

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

DEPARTAMENTO DE INGENIERÍA Y PRODUCCIÓN INDUSTRIAL



TESIS DOCTORAL

Modelado, estudio y validación experimental de la influencia de los parámetros internos
en el rendimiento de sistemas de almacenamiento de energía basados en baterías.
Aplicación al caso del Departamento del Chocó (Colombia)

Autor:

Edison Banguero Palacios

Directores:

Dr. Ángel Pérez-Navarro Gómez

Dr. Antonio Correcher Salvador

Valencia, España, Febrero de 2020

Memoria presentada por Edison Banguero Palacios, en la Escuela de Doctorado de la Universitat Politècnica de València, programa de Doctorado en Ingeniería y Producción Industrial, para optar al título de doctor.

Esta investigación ha sido desarrollada, en el Instituto Universitario de Automática e Informática Industrial (Instituto ai2) de la Universitat Politècnica de València, con la ayuda financiera del proyecto “Implementación de un programa de desarrollo e investigación de energías renovables en el departamento del Chocó”—BPIN: 20130000100285; COLCIENCIAS (Departamento Administrativo de Ciencia, Tecnología e Innovación de Colombia) y la Universidad Tecnológica del Chocó

“Diego Luis Córdoba”

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

DEPARTAMENTO DE INGENIERÍA Y PRODUCCIÓN INDUSTRIAL



TESIS DOCTORAL

Modelado, estudio y validación experimental de la influencia de los parámetros internos
en el rendimiento de sistemas de almacenamiento de energía basados en baterías.
Aplicación al caso del Departamento del Chocó (Colombia)

Autor:

Edison Banguero Palacios

Directores:

Dr. Ángel Pérez-Navarro Gómez

Dr. Antonio Correcher Salvador

Valencia, España, Febrero de 2020

AGRADECIMIENTOS

A Dios por haberme brindando la oportunidad de alcanzar un nuevo peldaño en la vida.

A mi madre Basilia Palacios Mosquera, que con mucho esfuerzo logró sacar a sus hijos adelante, brindándonos lo más importante para un ser humano, la educación. A mi familia, integrada por mi esposa Yasiris Pino Mosquera, y mis hijos Dreinner Banguero Pino, Dylan Mauricio Banguero Pino y Daniel Dareh Banguero Pino, por su apoyo y espera durante todo este proceso de formación los cuales me animaban a no desfallecer.

A mis hermanas y demás familiares.

Un especial agradecimiento al Dr. William Murillo López, director del Grupo de Investigación en Energías Renovables y Meteorología de la “UTCH”, ya que es uno de los artífices de este sueño, hoy hecho realidad. De igual forma, un profundo agradecimiento a todos los integrantes del grupo de investigación en mención.

Al proyecto “Implementación de un programa de desarrollo e investigación de energías renovables en el departamento del Chocó”—BPIN: 20130000100285; COLCIENCIAS (Departamento Administrativo de Ciencia, Tecnología e Innovación de Colombia) y a la Universidad Tecnológica del Chocó “Diego Luis Córdoba” por el apoyo financiero recibido durante todo este proceso, para que este trabajo de tesis llegará a buen puerto.

A mis directores de tesis Dr. Ángel Pérez-Navarro Gómez y Dr. Antonio Correcher Salvador, por acogerme y direccionarme en esta aventura. Muchas gracias por hacerme sentir parte de su círculo más cercano de amistad. En Colombia tienen un amigo, que siempre tendrá las puertas abiertas, en aras de seguir trabajando conjuntamente en proyectos de carácter investigativo.

Al ingeniero Helbert Eduardo Ariza Chacón, por sus aportes en el montaje de las simulaciones.

Finalmente, mis agradecimientos a todos los compañeros del laboratorio de Supervisión y Diagnósticos de Fallos “SDF” de la UPV.

DEDICATORIA

Esta tesis doctoral se la dedico a mi familia, integrada por mi esposa Yasiris Pino Mosquera, y mis hijos Dreinner Banguero Pino, Dylan Mauricio Banguero Pino y Daniel Dareh Banguero Pino, ya que durante mi ausencia producto de mi actividad de formación doctoral, han sabido sobrellevar los embates de la vida y sacar adelante este proyecto de vida llamado “familia Banguero Pino”.

MODELADO, ESTUDIO Y VALIDACIÓN EXPERIMENTAL DE LA INFLUENCIA DE LOS PARÁMETROS INTERNOS EN EL RENDIMIENTO DE SISTEMAS DE ALMACENAMIENTO DE ENERGÍA BASADOS EN BATERÍAS. APLICACIÓN AL CASO DEL DEPARTAMENTO DEL CHOCÓ (COLOMBIA)

RESUMEN

El Chocó es uno de los departamentos de Colombia con mayor número de municipios por fuera de la interconexión eléctrica nacional. En algunas zonas no se cuenta con ningún tipo de suministro de energía eléctrica. En otras, el suministro de energía eléctrica se realiza a través de generadores diésel instalados por una entidad gubernamental con un tiempo de operación entre 6 y 12 horas. En un porcentaje menor, el servicio de energía eléctrica se lleva a cabo con sistemas solares fotovoltaicos aislados. Estos sistemas han ayudado a solventar una de las necesidades básicas insatisfechas, como lo es, el derecho al servicio de energía eléctrica, ya que no contar con éste se convierte en sinónimo de atraso. Sin embargo, esta alternativa renovable de suministro eléctrico, viene de la mano con sistemas de almacenamiento de energía eléctrica en baterías, para ser usada en momentos en que la demanda lo requiera. Por lo tanto, el almacenamiento de energía se ha convertido en un componente fundamental en los sistemas de energía renovable, especialmente aquellos que incluyen baterías. De allí, la necesidad de buscar métodos de control eficientes que ayuden a proteger y prolongar la vida útil de la batería. Dentro de los métodos de control reportados en la literatura, el más utilizado es el de corriente constante – voltaje constante. Otros métodos como el control con lógica difusa o el modelo de control predictivo han demostrado ser más eficientes que los métodos tradicionales, ya que reducen el tiempo de carga, mitigan el aumento de la temperatura y mantienen el estado de carga dentro de los límites seguros. Sin embargo, en los procesos de carga y descarga, algunos de los parámetros no están controlados por el usuario de la batería, convirtiéndose ésta en una de las causas que provoca el envejecimiento de las baterías, una reducción del ciclo de vida y, por ende, un reemplazo prematuro de la batería. En esta tesis doctoral, se usa el modelo de batería propuesto por Copetti para simular el voltaje de carga y descarga de un banco de baterías de plomo-ácido e identificar aquellos parámetros que afectan el rendimiento de la batería.

El modelo se valida sobre medidas reales tomadas de un sistema de almacenamiento de energías basado en baterías instalado en el Laboratorio de Energías Renovables (LadER) ubicado en el departamento del Chocó, Colombia.

Para ajustar el modelo e identificar los parámetros internos del banco de baterías se implementan y se comparan tres algoritmos evolutivos: optimización por enjambre de partículas - PSO, búsqueda de cuco - CS y optimización por enjambre de partículas+perturbación – PSO+P. Siendo este último una nueva propuesta en la que se introduce una perturbación periódica en la población para evitar que el algoritmo caiga

en mínimos locales. La perturbación consiste en una nueva población PS_j^k basada en la mejor solución global que permita la reactivación del algoritmo PSO.

Los parámetros internos que están asociados a la capacidad de la batería son usados para estimar el estado de salud del sistema de almacenamiento de energía en baterías, encontrándose que éste perdió un 5% de su capacidad nominal, por lo que su estado de salud se estima en un 95%. Adicionalmente, el uso de análisis de componentes principales (PCA) es propuesto para realizar un diagnóstico del sistema. El modelo de análisis de componentes principales se aplica a un conjunto de parámetros asociados a la capacidad, resistencia interna y voltaje de circuito abierto de un sistema de almacenamiento de energía en baterías. El modelo PCA conserva las 5 primeras componentes que recolectan el 80.25% de la variabilidad total. Durante la prueba en condiciones de operación real, el modelo PCA, diagnosticó una degradación del estado de salud más rápido que el controlador de batería comercial. Sin embargo, un cambio en los modos de carga, llevó a una recuperación de la batería que también fue monitoreada por el algoritmo propuesto. Finalmente, se proponen acciones de control que llevan al sistema de almacenamiento de energía en baterías a funcionar en condiciones normales.

MODELATGE, ESTUDI I VALIDACIÓ EXPERIMENTAL DE LA INFLUÈNCIA
DELS PARÀMETRES INTERNS EN EL RENDIMENT DE SISTEMES
D'EMMAGATZEMATGE D'ENERGIA BASATS EN BATERIES. APLICACIÓ AL
CAS DEL DEPARTAMENT DE L'CHOCÓ (COLÒMBIA).

RESUM

El Chocó és un dels departaments de Colòmbia amb major nombre de municipis per fora de la interconnexió elèctrica nacional. En algunes zones no es compta amb cap tipus de subministrament d'energia elèctrica. En altres, el subministrament d'energia elèctrica es realitza a través de generadors dièsel instal·lats per una entitat governamental amb un temps d'operació entre 6 i 12 hores. En un percentatge menor, el servei d'energia elèctrica es porta a terme amb sistemes solars fotovoltaics aïllats. Aquests sistemes han ajudat a solucionar una de les necessitats bàsiques insatisfetes, com ho és, el dret al servei d'energia elèctrica, ja que no comptar amb aquest es converteix en sinònim d'endarreriment. No obstant això, aquesta alternativa renovable de subministrament elèctric, ve de la mà amb sistemes d'emmagatzematge d'energia elèctrica en bateries, per ser usada en moments en què la demanda ho requereixi. Per tant, l'emmagatzematge d'energia s'ha convertit en un component fonamental en els sistemes d'energia renovable, especialment aquells que inclouen bateries. D'allí, la necessitat de buscar mètodes de control eficients que ajudin a protegir i allargar la vida útil de la bateria. Dins dels mètodes de control reportats en la literatura, el més utilitzat és el de corrent constant - voltatge constant. Altres mètodes com el control amb lògica difusa o el model de control predictiu han demostrat ser més eficients que els mètodes tradicionals, ja que redueixen el temps de càrrega, mitiguen l'augment de la temperatura i mantenen l'estat de càrrega dins dels límits segurs. No obstant això, en els processos de càrrega i descàrrega, alguns dels paràmetres no estan controlats per l'usuari de la bateria, convertint-se aquesta en una de les causes que provoca l'envelliment de les bateries, una reducció del cicle de vida i, per tant, un reemplaçament prematur de la bateria. En aquesta tesi doctoral, s'usa el model de bateria proposat per Copetti per simular el voltatge de càrrega i descàrrega d'un banc de bateries de plom-àcid i identificar aquells paràmetres que afecten el rendiment de la bateria.

El model es valida sobre mesures reals preses d'un sistema d'emmagatzematge d'energies en bateries instal·lat al Laboratori d'Energies Renovables (líder) situat en el departament del Chocó, Colòmbia.

Per ajustar el model i identificar els paràmetres interns del banc de bateries s'implementen i es comparen tres algorismes evolutius: optimització per eixam de partícules - PSO, recerca de cucut - CS i optimització per eixam de partícules + pertorbació - PSO + P. Sent aquest últim una nova proposta en la qual s'introdueix una pertorbació periòdica en la població per evitar que l'algoritme caigui en mínims locals.

La pertorbació consisteix en una nova població basada en la millor solució global que permeti la reactivació de l'algoritme PSO.

Els paràmetres interns que estan associats a la capacitat de la bateria són usats per estimar l'estat de salut del sistema d'emmagatzematge d'energia en bateries, trobant-se que aquest va perdre un 5% de la seva capacitat nominal, de manera que el seu estat de salut s'estima en un 95%. Addicionalment, l'ús d'anàlisi de components principals (PCA) és proposat per realitzar un diagnòstic del sistema. El model d'anàlisi de components principals s'aplica a un conjunt de paràmetres associats a la capacitat, resistència interna i voltatge de circuit obert d'un sistema d'emmagatzematge d'energia en bateries. El model PCA conserva les 5 primeres components que recullen el 80.25% de la variabilitat total. Durant la prova en condicions d'operació real, el model PCA, va diagnosticar una degradació de l'estat de salut més ràpid que el controlador de bateria comercial. No obstant això, un canvi en les maneres de càrrega, va portar a una recuperació de la bateria que també va ser monitoritzada per l'algoritme proposat. Finalment, es proposen accions de control que porten al sistema d'emmagatzematge d'energia en bateries a funcionar en condicions normals.

MODELING, STUDY AND EXPERIMENTAL VALIDATION OF THE
INFLUENCE OF INTERNAL PARAMETERS ON THE PERFORMANCE OF
BATTERY-BASED ENERGY STORAGE SYSTEMS. APPLICATION TO THE
CASE OF THE DEPARTMENT OF CHOCÓ (COLOMBIA)

ABSTRACT

El Chocó is one of the departments of Colombia, with the largest number of municipalities outside the national electricity interconnection. In some areas, there is no type of electricity supply. In others, the supply of electricity is done through diesel generators, installed by a government entity, with an operating time between 6 and 12 hours. In a smaller percentage, the electric power service is carried out with isolated photovoltaic solar systems. Regarding the latter, they have helped to solve one of the unmet basic needs, such as the right to electric power service, since, not having it, it becomes synonymous with backwardness. However, this renewable alternative of electrical supply comes hand in hand with battery energy storage systems, to be used at times when the demand requires it. Therefore, energy storage has become a fundamental component in renewable energy systems, especially those that include batteries. Hence, the need to look for efficient controls methods, which help to protect and prolong the battery life expectancy. Among the control methods reported in the literature, the most used is the constant current - constant voltage. Other methods such as fuzzy logic control or the model predictive control have proven to be more efficient than traditional methods, since they reduce the charging time, mitigate the increase in temperature and maintain the state of charge within the system the safe limits. However, in the charging and discharging processes, some of the parameters are not controlled by the user of the battery, this being one of the causes that leads to the aging batteries, a reduction in the life cycle, and therefore, a premature replacement of the battery. Therefore, in this doctoral thesis, the battery model proposed by Copetti is used to simulate the charge and discharge voltage of a battery of lead-acid batteries and identify those parameters that affect battery performance.

The model is validated on real measurements, taken from a battery energy storage system installed in the Renewable Energy Laboratory (LadER) located in the department of Chocó, Colombia.

To fitting the model and identify the internal parameters of the battery bank, three evolutionary algorithms are implemented and compared (particle swarm optimization - PSO, cuckoo search - CS and particle swarm optimization + perturbation - PSO + P), where PSO + P is a new proposal, in which a periodic perturbation is introduced in the population, to avoid that the algorithm falls at local minimums. The perturbation consists of a new population PS_j^k based on the best global solution that allows the reactivation of the PSO algorithm.

The internal parameters that are associated with the battery capacity are used to estimate the state of health of the battery energy storage system, found that it lost 5% of its nominal capacity, so that its state of health estimated at 95%. Additionally, the use of principal component analysis (PCA) is proposed to perform a system diagnosis. The principal component analysis model is applied on parameters set associated with the capacity, internal resistance and open circuit voltage of a battery energy storage system. The PCA model conserves the first 5 components, which collect 80.25% of the total variability. During the test under real operating conditions, the PCA model diagnosed a state of health degradation faster than the commercial battery controller. However, a change in charging modes led to a recovery of the battery that was also monitored by the proposed algorithm. Finally, control actions are proposed that lead to the battery energy storage system to operate under normal conditions.

Tabla de contenido

Capítulo 1	1
1. DESCRIPCIÓN GENERAL DEL DEPARTAMENTO DEL CHOCÓ (COLOMBIA)	1
1.1. DEPARTAMENTO DEL CHOCÓ	1
1.2. LABORATORIO DE ENERGÍAS RENOVABLES - LadER.....	5
1.3. OBJETIVOS DE LA TESIS	7
1.3.1. Objetivo General	7
1.3.2. Objetivos Específicos	7
1.4. ESTRUCTURA DE LA TESIS	7
1.5. APORTACIONES DE LA TESIS.....	9
Capítulo 2	11
2. UNA REVISIÓN SOBRE LAS ESTRATEGIAS DE CONTROL DE CARGA Y DESCARGA DE BATERÍAS: APLICACIÓN A SISTEMAS DE ENERGÍA RENOVABLE	11
2.1. MÉTODOS TRADICIONALES DE CONTROL DE CARGA.....	14
2.1.1. Corriente constante (CC).....	15
2.1.2. Voltaje constante (CV)	15
2.1.3. Corriente constante – voltaje constante (CC – CV)	15
2.1.4. Carga por pulsos (PC)	15
2.1.5. Carga de pulso negativo (NPC).....	16
2.1.6. Carga de goteo (TC)	16
2.1.7. Carga Flotante (FC).....	16
2.2. SISTEMAS DE GESTIÓN DE BATERÍA	17
2.2.1. Control de lógica difusa (FLC).....	17
2.2.2. Control de lógica difusa de los sistemas de almacenamiento de energía en aplicaciones independientes	18
2.2.3. Control de lógica difusa de sistemas de almacenamiento de energía en aplicaciones conectadas a la red.....	19
2.2.4. Modelo de control predictivo (MPC)	20
2.2.5. Modelo de control predictivo de sistemas de almacenamiento de energía en aplicaciones independientes	22
2.2.6. Modelo de control predictivo de sistemas de almacenamiento de energía en aplicaciones conectadas a la red.....	22

2.3.	RESULTADOS Y DISCUSIÓN	23
2.4.	CONCLUSIÓN.....	25
Capítulo 3	27
3.	SIMULACIÓN, IDENTIFICACIÓN DE PARÁMETROS Y VALIDACIÓN EXPERIMENTAL DE UN BANCO DE BATERÍAS DE PLOMO ÁCIDO USANDO ALGORITMO EVOLUTIVO.....	27
3.1.	MODELO DE BATERÍA.....	29
3.2.	ESTADO DE CARGA DE LA BATERÍA	31
3.2.1.	Métodos de estimación del SOC	31
3.2.2.	Zona de carga, sobrecarga y saturación.....	35
3.2.2.1.	Zona de carga.....	35
3.2.2.2.	Zona de sobrecarga	35
3.2.2.3.	Zona de saturación	36
3.2.3.	Zona de descarga, zona de sobre-descarga y zona de agotamiento.....	36
3.2.3.1.	Zona de descarga.....	36
3.2.3.2.	Zona de sobredescarga.....	36
3.2.3.3.	Zona de agotamiento.....	36
3.2.3.4.	Voltaje de transición	37
3.3.	IDENTIFICACIÓN DE PARÁMETROS	37
3.4.	DESCRIPCIÓN DE LOS ALGORITMOS EVOLUTIVOS.....	42
3.4.1.	Algoritmo de optimización por enjambres de partículas (PSO).....	42
3.4.2.	Algoritmo de búsqueda de Cuco (CS).....	44
3.5.	NUEVA PROPUESTA.....	46
3.5.1.	Criterios de configuración de los algoritmos.....	46
3.6.	RESULTADOS Y DISCUSION	47
3.6.1.	Validación experimental del SOC y el voltaje del BESS.....	49
3.7.	CONCLUSIÓN.....	63
Capítulo 4	65
4.	ESTIMACIÓN DEL ESTADO DE SALUD DE UN BANCO DE BATERÍA CONECTADO A UN SISTEMA DE ENERGÍA RENOVABLE.....	65
4.1.	METODOLOGÍA	65
4.2.	RESULTADOS Y DISCUSIÓN	66
4.2.1.	Validación experimental.....	66
4.2.2.	Estimación del SOH de un banco de baterías de plomo-ácido.....	68

4.3. CONCLUSIÓN.....	71
Capítulo 5	73
5. DIAGNÓSTICO DE UN SISTEMA DE ALMACENAMIENTO DE ENERGÍA EN BATERÍA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES 73	
5.1. METODOLOGÍA	74
5.1.1. Visión general.....	74
5.2. ANÁLISIS DE COMPONENTES PRINCIPALES (PCA).....	75
5.3. APLICACIÓN PRÁCTICA DEL PCA.....	76
5.4. ACCIONES DEL CONTROLADOR.....	80
5.5. APLICACIÓN DEL MODELO PCA AL BESS.....	81
5.5.1. Fase I: Construcción del modelo PCA.	81
5.5.2. Fase II – Diagnóstico de nuevas observaciones	85
5.6. APLICACIÓN A LA OBSERVACIÓN DE DATOS REALES.....	92
5.7. CONCLUSIÓN.....	97
REFERENCIAS	98

LISTADO DE FIGURAS

Figura 1.1. Municipios del departamento del Chocó; b) Porcentaje de ZNI en el Chocó.	3
Figura 1.2. Prestación del servicio de energía eléctrica en ZNI.	4
Figura 1.3. Laboratorio de energías renovables (LadER) – Andagoya (Chocó).	5
Figura 1.4. Equipos instalados en el LadER – Chocó.	6
Figura 1.5. Sistema de almacenamiento de energía en baterías. LadER - Andagoya (Chocó).	6
Figura 2.1. Campo de aplicación de las diferentes técnicas de almacenamiento según la energía almacenada y la potencia de salida.	11
Figura 2.2. Tecnologías de almacenamiento de energía.	12
Figura 2.3. Sistemas de almacenamiento de energía.	12
Figura 2.4. Esquema de control de la batería.	14
Figura 2.5. Fases de carga del inversor Sunny Island TM para una batería AGM.	17
Figura 2.6. Estructura de un FLC.	18
Figura 2.7. Principio de un MPC.	21
Figura 2.8. Principales ventajas del control de lógica difusa (FLC) y del modelo de control predictivo (MPC).	24
Figura 2.9. Simulación de la temperatura de la batería.	25
Figura 3.1. Diagrama de bloques del Sistema solar fotovoltaico instalado en el LadER en el Departamento del Chocó, Colombia.	29
Figura 3.2. Modelo de batería de circuito equivalente.	30
Figura 3.3. Zonas de trabajo de la batería: evolución del voltaje de la batería (V_{bat}) en función de la corriente.	34
Figura 3.4. Diagrama de flujo del algoritmo de PSO.	41
Figura 3.5. Diagrama de flujo del algoritmo de búsqueda de Cuco (CS).	45
Figura 3.6. Comportamiento de los algoritmos de optimización en modo de carga y descarga.	47
Figura 3.7. Modelo de batería representado en Labview®.	48
Figura 3.8. Validación experimental del SOC y voltaje de la batería obtenidas por el algoritmo PSO+P.	50
Figura 3.9.a. Simulación y validación del SOC del BESS para un año de medición. Septiembre 2017.	51
Figura 3.9.b. Simulación y validación del SOC del BESS para un año de medición. Septiembre 2017.	51
Figura 3.9.c. Simulación y validación del SOC del BESS para un año de medición. Octubre 2017.	52
Figura 3.9.d. Simulación y validación del SOC del BESS para un año de medición. Noviembre 2017.	52
Figura 3.9.e. Simulación y validación del SOC del BESS para un año de medición. Diciembre 2017.	53
Figura 3.9.f. Simulación y validación del SOC del BESS para un año de medición. Enero 2018.	53
Figura 3.9.g. Simulación y validación del SOC del BESS para un año de medición. Febrero 2018.	54
Figura 3.9.h. Simulación y validación del SOC del BESS para un año de medición. Marzo 2018.	54
Figura 3.9.i. Simulación y validación del SOC del BESS para un año de medición. Abril 2018.	55

Figura 3.9.j. Simulación y validación del SOC del BESS para un año de medición. Mayo 2018.....	55
Figura 3.9.k. Simulación y validación del SOC del BESS para un año de medición. Junio 2018.....	56
Figura 3.9.l. Simulación y validación del SOC del BESS para un año de medición. Julio 2018.....	56
Figura 3.10. a. Simulación y validación del voltaje del BESS para un año de medición. Agosto 2017.....	57
Figura 3.10. b. Simulación y validación del voltaje del BESS para un año de medición. Septiembre 2017.....	57
Figura 3.10. c. Simulación y validación del voltaje del BESS para un año de medición. Octubre 2017.....	58
Figura 3.10. d. Simulación y validación del voltaje del BESS para un año de medición. Noviembre 2017.....	58
Figura 3.10. e. Simulación y validación del voltaje del BESS para un año de medición. Diciembre 2017.....	59
Figura 3.10. f. Simulación y validación del voltaje del BESS para un año de medición. Enero 2018.....	59
Figura 3.10. g. Simulación y validación del voltaje del BESS para un año de medición. Febrero 2018.....	60
Figura 3.10. h. Simulación y validación del voltaje del BESS para un año de medición. Marzo 2018.....	60
Figura 3.10. i. Simulación y validación del voltaje del BESS para un año de medición. Abril 2018.....	61
Figura 3.10. j. Simulación y validación del voltaje del BESS para un año de medición. Mayo 2018.....	61
Figura 3.10. k. Simulación y validación del voltaje del BESS para un año de medición. Junio 2018.....	62
Figura 3.10. l. Simulación y validación del voltaje del BESS para un año de medición. Julio 2018.....	62
Figura 4.1. Mediciones y simulación SOC del banco de baterías de plomo ácido. Febrero 2018.....	67
Figura 4.2. Mediciones de voltaje de banco de baterías de plomo ácido y simulación. Febrero 2018.....	68
Figura 4.3. Resultados de la simulación de la capacidad del banco de baterías de plomo y el estado de salud (SOH). Febrero 2018.....	69
Figura 4.4. Corriente medida del banco de baterías (desde enero 01/2018 hasta febrero 28/2018).....	70
Figura 4.5. Resultados de la estimación de la resistencia interna del banco de batería de plomo ácido. Febrero 2018.....	70
Figura 4.6. Evolución de los parámetros asociados con la capacidad de la batería obtenida durante el proceso de simulación. Febrero 2018.....	71
Figura 5.1. Mediciones de un año de la corriente del BESS, tomadas del laboratorio de energía renovable en Chocó - Colombia.....	81
Figura 5.2. a) Gráfico del modelo final de PCA. b) Los gráficos de control T^2 de Hotelling y SPE para los datos de referencia filtrados.....	82
Figura 5.3. Coeficientes (loadings) de los parámetros en cada PC.....	83
Figura 5.4. Proyecciones de las PCs sobre cada subespacio bidimensional.....	85
Figura 5.5. Gráfico de control T^2 de Hotelling para el monitoreo del mes de noviembre de 2017.....	86

Figura 5.6. Diagrama de flujo del gráfico de control T^2 de Hotelling.....	89
Figura 5.7. Gráfico de contribución al T^2 de Hotelling de las observaciones extremas dentro del modelo de PCA.....	90
Figura 5.8. Proyecciones de las observaciones del mes de Noviembre superpuestas sobre el mes de entrenamiento.....	91
Figura 5.9. Ampliación de las proyecciones de las observaciones del mes de Noviembre superpuestas sobre el mes de entrenamiento de la combinación de la PC 1-5.....	92
Figura 5.10. Monitoreo de T_i^2 de Hotelling desde Noviembre de 2017 hasta Julio de 2018.....	93
Figura 5.11. Proyecciones de los centroides de las observaciones del mes de Noviembre de 2017 a Julio de 2018 en el espacio de las PC.....	95
Figura 5.12. Estimación del estado de salud (SOH) del BESS instalados en el LadER en el departamento del Chocó - Colombia.....	96

LISTADO DE TABLAS

Tabla 1.1. Ficha técnica del departamento del Chocó, Colombia.	1
Tabla 1.2. Municipios y porcentaje de población del departamento del Chocó.....	2
Tabla 2.1. Tecnologías de baterías usadas en sistemas de energías renovables (RES). Pb-acid: plomo-ácido; Li-Ion: ion litio; Ni-Cd: níquel-cadmio; Na-S: sodio-azufre; PSB: batería de polisulfuro-bromuro; VRB: batería de redox de vanadio.....	13
Tabla 3.1. Ventajas y desventajas de los métodos de estimación existentes de SOC. ...	32
Tabla 3.2. Descripción de las zonas de trabajo de una batería.	34
Tabla 3.3. Valores nominales de los parámetros identificados por algunos autores.	38
Tabla 3.4. Configuración de los algoritmos de optimización.....	46
Tabla 3.5. Comparación de algoritmos utilizando el error medio mínimo alcanzado....	48
Tabla 3.6. Identificación de parámetros por PSO + P.	49
Tabla 4.1. Cálculo de las mediciones de error de SOC y voltaje del banco de batería. .	68
Tabla 5.1. Parámetros considerados para el diagnóstico del BESS.....	81

ABREVIATURAS

AC: alternating current.

BDR: battery dynamic range.

BESS: battery energy storage system.

BMS: battery management system.

CAES: compressed air energy storage.

CC-CV: constant current – constant voltage.

CC: constant current.

CV: constant voltage.

CPV: cumulative percent variance

CS: cuckoo search.

DC: direct current.

DOD: depth of discharge.

DSP: digital signal processor.

EA: evolutive algorithm.

ESS: energy storage system.

FBES: flow battery energy storage.

FC: float charge.

FES: flywheel energy storage.

FIS: fuzzy inference system.

FLC: fuzzy logic control.

GA: genetic algorithm.

HES: hydrogen-based energy storage system.

IAE: integral absolute error.

ISE: integral square error.

LadER: laboratorio de energías renovables.

LOE: level of energy.

MPC: model predictive control.

NMPC: nonlinear model predictive control.

