. [En línea]. Disponible en: <https://www.gurobi.com/>

- [96] N. Beheshti Asl y S. A. MirHassani, «Accelerating benders decomposition: multiple cuts via multiple solutions», *J Comb Optim*, vol. 37, n.º 3, pp. 806-826, abr. 2019, doi: 10.1007/s10878-018-0320-8.
- [97] K. Movassagh, A. Raihan, B. Balasingam, y K. Pattipati, «A Critical Look at Coulomb Counting Approach for State of Charge Estimation in Batteries», *Energies*, vol. 14, n.º 14, Art. n.º 14, ene. 2021, doi: 10.3390/en14144074.
- [98] H. M. Fahmy, R. A. Sweif, H. M. Hasanien, M. Tostado-Véliz, M. Alharbi, y F. Jurado, «Parameter Identification of Lithium-Ion Battery Model Based on African Vultures Optimization Algorithm», *Mathematics*, vol. 11, n.º 9, Art. n.º 9, ene. 2023, doi: 10.3390/math11092215.
- [99] S. Mohtaram, M. Sina Mohtaram, S. Sabbaghi, X. You, W. Wu, y N. Golsanami, «Enhancement strategies in CO<sub>2</sub> conversion and management of biochar supported photocatalyst for effective generation of renewable and sustainable solar energy», *Energy Conversion and Management*, vol. 300, p. 117987, ene. 2024, doi: 10.1016/j.enconman.2023.117987.
- [100] M. Tostado-Véliz, A. Rezaee Jordehi, H. M. Hasanien, N. Khosravi, S. A. Mansouri, y F. Jurado, «On different collective storage schemes in energy communities with internal market», *Journal of Energy Storage*, vol. 75, p. 109699, ene. 2024, doi: 10.1016/j.est.2023.109699.
- [101] H. Ghasemi-Mobtaker, F. Mostashari-Rad, Z. Saber, K. Chau, y A. Nabavi-Pelesaraei, «Application of photovoltaic system to modify energy use, environmental damages and cumulative exergy demand of two irrigation systems-A case study: Barley production of Iran», *Renewable Energy*, vol. 160, pp. 1316-1334, nov. 2020, doi: 10.1016/j.renene.2020.07.047.
- [102] B. Hamidinasab, H. Javadikia, F. Hosseini-Fashami, H. Kouchaki-Penchah, y A. Nabavi-Pelesaraei, «Illuminating sustainability: A comprehensive review of the environmental life cycle and exergetic impacts of solar systems on the agri-food sector», *Solar Energy*, vol. 262, p. 111830, sep. 2023, doi: 10.1016/j.solener.2023.111830.

- [103] A. Nabavi-Pelesaraei *et al.*, «Prospects of solar systems in production chain of sunflower oil using cold press method with concentrating energy and life cycle assessment», *Energy*, vol. 223, p. 120117, may 2021, doi: 10.1016/j.energy.2021.120117.
- [104] A. Nabavi-Pelesaraei y A. Damgaard, «Regionalized environmental damages and life cycle cost of chickpea production using LC-IMPACT assessment», *Environmental Impact Assessment Review*, vol. 103, p. 107259, nov. 2023, doi: 10.1016/j.eiar.2023.107259.