NPC: reflex charging or negative pulse charging.

OGS: optimal generation scheduling.

PC: pulse charging.

PCC: point of common coupling.

PHES: pumped hydro energy storage.

PI: proporcional-integral.

PID: proportional–integral–derivative.

PQ: power quality.

PSO: particle swarm optimization.

PSO+P: particle swarm optimization+perturbation.

PV: photovoltaic.

PVR: power variation range.

R_i: internal resistance.

RES: renewable energy system.

RTDS: real-time digital simulator.

SES: supercapacitor energy storage.

SMES: superconducting magnetic energy storage.

SOC: state of charge.

SOH: state of health.

SPE: squared prediction error

TC: trickle charge.

UCL: upper control limit

V_{oc}: open circuit voltage.

Capítulo 1

1. DESCRIPCIÓN GENERAL DEL DEPARTAMENTO DEL CHOCÓ (COLOMBIA)

1.1. DEPARTAMENTO DEL CHOCÓ

El departamento del Chocó está ubicado al noroeste de la República de Colombia en Suramérica y tiene límites de frontera con la República de Panamá, el Mar Caribe y el Océano Pacífico (ver Figura 1.1a). Cuenta con una extensión terrestre de 46.530 km² y se caracteriza por presentar altas precipitaciones durante todo el año (entre 8.000 y 12.000 mm anuales) siendo considerado la segunda parte más lluviosa del mundo después de Cherranpunji en la India. La humedad relativa está alrededor del 90% y su temperatura promedio es de 27 °C (ver **Tabla 1.1**).

Tabla 1.1. Ficha técnica del departamento del Chocó, Colombia [1]

Localización y extensión	Está ubicado en la esquina noroccidental de Colombia en Suramérica. Tiene límites de frontera con la República de Panamá, el Océano Pacífico y el Mar Caribe.
Límites políticos administrativos	Políticamente, limita por el norte, con la República de Panamá y el mar Caribe; por el este, con los departamentos de Antioquia, Risaralda y Valle del Cauca; por el sur, con el departamento del Valle de Cauca; y por el oeste, con el océano Pacífico.
Límites geográficos	Están definidos entre los 04° 00' 50" y 08° 41' 32" de latitud norte y los 76° 02' 57" y 77° 53' 38" de longitud oeste.
Extensión terrestre	Noveno departamento en extensión de Colombia. Su extensión terrestre es de 46.530 km ² (4% del país).
Extensión marítima	El 57,3% de los 1.382 km de la frontera marítima de Colombia con el océano Pacífico.
Número de municipios	El departamento del Chocó está conformado por 30 municipios.
Población y densidad poblacional	Población de 500.093 habitantes. Densidad (Habitantes por km ²): 10.75 porcentaje población de departamento del total nacional 1,0
Distribución étnica	El 90% es de raza negra; el 6% es mulato y blanco, el 4% restante es indígena.
Pluviosidad y temperatura	Entre 8.000 y 12.000 milímetros de precipitación anual y su temperatura oscila entre 26° y 30° C
Principales ríos	Atrato, San Juan, Baudó.
Condiciones básicas de la población	Índice de 39,1% de pobreza extrema y de 65,9 % de pobreza, frente a los índices nacionales de 8,1% y 28,5%. Necesidades Básicas Insatisfechas NBI en el Chocó es de 79,2%, mientras en el país es de 27,7%. La esperanza de vida en Chocó es 70,64 años, mientras que el promedio nacional es 76,15. El 79% de los habitantes de Chocó presenta al menos una necesidad básica insatisfecha, mientras que a nivel nacional este indicador es del 27,6%. El indicador de calidad de vida es el más bajo del país (58 puntos frente a un promedio nacional de 79).

Según proyecciones a 2015 del censo poblacional de 2005, el departamento del Chocó cuenta con un total de 505.016 habitantes, repartidos en 30 municipios (ver **Tabla 1.2**). Sin embargo, las tres cuartas partes del departamento pertenecen a áreas rurales con un índice de ruralidad entre 43.65 y 73.67%.

Tabla 1.2. Municipios y porcentaje de población del departamento del Chocó [1].

No.	Código DANE	Municipios	Total		Cabecera Mup.		Resto	
			Población	%	Población	%	Población	%
1	27001	Quibdó	116.861	23,14	106.332	90,99	10.529	9,01
2	27006	Acandí	9.696	1,92	4.809	49,6	4.887	50,40
3	27025	Alto Baudó	37.119	7,35	8.203	22,1	28.915	77,9
4	27050	Atrato	10.050	1,99	3.349	33,32	6.701	66,68
5	27073	Bagadó	8.131	1,61	2.317	28,5	5.813	71,50
6	27075	Bahía Solano	9.444	1,87	4.467	47,3	4.977	52,7
7	27077	Bajo Baudó	17.575	3,48	2.619	14,9	14.956	85,1
8	27099	Bojayá	10.201	2,02	5.162	50,6	5.039	49,4
9	27135	Cantón de San Pablo	8.030	1,59	3.332	41,5	4.697	58,5
10	27150	Carmen del Darién	5.505	1,09	1.327	24,1	4.178	75,9
11	27160	Certegui	10.151	2,01	5.634	55,5	4.517	44,5
12	27205	Condoto	14.797	2,93	10.432	70,5	4.365	29,5
13	27245	El Carmen de Atrato	14.191	2,81	6.386	45	7.805	55
14	27361	Istmina	23.411	5,07	18.073	77,2	5.338	22,8
15	27372	Juradó	3.333	0,66	1.557	46,7	1.777	53,3
16	27250	Litoral del San Juan	15.403	3,05	1.325	8,6	14.078	91,4
17	27413	Lloró	11.312	2,24	3.077	27,2	8.235	72,8
18	27425	Medio Atrato	29.796	5,9	1.073	3,6	28.723	96,4
19	27430	Medio Baudó	13.686	2,71	561	4,1	13.125	95,9
20	27450	Medio San Juan	16.464	3,26	922	5,6	15.542	94,4
21	27491	Nóvita	8.030	1,59	2.674	33,3	5.356	66,7
22	27495	Nuquí	8.636	1,71	2.573	29,8	6.062	70,2
23	27580	Río Iró	9.797	1,94	1.568	16	8.230	84
24	27600	Río Quito	9.040	1,79	7.286	80,6	1.754	19,4
25	27615	Riosucio	29.139	5,77	15.298	52,5	13.841	47,5
26	27660	San José del Palmar	4.848	0,96	1.086	22,4	3.762	77,6
27	27745	Sipí	4.091	0,81	344	8,4	3.747	91,6
28	27787	Tadó	19.090	3,78	12.179	63,8	6.910	36,2
29	27800	Unguía	15.251	3,02	4.514	29,6	10.737	70,4
30	27810	Unión Panamericana	9.696	1,92	3.927	40,5	5.769	59,5
		Total	505.016	100	250.650	49,63	254.366	50,35

El Chocó (ver **Figura 1.1a**), es uno de los departamentos de Colombia con el mayor número de municipios con Zonas No Interconectadas (ZNI), dentro de los cuales se

mencionan los siguiente: Acandí, Riosucio, Unguía, Carmen del Darién, Bahía Solano, Bojayá, Nuquí, El Baudó (alto, medio y bajo), Sipí, Litoral del San Juan (ver **Figura 1.1 b**).

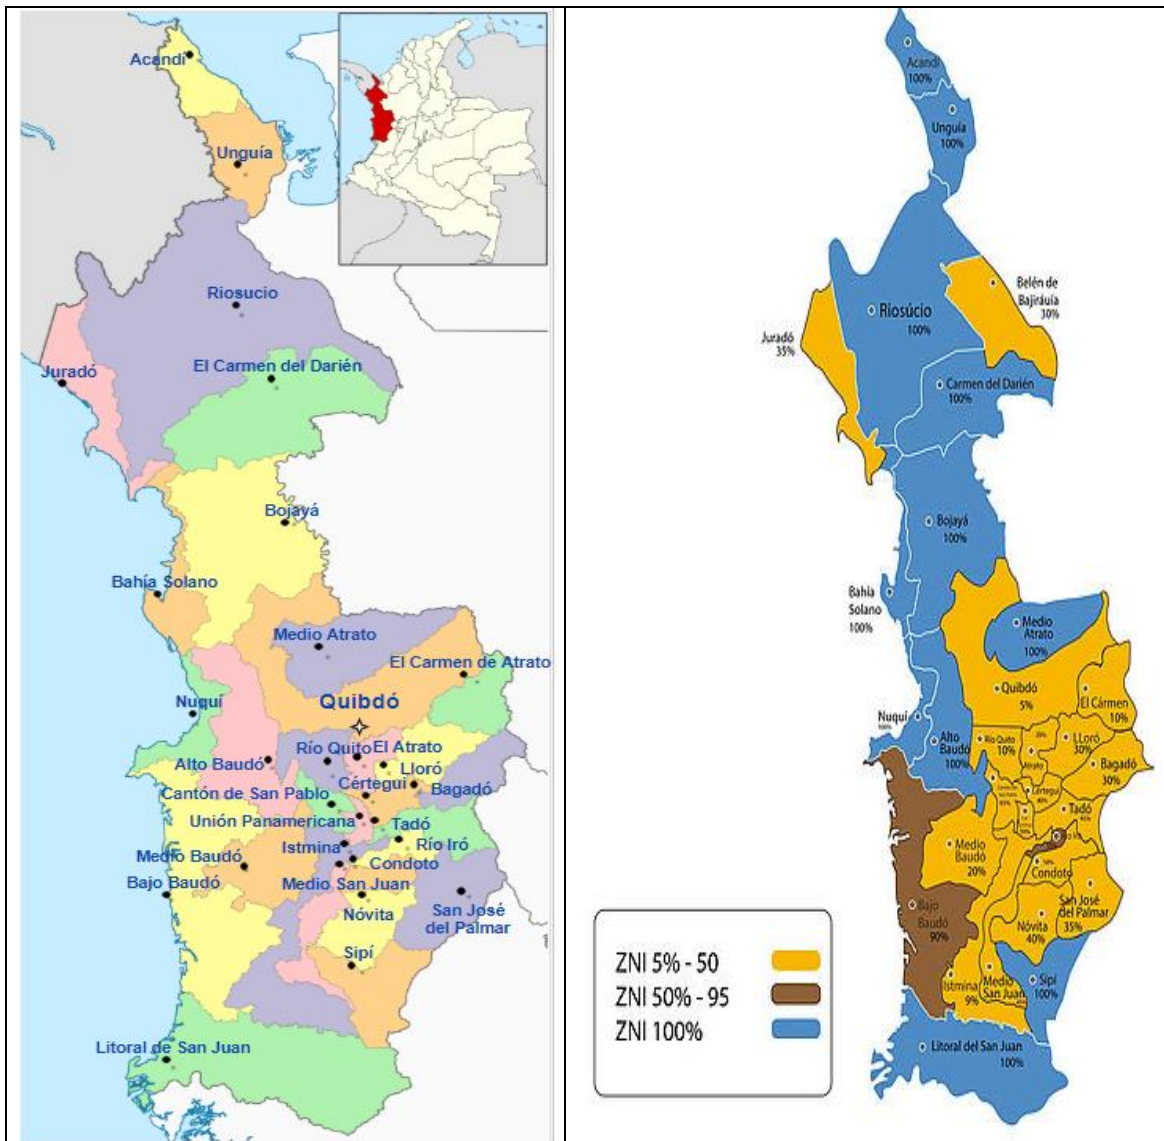


Figura 1.1. a) Municipios del departamento del Chocó; **b)** Porcentaje de ZNI en el Chocó [2,3].

El servicio de energía eléctrica se hace a través de generadores Diésel (ver **Figura 1.2**) instalados mayoritariamente por el Instituto de Planificación y Promoción de Soluciones Energéticas para las Zonas No Interconectadas (IPSE), con un tiempo de operación entre 6 y 12 horas. Sin embargo, muchos de los generadores Diésel se encuentran fuera de servicio debido a la falta de combustible o por daños irreparables (ver **Figura 1.2**).

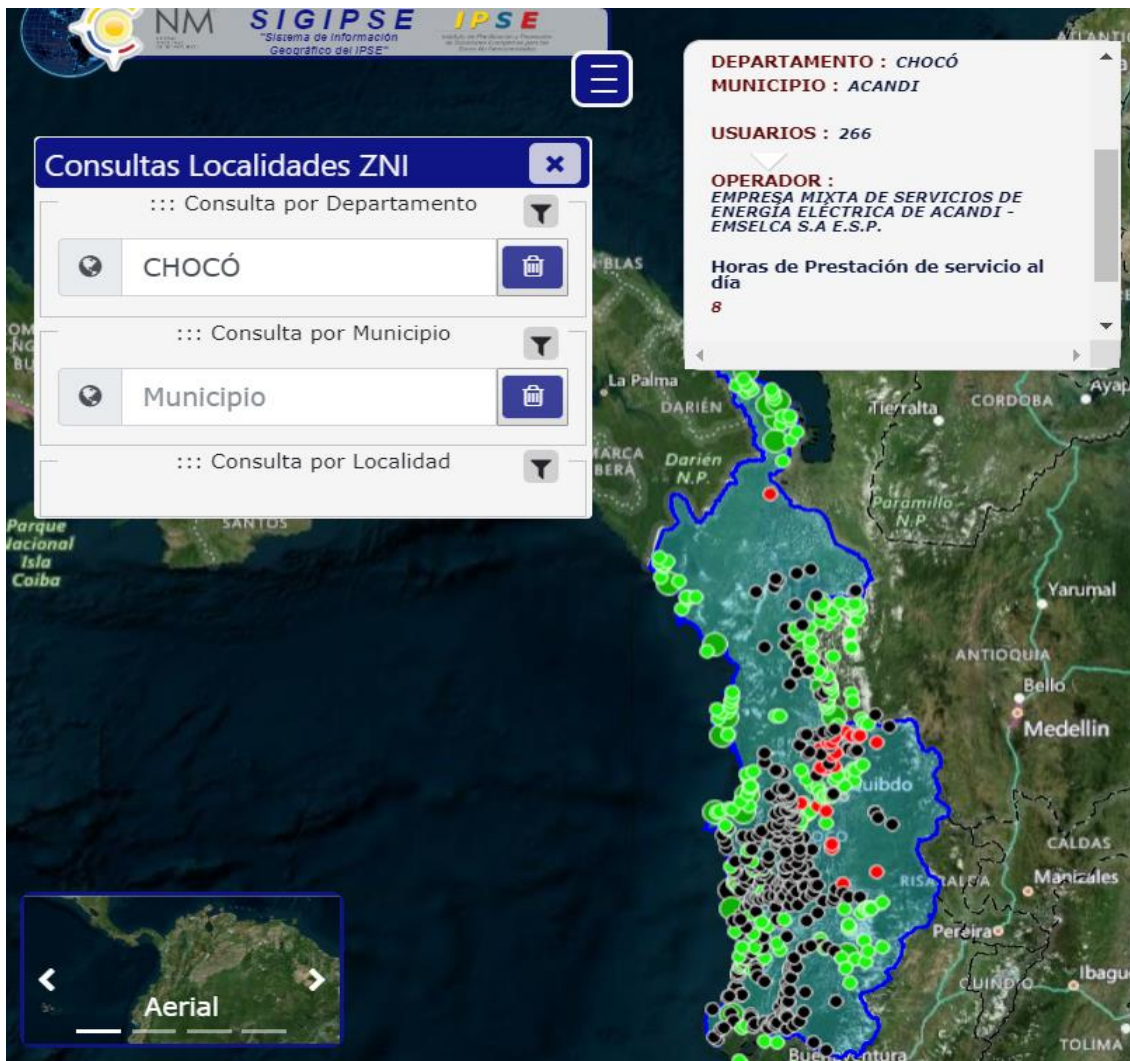


Figura 1.2. Prestación del servicio de energía eléctrica en ZNI. [4]. Los puntos en color verde: Con servicio; Los puntos en color rojo: Sin servicio; Los puntos en color negro: Sin información.

Teniendo en cuenta las dificultades de transporte y compra de combustible sumado a la falta de recursos económicos de los pobladores que habitan esta región, se están llevando a cabo proyectos con fines de abastecimiento energético que ayuden a mitigar una de las tantas necesidad básicas insatisfechas (NBI) que abundan en aquellas ZNI. Es por ello, que se están implementando alternativas de energización mediante proyectos que promuevan el uso de fuentes no convencionales de energía (FNCE) como sistemas solares fotovoltaicos aislados con almacenamiento de energía en baterías, lo cuales son de fácil transporte e instalación. Algunos de estos proyectos son:

- ✓ Luces para aprender, Convenio IPSE - Organización de Estados Iberoamericanos (OEI) 061-2012 (Energización de centros educativos rurales).
- ✓ Implementación de sistemas fotovoltaicos individuales para la generación de energía eléctrica en la vereda Titiza. Municipio de Acandí. Departamento del Chocó. Contrato 105-2014.
- ✓ Sistema solar fotovoltaico en Titumate.

- ✓ Implementación de sistemas fotovoltaicos individuales para la generación de energía eléctrica en la vereda Los Tibirre alto, medio y bajo. Municipio de Acandí. Departamento del Chocó, contrato 105-2014.

Sin embargo, debido a la falta de un sistema de gestión de la energía sumado a la falta de transferencia de conocimiento que induzcan a la población a realizar un buen uso eficiente de la energía almacenada que evite el deterioro prematuro de la batería, ha llevado a que varios de estos sistemas solares fotovoltaicos queden fuera de operación.

Recientemente en el municipio del Medio San Juan (Andagoya) se ejecutó un proyecto denominado “Implementación de un programa de desarrollo e investigación en energías renovables en el departamento del Chocó 2014 – 2018, BPIN: 20130000100285”. Como resultado de la ejecución de este proyecto nace el Laboratorio de Energías Renovables del departamento del Chocó - LadER (ver **Figura 1.3**), donde se estudian alternativas de abastecimiento energético de acuerdo a las características ambientales y socioculturales en las áreas de influencia del proyecto.



Figura 1.3. Laboratorio de energías renovables (LadER) – Andagoya (Chocó).

1.2. LABORATORIO DE ENERGÍAS RENOVABLES - LadER

El laboratorio de energías renovables quien en adelante se conocerá como “LadER”, cuenta con un sistema solar fotovoltaico de 20 kW, un sistema eólico de 5.5 kW, un sistema de aprovechamiento de la biomasa residual de 25 kW, una planta diésel de 50 kW, un sistema de almacenamiento de energía en pilas de Hidrógeno de 6.2 kW, una estación meteorológica (ver **Figura 1.4**), y un sistema de almacenamiento de energía en

baterías (ver **Figura 1.5**) de 4328 Ah (C_{10}), compuesto por 48 vasos TECHNO SUN 2V-OPzS-TCH2765, dividido en dos bancos de 24 vasos conectados en serie.



Figura 1.4. Equipos instalados en el LadER – Chocó.



Figura 1.5. Sistema de almacenamiento de energía en baterías. LadER - Andagoya (Chocó).

1.3.OBJETIVOS DE LA TESIS

1.3.1. Objetivo General

Modelar, estudiar y validar experimental la influencia de los parámetros internos en el rendimiento de sistemas de almacenamiento de energía basados en baterías. Aplicación al caso del Departamento del Chocó (Colombia).

1.3.2. Objetivos Específicos

- ✓ Realizar una revisión bibliográfica que permita tener una visión clara acerca de las estrategias de control de carga y descarga de baterías, aplicadas a sistemas de almacenamiento de energías comúnmente usadas en sistemas de energía renovable.
- ✓ Diseñar en el software LabView una simulación que permita modelar, identificar los parámetros internos de un sistema de almacenamiento de energía basado en baterías de plomo ácido y validar experimentalmente la tensión y el estado de carga usando algoritmo evolutivo.
- ✓ Analizar el rendimiento de un sistema de almacenamiento de energía basado en baterías de plomo ácido instalado en el laboratorio de energías renovables del departamento del Chocó y estimar su estado de salud.
- ✓ Proponer una metodología de diagnóstico usando estadística descriptiva para ser aplicada a un conjunto de parámetros extraídos de un sistema de almacenamiento de energía basado en baterías.

1.4. ESTRUCTURA DE LA TESIS

Esta tesis está estructurada en cinco capítulos como se detalla a continuación:

Capítulo 1 - Descripción general del departamento del Chocó. Se muestra una visión general de la región donde es aplicada esta investigación y se presenta el Laboratorio de Energías Renovables del departamento del Chocó con los diferentes equipos que lo conforman.

Capítulo 2 - Una revisión sobre las estrategias de control de carga y descarga de baterías: aplicación a sistemas de energía renovable. Se realiza una revisión en la literatura acerca de los métodos de control existentes utilizados para controlar los procesos de carga y descarga centrándose en sus impactos en la vida útil de la batería. Los métodos clásicos y modernos se estudian juntos para encontrar el mejor enfoque para los sistemas reales.

Capítulo 3 - Modelado, identificación de parámetros y validación experimental de un banco de baterías de plomo ácido usando algoritmo evolutivo: Se agregan nuevos parámetros al modelo de batería propuesto por Copetti y se incluye una perturbación al algoritmo de optimización de enjambre de partículas (PSO) que evita que éste caiga en mínimos locales, por lo que alcanza un error más bajo que el algoritmo convencional. Luego se modela y se identifican los parámetros internos de un sistema de almacenamiento de energía en baterías y se validan los resultados con datos experimentales, tomando como insumos, la base de datos del Laboratorio de Energías Renovables del departamento del Chocó.

Capítulo 4 - Estimación del estado de salud de un banco de batería conectado a un sistema de energía renovable: Una vez identificados en el Capítulo III los parámetros internos del sistema de almacenamiento de energía en baterías, se seleccionan los parámetros que están asociados a la capacidad de la batería y se usan para estimar el estado de salud de la batería.

Capítulo 5 - Diagnóstico de un sistema de almacenamiento de energía en batería basado en el análisis de componentes principales: Se propone una metodología basada en el uso del análisis de componentes principales (PCA) para realizar un diagnóstico al sistema de almacenamiento de energía en baterías. El modelo de análisis de componentes principales se aplica a un conjunto de parámetros asociados a la capacidad, resistencia interna y voltaje de circuito abierto del sistema de almacenamiento en mención. El modelo PCA conserva las 5 primeras componentes que recolectan el 80.25% de la variabilidad total. Adicionalmente, se proponen acciones de control que llevan al sistema de almacenamiento de energía en baterías a funcionar en condiciones normales.

1.5. APORTACIONES DE LA TESIS

En el capítulo 2, se aporta un estado del arte de los métodos de control usados en los procesos de carga y descarga de una batería resaltando sus ventajas y desventajas entre ellos. Posteriormente, se evalúan otras técnicas de control como el control de lógica difusa y el modelo de control predictivo, resaltando sus principales ventajas frente a los métodos tradicionales; convirtiéndose esto en una información importante en la toma de decisiones donde se requiera implementar un sistema de gestión de la batería.

En el capítulo 3, se utiliza el modelo de batería propuesto por Copetti y se incluyen cuatro nuevos parámetros que permiten hacer un mejor ajuste al modelo. Adicionalmente, se introduce una perturbación periódica en la población para evitar que el algoritmo de optimización de enjambre de partículas caiga en mínimo locales cuando éste realiza la búsqueda del mejor candidato. La perturbación consiste en una nueva población PS_j^k basada en la mejor solución global que permite la reactivación del algoritmo de optimización de enjambre de partículas. La inclusión de esta perturbación, permite obtener mejores resultados que el algoritmo de optimización de enjambre de partículas clásico. Los resultados son validados con medidas experimentales tomadas de la base de datos del laboratorio de energías renovables del departamento del Chocó (Colombia), los cuales muestran errores muy bajos. La principal ventaja del modelo desarrollado es su bajo costo computacional y su capacidad para absorber los problemas de lectura y los errores de escalado. El modelo y su enfoque de ajuste presentado en este documento pueden aplicarse a otros tipos de baterías, especialmente las utilizadas en sistemas de energías renovables independientes.

En el capítulo 4, se presenta una metodología basada en la identificación paramétrica que permite estimar el estado de salud de un banco de batería experimental y se analiza la tendencia que presentan los parámetros internos asociados a la capacidad de la batería que ayudaran a desarrollar técnicas que permitan pronosticar o estimar el estado de salud de un banco de batería experimental. A diferencia de otros métodos, el método propuesto es aplicado a grandes bases de datos.

En el capítulo 5, se presenta una metodología basada en el análisis de componentes principales que permite realizar un diagnóstico general del sistema de almacenamiento de energía en baterías. Cabe resaltar que esta metodología es aplicada por primera vez en este campo. De igual forma, se presentan unas acciones de control plasmadas en un algoritmo que llevan a tener una respuesta más rápida que el controlador convencional. Finalmente y como producto de los resultados alcanzados, la tesis ha permitido la participación en eventos científicos y la publicación de cuatro (4) artículos de investigación, los cuales se relacionan a continuación:

- ✓ **Banguero, E.**, Correcher, A., Pérez-Navarro, Á., Morant, F., & Aristizabal, A. (2018). A review on battery charging and discharging control strategies: Application to renewable energy systems. *Energies*, 11(4), 1021.

- ✓ Ariza, H. C., **Banguero, E.**, Correcher, A., Pérez-Navarro, Á., & Morant, F. (2018). Modelling, Parameters Identification and Experimental Validation of a Lead Acid Battery Bank Using Genetic Algorithms. *Energies*, 11(9), 2361; <https://doi.org/10.3390/en11092361>
- ✓ **Banguero, E.**, Correcher, A., Pérez-Navarro, A., & García, E. (2018, October). State of health estimation of lead acid battery bank in a renewable energy system by parameter identification with genetic algorithms. In 2018 7th International Conference on Systems and Control (ICSC) (pp. 418-423). IEEE. In 2018 7th International Conference on Systems and Control (ICSC) (pp. 418-423). IEEE. DOI: 10.1109/ICoSC.2018.8587801
- ✓ **Banguero, E.**, Correcher, A., Pérez-Navarro, Á., García, E., & Aristizabal, A. (2020). Diagnosis of a battery energy storage system based on principal component analysis. *Renewable Energy*, 146, 2438-2449. doi: <https://doi.org/10.1016/j.renene.2019.08.064>.

Capítulo 2

2. UNA REVISIÓN SOBRE LAS ESTRATEGIAS DE CONTROL DE CARGA Y DESCARGA DE BATERÍAS: APLICACIÓN A SISTEMAS DE ENERGÍA RENOVABLE

La electrificación de áreas aisladas remotas y rurales con la red nacional no siempre es posible, ya que, tiene un costo prohibitivo. Por lo tanto, muchas comunidades fuera de la red se ven en la necesidad de usar generadores diésel como su principal fuente de energía. Para satisfacer las necesidades energéticas de estas comunidades aisladas, los gobiernos han optado por instalar conjuntos de energías renovables independientes con sistema de almacenamiento de energía en batería (BESS, por sus siglas en inglés) [5]. Sin embargo, el almacenamiento de energía es uno de los mayores desafíos para los sistemas de energía renovable, especialmente en sistemas fotovoltaicos independientes y parques eólicos, donde han demostrado ser muy confiables debido a su eficiencia y alto tiempo de respuesta [6, 7]. En una instalación basada en energías renovables el BESS representa el 40% del costo total del sistema [8, 9].

Según el tiempo necesario para almacenar energía, las tecnologías se clasifican en (ver **Figura 2.1**): instantáneas (pocos segundos), a corto plazo (pocos minutos), a medio plazo (pocas horas) y a largo plazo (días) [5, 10].




Figura 2.1. Campo de aplicación de las diferentes técnicas de almacenamiento según la energía almacenada y la potencia de salida [11].

Además del BESS existen diferentes tipos de tecnologías de almacenamiento de energía [10-19] (ver **Figura 2.2**). Dentro de las cuales se mencionan las siguientes: almacenamiento de energía por hidro-bombeo (PHES, por sus siglas en inglés), almacenamiento de energía mediante aire comprimido (CAES, por sus siglas en inglés), almacenamiento de energía del volante (FES, por sus siglas en inglés), almacenamiento de energía a base de hidrógeno (HES, por sus siglas en inglés), almacenamiento de energía por baterías de flujo (FBES, por sus siglas en inglés), almacenamiento de energía magnética por superconducción (SMES, por sus siglas en inglés) y almacenamiento de energía en supercapacitores (SES, por sus siglas en inglés).

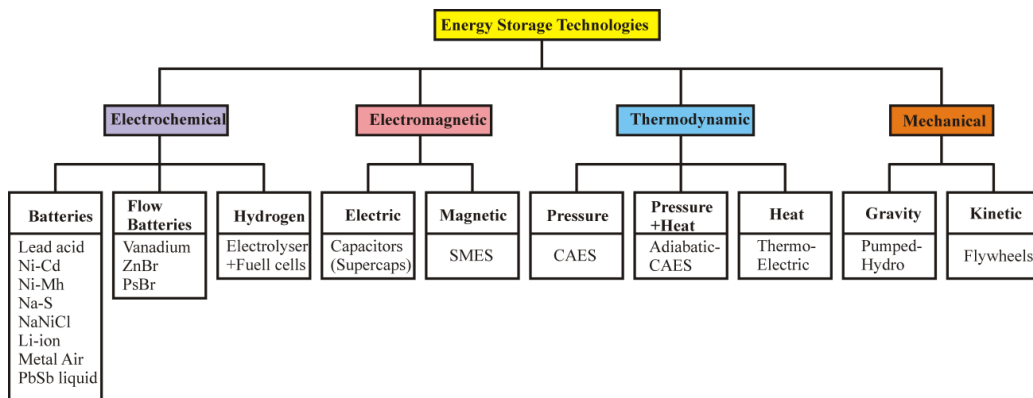


Figura 2.2. Tecnologías de almacenamiento de energía.

Sin embargo, debido a su flexibilidad, eficiencia, escalabilidad y otras características atractivas [20], el BESS es la tecnología más usada [21] (ver **Figura 2.3**).

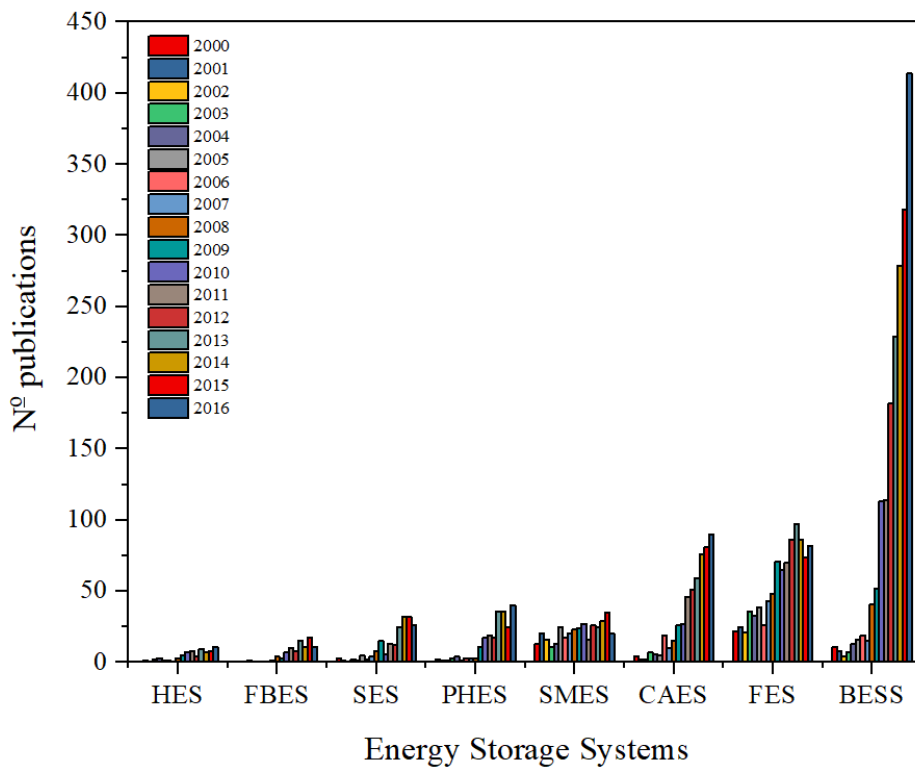


Figura 2.3. Sistemas de almacenamiento de energía, (ESS, por sus siglas en inglés).

En la actualidad, existen varios tipos de baterías comerciales utilizadas en los sistemas de energía renovable (RES, por sus siglas en inglés) como las baterías de plomo-ácido, ión litio (Li-Ion), níquel-cadmio (Ni-Cd) y sodio-azufre (Na-S), entre otras. La **Tabla 2.1**, muestra las características principales de estos tipos de baterías [12, 14-18, 22-27].

Tabla 2.1. Tecnologías de baterías usadas en sistemas de energías renovables (RES). Pb-acid: plomo-ácido; Li-Ion: ion litio; Ni-Cd: níquel-cadmio; Na-S: sodio-azufre; PSB: batería de polisulfuro-bromuro; VRB: batería de redox de vanadio.

Technology	Pb-Acid	Li-Ion	Ni-Cd	Na-S	PSB	VRB
Capital cost (\$/kWh)	50-400	600-2500	400-2400	200-600	150-1000	150-1000
Efficiency (%)	70-90	75-95	60-70	71-90	60-75	65-85
Operating temperature ($^{\circ}$ C)	-5 to 40	-30 to 60	-40 to 50	325	0 to 40	0 to 40
Depth of discharge (%-DOD)	60-70	80	100	60-100	75	75
Energy density (Wh/kg)	30-50	75-250	50-75	100-240	>400	10-75
Life cycles (cycles)	500-2000	1000-10000	1000-3500	2000-5000	100-13000	12000+
Lifetime (years)	3-15	5-20	5-20	5-20	10-15	5-20
Availability (%)	99.99	97+	99+	Up to 99.98	*****	96-99
Technological maturity level (1-lower to 5-higher)	5	4	4	4	*****	3
Response time (ms)	Fast	Fast	Fast	Fast	*****	*****
Capacity (MW)	0.001-50	0.001-50	0-50	0.05-30	0.005-120	0.005-1.5

Nota: *****: No hay datos disponibles.

Con respecto al BESS utilizado en sistemas fotovoltaicos la tecnología de plomo ácido es la más utilizada [16, 23]. Esto debido a su bajo costo, madurez, alta confiabilidad, respuesta rápida y baja tasa de autodescarga [16, 28]. Debido al alto costo económico que genera el reemplazo prematuro del BESS, se requiere de un método de control de carga y una estrategia de control adecuada que protejan la batería contra sobrecargas y sobredescargas [29, 30].

La eficiencia del método de control de carga dependerá de la cantidad de corriente utilizada, el nivel de las oscilaciones en la corriente de carga, los niveles de voltaje, el tiempo y las fluctuaciones de la temperatura [31]. Sin embargo, hay parámetros de la batería que debido a su complejidad no se pueden obtener utilizando métodos de control convencionales.

Las nuevas tendencias de investigación en almacenamiento de energía incluyen baterías de iones de litio, especialmente las de litio ferroso (LiFePO_4). Esta tecnología tiene mayores ventajas frente a la tecnología de plomo ácido en cuanto a densidad de energía, voltaje, vida útil y velocidad de carga y descarga. Sin embargo, hoy en día la mayoría de las instalaciones renovables incluyen baterías de plomo-ácido y exigen nuevos métodos de control para mejorar la vida útil del sistema. Por lo que, este documento se centrará solo en los métodos de control aplicados a este tipo de tecnología de almacenamiento de energía.

Con respecto a los sistemas de gestión de la batería, la investigación se centra en mostrar las bondades que tienen el FLC y el MPC frente a los métodos de control clásicos, teniendo en cuenta sus roles principales en el control de la batería (ver **Figura 2.4**). Donde la energía de entrada puede ser suministrada por la red eléctrica,

por lo que no se requiere de un sistema solar fotovoltaico o un sistema de energía eólica.

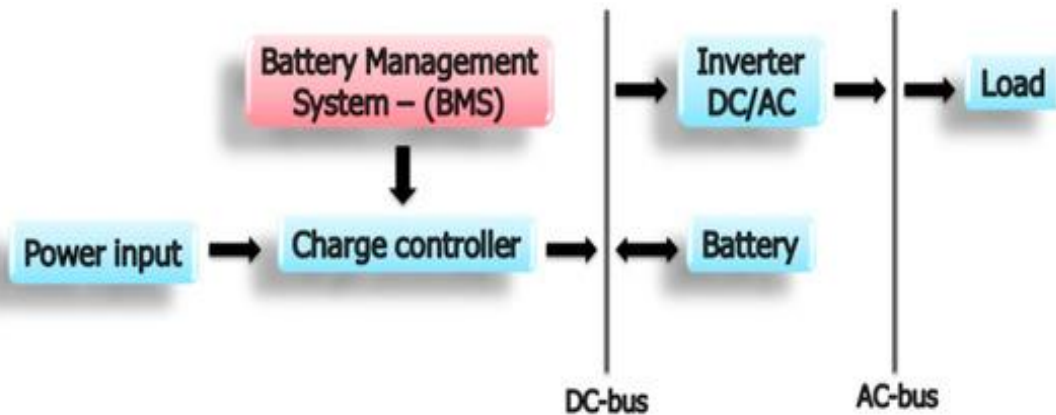


Figura 2.4. Esquema de control de la batería.

Se ha demostrado que en términos de gestión de energía, el FLC y el MPC tienen un mayor rendimiento que los métodos tradicionales de control de carga, lo que mejora el tiempo de carga, la eficiencia de carga, el SOC y la vida útil de la batería. Las estrategias utilizadas, los objetivos y los resultados alcanzados con estos controles, se describen más adelante. En términos generales, las variables de entrada utilizadas en un FLC y MPC son: el voltaje, la temperatura de la batería, el SOC, los precios de la energía, la potencia del sistema fotovoltaico, el pronóstico del tiempo, entre otros. La corriente, la potencia del ESS y la potencia de la red, se utilizan como variables de salida.

2.1.MÉTODOS TRADICIONALES DE CONTROL DE CARGA

El objetivo principal de los métodos de control de carga es aumentar el SOC. Sin embargo, las especificaciones como el rendimiento de la batería, el tiempo de carga, la protección de la batería contra la sobrecarga o la sobredescarga y el aumento de la vida útil también son variables importantes que deben ser investigadas. Por lo que se han desarrollado diferentes métodos para controlar de manera efectiva la carga de la batería. Los métodos de control comúnmente utilizados en la carga de la batería son: corriente constante (CC, por sus siglas en inglés), voltaje constante (CV, por sus siglas en inglés), carga en dos pasos (es decir, CC – CV), carga por pulsos (PC, por sus siglas en inglés), carga por reflejo o carga por pulsos negativos (NPC, por sus siglas en inglés), carga por goteo (TC, por sus siglas en inglés) y carga flotante (FC, por sus siglas en inglés) [32-35].

2.1.1. Corriente constante (CC)

Este método consiste en cargar la batería con una corriente constante. El CC limita la corriente para evitar la sobrecorriente de la carga inicial [36]. El valor del voltaje dependerá de la corriente de carga, y una de sus ventajas es el fácil cálculo del tiempo de carga y el SOC [37]. Sin embargo, como el voltaje generalmente no se controla, esto puede causar una sobrecarga de la batería y un aumento de la temperatura lo que resulta en una degradación de la vida útil de la batería [32, 34].

2.1.2. Voltaje constante (CV)

Este método se usa principalmente para cargar la batería mediante la aplicación de un voltaje constante en sus terminales. Durante la etapa inicial de carga la corriente de carga es alta. A medida que el voltaje de la batería alcanza el límite la corriente de carga disminuye [34]. Este tipo de control se usa en aplicaciones que requieren períodos de carga prolongados para alcanzar la carga completa. Debido a que este método requiere un tiempo de carga prolongado podría causar un aumento de la temperatura y una degradación de la vida útil de la batería.

2.1.3. Corriente constante – voltaje constante (CC – CV)

Este método de carga también se conoce como el método de dos pasos porque combina CC y CV. El CC se aplica en la etapa de carga inicial hasta que el voltaje de la batería alcanza una etapa de sobrecarga o un voltaje predefinido [38]. En una segunda etapa, el método de carga cambia a CV para mantener el voltaje de la batería de modo que evite la sobretensión [32, 37].

Investigaciones anteriores han mostrado que el método de carga CC - CV es el más eficiente para cargar la batería independientemente del tipo de batería [30, 39], lo que lo convierte en el método de control más utilizado [30, 40, 41]. Sin embargo, su velocidad de carga y su eficiencia son muy bajas [42]. Además, el método CC - CV no es adecuado para una carga rápida, ya que la etapa de carga de CV prolonga el tiempo de carga lo que provoca un aumento de la temperatura de la batería y una reducción del ciclo de vida de la batería [43-45].

2.1.4. Carga por pulsos (PC)

Este método de carga consiste en aplicar periódicamente una corriente pulsada a la batería. Las baterías se descargan completamente y se recargan periódicamente en lo que se denomina una carga de compensación [46]. Esto permitirá que el voltaje de la batería sea más estable. En este método de carga es importante tener en cuenta la

frecuencia de carga, el pico de pulso y el ancho del pulso, ya que están relacionados con la capacidad y el tiempo de carga. Este método puede reducir la polarización para evitar el aumento de la temperatura de la batería [36]. El punto débil de este método de carga es su complejidad.

2.1.5. Carga de pulso negativo (NPC)

Esta es una mejora del método PC. El concepto de aplicar la carga de pulso negativo comenzó con las patentes de W. Burkett y J. Bigbee y W. Burkett y R. Jackson [37, 47] en 1971. El NPC sigue esta secuencia de carga: un pulso de carga positivo, un período de descanso (no cargando), y un pulso de descarga [47]. Al igual que el método PC podría eliminar la polarización de modo que evita el aumento de la temperatura. Sin embargo, también puede reducir la eficiencia de carga [48, 49].

2.1.6. Carga de goteo (TC)

Este método consiste en proporcionar a la batería una carga de CC continua a una tasa baja (aproximadamente $C/100$) [50], y está diseñado para compensar la autodescarga de la batería [46]. Este método puede cargar la batería hasta el 100% usando una corriente de carga muy pequeña. Normalmente se usa para aplicaciones de batería de arranque, iluminación o encendido (SLI, por sus siglas en inglés), pero no es adecuado para baterías que pueden dañarse por sobrecarga.

2.1.7. Carga Flotante (FC)

Este método implica una carga de CV suficiente para finalizar la carga de la batería o para mantener la carga completa de la batería [51, 52]. El FC se utiliza para baterías estacionarias, principalmente baterías de plomo-ácido [46].

Estos métodos tradicionales de control de carga, han sido incorporados en inversores comerciales como Victron Energy, Sunny Island, entre otros. Este último controla la carga de la batería en tres fases: fase CC (fase I/fase bulk), fase CV (fase de absorción/fase V_o) y carga de mantenimiento o carga flotante/fase V (ver **Figura 2.5**).




Figura 2.5. Fases de carga del inversor Sunny Island TM para una batería AGM, (en inglés, Absorbed Glass Material) [53].

2.2.SISTEMAS DE GESTIÓN DE BATERÍA

Debido a que el proceso de carga y descarga de la batería es complejo, se requiere del diseño de un control de supervisión robusto sobre el controlador clásico presentado en la Sección 2 .

FLC y MPC son especialmente adecuados para la gestión de la carga de la batería porque no requieren un conocimiento preciso de los modelos matemáticos del sistema y tienen una gran flexibilidad.

2.2.1. Control de lógica difusa (FLC)

En 1965, Lotfi Zadeh propuso por primera vez la teoría difusa [54]. Entre las aplicaciones de la lógica difusa, el control difuso (FC, por sus siglas en inglés) ha sido uno de los campos donde las técnicas difusas han obtenido mayores éxitos trabajando con sistemas complejos no lineales o incluso no analíticos [55, 56]. El FLC está compuesto por una base de conocimientos donde sus parámetros pueden determinarse sin un modelo exacto del sistema [57-59].

La estructura básica de un FLC se muestra en la **Figura 2.6** , y consta principalmente de cuatro partes: fuzzificación, donde los datos de entrada se convierten en valores lingüísticos adecuados [60]; una base de conocimiento conformada por una base de datos con las definiciones lingüísticas necesarias y el conjunto de reglas de control, que proporciona el conocimiento que ayuda a controlar el sistema [60, 61]; una toma

de decisiones que simula un proceso de decisión humano, infiere la acción de control difuso a partir del conocimiento de las reglas de control y las definiciones de variables lingüísticas [60]; una defusificación que produce una acción de control no difusa a partir de una acción de control difusa inferida [60, 62].

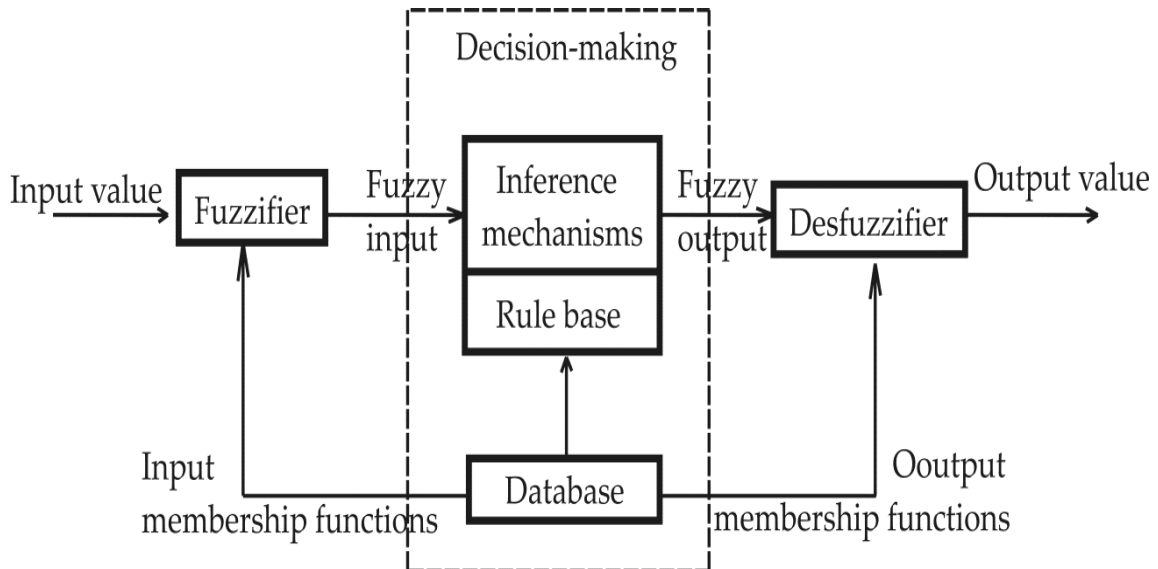


Figura 2.6. Estructura de un FLC [63].

2.2.2. Control de lógica difusa de los sistemas de almacenamiento de energía en aplicaciones independientes

Un método de FLC fue desarrollado por Bandara et al. [31] para cargar una batería de plomo-ácido. El FLC carga la batería en dos etapas. En la primera etapa utilizan una corriente alta que les permite alcanzar el 70% de la capacidad total de la batería. En la segunda etapa el voltaje de la batería se mantiene en un valor constante mientras que la corriente disminuye exponencialmente [31]. Rahim et al. [64] desarrolló un cargador de batería con un procesador de señal digital (DSP, por sus siglas en inglés), que incluía al FLC como un algoritmo de control. Este enfoque produjo una corriente de carga más alta admitiendo suministros de entrada más altos. Por lo tanto, el tiempo de carga se pudo reducir.

Huang et al. [65] utilizó un procesador de cristal como controlador básico y un DSP para obtener los voltajes, la corriente y la temperatura de las baterías [66]. Este enfoque les permitió bajar la temperatura de la batería en aproximadamente 4° C. Kim et al. [67] propuso un controlador proporcional, integral y derivativo difuso (PID, por sus siglas en inglés) para mejorar el rendimiento del control de frecuencia de una microrred aislada. La estrategia de control consistió primero en controlar el BESS y en segundo lugar controlar el sistema de gestión de la energía [68]. El control está compuesto por un FLC y un controlador proporcional integral (PI, por sus siglas en inglés) convencional conectado en serie [67]. Las ganancias del controlador PI convencional y del controlador PID difuso se determinaron mediante el algoritmo de optimización por enjambre de partículas (PSO, por sus siglas en inglés). La simulación mostró que al

utilizar el controlador propuesto, se mejoró el rendimiento en comparación con un PI convencional.

Welch et al. [69] mostró que utilizar el algoritmo PSO con un FLC optimizado puede maximizar la energía del sistema y mantener un SOC de la batería más alto. La estrategia de carga mejoró aproximadamente en un 5,22% en relación con lo presentado en [70]. Wang et al. [71] observó que al utilizar un microcontrolador PIC6014 como núcleo de control en el diseño del FLC el tiempo de carga de la batería se reduce en dos horas en comparación con el método de control de tres etapas. Según Swathika et al. [61], utilizando un FLC el voltaje de la batería se puede controlar de manera más eficiente que con un controlador tradicional. Además, el error cuadrado integral (ISE, por sus siglas en inglés), el error absoluto integral (IAE, por sus siglas en inglés) y el tiempo se pueden reducir considerablemente en comparación con un control PI. Igual que en [69], Safari et al. [72] desarrolla un FLC optimizado basado en el algoritmo PSO. En el diseño de control se tomaron en cuenta los costos de operación y mantenimiento y la probabilidad de pérdida de suministro de energía. Los resultados de la simulación mostraron que el FLC optimizado reduce las fluctuaciones en el SOC y extiende la esperanza de vida de la batería. Además, puede reducir los costos operativos y de mantenimiento y la pérdida de suministro de energía en un 57% y 33%, respectivamente. Además, el SOC puede incrementarse en un 6.18%, reduciendo el coste de inversión de la capacidad hasta un 18% de los equipos del sistema de energía autónomo; mejorando lo presentado en [69]. Berrazouane et al. [73] adopta la idea de un FLC optimizado pero a diferencia de [69, 72], usa el algoritmo de búsqueda de cuco (CS, por sus siglas en inglés) para ajustar la forma de las funciones de membresía del sistema FLC y lograr un mejor rendimiento. Al igual que con el FLC basado en PSO, el control propuesto redujo la pérdida de suministro de energía, el exceso de energía y el costo de energía [73].

2.2.3. Control de lógica difusa de sistemas de almacenamiento de energía en aplicaciones conectadas a la red

El FLC ha demostrado ser un método muy eficiente en la gestión de la energía de una microrred con sistema de almacenamiento de energía, ya que garantiza el funcionamiento continuo de la carga a través de los recursos de energía de la microrred mejorando la vida útil de las baterías [74]. Yin et al. [75] dividió el proceso de carga en dos etapas. En la primera etapa implementaron un FLC para determinar el tiempo de inicio de carga y para evitar la sobrecarga o la carga insuficiente de la batería. En la segunda etapa utilizaron el método de carga clásico. Sin embargo, durante la simulación la variable de temperatura no fue tomada en cuenta.

Contrariamente a [67], Haoran et al. [68] tomó en cuenta el SOC del BESS como una entrada al FLC donde FLC ajusta la salida de potencia activa del BESS y el flujo de potencia activa de la microrred. Arcos-Aviles et al. [76] divide su estrategia en dos etapas: en la primera minimiza los picos de potencia y las fluctuaciones en el perfil de potencia de la red y mantiene el SOC de la batería de plomo-ácido por encima del 70%. En la segunda realiza un proceso de optimización fuera de línea (Offline) basado en un conjunto de criterios de calidad de evaluación [76]. Con esa estrategia el control propuesto redujo la potencia máxima y mínima de la red en un 61% y 15%, respectivamente; y 53% y 4%, respectivamente con respecto al FLC del sistema de gestión de la energía basado en una microrred. La estrategia propuesta por Derrouazin et

al. [77] llevó a un uso óptimo de los recursos de energía disponibles más allá de un umbral para soportar la demanda de carga dando prioridad a la fuente de energía más alta, mientras que la energía disponible se enviaba directamente a la batería a través de un sistema regulador de carga/descarga. Esto les permitió mejorar la eficiencia energética en aproximadamente un 7% en comparación con el FLC clásico. Paliwal et al. [78] reveló que la incorporación de la eficiencia de carga de la batería como función del SOC de la batería ofrece un enfoque más práctico para la planificación del sistema. En esta investigación los autores concluyen que asumir un valor constante de eficiencia puede llevar a un impedimento que les permita garantizar un rendimiento óptimo del sistema, ya que la eficiencia de carga obtenida será mayor o menor que el valor supuesto que afecta la potencia de carga extraída por el sistema de almacenamiento de energía. Teo et al. [79] diseñó un control basado en el sistema de inferencia difusa (FIS, por sus siglas en inglés) para determinar la velocidad de carga/descarga y el SOC actual de un sistema de almacenamiento de energía donde la calidad de la energía (PQ, por sus siglas en inglés), el rango de variación de energía (PVR, por sus siglas en inglés) y el rango dinámico de la batería (BDR, por sus siglas en inglés) se utilizaron como índices de calidad [68], reduciendo así la potencia máxima y mínima de la red. Hussain et al. [80] propuso una estrategia de control donde el controlador decide el modo de operación del BESS (modo subordinado, modo resiliente o modo de emergencia). En el modo subordinado el BESS está controlado por el sistema de gestión de energía, y el modo resiliente minimiza el costo operacional de la microrred. El objetivo de la operación en modo de emergencia era reducir el shedding de carga durante el período de emergencia. Respecto a este último, el shedding de la carga puede reducirse en un 92%.

2.2.4. Modelo de control predictivo (MPC)

El modelo de control predictivo (MPC) es un método de control que proporciona la secuencia de variables de control óptimo en un horizonte de tiempo finito al resolver un problema de optimización [81, 82]. Por lo tanto, es ampliamente utilizado en muchos campos [83-89].

La **Figura 2.7**, muestra el principio general del MPC.




Figura 2.7. Principio de un MPC [90].

La función de costo o función objetivo se da como [91, 92]:

$$J_N = \sum_{k=0}^N \lambda(k)c(t+k)T \left[P_{grid}(t+k) - P_{ref}(t+k) \right] + c_{soc}(t+N+1)E_{ES}(t+N+1) \quad (1)$$

Donde, $\lambda(k)$ es una secuencia de ponderación, $c(t+k)$ es el costo de desequilibrio al instante $(t+k)$, T Es el periodo de muestreo del MPC, $P_{grid}(t+k)$ es la potencia suministrada a la red en $(t+k)$, $P_{ref}(t+k)$ es el futuro la producción de energía constante por horas entregada por el sistema fotovoltaico, $c_{soc}(t+N+1)$ es el valor de la energía almacenada en el BESS al instante $(t+N+1)$ y $E_{ES}(t+N+1)$ es la energía almacenada en el BESS al instante $(t+N+1)$.

La energía almacenada en el BESS en cualquier instante futuro $E_{ES}(t+k)$ puede ser calculado como:

$$E_{ES}(t+k) = E_{ES}(t+k-1) - TP_{ES}(t+k-1) \quad (2)$$

2.2.5. Modelo de control predictivo de sistemas de almacenamiento de energía en aplicaciones independientes

Pérez et al. [91] diseñó un control que anticipa las futuras saturaciones del ESS. El MPC permitió que el sistema redujera su producción de energía durante las primeras horas [91]. Para obtener el rendimiento óptimo de la batería, Pezeshki et al. [93] se centró en dos objetivos: costo operacional de la energía y carga suave.

Basado en un modelo de control predictivo no lineal (NMPC, por sus siglas en inglés), Dizqah et al. [94] desarrolló una estrategia de gestión de la energía que controla el flujo de energía a través de una microrred de corriente continua (DC, por sus siglas en inglés). El NMPC resuelve un problema de control encontrando los valores óptimos para el ángulo de inclinación [94]. El control tenía tres objetivos principales: la regulación del nivel de voltaje, el sistema de gestión de la batería (BMS, por sus siglas en inglés) y la distribución proporcional de potencia reactiva [94]. Morstyn et al. [95] utilizó una formulación convexa del problema de flujo de potencia óptimo dinámico de la microrred DC. La propuesta se basó en un modelo de corriente constante y aproximaciones de flujo de potencia lineal. Las simulaciones se realizaron en un simulador digital en tiempo real (RTDS, por sus siglas en inglés) que utilizaba modelos de baterías no lineales y modelos de convertidores de conmutación. El MPC convexo proporciona un entorno para generar valores aproximados razonables basados en el estado de funcionamiento de la microrred lo que permite la reducción del tiempo de cálculo en un factor de 1000 [96]. Además de las restricciones adicionales al MPC para mantener el voltaje de la batería por debajo del umbral superior, el nivel de voltaje proporcionado por el fabricante hace que el MPC disminuya la corriente de carga [97]. Sin embargo, esto genera una carga más lenta en comparación con el MPC tradicional. Zeng et al. [98] propuso combinar un MPC con una optimización jerárquica para aumentar la producción de la generación del sistema de energía renovable y disminuir las fluctuaciones entre los horarios intradía y el horario diario [98]. Li et al. [99] presentó un MPC para mitigar la intermitencia de la energía eólica. El control propuesto tuvo en cuenta dos características: la suavidad en la programación de la energía eólica y la pérdida de eficiencia del BESS [99].

2.2.6. Modelo de control predictivo de sistemas de almacenamiento de energía en aplicaciones conectadas a la red

Un sistema de control basado en MPC fue propuesto por Khalid et al. [100] para regular la frecuencia primaria del BESS que permita mantener una operación confiable. A través de un predictor de frecuencia optimizaron el rendimiento del controlador utilizando predicciones de múltiples pasos [101] presentando así dos escenarios: en el primer escenario la operación del BESS se ajustó entre 40% y 80%; y en el segundo se ajustó el BESS entre 10% y 50%. En el primer caso el SOC máximo de la batería se alcanzó en aproximadamente 17 min, mientras que el SOC mínimo de la batería se alcanzó en aproximadamente 70 min. En el segundo caso el SOC máximo de la batería se alcanzó a los 80 min, mientras que el mínimo se alcanzó a los 12 min. De otro lado, Ferrarini et al. [82] desarrolló un MPC para almacenar la energía necesaria para un edificio, y entregarla cuando la carga del edificio lo requiere en lugar de comprarla de la

red. En esta investigación diseñaron dos controles MPC: Un MPC para gestionar la energía del edificio y otro MPC para gestionar la energía de la batería. El objetivo del primero era optimizar el control de la temperatura, mientras que el segundo, tenía como objetivo minimizar el flujo de energía en el punto de acoplamiento común (PCC, por sus siglas en inglés). El flujo de energía del PCC se mantuvo con éxito alrededor del 50% hasta que la batería alcanzó un SOC del 90%. Wang et al. [102] usó un MPC para optimizar y distribuir el almacenamiento de energía de un proyecto en Nuevo México. El BESS se dividió en dos unidades: una unidad grande y de carga lenta para el cambio de energía; y una unidad pequeña de carga rápida para suavizar [102]. El primer objetivo fue proporcionar arbitraje de energía y suavizar la salida intermitente de la matriz fotovoltaica (PV, por sus siglas en inglés) [102]. El segundo objetivo fue reducir los ciclos de carga/descarga excesivos de las unidades del BESS [102]. Un MPC y un EMS basados en una programación de generación óptima (OGS, por sus siglas en inglés) fueron combinados para optimizar el funcionamiento a corto plazo de la microrred [103]. El OGS se utilizó para comparar la potencia esperada producida por los generadores renovables con la carga esperada demandada durante un período de tiempo. Además, definió la programación y la evolución del SOC del ESS durante unas pocas horas minimizando el costo operativo de la microrred. El MPC apunta al control en tiempo real para garantizar la estabilidad de la microrred. Se implementó un enfoque estocástico para pronosticar el clima e incertidumbres de carga. El funcionamiento simultáneo de OGS y MPC puede reducir la carga computacional como fue demostrado en [96].

Matthiss et al. [104] usó un MPC para mantener altos niveles de autoconsumo, reducir la potencia de alimentación máxima en aras de mejorar la compatibilidad de la red y minimizar los costos de energía. En este caso se implementaron cuatro algoritmos de carga de la batería: carga rápida, carga lineal diferida, reducción de picos y MPC. Además, el precio de la energía se utilizó como un parámetro adicional del proceso de optimización. Los resultados muestran que al usar un MPC, la energía eólica se mejora en un 35% y los costos de energía podrían reducirse en un 25%.

2.3.RESULTADOS Y DISCUSIÓN

Esta investigación muestra que el método de control más utilizado para cargar y descargar baterías en sistemas de energía renovable con almacenamiento de energía de batería es el CC-CV. Sin embargo, este método de control requiere mucho tiempo para cargar la batería. Esta prolongación en el tiempo de carga genera un aumento en la temperatura de la batería, por lo que puede llevar a un daño irreversible en la batería. Además, durante el proceso de carga y descarga de la batería los controles tradicionales dejan algunos aspectos sin controlar.

Para resolver estos eventos se están realizando simulaciones y pruebas experimentales con FLC y MPC. En general, estos controles se utilizan en la gestión de la energía de microrredes independientes y microrredes conectados a la red. Estos controles han demostrado ser más eficientes que un control tradicional. La **Figura 2.8**, muestra algunos resultados logrados utilizando FLC o MPC en sistemas de energía renovable con BESS. Cuando se comparan estos resultados con un control tradicional se encuentran algunas ventajas como: la desconexión liberada de ciertas

cargas de forma manual o automática como consecuencia de condiciones anormales de funcionamiento se pueden reducir hasta un 92%. Además, la implementación de estos controles permite mantener el SOC por encima del 50% evitando así, descargas profundas que lleven a una degradación de la batería. A través del uso óptimo de la energía, la potencia máxima y mínima de la red se puede reducir en un 61% y un 15%, respectivamente. Este uso racional y eficiente de la energía permite reducir los costos de energía de la microrred en un 25%. Además, la operación, mantenimiento y la pérdida de la fuente de alimentación se pueden reducir alrededor del 57% y 33%, respectivamente.

Respecto al BESS, el tiempo de carga se reduce en un 40% lo que conduce a una disminución de la temperatura de aproximadamente el 26% (ver **Figura 2.9**) y una reducción del costo de inversión en la capacidad de almacenamiento de energía de aproximadamente el 18%; por lo que se puede extender la esperanza de vida alrededor de un 5%.

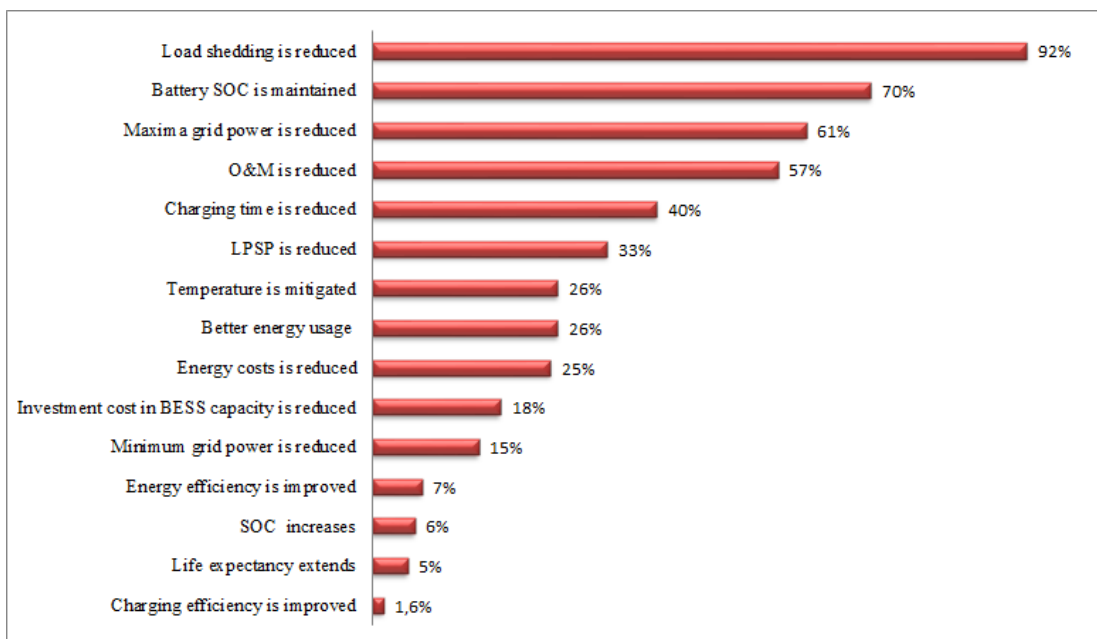


Figura 2.8. Principales ventajas del control de lógica difusa (FLC) y del modelo de control predictivo (MPC) con respecto a los métodos de control tradicionales. SOC: estado de carga; O&M: Los costos de operación y mantenimiento. Sistema de almacenamiento de energía en baterías (BESS) y LPSP: posibilidad de pérdida de suministro de energía. Elaboración propia.

A pesar de las ventajas de los controladores FLC y MPC frente a los controles tradicionales su implementación es necesaria en entornos reales con sistemas de almacenamiento de energía a gran escala, ya que muchos de los resultados se han logrado a través de simulaciones.

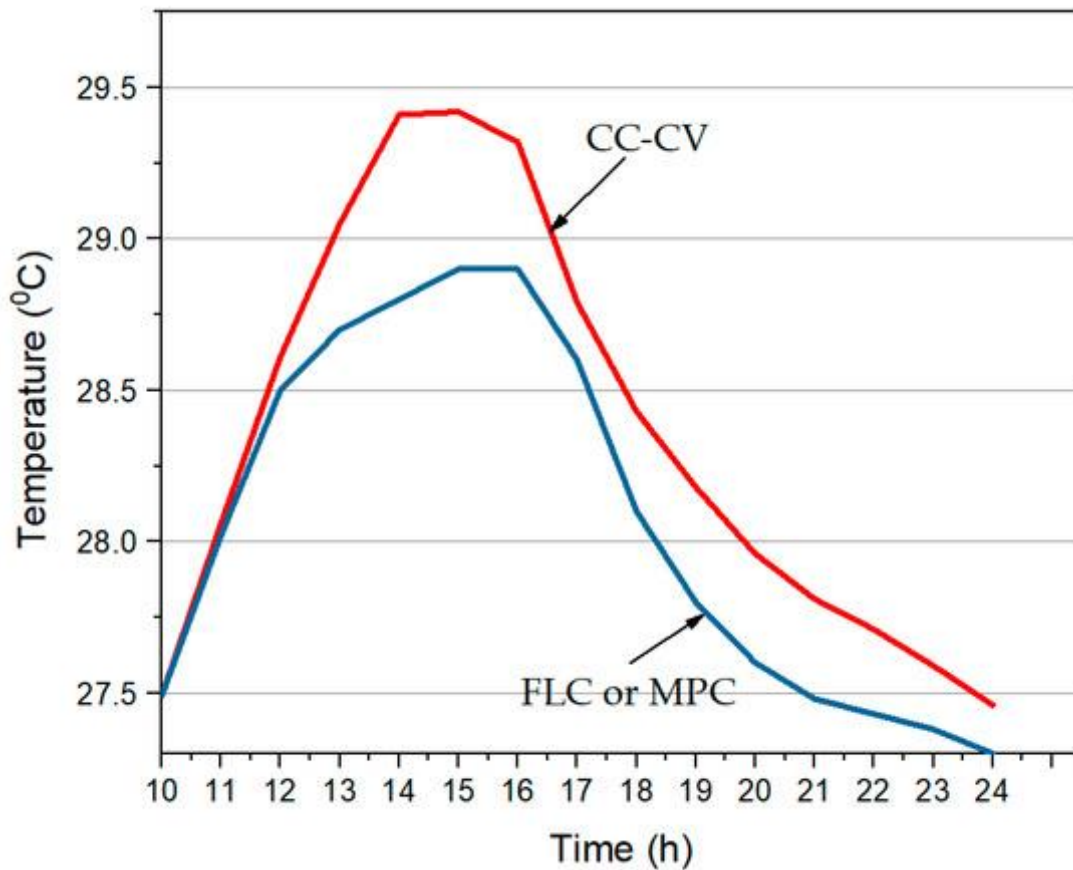


Figura 2.9. Simulación de la temperatura de la batería.

Además, las investigaciones desarrolladas anteriormente no estudiaron parámetros como el límite de SOC de la batería y la influencia de variables ambientales como la humedad relativa o la predicción del estado de salud (SOH, por sus siglas en inglés). Finalmente, estos controles también se están implementando para controlar la carga de las baterías de LiFePO_4 , como se muestra en [105-107].

2.4.CONCLUSIÓN

Los sistemas de energía renovable han sido una solución a corto plazo para mitigar las necesidades de energía en áreas aisladas donde no hay servicio de energía por interconexión eléctrica. Muchos de estos sistemas cuentan con sistemas de almacenamiento de energía en baterías para el suministro de energía en aquellas horas en las cuales no se cuenta con el recurso solar o eólico. Por lo tanto, se requiere de un método de control y una estrategia de control que permitan optimizar la gestión de la energía y eviten que el sistema de almacenamiento de energía entre en estados de sobrecarga o sobredescarga. A pesar que CC - CV es el método de control más utilizado para cargar y descargar la batería, otros métodos como el FLC o el MPC

han mostrado mejores rendimientos. Los principales beneficios son: reducción del tiempo de carga, mejora de la eficiencia de carga, mitigación del aumento de la temperatura y mantenimiento del SOC de la batería dentro de límites seguros. Además, la reducción del costo de inversión en la capacidad de almacenamiento de energía y la esperanza de vida aumenta.

La mayoría de los artículos consultados basan sus resultados en simulaciones y en algunos casos en pruebas experimentales con baterías VRLA. Por lo tanto, se necesitan más experimentos que permitan extender los resultados a sistemas reales.

La extensión a otros tipos de baterías como las baterías de plomo-ácido OPzS y las baterías LiFePO₄ también es un tema de investigación. Sin embargo, el alto costo de las baterías LiFePO₄ se convierte en una restricción para las implementaciones a gran escala en sistemas de energías renovables.

Capítulo 3

3. SIMULACIÓN, IDENTIFICACIÓN DE PARÁMETROS Y VALIDACIÓN EXPERIMENTAL DE UN BANCO DE BATERÍAS DE PLOMO ÁCIDO USANDO ALGORITMO EVOLUTIVO

Como ya se ha mencionado en el capítulo anterior, de las diferentes tecnologías existentes para el almacenamiento de energía la más utilizada es la batería [108, 109] debido a su costo, portabilidad y facilidad de reemplazo [10, 12, 15, 17, 18]. Éstas son utilizadas como fuente de alimentación de energía, ya sea para vehículos eléctricos (EV, por sus siglas en inglés), sistemas de comunicación, dispositivos eléctricos y electrónicos, sistemas de energía renovable (RES, por sus siglas en inglés), entre otros. En lo que respecta a los RES comúnmente usados en zonas aisladas llámese solar, eólico o híbrido (solar - eólico, solar - diésel, eólico - diésel, etc), generalmente cuentan con un BESS de tecnología de plomo ácido. Estas baterías a pesar de ser una tecnología madura aún sigue siendo un tema de gran interés para los investigadores como se demuestra en los estudios recientes llevados a cabo en [110-113].

Los BESS están compuestos principalmente de elementos de 2V que se conectan en serie para suministrar un voltaje de 12V, 24V o 48V.

Dada la gran importancia que tiene un BESS en un RES, se requiere de un modelado preciso y eficiente de la batería que permita maximizar el rendimiento y prolongar su vida útil. Sin embargo, debido a su naturaleza no lineal, y fenómenos asociados al envejecimiento, la corrosión, gasificación, sulfatación, estratificación del electrolito, degradación de la materia activa, shedding, entre otros, hacen que modelar el comportamiento de la batería sea un proceso complejo. Esto ha llevado a investigadores a desarrollar e implementar modelos que permitan simular el comportamiento de una batería [21, 97, 114-129].

En este orden de idea se han propuesto diferentes métodos para identificar los parámetros internos de la batería [130-137]. Siendo el más usado el modelo de batería de Copetti [38]. Sin embargo, los algoritmos evolutivos (EA, por sus siglas en inglés) han mostrado ser muy eficaces mostrando un alto rendimiento. Los EA son métodos basado en la optimización y búsqueda de soluciones [138] que imitan los procesos biológicos para resolver problemas complejos; en donde los miembros exitosos evolucionan hacia mejores soluciones. Los sujetos que representan las soluciones se denominan individuos o cromosomas que se puede agrupar en un conjunto más grande llamado población. Durante el proceso de selección se eliminan los miembros menos aptos del conjunto de la población, mientras que los miembros aptos pueden sobrevivir y continuar hasta que se determinen las mejores soluciones. Los EA tienen amplias aplicaciones en bioinformática, ingeniería, física, ciencias computacionales, matemáticas y otros campos a fines [139-143].

En la literatura se pueden encontrar algunos trabajos como el presentado por Guasch et al. [144] en donde usa el modelo de batería desarrollado por Copetti [137] y lo

mejora introduciendo dos nuevos parámetros: el nivel de energía (LOE, por sus siglas en inglés) y el estado de salud (SOH, por sus siglas en inglés).

Estos nuevos parámetros son capaces de predecir la degradación de la capacidad de la batería y el aumento de la corriente de autodescarga a largo plazo. Para ajustar el modelo aplicaron el algoritmo de Levenberg-Marquardt lo que les permitió alcanzar un error promedio de voltaje del 1%. Por su parte Blaifi et al. [145-147] propone incluir 4 parámetros que permiten estimar el efecto de gaseo y los niveles de saturación. Los resultados de la simulación mostraron que el error medio con los parámetros identificados en [137] fue de 1,49%, mientras que el error medio con la identificación del EA fue de 0,45%. Sin embargo, una desventaja de este modelo es su alto tiempo de cálculo debido a la gran cantidad de muestras requeridas para una buena identificación. Otro EA que ha despertado el interés de los investigadores y que ha sido usado en la identificación de parámetros tiene que ver con el algoritmo de búsqueda de Cuco (CS, por sus siglas en inglés) [73, 148]. En este EA, la caminata aleatoria se genera a través de los vuelos de Lévy como estrategia de búsqueda. CS se considera como un algoritmo metaheurístico moderno capaz de resolver problemas complejos de optimización con alta precisión [149-151]. CS emula el comportamiento de las aves cuco relacionadas con su estrategia agresiva de reproducción que coloniza y parasita los nidos de otra ave. El cuco elige un nido con huevos y deja su propio huevo; Si se acepta el huevo y se incuban la cría será alimentada por las aves de crianza. En CS, la probabilidad de que el huevo sea descubierto y rechazado es configurable como $Pa \in [0, 1]$. La estrategia de movimiento CS sigue los vuelos de Lévy, y cada paso tiene una distancia aleatoria y un movimiento angular condicionado por valores configurables: α ($\alpha > 0$) y λ ($\lambda \in [1, 3]$).

En este capítulo, se presenta una mejora del modelo propuesto por Copetti [137] en donde se incluyen 4 nuevos parámetros que permiten obtener un mejor ajuste de las curvas de carga y descarga del banco de baterías. Adicionalmente, se implementan 3 EA: PSO, CS y PSO+Perturbación, siendo este último una nueva propuesta para la identificación paramétrica. Los 3 EA se implementan y se comparan para obtener un modelo más preciso que permita identificar los parámetros internos de un BESS de tecnología plomo-ácido. Los modelos son implementados a través del lenguaje de programación LabView[®] (V2015, National Instruments, Austin, TX, EE. UU.). Los resultados de la simulación se validan con los datos experimentales obtenidos en el LadER del Departamento del Chocó (Colombia) [152, 153].

En la **Figura 3.1**, se presenta el esquema del sistema solar fotovoltaico instalado en el LadER del departamento del Chocó. El sistema puede operar en modo conectado a la red o en modo isla. El sistema solar fotovoltaico, está compuesto por:

- 80 módulos solares de silicio policristalino (Amerisolar ASP-6P30; 250 W, Worldwide Energy and Manufacturing USA Co., Ltd., San Francisco, CA, USA).
- Un inversor solar trifásico DC/AC de 20 kW.
- 6 inversores/cargadores SMA Sunny Island AC/DC (SMA Solar Technology AG, Kassel, Alemania).
- Una caja multicluster (220 V, 60 Hz).
- Un sistema de almacenamiento de energía en baterías compuesto de 48 acumuladores electroquímicos Techno Sun 2V-OPzS-TCH2765 divididos en dos ramas de 24 celdas conectadas en serie.
- Un sistema de adquisición de datos (Webbox) encargada de recolectar la información cada 15 minutos.

- Un computador de escritorio, donde se almacena y se visualiza toda la información obtenida del RES.

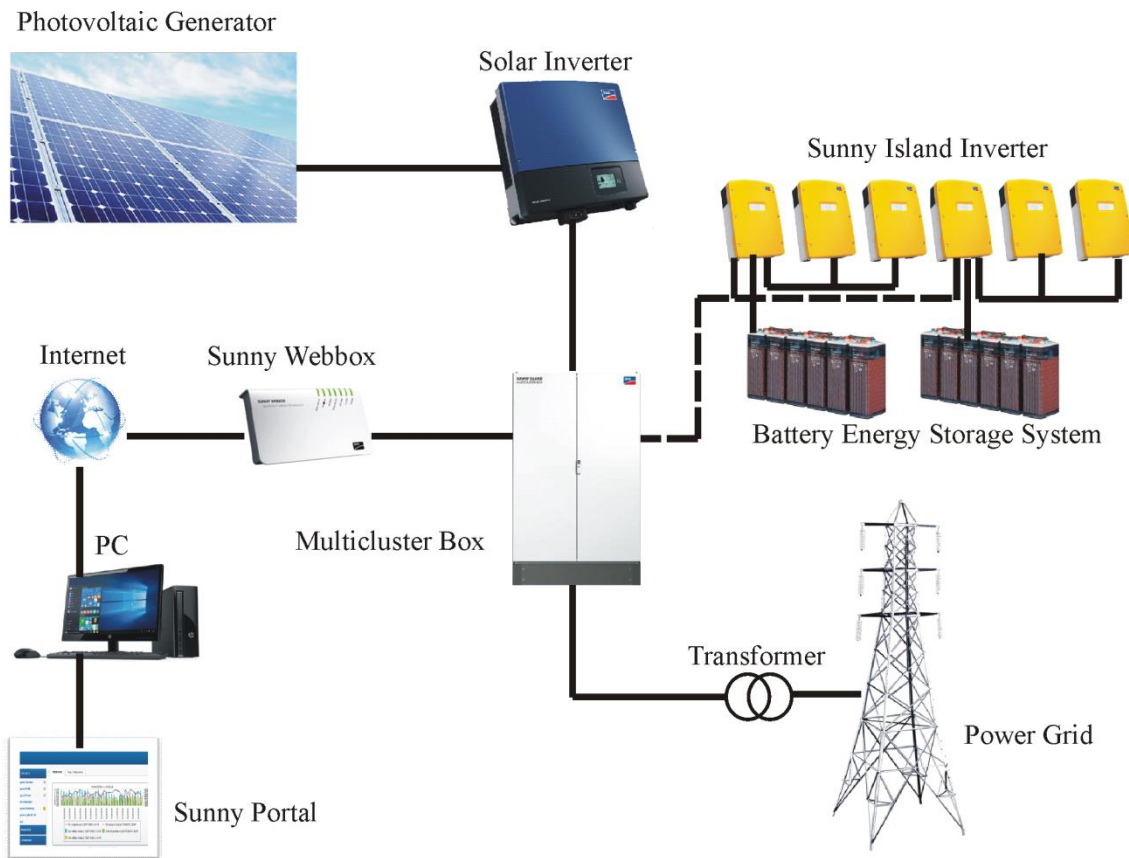


Figura 3.1. Diagrama de bloques del Sistema solar fotovoltaico instalado en el LadER en el Departamento del Chocó, Colombia.

El sistema solar fotovoltaico entró en operación desde el año 2016, y desde este tiempo se está recopilando información de las diferentes variables que se están midiendo en el LadER, así como de las variables meteorológicas de temperatura, radiación solar global, velocidad del viento, entre otras.

3.1.MODELO DE BATERÍA

El modelo Copetti [137] utilizado en esta investigación, está basado en un circuito eléctrico equivalente como el mostrado en la **Figura 3.2**, en donde V_{oc} representa el voltaje de circuito abierto entre los terminales de la batería y depende del SOC de la batería. R_i es la resistencia interna y representa todas las pérdidas durante el proceso de carga/descarga. R_i depende de la corriente (I_{bat}) y de la temperatura (T) de la batería. Además, R_i es inversamente proporcional al SOC, por lo tanto, si el SOC disminuye R_i aumenta.

Respecto a la **Figura 3.2**, el voltaje de la batería (V_{bat}) se calcula de acuerdo a la ecuación (3):

$$V_{bat} = V_{oc} \pm I_{bat} \times R_i \quad (3)$$

Donde I_{bat} es la corriente que circula a través de la batería. $I_{bat} > 0$ durante la carga, e $I_{bat} < 0$ cuando se descarga.




Figura 3.2. Modelo de batería de circuito equivalente.

V_{oc} y R_i son funciones no lineales dependientes del tiempo.

La evolución de R_i de la batería es expresada de acuerdo a la ecuación (4):

$$R_{int}(T) = \frac{n_s}{C_N} (R_1 + R_2 + R_3) (1 - \alpha_T \Delta T(t)) \quad (4)$$

En donde R_1 y R_2 representan la influencia de la corriente de carga/descarga, R_3 representa el efecto óhmico [126], n_s , el número de acumuladores electroquímicos conectados en serie, C_N es la capacidad nominal de la batería, α_T es un parámetro empírico que debe ser identificado, ΔT es la variación de la temperatura expresada como: $\Delta T = T - T_{ref}$, donde la T_{ref} es 25 °C

Por lo tanto,

$$R_{int}(T) = \frac{n_s}{C_N} \left(\frac{P_1}{1 + |I_{bat}(t)|^{P_2}} + \frac{P_3}{(1 - SOC(t))^{P_4}} + P_5 \right) (1 - \alpha_T \Delta T(t)) \quad (5)$$

Los términos P_1 , P_2 , P_3 , P_4 , y P_5 son parámetros empíricos que deben ser identificados y están relacionados con pérdidas resistivas [144-146].

3.2. ESTADO DE CARGA DE LA BATERÍA

El SOC se entiende como la fracción o el porcentaje de la capacidad total del acumulador que todavía está disponible en la batería y que puede ser entregada al sistema del cual forma parte [154-157]. El SOC se obtiene mediante la adición de amperios entrantes y salientes desde y hacia la batería en relación con su capacidad instantánea [145]. El SOC se relaciona con otras magnitudes de los acumuladores, en particular con V_{oc} , con la densidad del electrolito y con R_i [154]. Sin embargo, hacer una estimación precisa del SOC se ha convertido en un gran desafío para los académicos e investigadores. Además, la complejidad del cálculo y el alto costo de computación son las otras preocupaciones que hacen que el proceso de estimación sea muy difícil [156, 157]. Una estimación precisa y eficiente del SOC da una idea acerca de las estrategias de carga/descarga que se deben abordar las cuales tienen un impacto significativo en la aplicación de la batería [157].

3.2.1. Métodos de estimación del SOC

Teniendo en cuenta la importancia que tiene el SOC en sistemas que utilizan almacenamiento de energía en batería, académicos, investigadores y científicos de todo el mundo, han desarrollado diferentes métodos de estimación del SOC [155-164] los cuales son mostrados en la **Tabla 3.1**.

Tabla 3.1. Ventajas y desventajas de los métodos de estimación existentes de SOC.

Métodos de estimación del SOC		
Método	Ventajas	Desventajas
Conteo de Coulomb	Fácil de usar y rápido para el cálculo.	Es una estimación de bucle abierto, y puede tener un gran error acumulado debido a incertidumbres o perturbaciones, sensible a la precisión actual del sensor y requiere un valor preciso del SOC inicial.
Voltaje de circuito abierto	Fácil de usar y rápido para el cálculo.	Bucle abierto, sensible a la precisión del sensor de voltaje, inadecuado para baterías con curvas planas de Voc, sensible a la temperatura, baja dinámica y requiere de mucho tiempo.
Red neuronal	Genérico, buena aproximación de mapeo no lineal.	Sensible a la cantidad y calidad de los datos de entrenamiento.
Lógica difusa	Genérico, buena aproximación de mapeo no lineal.	Sensible a la cantidad y calidad de los datos de entrenamiento.
Máquina de vectores de soporte	Genérico, buena cartografía no lineal.	Sensible a la cantidad y calidad de los datos de entrenamiento.
Filtro de Kalman	Bucle cerrado, en línea, precisión.	Es más costoso desde el punto de vista de la computación que los métodos sin retroalimentación y depende en gran medida de la precisión del modelo.
Observador de modo deslizante	Bucle cerrado, en línea y preciso.	Es más costoso desde el punto de vista de la computación que los métodos sin retroalimentación y depende en gran medida de la precisión del modelo.
Prueba de descarga	Fácil, preciso e independiente del SOH.	Fuera de línea, requiere de mucho tiempo, modifica el SOC de la batería y genera pérdida de energía.
Espectrometría de impedancia eléctrica.	Fácil de implementar, posibilidad de medir en línea, y da información sobre el SOH.	Sensible a la temperatura y a la frecuencia (requiere de una alta frecuencia), coste intensivo.
Resistencia interna DC	Posibilidad de medición en línea, económico, da información sobre el SOH, fácil.	Buena precisión pero solo para SOC bajos.
Modelo lineal	Fácil, en línea.	Necesita datos de referencia para ajustar los parámetros.
Propiedades físicas del electrolito (densidad, concentración, color)	En línea, da información acerca del SOH.	Error en caso de estratificación ácida, la pérdida de agua, baja dinámica, problemas de estabilidad a largo plazo de los sensores, sensible a la temperatura y las impurezas.

El SOC de la batería puede ser calculado por la ecuación (6):

$$SOC(t) = SOC_0 - \frac{1}{C(t)} \int_0^t \eta_c(t) \times I(t) dt \quad (6)$$

Siendo SOC₀: el estado de carga inicial de la batería. C (t): la capacidad instantánea de la batería. I (t): corriente de la batería.

El rango de valores aplicables es $0 \leq SOC(t) \leq 1$.

De donde,

$$\eta_c = 1 - \exp \left(\frac{a_{cmt}}{\left(\frac{I}{I_N} + b_{cmt} \right)} (SOC(t) - 1) \right) \quad (7)$$

Donde η_c es la eficiencia de carga coulombica y se tiene en cuenta en el caso del modo de carga. Ésta depende en gran medida de la tasa de carga. Su valor es cercano a 1 para corrientes de baja carga y bajo SOC [165]. Sin embargo, cuando se alcanza una carga completa la eficiencia de Coulomb disminuirá a cero [145].

Por lo tanto, su representación discreta está dada por la ecuación (8):

$$SOC(k+1) = k_{soc} \times \left[k_I \times \Delta t \left(\frac{I(k+1) - I(k)}{2} + I(k) \right) \times \frac{k_{c_bat}}{C(t)} \right] \quad (8)$$

Donde k_{soc} es un factor de ganancia asociada al SOC, k_I se relaciona con la eficiencia de coulomb, Δt es el período de muestreo y k_{c_bat} es un parámetro asociado al envejecimiento de la batería. Esta ecuación incluye nuevos parámetros (k_{c10} , k_{soc} , k_I , k_{c_bat}) para encontrar un mejor ajuste. Estos parámetros tienen un valor inicial de 1.

La capacidad de la batería ($C(t)$) y la corriente nominal (I_N) es calculada con la ecuación (9) y (10), respectivamente:

$$C(t) = \frac{C_N \times C_{icoef} \times k_{c10}}{1 + A_{cap} \left(\frac{|I(t)|}{I_N} \right)^{B_{cap}}} (1 + \alpha_c \Delta T + \beta_c \Delta T^2) \quad (9)$$

$$I_N = \frac{C_N}{m} \quad (10)$$

Una vez establecido el valor inicial del SOC la evolución de la batería se evalúa en función de la zona de trabajo (carga, sobrecarga, saturación, descarga, sobredescarga o agotamiento), y la temperatura T las cuales son representadas en la **Figura 3.3**.




Figura 3.3. Zonas de trabajo de la batería: evolución del voltaje de la batería (V_{bat}) en función de la corriente.

La descripción de las zonas de trabajo de la batería, son presentadas en la **Tabla 3.2**.

Tabla 3.2. Descripción de las zonas de trabajo de una batería [144].

Tensión de la batería (V_{bat})	Zona de trabajo	Condiciones de trabajo	
V_{sc}	Saturación	$I_{bat} > 0$	$V_{bat} = V_{ec}$
	Sobrecarga		$V_{ec} \geq V_{bat} \geq V_g$
V_c	Carga	$I_{bat} \approx 0$	$V_{bat} < V_g$
V_{cdc}	Transición carga/descarga		$V_c \geq V_{bat} \geq V_{dc}$
V_{dc}	Descarga	$I_{bat} < 0$	$V_{bat} > 0.9V_N$
	Sobrecarga		$0.9V_N \geq V_{bat} \geq 0.7V_N$
	Agotamiento		$V_{bat} < 0.7V_N$

3.2.2. Zona de carga, sobrecarga y saturación

3.2.2.1.Zona de carga

Cuando hay demasiada energía en el sistema la batería se ubica en esta zona absorbiendo esta energía, lo cual provoca un aumento de voltaje y SOC tal como se describe en la ecuación (11).

El primer término representa la variación del voltaje con el SOC y el segundo término representa la variación del voltaje debido al cambio en la R_i .

$$V_c(t) = n_s [V_{boc} + K_{boc}(SOC(t))] + n_s \frac{|I_{bat}(t)|}{C_{10c}} \times \left(\frac{P_{1c}}{1 + |I_{bat}(t)|^{P_{2c}}} + \frac{P_{3c}}{(1 - SOC(t))^{P_{4c}}} + P_{5c} \right) \times (1 - \alpha_{rc} \Delta T(t)) \quad (11)$$

Esta fase de carga es considerada como la mejor zona de trabajo para prolongar la vida útil de la batería.

3.2.2.2.Zona de sobrecarga

Cuando se almacena demasiada energía en la batería está alcanza el nivel de voltaje de gasificación (V_g), y por lo tanto puede comenzar a saturarse lo que conlleva a que la corriente de carga comience a disminuir. Esto genera una disminución de la carga debido al efecto de gasificación del electrolito el cual aparece cuando la carga de la batería está cerca del 95% [137, 144]. Este nivel varía según la corriente de carga y la temperatura del electrolito.

El modelo asume que la batería ingresa a esta zona cuando $V_{bat} \geq V_g$

Las ecuaciones (12) – (16) están relacionadas con esta zona en particular:

$$V_{sc}(t) = V_g(t) + (V_{ec}(t) - V_g(t)) \left[1 - \exp\left(\frac{(LOE(t)C(t) - SOC_{Vg}(t)C(t))}{I(t)\tau(t)} \right) \right] \quad (12)$$

Donde,

$$V_g(t) = \left[A_{gas} + B_{gas} \ln\left(\frac{I(t)}{C_N} \right) \right] (1 - \alpha_{gas} \Delta T(t)) \quad (13)$$

$$V_{ec}(t) = \left[A_{fonse} + B_{fonse} \ln\left(1 + \frac{I(t)}{C_N} \right) \right] (1 - \alpha_{fc} \Delta T(t)) \quad (14)$$

$$\tau(t) = \frac{A_{\tau sc}}{1 + B_{\tau sc} \left(\frac{I(t)}{C_N} \right)^{C_{\tau sc}}} \quad (15)$$

$$SOC_{V_g} = SOC \Big|_{V_c=V_g} \quad (16)$$

Siendo SOC_{V_g} el estado de carga correspondiente al comienzo del gaseo.

3.2.2.3. Zona de saturación

En esta zona la batería alcanza su máximo voltaje por lo que no se debe seguir suministrando energía a la batería debido a que ésta podría sufrir daños irreparables ya que el SOH podría verse afectado llevando a un reemplazo prematuro de la batería. Por lo tanto, el controlador del BESS deberá desconectar el BESS para impedir que éste reciba más energía.

3.2.3. Zona de descarga, zona de sobre-descarga y zona de agotamiento.

3.2.3.1. Zona de descarga

En esta zona la batería proporciona energía a la carga y su evolución está representada por la ecuación (17). En esta ecuación I_{bat} es siempre positiva debido a su valor absoluto. Los límites de esta zona son $V_{bat} > 0.9V_N$, siendo V_N el voltaje nominal de la batería.

$$V_{dc}(t) = n_s [V_{b0dc} - K_{b0dc} (1 - SOC(t))] - n_s \frac{|I_{bat}(t)|}{C_{10dc}} \times \left(\frac{P_{1dc}}{1 + |I_{bat}(t)|^{P_{2dc}}} + \frac{P_{3dc}}{SOC(t)^{P_{4dc}}} + P_{5dc} \right) \times (1 - \alpha_{rdc} \Delta T(t)) \quad (17)$$

3.2.3.2. Zona de sobredescarga

La batería entra en esta zona cuando de ella se extrae una gran cantidad de energía; es decir, cuando V_{bat} alcanza el 90% del V_N . Esto lleva a una disminución del voltaje y por lo tanto a una descarga rápida de la batería hasta quedar casi vacía. Cuando la batería se encuentra en esta zona se debe desconectar la carga que esté conectada a ésta.

3.2.3.3. Zona de agotamiento

Se debe evitar que la batería entre a esta zona ($V_{bat} < 0.7V_N$) debido a que podría sufrir daños irreparables.

3.2.3.4. Voltaje de transición

En esta transición la batería presenta una caída de voltaje que causa una singularidad numérica en el modelo.

$$V_c \Big|_{I=0} \neq V_{dc} \Big|_{I=0}$$

Según Guash et al. [144] este problema podría resolverse permitiendo una evolución lineal entre ambas zonas de trabajo definiendo un umbral de corriente $|I_\delta|$ que delimite la zona de linealización del modelo.

Por lo tanto, cuando $|I_{bat}| \geq |I_\delta|$ el voltaje de la batería se calcula de acuerdo a su zona de trabajo.

Si $|I_{bat}| < |I_\delta|$, el voltaje podrá ser calculado por la ecuación (18):

$$V_{cdc} = \frac{V_{c|I_\delta} - V_{dc|I_\delta}}{2I_\delta} I + \frac{V_{c|I_\delta} + V_{dc|I_\delta}}{2} \quad (18)$$

Donde V_c y V_{dc} son los voltajes en el umbral de corriente.

3.3. IDENTIFICACIÓN DE PARÁMETROS

En la **Tabla 3.3**, se pueden encontrar aquellos parámetros que han sido identificados mediante la implementación de varias técnicas. Es de aclarar que la variación de estos parámetros obedece a las características del tipo de batería usada y a la efectividad del método empleado.

Tabla 3.3. Valores nominales de los parámetros identificados por algunos autores.

Parámetros	Copetti [137]	Guasch [144]	Blaifi [145, 146]	Blaifi [147]
V_{bodc} (V)	2,085	2,147	2,148	2,1612
K_{bodc} (V)	0,12	0,284	0,127	0,219
P_{1dc} (VAh)	4	4,083	0,406	9,5044
P_{2dc}	1,3	-6,634	3,041	4,9361
P_{3dc} (Vh)	0,27	0,27	1,218	0,9311
P_{4dc}	1,5	1,5	0,7812	0,037
P_{5dc} (Vh)	0,02	0,02	0,484	1,8837
α_{rdc} ($^{\circ}\text{C}^{-1}$)	0,007	0,007	0,0197	0,0167
V_{boc} (V)	2	1,98	1,781	1,9016
K_{boc} (V)	0,16	0,149	0,5313	0,16
P_{1c} (VAh)	6	5,923	7,234	6,0809
P_{2c}	0,86	0,024	0,667	1,6701
P_{3c} (Vh)	0,48	0,48	0,078	0,3375
P_{4c}	1,2	1,2	0,492	0,9853
P_{5c} (Vh)	0,036	0,036	0,7421	1,7838
α_{rc} ($^{\circ}\text{C}^{-1}$)	0,025	0,025	0,43	0,01

Como ya se mencionó anteriormente, para la identificación de los parámetros internos del BESS se implementan y se compraran 3 EA. En el proceso de identificación se busca un conjunto de parámetros (PS por sus siglas en inglés) que se ajusten a los datos reales del BESS.

Debido a que el modelo describe los procesos de carga y descarga por separado, se identifican dos PS para cada modo de trabajo. Por lo tanto, un PS particular en el modelo de batería consiste en:

$$PS = \begin{cases} I(A) > 0; & PS = \{V_{boc}, K_{boc}, P_{1c}, P_{2c}, P_{3c}, P_{4c}, P_{5c}, \alpha_{rc}, k_{c10c}, k_{socc}, k_{lc}, k_{c_bate}\} \\ I(A) \leq 0; & PS = \{V_{bodc}, K_{bodc}, P_{1dc}, P_{2dc}, P_{3dc}, P_{4dc}, P_{5dc}, \alpha_{rdc}, k_{c10dc}, k_{socdc}, k_{ldc}, k_{c_batdc}\} \end{cases}$$

Un PS general se define como:

$$PS_j^k = \{c_{1,j}^k, c_{2,j}^k, c_{3,j}^k, \dots, c_{i,j}^k\}$$

Donde $c_{i,j}^k$ representa cualquier parámetro del PS; por ejemplo, $c_{1,2}^7$ es el valor del primer parámetro (V_{bo}) en el segundo conjunto de parámetros de la séptima población PS_2^7 . En el primer paso los valores iniciales se tomaron de la literatura (ver **Tabla 3.3**).

En el segundo paso la población inicial ($k = 1$) de tamaño j es una matriz de PS que se crea siguiendo las siguientes reglas:

$$PS_j^1 = \begin{cases} j = 1; & C_{i,1}^1 = C_{i,1}^1 \\ j \geq 1; & C_{i,j}^1 = (C_{i,j}^1 \cdot z \cdot v_d) + C_{i,j}^1 \end{cases}$$

Donde “z” es un número aleatorio ($z \in [-1, 1]$) y v_d es un valor que genera una posible dispersión de los parámetros $C_{i,j}^1$ en la población inicial de manera que $C_{i,j}^1 \in [-v_d * C_{i,j}^1, v_d * C_{i,j}^1]$.

En la tercera etapa cada PS_j^1 se evalúa en el modelo de batería y se calculan los errores para las señales en el modo de carga y descarga en las señales de SOC y voltaje de la batería.

El error de la señal del SOC de la batería ($E_{SOC}PS_j^1$) es calculado como:

$$E_{SOC}PS_j^k = \frac{(E_{SOCc} + E_{SOCdc})}{2} \quad (19)$$

Donde E_{SOCc} y E_{SOCdc} son el error de carga/descarga del SOC de la batería. El error medio es calculado como:

$$E_{SOCc} = \frac{1}{lc} \left(\sum_{i=1}^{lc} \frac{|SOC_{cm} - SOC_{cs}|}{SOC_{cm}} \right) \quad (20)$$

$$E_{SOCdc} = \frac{1}{ldc} \left(\sum_{i=1}^{ldc} \frac{|SOC_{dcm} - SOC_{dcs}|}{SOC_{dcm}} \right)$$

Donde SOC_m y SOC_s son el SOC medido y simulado de la batería respectivamente, y lc y ldc son la cantidad de datos de entrada en el archivo que pertenece al modo de carga y al modo de descarga respectivamente.

El error de la señal de voltaje de la batería ($E_VPS_j^1$) es calculado como:

$$E_VPS_j^k = \frac{(E_{Vc} + E_{Vdc})}{2} \quad (21)$$

Donde E_{Vc} y E_{Vdc} son el error de carga/descarga del voltaje de la batería. El error medio es calculado con la ecuación (22):

$$E_{V_c} = \frac{1}{l_c} \left(\sum_{i=1}^{l_c} \frac{|V_{cm} - V_{cs}|}{V_{cm}} \right) \quad (22)$$

$$E_{V_{dc}} = \frac{1}{l_{dc}} \left(\sum_{i=1}^{l_{dc}} \frac{|V_{dcm} - V_{dcs}|}{V_{dcm}} \right)$$

Donde V_m y V_s son el voltaje medido y simulado de la batería respectivamente, y l_c y l_{dc} son la cantidad de datos de entrada en el archivo que pertenece al modo de carga y al modo de descarga respectivamente.

El objetivo es minimizar ambos errores para que el modelo pueda seguir la señal del SOC y del voltaje de la batería. El proceso de optimización finaliza cuando se cumple una condición de parada. Si la condición de parada no se cumple el EA crea una nueva población PS^{k+1} . Esta nueva población se evalúa nuevamente repitiendo así el proceso. Por lo tanto, en cada paso k el sistema ejecuta el modelo n veces. Cada vez que los sistemas utilizan una fila (j) de PS^k . Los resultados de la simulación son comparados con datos reales por lo que hay un error de simulación para cada PS_j^k . Este error se utiliza para generar la siguiente población que se va a probar o para decidir si es lo suficientemente pequeño como para finalizar el proceso. La condición de parada generalmente se define como un umbral para el mínimo de EPS_j^k o como un número máximo de iteraciones.

El proceso de optimización comienza con la creación de un conjunto inicial de candidatos. Este conjunto se evalúa sobre el sistema uno por uno y se calcula la diferencia entre la simulación y el rendimiento experimental. Basándose en esas diferencias, cada EA usa una política particular para crear la nueva población. El objetivo es converger a la solución óptima en un número mínimo de pasos. Para realizar esta operación los EA incluyen componentes aleatorios que permiten buscar la mejor solución global ($Gbest$) que incluya valores de dispersión para difundir o enfocar a la descendencia cerca de una posible solución. El flujo de identificación general del proceso de EA se muestra en la **Figura 3.4**.

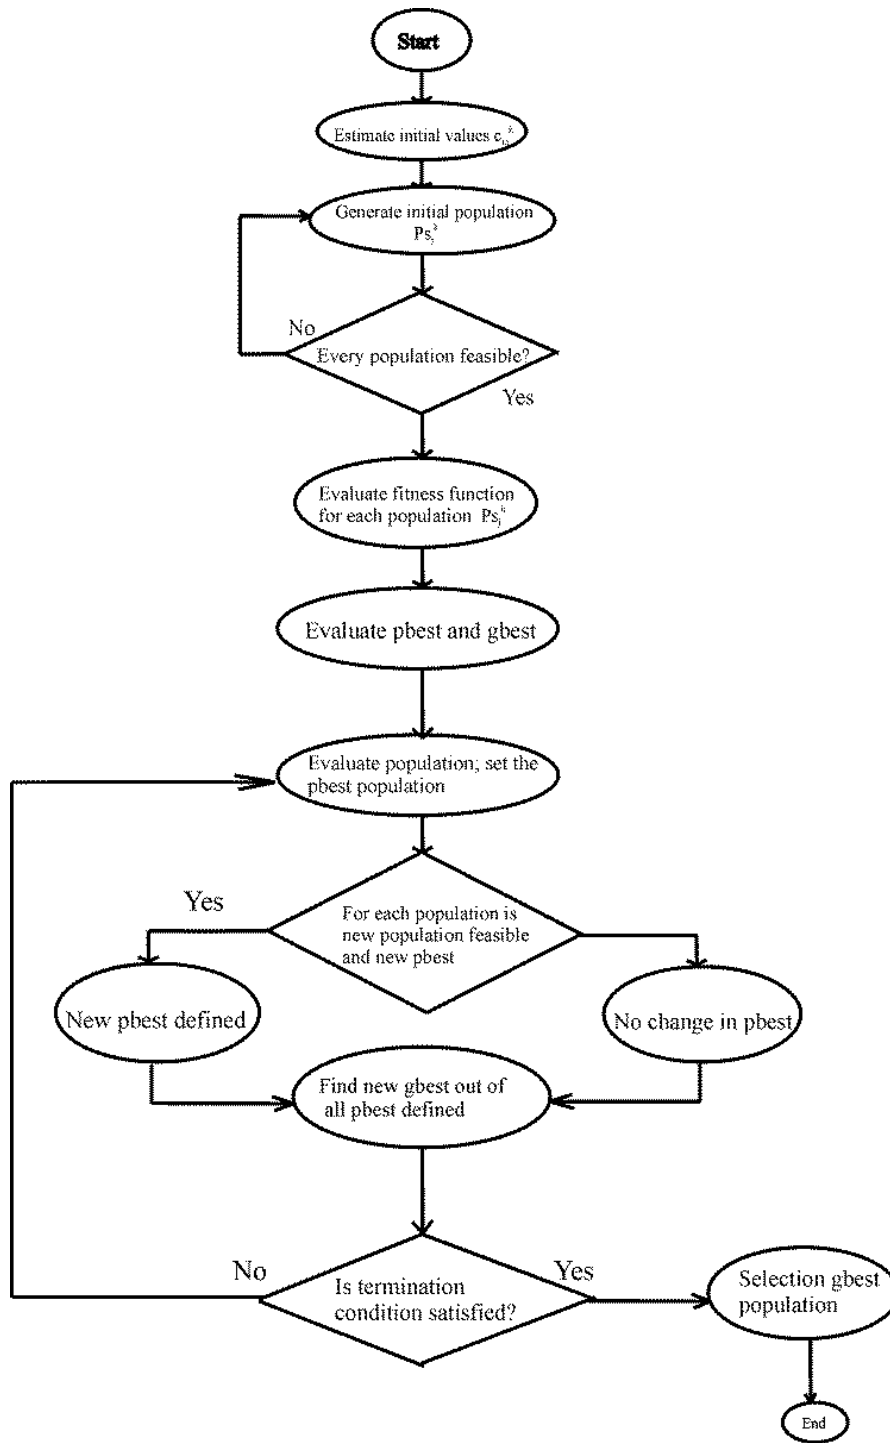


Figura 3.4. Diagrama de flujo del algoritmo de PSO.

3.4. DESCRIPCIÓN DE LOS ALGORITMOS EVOLUTIVOS

3.4.1. Algoritmo de optimización por enjambres de partículas (PSO)

PSO es una técnica de computación evolutiva desarrollada por Kennedy y Eberhart en 1995 [166]. PSO se ha hecho popular debido a su fácil implementación, alta precisión, y su capacidad para converger rápidamente a una solución óptima demostrando así su eficacia en la resolución de problemas prácticos. A pesar de la similitud con otras técnicas heurísticas como los algoritmos genéticos (GA, por sus siglas en inglés), PSO no implica la mutación y la función de cruce. En PSO, cada una de las partículas mantiene el registro de la ubicación de la mejor partícula que proporciona el valor de posición/ubicación y se denota $pbest$ [167, 168]. Después de recopilar la información de $pbest$ para cada partícula el algoritmo utiliza estos valores para encontrar la solución óptima global que se denota por $gbest$ [167, 168]. PSO encuentra la mejor solución global ajustando el vector de movimiento de cada partícula de acuerdo con su mejor posición personal (aspecto cognitivo, segundo término) y la mejor posición global (aspecto social, tercer término) de las partículas en todo el enjambre en cada iteración.

El primer término es solo la velocidad actual de la partícula y puede considerarse como un término de impulso. El segundo término que está asociado con una búsqueda local es proporcional al vector $(pbest_i^k - x_i^k)$ y apunta desde la posición actual de la partícula hacia su mejor posición personal. El tercer término que está asociado con una búsqueda global es proporcional a $(gbest^k - x_i^k)$ y apunta hacia la posición de la mejor partícula global.

En cada iteración de PSO, cada partícula actualiza su posición y velocidad en el espacio de búsqueda de acuerdo con su mejor solución individual $pbest_i$ y la solución óptima global del grupo $gbest$, de la siguiente manera [168-170]:

$$v_i^{k+1} = v_i^k + c_1 r_1 (pbest_i^k - x_i^k) + c_2 r_2 (gbest^k - x_i^k) \quad (23)$$

$$x_i^{k+1} = x_i^k + v_i^{k+1} \quad (24)$$

Donde, r_1 y r_2 son números aleatorios en el rango $[0, 1]$. k es el número actual de iteraciones.

Por lo tanto, la modificación del PSO estándar mejorado introduce el peso de inercia ω en la ecuación (23), y su velocidad se representa de la siguiente manera:

$$v_i^{k+1} = \omega \cdot v_i^k + c_1 r_1 (pbest_i^k - x_i^k) + c_2 r_2 (gbest^k - x_i^k) \quad (25)$$

En este algoritmo, ω se conoce como la constante de inercia o peso de inercia y su valor recomendado es ligeramente menor que 1 (un número no negativo) el cual regula el rango de búsqueda del espacio de solución, c_1 y c_2 son las constantes de aceleración que determinan la cantidad de partículas dirigidas hacia una posición ideal.

Uno de ellos se denomina componente cognitivo y el otro se designa como componente social. El significado de estas dos constantes es que determinan en qué medida $pbest$ y $gbest$ afectan el movimiento de las partículas. El valor recomendado para estas dos constantes es aproximadamente 2 [169, 171].

Los pasos específicos del algoritmo son [169]:

- Paso 1: Configuración de parámetros

Determine algunos parámetros básicos basados en el modelo de batería incluido el número del tamaño de la población, las dimensiones de una sola partícula y el rango de dimensiones en operación que se pueden definir de acuerdo con el rango de los parámetros que se muestran en la **Tabla 3.4**.

- Paso 2: Inicializando el enjambre de partículas.

Inicializar enjambre de partículas (el tamaño de la población es n), incluidas las ubicaciones aleatorias y velocidades.

- Paso 3: Calcula el ajuste de cada partícula

En el algoritmo, cada dimensión de una sola partícula representa un conjunto completo de parámetros del modelo en donde n partículas forman una población. La función objetivo se configura para calcular los errores correspondientes de cada conjunto de parámetros con el ajuste obtenido en consecuencia.

- Paso 4: Encontrar la posición óptima individual ($pbest$)

Para cada partícula la adaptación actual se compara con el valor adaptativo correspondiente a su mejor posición histórica individual ($pbest$). Entonces el $pbest$ se actualizará con la posición actual si el valor de adaptación actual es mejor.

- Paso 5: Encontrar la posición óptima global ($gbest$)

De manera similar, compara el ajuste actual con la adaptación de la posición óptima global ($gbest$) y actualice el $gbest$ con la ubicación actual de las partículas si el valor de adaptación actual es mejor.

- Paso 6: Actualizar la velocidad y posición de cada partícula.

Actualizar la velocidad y la posición de la dimensión d de la partícula i de acuerdo con las ecuaciones (23) y (24); donde v_i^{k+1} es la componente dimensional d del vector de velocidad de la partícula i en la iteración k y x_i^k es el vector de posición.

- Paso 7: la iteración de bucle para el algoritmo terminado

Repita los pasos 3 a 6 anteriores hasta que la iteración máxima o el incremento del ajuste óptima sea inferior a un umbral determinado. El algoritmo se detiene.

3.4.2. Algoritmo de búsqueda de Cuco (CS)

Como se mencionó en el apartado 3, CS se basa en el parasitismo de cría de algunas especies de Cuco. Además, este algoritmo es mejorado por los llamados vuelos o procesos de Levy, en lugar de por simples paseos aleatorios isotrópicos. Para aplicar el comportamiento de cría de Cuco a los problemas de optimización, Yang et al. [148] idealizó el comportamiento parásito de cría de algunos Cucos y se han propuesto las siguientes tres reglas [172-175]:

1. Cada cuco pone un huevo a la vez y lo descarga en un nido elegido al azar.
2. Los mejores nidos con huevos de alta calidad serán trasladados a las próximas generaciones.
3. El número de nidos anfitriones disponibles es fijo, y el ave huésped descubre el huevo puesto por un Cuco con una probabilidad $p_\alpha \in [0, 1]$. En este caso, el ave huésped puede deshacerse del huevo o simplemente abandonar el nido y construir un nido completamente nuevo. Además, la probabilidad p_α puede ser utilizada por la n nidos del huésped para reemplazar los nuevos nidos, si es mejor.

Al igual que otros algoritmos basados en enjambres, el algoritmo CS comienza con una población inicial de n nidos huéspedes. Estos nidos anfitriones iniciales serán atraídos aleatoriamente por los Cucos con huevos y también por vuelos aleatorios de Lévy para poner los huevos. Luego, la calidad del nido se evaluará y comparará con otro nido de huésped aleatorio.

Algoritmo de búsqueda de Cuco a través de vuelos de lévy [172, 175]

1. Función objetivo $f(X), X = (x_1, \dots, x_d)^T$
 2. Generar población inicial de n nidos de huéspedes $X_i (i = 1, b, \dots, n)$; generación $t = 1$; Evalúe la aptitud física para cada individuo y determine el mejor individuo con el mejor valor objetivo;
 3. Mientras que $t \ll$ iteraciones máximas, hacer;
 4. ($t \ll$ Generación Máxima) o (criterio de parada);
 5. Obtener un Cuco al azar por los vuelos de Lévy
 6. Evaluar su calidad física.
 7. Elegir α nido entre n (por ejemplo, j) al azar;
 8. Si $F_i \gg F_j$ entonces
 9. Sustituye j por la nueva solución.
 10. Termina sí;
 11. Una fracción (p_α) de nidos peores se abandonan y se construyen otros nuevos;
 12. Mantener las mejores soluciones (o nidos con soluciones de calidad);
 13. Clasifica las soluciones y encuentra la mejor actual.
 14. Actualizar el número de generación $t = t + 1$
 15. Terminar.
 16. Fin.
-

En caso de que el nido del huésped sea mejor, reemplazará a los antiguos nidos del huésped. Esta nueva solución tiene el huevo puesto por un Cuco. Si el ave huésped descubre el huevo con una probabilidad $p_a \in (0, 1)$, el huésped arroja el huevo o lo abandona y construye un nuevo nido. Este paso se realiza reemplazando las abundantes soluciones con las nuevas soluciones aleatorias. La Figura 3.5, muestra un diagrama de flujo del algoritmo CS.

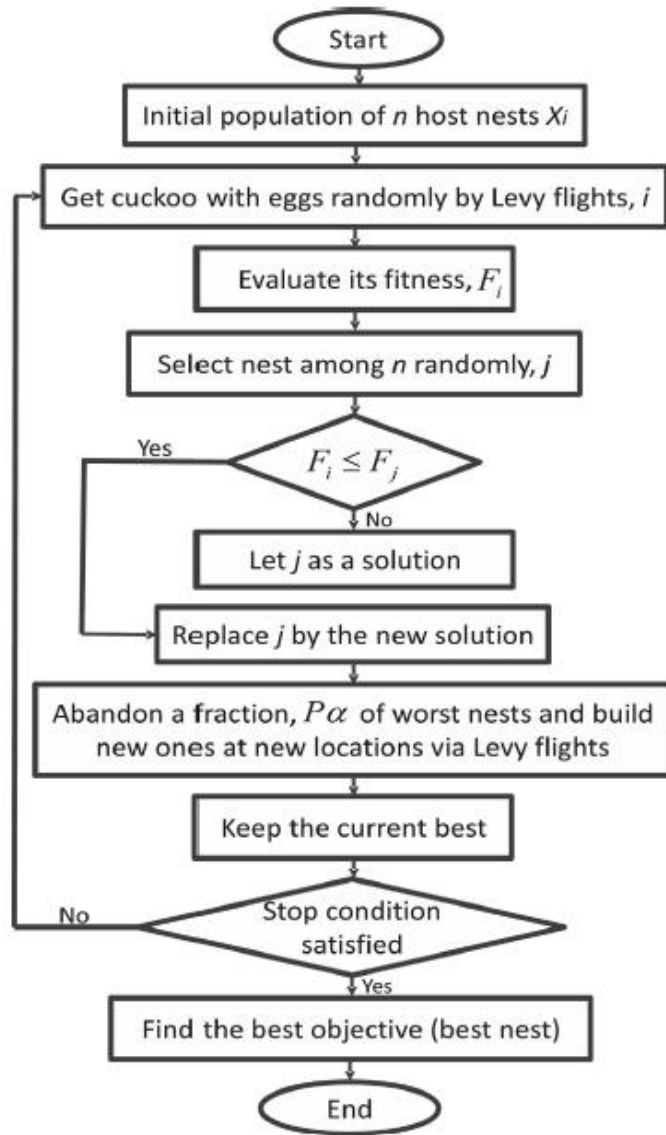


Figura 3.5. Diagrama de flujo del algoritmo de búsqueda de Cuco (CS) [175].

Como el Cuco pone solo un huevo, también representa una solución. El propósito es aumentar la diversidad de nuevos (y probablemente mejores) Cucos (soluciones) y reemplazarlos en su lugar con las peores soluciones. Sin embargo, el algoritmo CS puede volverse más complicado al usar varios huevos en cada nido para representar un conjunto de soluciones.

3.5.NUEVA PROPUESTA

Una característica importante de PSO es su capacidad para enfocar gradualmente la búsqueda alrededor del mínimo local. Sin embargo, cuando el algoritmo cae alrededor de un mínimo local, es difícil obtener una mejor solución. Este capítulo propone la introducción de perturbaciones periódicas dentro de la población con la finalidad de forzar la reactivación del algoritmo PSO. La perturbación consistirá en una nueva población PS_j^l basada en la mejor solución global:

$$c_{i,j}^l = (c_i^{gbest} * z * p) + c_i^{gbest} \quad (26)$$

Donde c_i^{gbest} es un coeficiente que pertenece a $gbest$ en la iteración l , y p es el valor de perturbación. Debido a que el uso de perturbaciones hacen que PSO pase a ser PSO+P, la perturbación se introduce después que el algoritmo PSO esté estabilizado, por lo tanto es necesario ejecutar primero el PSO.

3.5.1. Criterios de configuración de los algoritmos

Actualmente existen diferentes criterios para las configuraciones de los algoritmos. Como se muestra en la **Tabla 3.4**, este documento trabaja con la configuración más común [150, 169, 171, 176, 177]. El tamaño de la población, el número de iteraciones y la dispersión inicial (v_d) toman valores iguales en todos los algoritmos.

Tabla 3.4. Configuración de los algoritmos de optimización.			
Criterios	PSO	PSO+P	CS
Tamaño de la población	1000	1000	1000
Iteraciones	100	100	100
Peso inicial (ω_1)	0,9	0,9	-
Pesos final (ω_2)	0,1	0,1	-
c_1	1	1	-
c_2	1	1	-
v_d	5	5	5
Iteraciones a perturbar	-	10	-
Pa	-	-	0,5
α	-	-	1
λ	-	-	2

Teniendo en cuenta las ecuaciones (11) - (26) y los criterios de la **Tabla 3.4**, se realiza el montaje de la simulación del modelo de batería junto con los EAs. La simulación se realiza bajo el entorno de programación LabView®.

3.6.RESULTADOS Y DISCUSION

Al comparar los 3 EAs (ver **Figura 3.6**), se observa que al estimar el error de carga y descarga el algoritmo CS es el que presenta menores resultados.

Un análisis sobre las curvas muestra que PSO es el algoritmo más rápido, alcanzando en la décima iteración un valor aceptable de menos del 1.0%. Sin embargo, PSO cae en mínimos locales por lo que pierde la capacidad de búsqueda lo que confirma sus limitaciones. Por su parte, PSO+P obtiene los mejores resultados a partir de la 43ª iteración pero requiere más iteraciones para lograrlo.




Figura 3.6. Comportamiento de los algoritmos de optimización en modo de carga y descarga.

En la **Tabla 3.5**, se muestra los criterios utilizados para evaluar cada algoritmo y la comparación cuantitativa entre ellos.

Tabla 3.5. Comparación de algoritmos utilizando el error medio mínimo alcanzado. d * = modo de descarga; c * = Modo de carga.

Criterios/Algoritmos		PSO		PSO+P		CS	
		d*	c*	d*	c*	d*	c*
Precisión (error)	Valor	0.50	0.91	0.34	0.51	3.09	2.81
	Puntaje	1.48	1.78	1.00	1.00	9.23	5.53
Velocidad (iteración)	Valor	17.0	11.00	91,0	90.0	89.00	97.0
	Puntaje	1.00	1.00	5.35	8.18	5.24	8.82
Costo Computacional (ms/iteración)	Valor	0.41	0.41	0.42	0.42	0.71	0.71
	Puntaje	1.0	1.00	1.03	1.03	1.72	1.72

El error de precisión se mide como el valor de error más bajo alcanzado por un EA. La velocidad se mide con la iteración cuando el algoritmo realiza su última mejora. Finalmente, el costo computacional se mide como el tiempo promedio utilizado por la computadora para realizar una única iteración de optimización. Las puntuaciones se calculan en cada modo de operación (carga/descarga) a través de la relación entre el valor obtenido por el algoritmo y el valor más bajo alcanzado. Por lo tanto, un valor de 1.0 representa el mejor resultado y un valor de 2.0 representa una desviación del 100% del mejor resultado.

Los resultados mostrados en la **Tabla 3.6**, revelan a PSO como el mejor algoritmo en cuanto a velocidad y costo computacional. Sin embargo, PSO+P muestra el mejor ajuste. Por lo tanto, el modelo se ajusta a partir de los resultados de PSO+P. Parte de la codificación del modelo en LabView® junto con el algoritmo PSO+P es mostrado en la **Figura 3.7**.

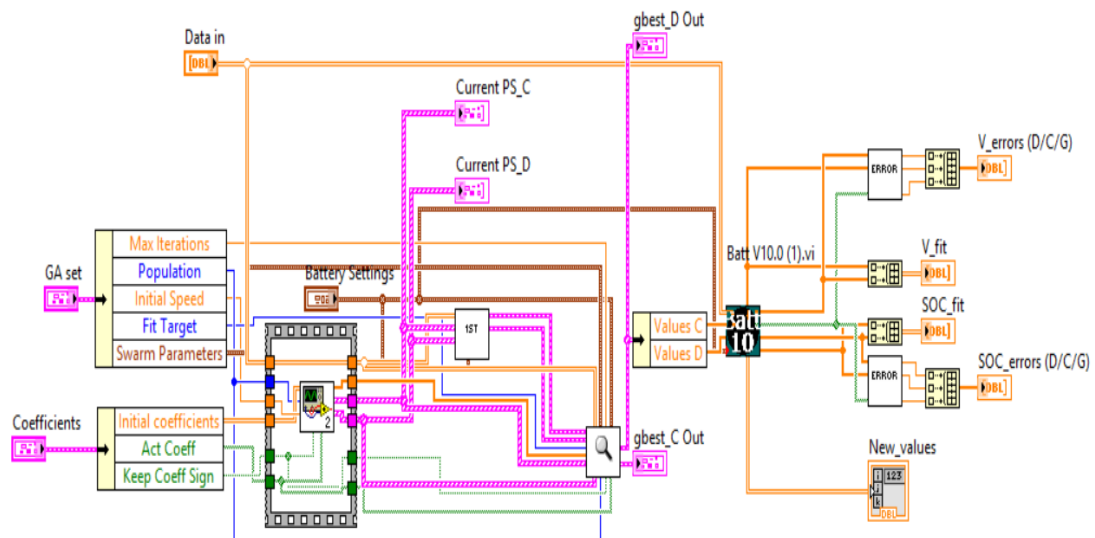


Figura 3.7. Modelo de batería representado en Labview®.

3.6.1. Validación experimental del SOC y el voltaje del BESS.

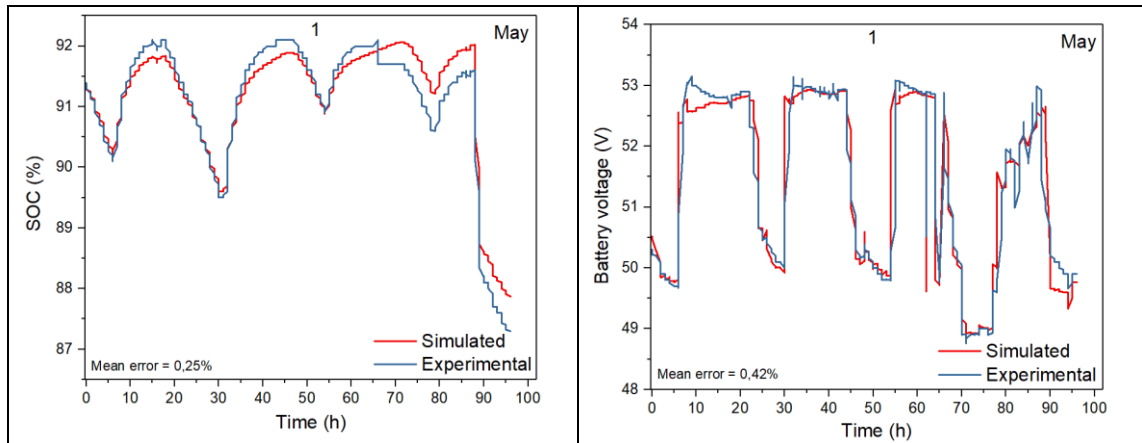
Los parámetros mostrados en la **Tabla 3.6**, son usados para validar experimental el modelo propuesto con las mediciones reales tomadas del LadER.

Tabla 3.6. Identificación de parámetros por PSO + P.

Carga		Descarga	
V_{boc} (V)	2.164	V_{bodc} (V)	2.135
k_{boc}	0.483	k_{bodc}	0.005
P_{1c} (VAh)	32.618	P_{1dc} (VAh)	38.150
P_{2c}	1.393	P_{2dc}	0.965
P_{3c} (Vh)	0.275	P_{3dc} (Vh)	0.085
P_{4c}	0.062	P_{4dc}	1.820
P_{5c} (Vh)	0.042	P_{5dc} (Vh)	0.372
α_{rc} ($^{\circ}C^{-1}$)	0.043	α_{rdc} ($^{\circ}C^{-1}$)	0.037
C_{tcoef_c}	6.001	C_{tcoef_c}	1.823
A_{cap_c}	3.877	A_{cap_c}	0.020
B_{cap_c}	0.373	B_{cap_dc}	0.946
α_{c_c}	0.212	α_{c_dc}	0.031
k_{Ic}^*	0.3547	k_{Idc}^*	2.3562
$k_{c_batc}^*$	0.3865	$k_{c_batdc}^*$	2.5614
k_{socc}^*	17.012	k_{socdc}^*	2.5624
k_{c10c}^*	1.460	k_{c10dc}^*	0.0491

*Corresponde a nuevos parámetros incluidos en el modelo.

En la validación experimental (ver **Figura 3.8**), se utilizan paquetes de datos de 4 días y se compara con lo reportado hasta ahora en la literatura [145-147].



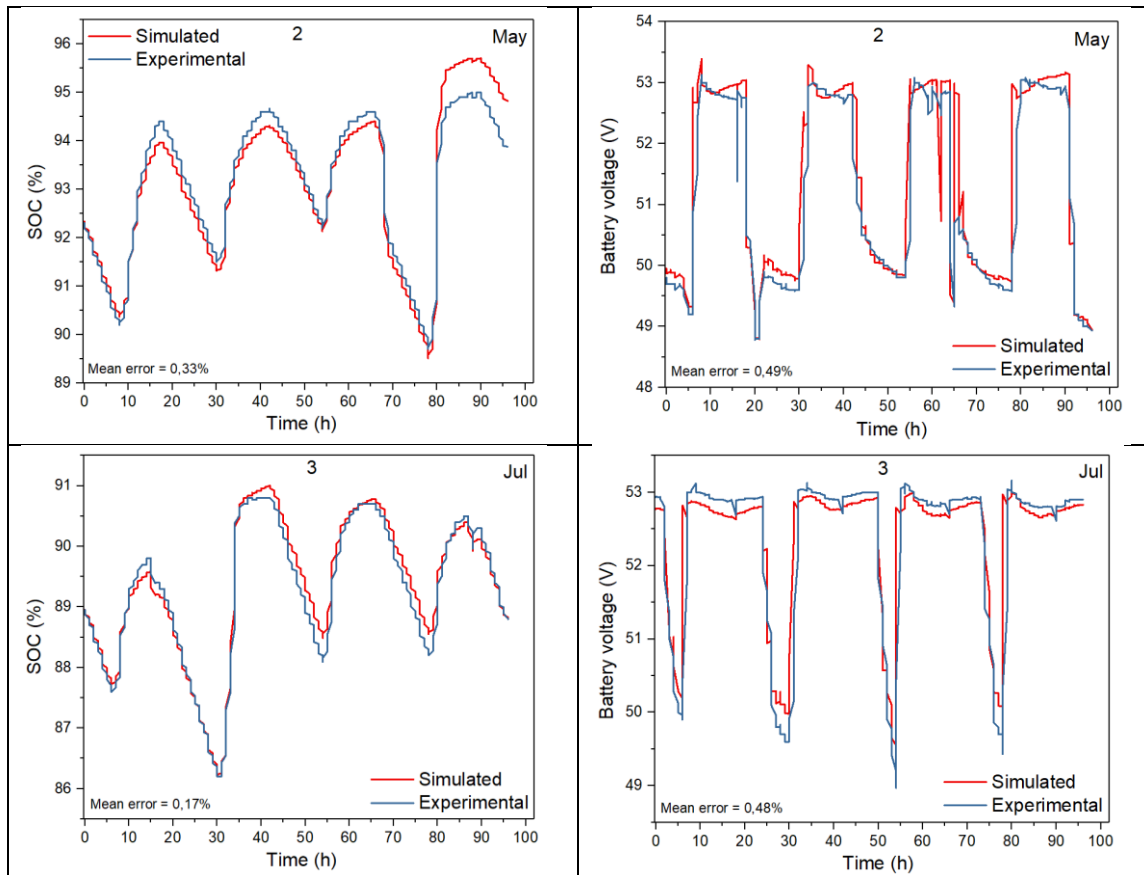


Figura 3.8. Validación experimental del SOC y voltaje de la batería obtenidas por el algoritmo PSO+P.

Los resultados de la validación muestran que el modelo desarrollado puede representar el SOC y el voltaje de la batería (ver **Figura 3.8**, simulaciones 1, 2 y 3) alcanzando errores promedio entre 0.17% (simulación 3) y 0.33% (simulación 2) para el SOC y 0.42%, 0.49% y 0.48% para el voltaje mejorando el error medio del 0.45% presentado en [146].

Una vez demostrada la eficacia del modelo se procede a simular y validar el SOC del BESS para un periodo de un año (ver **Figura 3.9 a - I**), representado mes a mes a partir de Agosto del año 2017 (**Figura 3.9.a**).

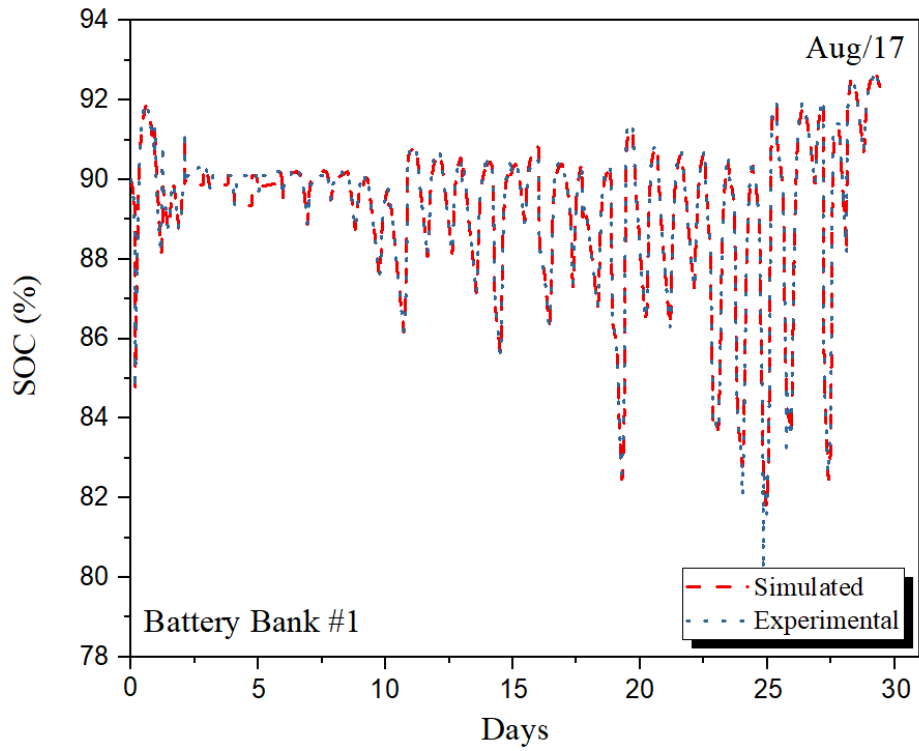


Figura 3.9 a. Simulación y validación del SOC del BESS para un año de medición. Agosto 2017.




Figura 3.9 b. Simulación y validación del SOC del BESS para un año de medición. Septiembre 2017.




Figura 3.9 c. Simulación y validación del SOC del BESS para un año de medición. Octubre 2017.

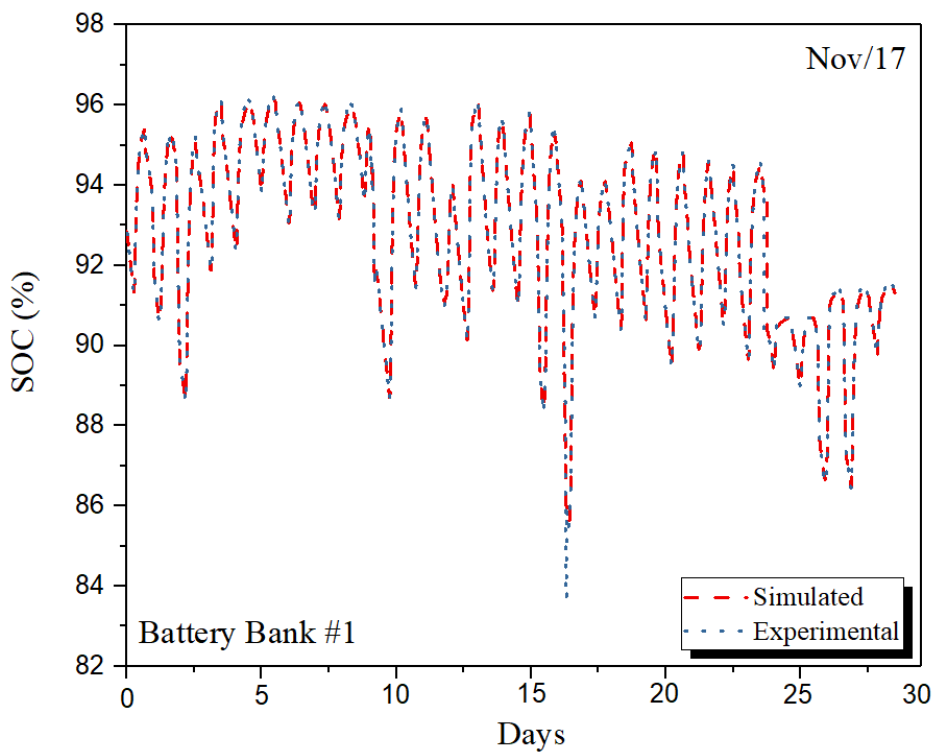


Figura 3.9 d. Simulación y validación del SOC del BESS para un año de medición. Noviembre 2017.




Figura 3.9 e. Simulación y validación del SOC del BESS para un año de medición. Diciembre 2017.




Figura 3.9 f. Simulación y validación del SOC del BESS para un año de medición. Enero 2018.

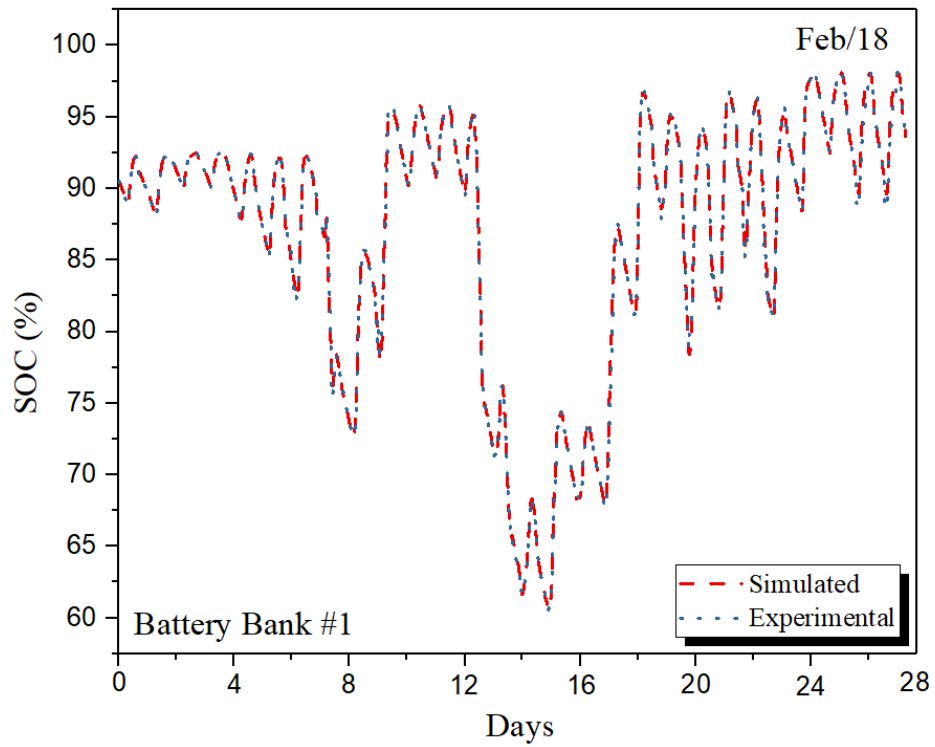


Figura 3.9 g. Simulación y validación del SOC del BESS para un año de medición. Febrero 2018.




Figura 3.9 h. Simulación y validación del SOC del BESS para un año de medición. Marzo 2018.

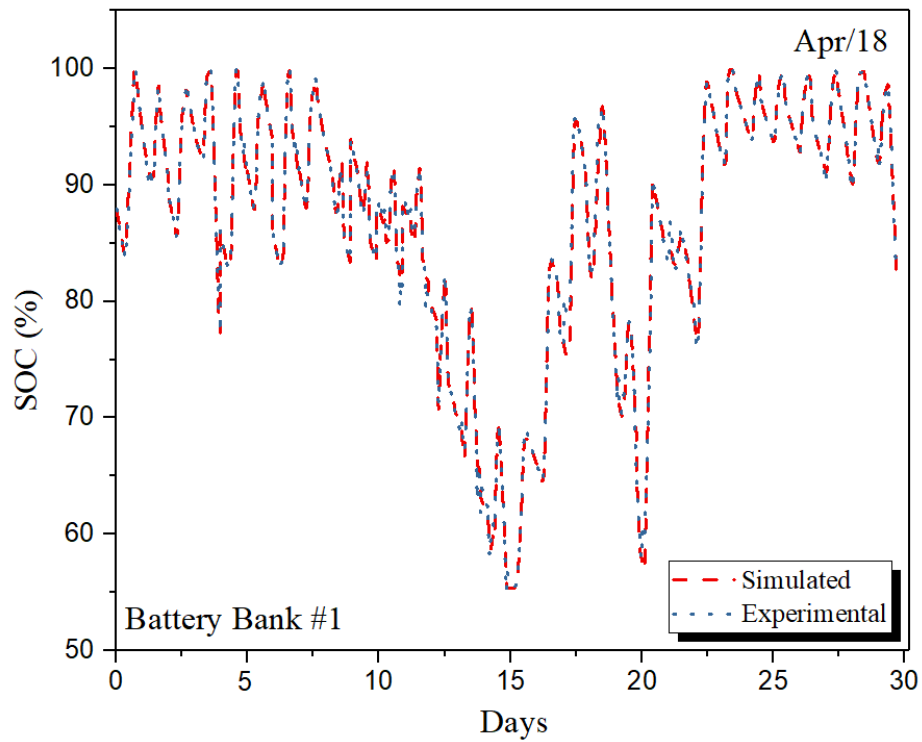


Figura 3.9 i. Simulación y validación del SOC del BESS para un año de medición. Abril 2018.

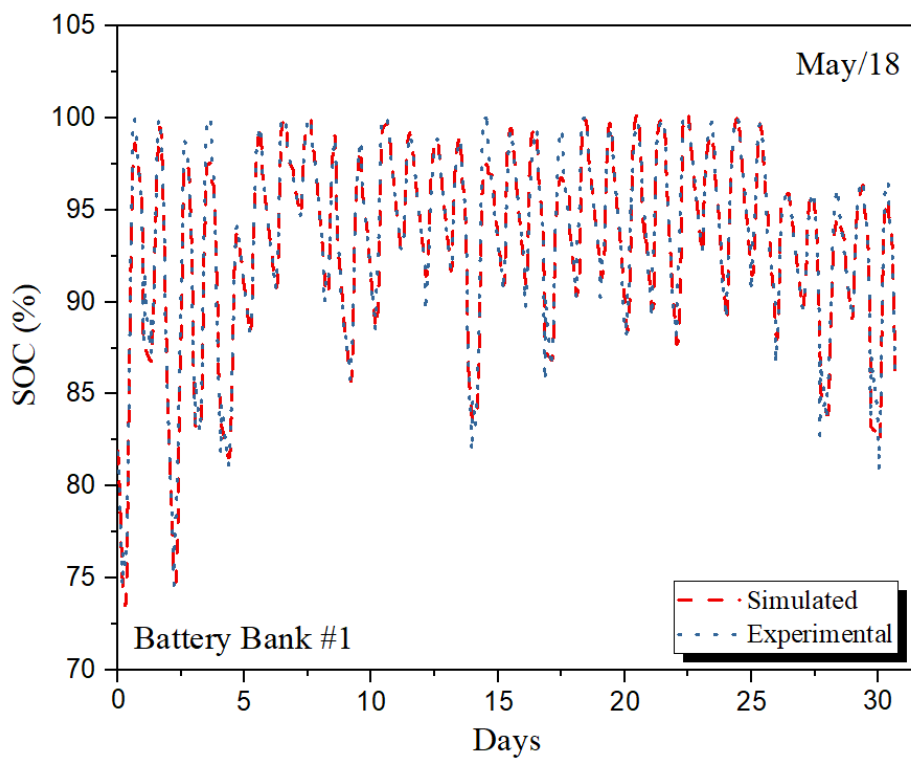


Figura 3.9 j. Simulación y validación del SOC del BESS para un año de medición. Mayo 2018.

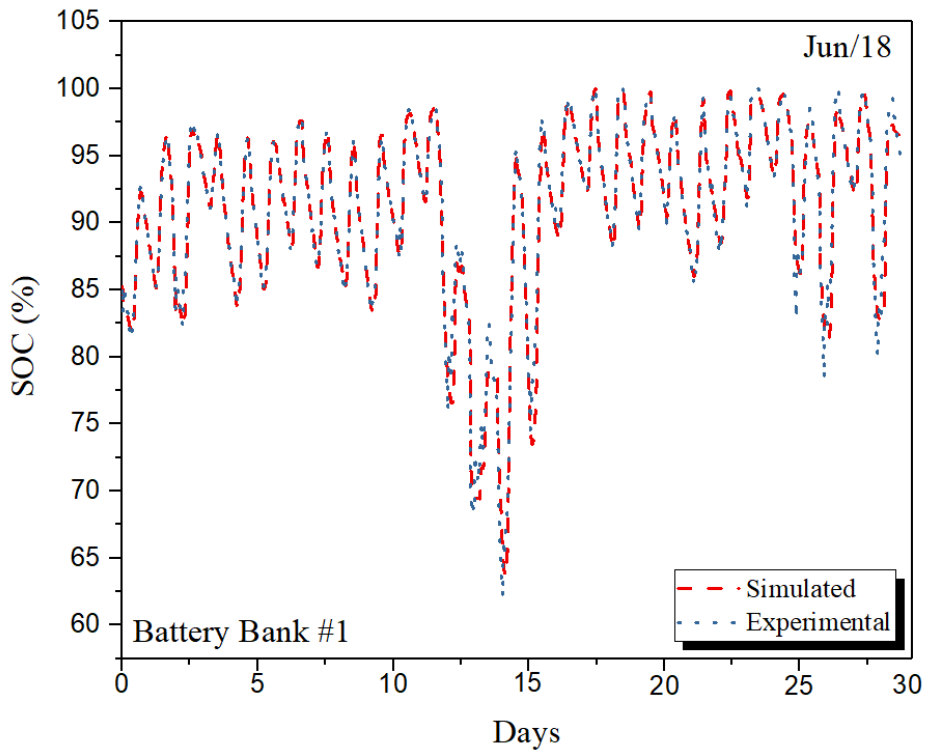


Figura 3.9 k. Simulación y validación del SOC del BESS para un año de medición. Junio 2018.

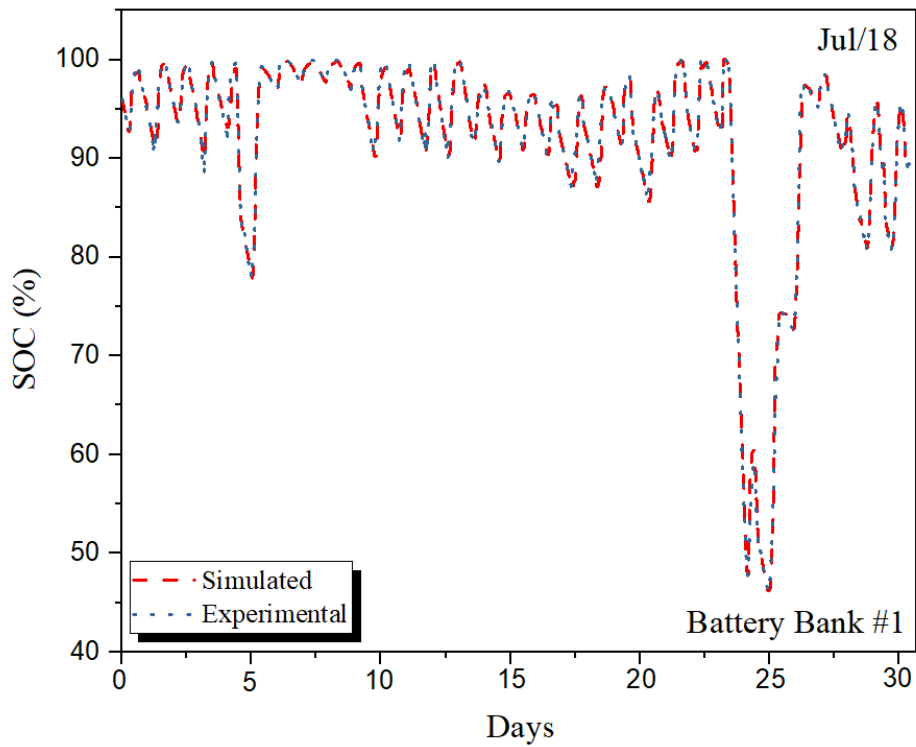


Figura 3.9 l. Simulación y validación del SOC del BESS para un año de medición. Julio 2018.

En la **Figura 3.9 (i, k, l)**, se observa que en el primer semestre del año 2018 el BESS fue sometido a descargas incontroladas alcanzando valores por debajo del 70% (Febrero, Abril, Junio y Julio), por lo que éste podría estar sujeto a un deterioro en su estado de salud (SOH, por sus siglas en inglés) y posteriormente aun reemplazo prematuro de algunos de sus componentes.

De igual forma, en la **Figura 3.10 (a - l)**, se observa como durante el mismo periodo de tiempo el BESS ha presentado sobrecargas siendo éstas más reiterativas a partir del mes de Marzo del año 2018.




Figura 3.10. a. Simulación y validación del voltaje del BESS para un año de medición. Agosto 2017.




Figura 3.10. b. Simulación y validación del voltaje del BESS para un año de medición. Septiembre 2017.




Figura 3.10. c. Simulación y validación del voltaje del BESS para un año de medición. Octubre 2017.




Figura 3.10. d. Simulación y validación del voltaje del BESS para un año de medición. Noviembre 2017.




Figura 3.10. e. Simulación y validación del voltaje del BESS para un año de medición. Diciembre 2017.




Figura 3.10. f. Simulación y validación del voltaje del BESS para un año de medición. Enero 2018.




Figura 3.10. g. Simulación y validación del voltaje del BESS para un año de medición. Febrero 2018.




Figura 3.10. h. Simulación y validación del voltaje del BESS para un año de medición. Marzo 2018.




Figura 3.10. i. Simulación y validación del voltaje del BESS para un año de medición. Abril 2018.

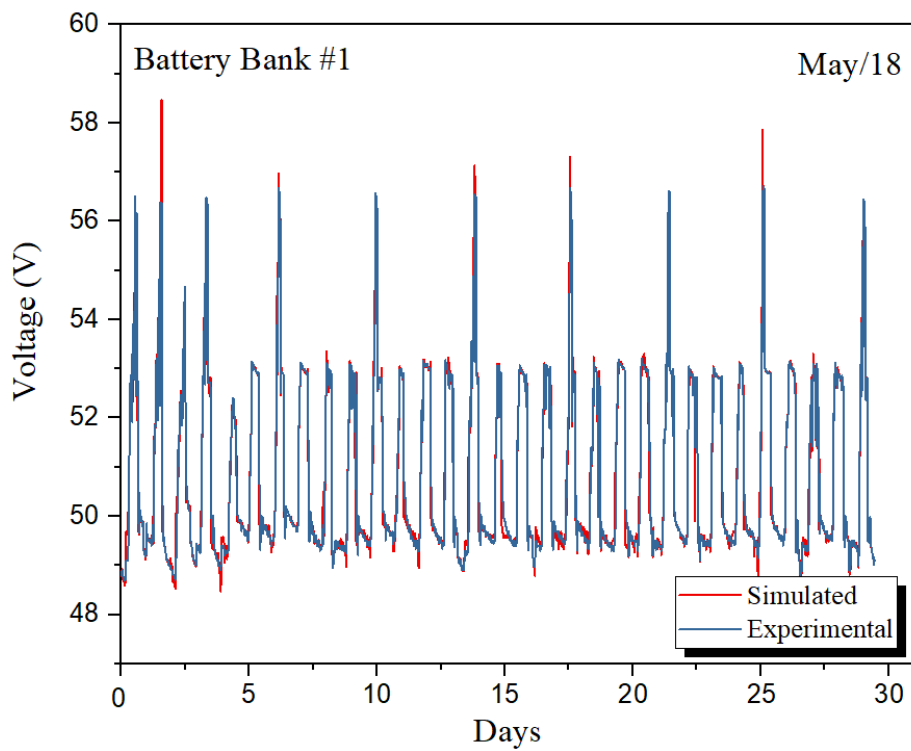


Figura 3.10. j. Simulación y validación del voltaje del BESS para un año de medición. Mayo 2018.




Figura 3.10. k. Simulación y validación del voltaje del BESS para un año de medición. Junio 2018.




Figura 3.10.l. Simulación y validación del voltaje del BESS para un año de medición. Julio 2018

3.7. CONCLUSIÓN

Este documento propone un modelo dinámico mejorado que es capaz de predecir el comportamiento de un banco de baterías de plomo-ácido en condiciones reales de operación.

El modelo de batería propuesto por Copetti muestra un buen rendimiento al representar la dinámica de la batería. Sin embargo, cuando se prueba con mediciones reales este modelo presenta problemas de escalado y retraso en la señal por lo que este documento ha propuesto la inclusión de cuatro nuevos parámetros para mejorar sus capacidades de modelado.

El modelo ha sido adecuado para representar el comportamiento real de un BESS instalado en "El Chocó", Colombia. La complejidad del modelo justifica el uso de EA para realizar la optimización por lo que este documento ha probado tres EAs para encontrar el mejor enfoque. Además, algunos algoritmos conocidos como CS y PSO, y un nuevo algoritmo propuesto (optimización de enjambre de partículas + perturbación) se han probado para identificar los parámetros de la batería OPzS plomo de ácido. La inclusión de la perturbación hace que el PSO+P sea más preciso que el PSO. Esta mejora hace que el modelo sea útil para estimar y administrar algunas características de la batería como el SOC y el voltaje de la batería con resultados que mejoran trabajos anteriores relacionados.

El modelo de batería con los nuevos parámetros extraídos presenta una buena coincidencia con las mediciones reales obtenidas del LadER del departamento del Chocó. La principal ventaja del modelo desarrollado es su bajo costo computacional y su capacidad para absorber los problemas de lectura y los errores de escala. La validación con medidas reales muestra bajos errores. El modelo y su enfoque de ajuste presentado en este documento pueden aplicarse a otros tipos de baterías, especialmente las utilizadas en sistemas independientes.

La presente propuesta tiene la capacidad de encontrar un PS que se ajuste al modelo sin preocuparse por el punto de inicio. Sin embargo, para continuar con el presente trabajo es necesario hacer un análisis de sensibilidad de los parámetros para definir la influencia de cada parámetro en los resultados de la simulación y establecer sus límites adecuados.

El proceso de ajuste presentado en este documento proporciona resultados de productos en términos de precisión del modelo. Por lo tanto, este modelo podría usarse para otros fines como simulación, diagnóstico de fallas, monitoreo de condición o modelo de control predictivo. Un parámetro clave para desarrollar aplicaciones en estas áreas es el SOC. Dado que las ecuaciones de voltaje de la batería incluyen SOC y el proceso de ajuste muestra un error bajo, por lo que será posible usar el modelo para predecir los valores de SOC. Por lo tanto, los trabajos futuros explorarán el potencial del modelo en

todas estas áreas para diseñar un mejor sistema de gestión de energía de la batería para el LadER en “El Chocó”, Colombia.

Aunque el modelo desarrollado obtiene buenos resultados es necesario continuar trabajando en la búsqueda de una mayor precisión y una mejor representación de la dinámica de la batería.

Capítulo 4

4. ESTIMACIÓN DEL ESTADO DE SALUD DE UN BANCO DE BATERÍA CONECTADO A UN SISTEMA DE ENERGÍA RENOVABLE

Las baterías son un componente esencial para el progreso de sistemas de energía renovable independientes [111, 178]. Por lo tanto, su estado de salud (SOH, por sus siglas en inglés) debe ser estudiado, ya que éste brinda información acerca del estado real de la batería [179, 180]. Contar con esta información permitirá detectar posibles daños que lleven a la degradación de la batería. Por lo que se podrá realizar un mantenimiento oportuno que evite el reemplazo prematuro de algunos de sus componentes [181] como consecuencia de la pérdida de capacidad, disminución del estado de carga o aumento de la resistencia interna de la batería.

En el momento de la fabricación se considera $SOH = 100\%$, y se considera $SOH = 0\%$ cuando la capacidad de la batería para almacenar y suministrar energía disminuye por debajo del umbral predefinido [182].

La caracterización y predicción del funcionamiento de la batería en sistemas de energía renovable (RES, por sus siglas en inglés) es muy complicado debido a los muchos procesos de envejecimiento involucrados. Algunos de los métodos más utilizados para estimar el SOH de la batería son: conteo de culomb [183], voltaje de circuito abierto (OCV) [184], espectroscopia de impedancia electroquímica (EIS) [185, 186], filtros kalman (KF) [187], Máquina de vectores de soporte (SVM) [188, 189], lógica difusa [105], mínimos cuadrados [190], redes neuronales (NN) [180, 191], entropía de muestra, modelo autoregresivo (AR) con optimización de enjambre de partículas (PSO) [192], entre otros métodos. La clasificación y la explicación detallada de los métodos de estimación de SOH se presentan en [165, 182, 193].

En este Capítulo, al igual que en el anterior se utiliza el algoritmo PSO+P en la identificación de los parámetros internos que están directamente asociados con la capacidad del banco de batería.

La información para llevar a cabo esta investigación es tomada de la base de datos del LadER [152, 153] del departamento del Chocó.

4.1.METODOLOGÍA

La metodología aplicada para hallar los parámetros internos del banco de batería es explicada en el Capítulo 2, Sección 2, y en la referencia [194] enfocándose especialmente en aquellos parámetros relacionados con la capacidad de la batería.

La resistencia interna, la evolución temporal de SOC y la capacidad real del banco de batería se expresan mediante las ecuaciones (5), (6) y (9) respectivamente, donde $\beta_c = 0$ °C.

El *SOH* es estimado mediante la ecuación (27):

$$SOH = \frac{C_{actual_max}}{C_N} \times 100\% \quad (27)$$

Donde C_{actual_max} es la capacidad máxima actual y C_N es la capacidad nominal.

El error absoluto medio (MAE, por sus siglas en inglés) y la raíz del error cuadrático medio (RMSE, por sus siglas en inglés) entre la señal simulada y la señal real es calculado mediante las ecuaciones (28) y (29):

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (28)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (29)$$

4.2. RESULTADOS Y DISCUSIÓN

4.2.1. Validación experimental

Para verificar la precisión del método desarrollado se simula y se valida experimentalmente con los resultados de voltaje y SOC de dos meses (Diciembre y Enero). Una vez identificados los parámetros se validan con el mes de Febrero del año 2018. Los datos correspondientes al mes de Febrero de 2018 son utilizados para llevar a cabo la estimación del SOC, voltaje, resistencia interna, capacidad y SOH del banco de baterías de plomo-ácido. Los resultados de la estimación obtenidos con el algoritmo propuesto para el SOC y voltaje de la batería se muestran en la **Figura 4.1** y **Figura 4.2** respectivamente.

La **Figura 4.1**, muestra muy buenos resultados entre el SOC estimado y el SOC medido obteniendo un MAE de 0.20, un RMSE de 0.35 y una media del 87%, mejorando así el error del 5% reportado en [187].

Cabe destacar que en los estudios de estimación de SOC reportados en la literatura previa a esta investigación los resultados se obtuvieron con pruebas en las que el tiempo

de simulación fue relativamente bajo (no más de 24 horas), lo que puede llevar a un error de medición más bajo durante la estimación.

Comparando los resultados obtenido de la señal del voltaje simulado con la señal del voltaje medido (ver **Figura 4.2**), se observa que el MAE y RMSE son 0.17 y 0.32 respectivamente, con una media de 51 V como es presentado en la **Tabla 4.1**.




Figura 4.1. Mediciones y simulación SOC del banco de baterías de plomo ácido. Febrero 2018.

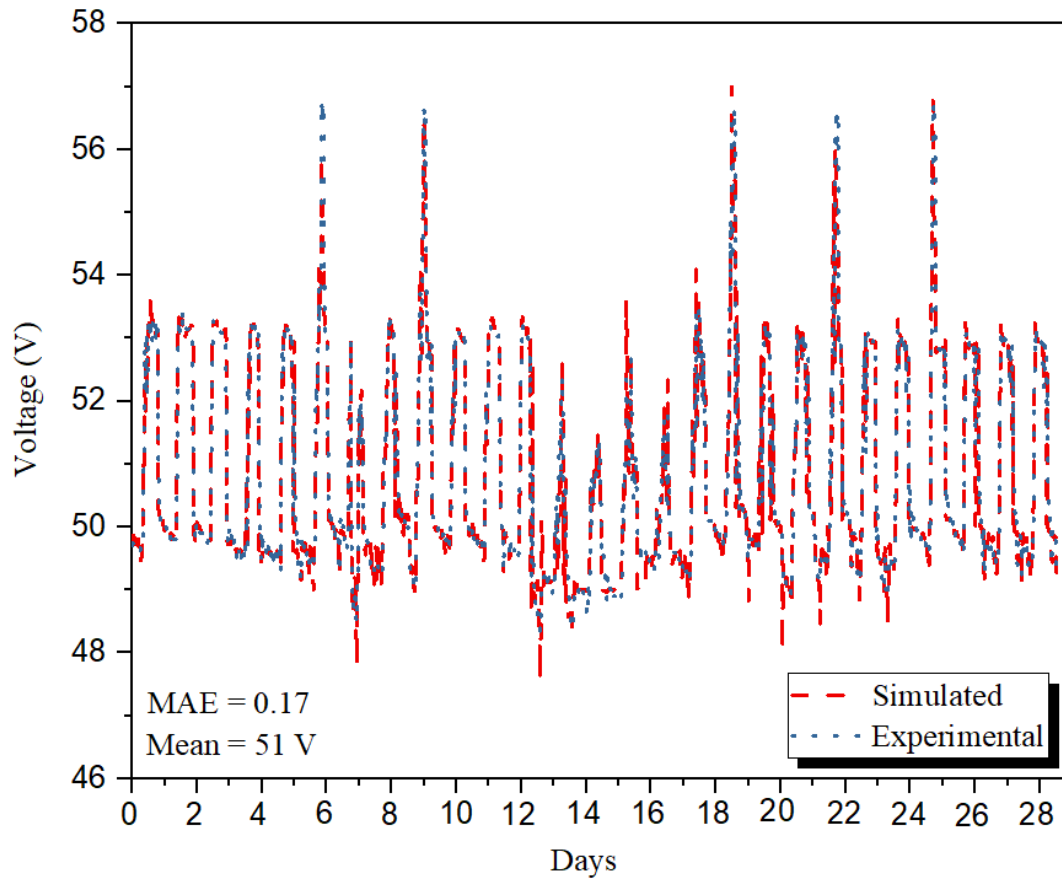


Figura 4.2. Mediciones de voltaje de banco de baterías de plomo ácido y simulación. Febrero 2018.

Estos resultados mejoran lo que se informó anteriormente en la literatura, por ejemplo, lo que se informó en [144] y [146] donde el error medio más bajo alcanzado fue de 0.66 y 0.46 respectivamente. Por lo tanto, el modelo como el método de ajuste es adecuado para la aplicación.

Tabla 4.1. Cálculo de las mediciones de error de SOC y voltaje del banco de batería.

Variable	MAE	RMSE	Mean	CC	SD
Voltaje	0.17	0.32	51	0.982	0.310823
SOC	0.20	0.35	87	0.999	0.34806

CC*: Correlation coefficient; SD*: Standard deviation.

4.2.2. Estimación del SOH de un banco de baterías de plomo-ácido.

El SOH del banco de batería se estima teniendo en cuenta la relación entre la capacidad actual y la capacidad nominal del banco de batería (ver ecuación (27)).

La **Figura 4.3**, muestra que el banco de batería presenta una reducción del 5% de su capacidad nominal pasando de 2164 Ah a 2054 Ah. Por lo tanto, el SOH se estima en un 95%. La ecuación (30) muestra la relación entre la capacidad y el SOH del banco de baterías.

$$SOH = 3.3635E - 9 + 0.0461894 * C(t) \quad (30)$$




Figura 4.3. Resultados de la simulación de la capacidad del banco de baterías de plomo y el estado de salud (SOH). Febrero 2018.

Este hallazgo indica que el banco de batería desde que fue puesto en funcionamiento no cuenta con un buen sistema de gestión de la energía, ya que como se observa en la **Figura 4.4**, durante el mes de Febrero del año 2018, el banco de batería registró en las primeras dos semanas un aumento significativo en la corriente lo que lleva a un aumento de la temperatura de la batería. Estos incrementos pueden traer consecuencias graves al funcionamiento normal del banco de batería y llevarla a un deterioro prematuro y posterior reemplazo.




Figura 4.4. Corriente medida del banco de baterías (desde enero 01/2018 hasta febrero 28/2018).

Estos resultados también confirman que durante las dos primeras semanas del mes de Febrero hubo un aumento en la resistencia interna del banco de batería (ver **Figura 4.5**), confirmando lo presentado en la **Figura 4.4**.




Figura 4.5. Resultados de la estimación de la resistencia interna del banco de batería de plomo ácido. Febrero 2018.

La evolución de los parámetros asociados a la capacidad de la batería es mostrada en la **Figura 4.6**. A pesar del hecho de que los valores observados implican una pérdida en el SOH, los parámetros C_{tcoef} y A_{cap} muestran una tendencia a la baja, mientras que los parámetros B_{cap} y α_c muestran una tendencia al alza. De continuar esta tendencia el SOH podría recuperarse hasta alcanzar mejores resultados.

Durante varios días el banco de batería operó bajo dos modos de carga: *carga flotante* y *carga Boost*. En el modo de carga de refuerzo (*carga Boost*), la batería tiene un alto voltaje de carga y por lo tanto, un aumento de la corriente como se muestra en la **Figura 4.4**. Si se mantiene este aumento de la corriente se deteriorará la vida útil del banco de baterías.




Figura 4.6. Evolución de los parámetros asociados con la capacidad de la batería obtenida durante el proceso de simulación. Febrero 2018.

4.3. CONCLUSIÓN

El presente estudio se diseñó para estimar el SOH de un banco de baterías de plomo-ácido que está operando en el Lader del departamento del Chocó. El método propuesto basado en el algoritmo PSO+P permite estimar el SOC, el voltaje, la resistencia interna y el SOH del banco de batería. A diferencia de otros métodos, el método propuesto es aplicado a grandes bases de datos.

La investigación llevada a cabo permite identificar posibles tendencias de algunos parámetros que ayuden a desarrollar técnicas que permitan pronosticar o estimar el SOH

de un banco de batería experimental. Además, los resultados de esta investigación demuestran que el banco de baterías presenta una pérdida de capacidad operativa y un aumento de la resistencia interna. Por lo tanto, se requiere hacer una intervención inmediata que permita implementar en el banco de batería un buen sistema de gestión de la energía que frene la pérdida de capacidad y conlleve a la pronta recuperación del SOH.

Capítulo 5

5. DIAGNÓSTICO DE UN SISTEMA DE ALMACENAMIENTO DE ENERGÍA EN BATERÍA BASADO EN EL ANÁLISIS DE COMPONENTES PRINCIPALES

El servicio de electricidad es de gran importancia para el desarrollo de una nación. Sin embargo, más de 1.100 millones de la población mundial carecen de acceso a la electricidad [195]. El 85% de esta población vive en áreas rurales donde llevar la interconexión de la red eléctrica puede ser muy costoso [195]. Algunas de estas poblaciones suplen esta necesidad con generadores diésel. Sin embargo, los avances del mercado en energías renovables están llevando a la sustitución de estos generadores con sistemas fotovoltaicos independientes o generadores híbridos renovables [196]. En estos casos, la tecnología más utilizada para almacenar energía es la batería. En aplicaciones fuera de la red el almacenamiento de energía es un componente crucial para garantizar la confiabilidad de estos sistemas de energía renovable independientes [197]. Estos sistemas utilizan principalmente baterías de plomo ácido como una forma de almacenar electricidad [198]. Además, esta tecnología es de bajo costo, madura y tiene procesos de reciclaje eficientes [185]. Los avances en la tecnología de iones de litio permiten que este tipo de baterías se utilicen en sistemas de energía renovable [199-201]. Sin embargo, en 2015 el mercado de baterías de plomo ácido aumentó a \$37 mil millones [202, 203], por lo que esta tecnología aún se está utilizando como lo demuestra la investigación desarrollada en [204], y funcionará por mucho tiempo.

Durante su funcionamiento, las baterías están sujetas a diferentes procesos de carga y descarga, estrés y cambios de temperatura que afectan su estado de salud (SOH). La reducción de SOH, implica pérdida de capacidad y un aumento de la resistencia interna. El SOH se utiliza para conocer las condiciones en las que una batería ha evolucionado desde su puesta en marcha [179, 180], y generalmente se define en función de la capacidad máxima actual y su capacidad nominal [205, 206]. Realizar un diagnóstico del SOH de la batería permite al operador detectar posibles fallos de la batería y realizar un mantenimiento o reemplazo oportuno de la batería [181]. El estudio de los parámetros internos de la batería abre un campo de investigación para mejorar el sistema de administración de la batería. Investigaciones anteriores muestran diferentes métodos para identificar los parámetros internos de una batería [137, 144-146, 194]. Estos parámetros están asociados con la capacidad, la resistencia interna y el voltaje de la batería. Sin embargo, no hay informes de investigación anteriores que analicen la evolución a lo largo del tiempo de estos parámetros y su relación con el SOH de la batería. Este Capítulo, propone el estudio de los parámetros internos de un BESS y su

evolución en el tiempo para generar información útil que permita realizar el monitoreo y diagnóstico del SOH.

Debido a que el número de datos a administrar es relativamente alto, es muy común en ingeniería utilizar una estrategia para encontrar estructuras de correlación entre las variables. Una de estas estrategias es el análisis de componentes principales (PCA, por sus siglas en inglés). De acuerdo con [207, 208], PCA es una técnica de control de proceso estadístico multivariado que reduce la dimensionalidad de un espacio original que se establece a partir de los datos históricos de las variables medidas a un espacio de menor dimensionalidad buscando combinaciones lineales entre las variables que mejor describe la tendencia del proceso. El método PCA se basa en la descomposición de la matriz de covarianza de las variables del proceso a lo largo de las direcciones que explican mejor las principales causas de variabilidad de la información analizada [209-211].

En este Capítulo, se realiza un diagnóstico del SOH de un BESS aplicando PCA a los parámetros internos de un BESS. La metodología utilizada para identificar y extraer los parámetros internos del BESS se explica en [194], y se proponen acciones de control que llevan al BESS a funcionar en condiciones normales.

Como se ha mencionado anteriormente, el BESS ha estado trabajando desde hace tres años, tiempo en el cual se han recopilado datos con un tiempo de muestreo de 15 minutos [152, 153]. El BESS está compuesto por 24 acumuladores electroquímicos Techno Sun 2V-OPzS-TCH2765 (C10 = 2164 Ah; C120 = 2765 Ah) conectados en serie.

5.1.METODOLOGÍA

5.1.1. Visión general

Para llevar a cabo este diagnóstico, primero utilizamos el modelo de batería desarrollado por Copetti [137] para representar el voltaje y el estado de carga del BESS. Luego identificamos los parámetros internos de BESS mediante el uso del algoritmo PSO el cual se explica en [194]. A los parámetros identificados se les aplica un modelo de PCA y se identifican las causas que afectan al modelo. Finalmente, se proponen acciones de control que llevan al BESS a trabajar en condiciones normales.

Para identificar los parámetros internos del BESS utilizamos nuevamente la metodología presentada en [194], donde se demuestra la eficacia y precisión del método propuesto. El conjunto de parámetros identificado para cada día son los datos iniciales para realizar el diagnóstico del SOH del BESS por análisis de componentes principales (PCA), siguiendo los pasos descritos a continuación:

Se modelan los datos con el objetivo de establecer un método para monitorear el funcionamiento del sistema de almacenamiento de energía en baterías. La idea consiste en tomar toda la matriz de datos (X) (de 31 registros y 26 parámetros relacionados con el SOH del BESS). La matriz X contiene la información de cómo se comporta el BESS cuando se encontraba funcionando en condiciones normales. EL PCA nos entrega unos parámetros resumen (cargas factoriales) que emplearemos para monitorear el funcionamiento posterior del BESS utilizando los nuevos registros de datos (X_{new}). Una vez hallada las cargas factoriales tomaremos la matriz de observaciones restantes (X_{new}) y verificaremos día a día si el comportamiento de estas observaciones es similar al inicial (mostrado en X) o si existen evidencias de algún cambio. Esto lo hacemos a través de dos gráficos de control (T^2 , SPE) que se interpretan de forma muy sencilla. Por debajo del límite el comportamiento es similar al habitual, por encima del límite hay un cambio en el funcionamiento.

Para hacerlo se deben abordar las siguientes fases en el análisis:

1. Análisis descriptivo de la matriz inicial (X).
 - Gráficos de tendencia.
 - Diagramas de dispersión entre variables.
 - Cálculo de coeficientes de correlación.
 - Identificación de datos atípicos.
2. Análisis de Componentes Principales (X).
 - Selección e interpretación de las componentes principales.
 - Identificación de observaciones anómalas.
 - Establecimiento de los gráficos de control T^2 y SPE (squared prediction error, por sus siglas en inglés) para X .
3. Monitoreo de nuevas observaciones.
 - Proyección de las nuevas observaciones en las componentes principales.
 - Representación en los gráficos de control.

5.2. ANÁLISIS DE COMPONENTES PRINCIPALES (PCA)

PCA es una técnica utilizada para reducir la dimensionalidad de un conjunto de datos que intenta perder la menor cantidad de información posible [208, 212]. PCA permite determinar las variables que más contribuyen a diferenciar las muestras y detectar correlaciones entre las variables. Cuando se aplica PCA se genera una nueva variable del sistema llamada componente principal (PC, por sus siglas en inglés). La primera PC recoge la mayor parte de la información contenida en la matriz de datos original; la segunda PC proporciona un máximo de la variación residual resultante, y así sucesivamente [213, 214]. Los resultados de PCA se pueden representar en los gráficos de "scores" y "loadings" [215]. La tabla de "scores" representa las diferencias y las similitudes entre las muestras y se utiliza para encontrar grupos entre ellas. El gráfico de

“loadings” determina la correlación entre variables. La representación univariada de los “loading” p_a contribuye a identificar las variables de mayor influencia en cada PC y asociar una interpretación práctica para los componentes.

A través de un gráfico bivariado de loadings (p_a vs $p_{a'}$) se obtiene una representación parcial de la estructura de correlación habitual entre las variables de la matriz original X . En esta representación la ubicación de las variables en la misma dirección y alejadas del origen es un indicador de correlación positiva. Por el contrario, su ubicación en la dirección opuesta indica una correlación negativa. Los grupos variables con baja correlación se ubicarán en direcciones perpendiculares distantes del origen. La similitud entre los registros de X se puede evaluar a través de gráficos bivariados de los “score” (t_a vs $t_{a'}$). Los individuos promedio se ubicarán en el centro del gráfico, mientras que los individuos excéntricos son los que más contribuyen para cada PC.

5.3.APLICACIÓN PRÁCTICA DEL PCA.

Para monitorear un sistema multivariado como el conjunto de parámetros internos de un BESS es esencial conocer ampliamente su comportamiento habitual y la estructura de correlación entre sus variables. Estos elementos pueden caracterizarse utilizando los datos recopilados durante un período de referencia (*Fase I*) en el que el sistema ha funcionado en condiciones normales o deseadas. Los datos recopilados en la *Fase I* se utilizan para ajustar un modelo estadístico que reproduce el comportamiento habitual del BESS. Más adelante en la *Fase II*, el modelo de la *Fase I*, se utiliza para evaluar la concordancia de observaciones futuras. En PCA la matriz de observación X (ecuación (31)), se descompone en un conjunto de matrices A ($A < \text{rango}(X)$) de rango 1 [216].

$$X = \sum_{a=1}^A t_a * p_a^T + \sum_{a=A+1}^{\text{rank}(X)} t_a * p_a^T = T * P^T + E \quad (31)$$

$P \in R^{K \times A}$ es la matriz “loading” compuesta por los vectores propios (p_a) asociados con los valores A más altos (λ_a) de la matriz de covarianza de X . K indica el número de variables; A es el número de componentes principales y N indica el número de muestras.

Los vectores p_a ($a = 1, 2, \dots, A$) contienen los coeficientes de las variables originales de X en las PC y definen las A direcciones de mayor variabilidad. $T \in R^{N \times A}$ es la matriz “score” que contiene la ubicación de las proyecciones de las filas de X sobre el subespacio A -dimensional ($T = XP$). Cada columna de T es un vector t_a ($a = 1, 2, \dots, A$) que representa la a -sima PC. La matriz $E \in R^{N \times K}$ almacena los residuos obtenidos al

predecir X a partir de $T * P^T (E = X - T * P^T)$. De manera que E (matriz residual) contiene la información de X que no es explicada por el modelo PCA.

PCA es una técnica escala-dependiente. Esto quiere decir que los resultados del PCA pueden variar notoriamente dependiendo de la escala de medición de las variables. En el monitoreo multivariante es muy frecuente que las escalas de las variables sean notoriamente diferentes, por lo cual es necesario realizar una labor previa de escalado de las columnas de la matriz X . Un procedimiento muy común consiste en estandarizar (centrar respecto a su media y escalar por la desviación estándar) cada una de las columnas de la matriz X . Con este preprocesamiento se pretende que todas las variables presenten el mismo peso en la construcción del modelo PCA.

También es común encontrar que la matriz de datos X está formada por pequeños subconjuntos o bloques de variables cada uno de los cuales contiene información sobre una característica particular del sistema. En estos casos, la contribución de cada bloque de variables se puede nivelar mediante un procedimiento de escala por bloque. En este preprocesamiento cada variable ($X_{.j}$) se centra con respecto a su valor promedio ($\bar{X}_{.j}$), y se escala según el producto entre su desviación estándar ($S_{.j}$) y la raíz cuadrada del número de parámetros ($\sqrt{K_h}$) que forman el bloque h -sima (al que pertenece la variable). Esta escala se representa en la ecuación (32). Una matriz de datos transformados (X^*) es generada con este procedimiento en el que cada bloque de parámetros proporciona el mismo nivel de variabilidad.

$$X_{.j}^* = \frac{X_{.j} - \bar{X}_{.j}}{\sqrt{K_h} * S_{.j}} \quad (32)$$

En la construcción del modelo PCA el usuario debe decidir el número de PCs (A) que se retienen para el análisis. Para determinar este número generalmente se usa un criterio de calidad para representar los datos en el nuevo subespacio. Uno de los criterios más utilizados es la variación porcentual acumulada (CPV, por sus siglas en inglés) [217], el cual se representa a través de la ecuación (33):

$$CPV(A) = \frac{\sum_{a=1}^A \lambda_a}{\sum_{a=1}^{rank(X)} \lambda_a} \times 100\% \quad (33)$$

A priori se define un valor umbral para el porcentaje de varianza explicado y se retiene el mínimo número de componentes necesarias para superar el umbral preestablecido. Una vez las A componentes son seleccionadas, los elementos del modelo PCA (T, P, E) son empleados para comprender el sistema de componentes principales, estudiar la

correlación entre las variables de X , evaluar la similaridad entre los registros e identificar observaciones extremas en el conjunto de datos de referencia. La identificación de observaciones extremas se realiza utilizando la información contenida en la matriz de scores (T) y en la matriz de residuales (E). El modelo PCA transforma cada observación (fila) de la matriz X^* , $x_i = (x_{i1}, x_{i2}, \dots, x_{ik})$ en un vector de proyecciones en las componentes principales $t_i = (t_{i1}, t_{i2}, \dots, t_{iA})$ y un vector de residuos $e_i = (e_{i1}, e_{i2}, \dots, e_{ik})$. Este par de vectores se resumen en dos estadísticos independientes: el estadístico T^2 de Hotelling (ecuación (34)) y la Suma de los Errores de Predicción al Cuadrado (SPE) ecuación (35)).

$$T_i^2 = t_i^T \theta^{-1} t_i = \sum_{a=1}^A \frac{t_{ia}^2}{\lambda_a} \quad (34)$$

$$SPE_i = e_i^T * e_i = \sum_{j=1}^K e_{ij}^2 \quad (35)$$

Aquí $\theta = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_A)$ es la matriz diagonal de los A valores propios asociados a las PC retenidas en el modelo PCA. Bajo el supuesto de que el vector de score t_i sigue una distribución normal multivariada, un límite de control superior (UCL, por sus siglas en inglés) al $(1-\alpha)$ % para el estadístico T^2 puede ser fijado en (ecuación (36)):

$$UCL_{T^2} = \frac{(N^2 - 1)A}{(N - A)N} F_{\alpha, A, N-A} \quad (36)$$

Donde $F_{\alpha, A, N-A}$ es el valor crítico de una variable aleatoria con distribución F (Fisher-Snedecor), con A grados de libertad en el numerador y $N - A$ grados de libertad en el denominador, y α es el nivel de significación [211, 217, 218]. Zhao et al. [219] sugiere establecer el límite de control para el estadístico SPE en el valor crítico de una distribución ponderada de chi-cuadrado ($g\chi_h^2$). Donde g es el peso y h son los grados de libertad. Nomikos et al. [220] sugieren aproximar el valor de los grados de libertad h y de la ponderación g igualando la media y la varianza de la distribución $g\chi_h^2$ con el promedio muestral (m) y la varianza muestral (v) del estadístico SPE en las observaciones de la *Fase I*. Por lo tanto, el límite de control al $(1 - \alpha)$ % para SPE se puede establecer como (ecuación. (37)):

$$UCL(SPE) = \frac{v}{2m} \chi_{\frac{2m^2}{v}, \alpha}^2 \quad (37)$$

Donde, $g = v/2m$ y $h = 2m^2/v$

Los estadísticos T^2 y SPE son calculados para cada fila de la matriz X^* y se representan gráficamente junto con los límites de control. Los dos estadísticos contienen información complementaria para identificar observaciones extremas en el conjunto de datos, sin embargo, su interpretación es notablemente diferente. Un punto que es señalado por el estadístico T^2 corresponde a una observación cuyas proyecciones en el espacio de las componentes son muy extremas. Esto quiere decir que esta observación presenta un valor anormal en una o varias de las variables pero que mantiene en la dirección de la estructura de correlación habitual. Este punto es rotulado como observación extrema dentro del modelo PCA. De otro lado, un punto que es señalado por el estadístico SPE corresponde a una observación cuyo pronóstico a través del modelo PCA es significativamente diferente de su valor observado. En este caso una o más de las variables presentan un valor anormal que no corresponde con la estructura de correlación habitual. Este punto es rotulado como observación extrema fuera del modelo PCA.

La presencia de estos puntos extremos pueden condicionar notablemente los resultados obtenidos en el modelo PCA. Por lo tanto, cuando son identificados en la *Fase I* es conveniente retirarlos de la matriz de observaciones y ajustar nuevamente el modelo.

En la *Fase II*, el modelo PCA final de la *Fase I* es empleado para monitorear nuevas observaciones del proceso. En esta fase cada nueva observación multivariante x_{new} es proyectada sobre el subespacio de las componentes principales calculando el vector de score ($t_{new} = x_{new}P$) y el vector de errores de pronóstico $e_{new} = x_{new} - t_{new}P^T$ con los cuales se calculan los estadísticos T^2 y SPE y se representa la observación en los dos gráficos de control. Si algunos de los dos estadísticos superan el límite de control, se genera una señal de cambio y se debe proceder a identificar la(s) variable(s) involucradas en el cambio.

En el monitoreo de procesos multivariantes los gráficos de contribución son una de las herramientas más empleadas para diagnosticar las potenciales variables asociadas a una señal de cambio. Cuando la observación es señalada por el gráfico SPE la contribución de la variable $j=1,2,\dots,k$, sobre el estadístico SPE corresponde al error de pronóstico cuadrático (se retiene el signo del error para facilitar la interpretación) como es mostrado en la ecuación (38):

$$C_j^{SPE} = \text{sign}(e_{new,j}) * e_{new,j}^2 \quad (38)$$

Si la observación es señalada por el estadístico T^2 , la contribución de la variable j al estadístico T^2 se calcula con la ecuación (39):

$$C_j^{T^2} = \sum_{a=1}^A \frac{t_{new,a} * e_{new,j} * p_{j,a}}{\lambda_a} \quad (39)$$

Por lo tanto, las variables con la mayor contribución al estadístico pueden identificarse como causa potencial de la perturbación de la señal. Además de los gráficos T^2 de Hotelling, SPE y de contribución, la representación gráfica de la proyección de las nuevas observaciones en el espacio de cada PC junto con las gráfico bivariado de

loadings son muy útiles para identificar las observaciones extremas y las posibles variables asociadas que causan el problema.

5.4.ACCIONES DEL CONTROLADOR

El inversor Sunny Island™, es un controlador comercial encargado de hacer la gestión de la batería.

El controlador aplica una estrategia de carga (boost, full, float or equalization) que dependerá del SOC y la configuración de la batería. **La Figura 2.5** [53], muestra las diferentes fases de carga del Sunny Island™. En el modo de carga de refuerzo (Boost Charge) y carga completa (Full Charge) se aplica un voltaje de carga de 2.4 V a las celdas del BESS, mientras que en el modo de carga de flotación (Float charge) y carga de ecualización (Equalization Charge) se aplica un voltaje de 2.25 V y 2.5 V respectivamente a las células del BESS. Cuando el BESS funciona en condiciones normales el controlador mantiene una carga flotante. Sin embargo, debido a las diferentes condiciones de operación el controlador puede usar otros modos de carga más agresivos: carga rápida, carga completa o carga de ecualización. Los diferentes modos de carga que experimenta el BESS pueden provocar un aumento de la corriente (ver **Figura 5.1**) y por lo tanto, un aumento de la temperatura en la batería. Este aumento en la corriente y la temperatura puede conducir a un deterioro prematuro de la batería.




Figura 5.1. Mediciones de un año de la corriente del BESS, tomadas del laboratorio de energía renovable en Chocó - Colombia.

Teniendo en cuenta este comportamiento anormal de la corriente del BESS, se procede a realizar un diagnóstico por PCA, encontrar las posibles causas y proponer soluciones que lleven al BESS a funcionar en condiciones normales.

5.5.APLICACIÓN DEL MODELO PCA AL BESS.

5.5.1. Fase I: Construcción del modelo PCA.

La caracterización del comportamiento habitual de los parámetros internos del BESS se realiza a través de un modelo de PCA. Como datos de referencia se utilizan los registros diarios correspondientes al mes de Octubre del año 2017 (31 registros). Cada registro contiene la medición de 13 parámetros que son evaluados en las fases de carga y descarga del BESS. Estos parámetros se agrupan en tres bloques según su relación con las características de desempeño del BESS. La **Tabla 5.1**, presenta la definición de los parámetros considerados y la característica relacionada¹.

Tabla 5.1. Parámetros considerados para el diagnóstico del BESS.

Parámetros	Característica / Bloque
$P_1, P_2, P_3, P_4, P_5, \alpha_r$	Resistencia Interna
$C_{coef}, A_{cap}, B_{cap}, \alpha_c, K_{c10}$	Capacidad
V_{boc}, K_{boc}	Voltaje de circuito abierto

Así, el conjunto de datos de referencia (X) corresponde a una matriz de 31 registros y 26 parámetros relacionados con el SOH del BESS. En esta matriz inicial cada parámetro tiene su propia escala de medida. Además, como muestra la **Tabla 5.1**, la cantidad de parámetros que conforman cada bloque no es homogénea. Por lo tanto, existe un desequilibrio en la contribución de cada bloque de parámetros, sobre la variabilidad total de la matriz de datos de referencia.

Para nivelar la contribución de cada bloque a la variabilidad total se realiza un procedimiento de escalado (como el descrito en 5.3) por bloque. Con la matriz de datos preprocesados (X^*) se construye un primer modelo de PCA cuyo objetivo es verificar la estabilidad de los datos de referencia e identificar puntos atípicos o influyentes en el modelo de PCA.

Los gráficos de control T^2 de Hotelling y SPE con límites de control establecidos con un nivel de significación del 1% se utilizan para el diagnóstico de las observaciones. Como se muestra en la **Figura 5.2a**), las primeras 5 PC retienen el 80.25% de la variabilidad total. Observaciones atípicas o influyentes no se presentan en el conjunto de datos de referencia (ver **Figura 5.2b**)).

¹ Tenga en cuenta que cada parámetro tiene un valor para el proceso de carga y otro para el proceso de descarga.

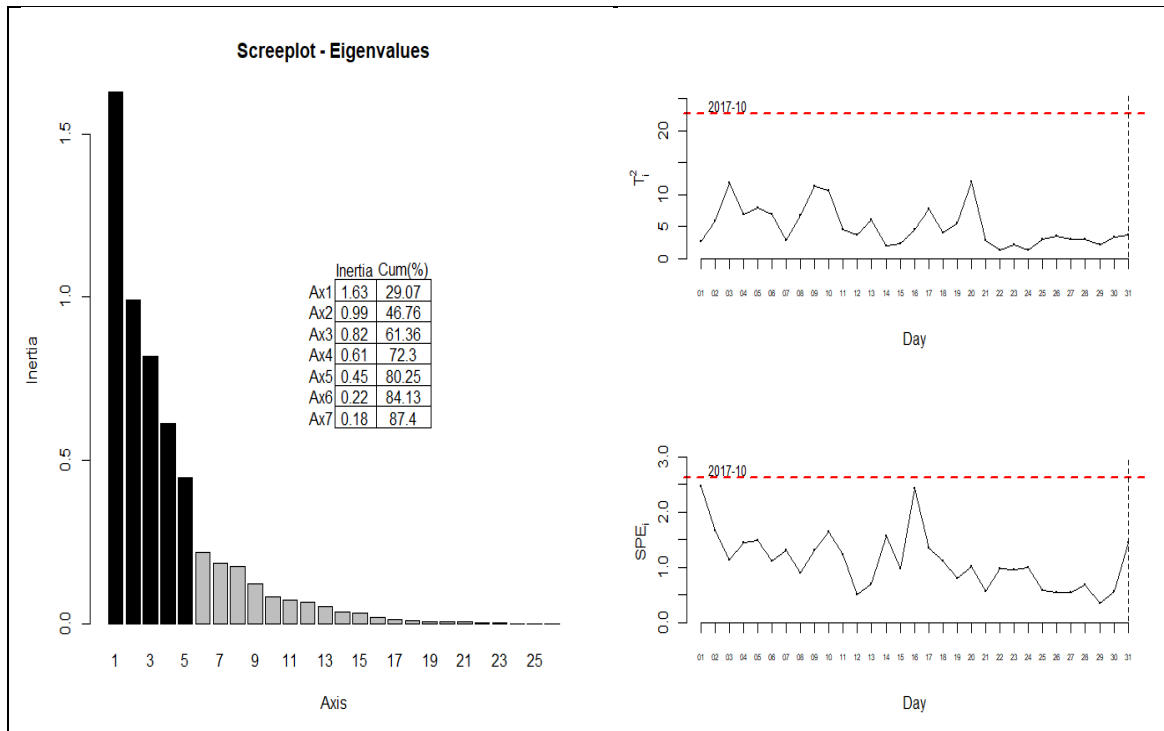


Figura 5.2. a) Gráfico del modelo final de PCA. b) Los gráficos de control T^2 de Hotelling y SPE para los datos de referencia filtrados.

El conjunto de PC constituye un conjunto de indicadores del SOH del BESS que se calculan a partir de la información contenida en los parámetros ponderados según los coeficientes ilustrados en la **Figura 5.3**. En cada estado (carga y descarga) del BESS, los parámetros que tienen más peso son: K_{boc} , K_{c10} , C_{tcoef} , A_{cap} , B_{cap} . Cuando se trabaja con 5 PC cada marcador evoluciona sobre un espacio de 5 dimensiones y es habitual utilizar las proyecciones sobre cada subespacio bidimensional para mostrar su evolución. Por lo tanto, 5 PC generan 10 combinaciones de PC (1-2, 1-3, 1-4, 1-5, 2-3, 2-4, 2-5, 3-4, 3-5, 4-5) con igual número de gráficos (ver **Figura 5.4**).

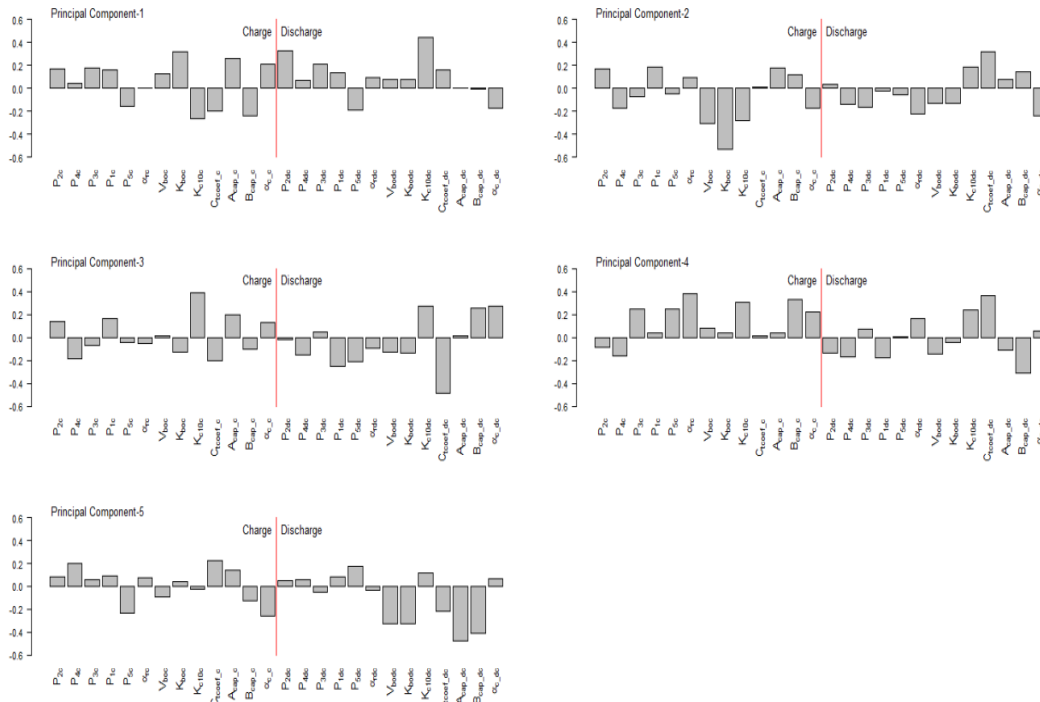

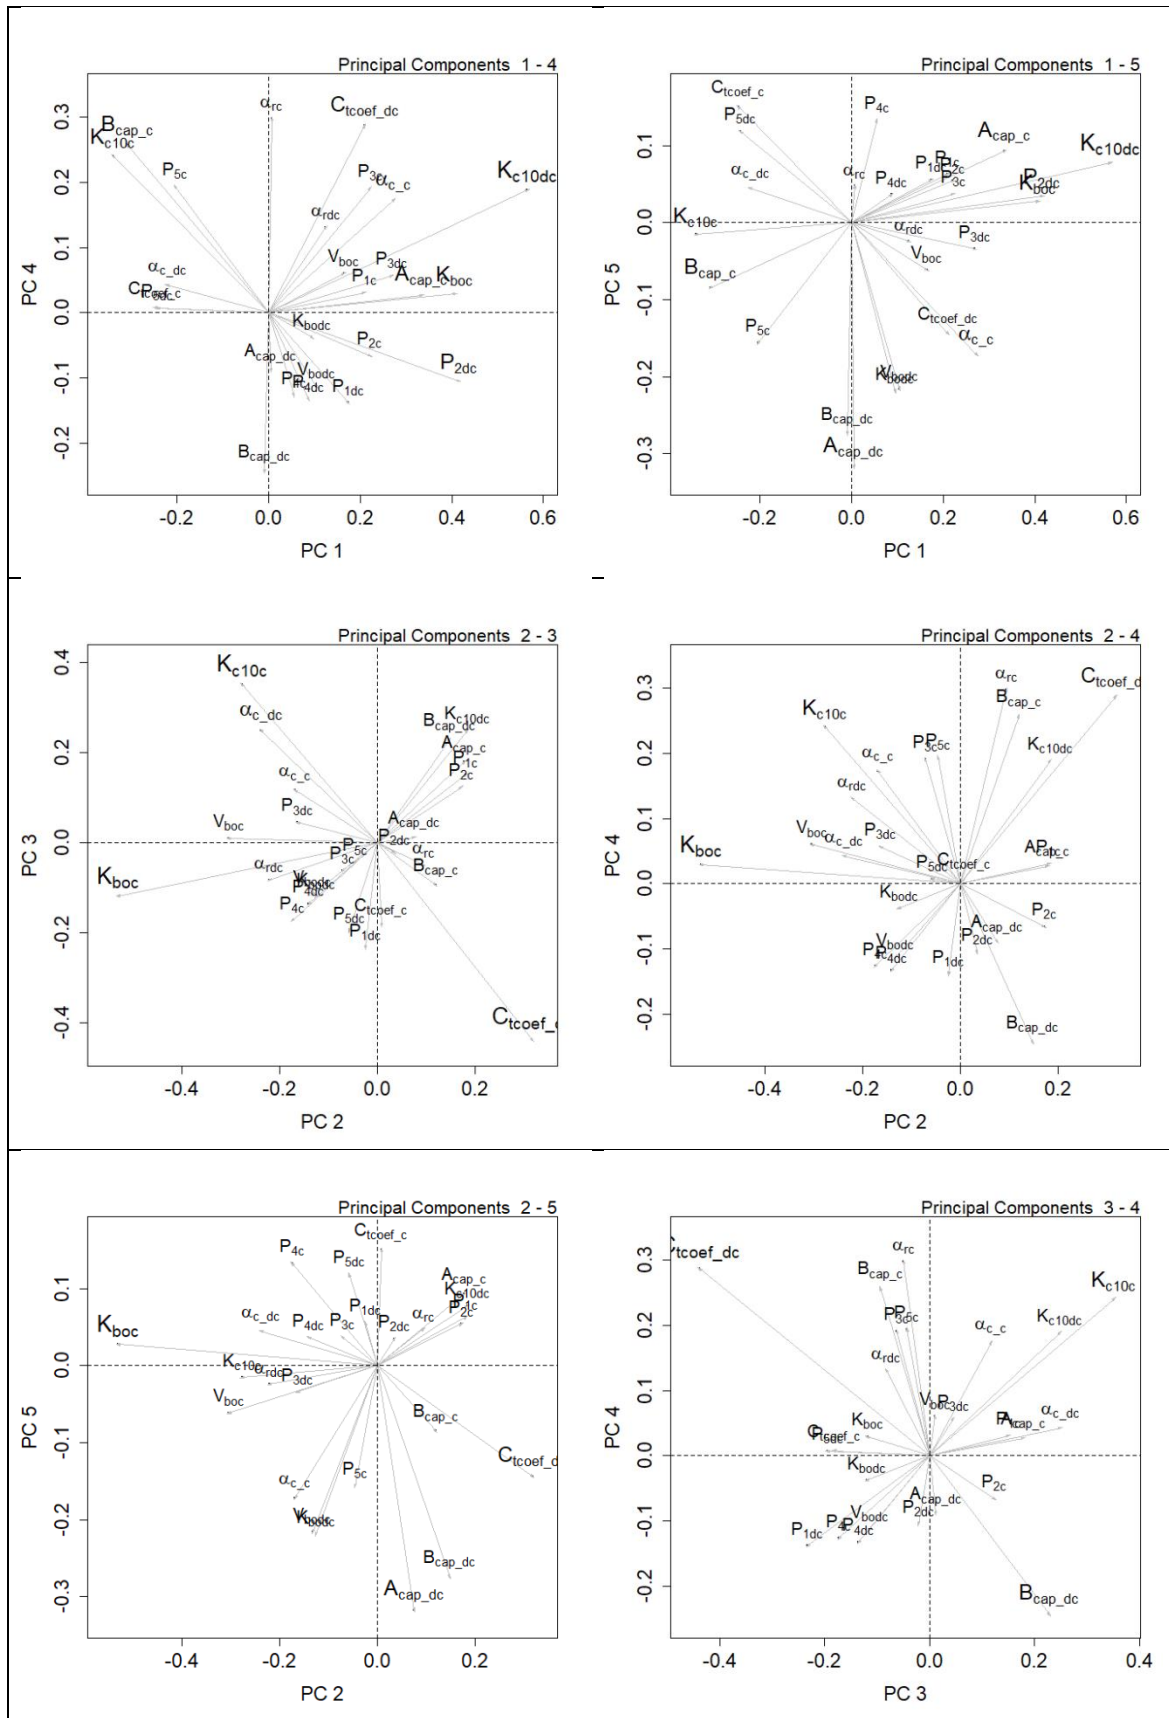


Figura 5.3. Coeficientes (loadings) de los parámetros en cada PC.

La **Figura 5.4**, muestra la representación de los parámetros del sistema en el espacio de las componentes principales. Nótese que en todos los planos factoriales los parámetros K_{c10c} y α_{c_dc} se ubican en la misma dirección lo cual indica alta correlación positiva. Por el contrario, el parámetro C_{tcoef_dc} se ubica siempre en dirección opuesta K_{c10c} y α_{c_dc} indicando la existencia de correlación negativa.





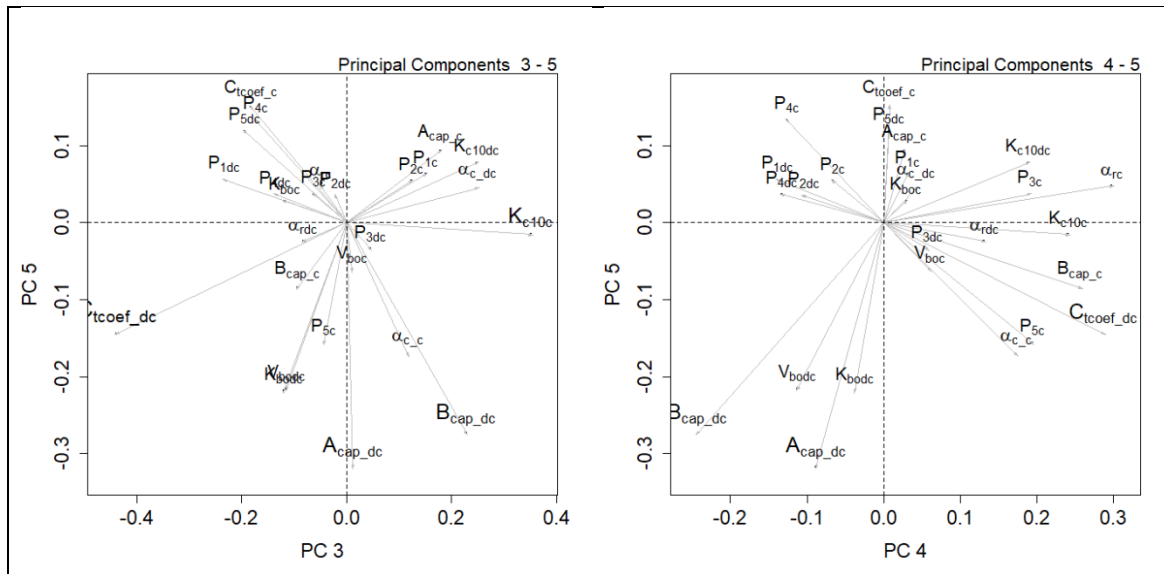


Figura 5.4. Proyecciones de las PCs sobre cada subespacio bidimensional.

5.5.2. Fase II – Diagnóstico de nuevas observaciones

El modelo PCA identificado en la *fase I* se utiliza para diagnosticar nuevas observaciones de los parámetros internos del BESS. Cada día un conjunto de nuevas observaciones se organiza en la matriz de datos X_{new} cuyas columnas reciben la misma transformación que en la ecuación (31). Luego el T_i^2 de Hotelling's (donde i representa el día) se calcula para este conjunto de datos y se monitorea con un gráfico de control.

El gráfico de control T^2 de Hotelling con límites de control es presentado en la **Figura 5.5**.




Figura 5.5. Gráfico de control T^2 de Hotelling para el monitoreo del mes de noviembre de 2017.

Tenga en cuenta que el eje Y del gráfico de control T^2 de Hotelling determina la similitud entre dos variables aleatorias multidimensionales, es decir, la distancia (distancia de Mahalanobis) de los nuevos datos con respecto al modelo original. La diferencia con la distancia euclidiana es que la distancia de Mahalanobis tiene en cuenta la correlación entre las variables aleatorias. Para monitorear el grado de alarma este documento propone dividir el gráfico de control T^2 de Hotelling en dos regiones: Nivel 0 (sin alarma) y nivel 1 de alarma. Por debajo del límite control establecido (tasa de falsa alarma del 1%) se asume que el BESS funciona en condiciones normales. En el nivel 1 de alarma el sistema aún muestra un buen rendimiento pero su rendimiento no coincide con las condiciones de entrenamiento. Sin embargo, cuando la diferencia es mayor que $6T^2$ el sistema funciona fuera de sus condiciones normales. Por lo tanto, si los datos nuevos en el T^2 de Hotelling se ubican en el nivel 0 el sistema funciona normalmente. Cuando hay 3 o más puntos consecutivos y tendencias al alza en el nivel 1 de alarma significan que los parámetros identificados son lo suficientemente diferentes de los originales. Entonces, se inicia el procedimiento de diagnóstico. El diagnóstico completo requiere el análisis de los parámetros que causan la alarma. Por lo tanto, después del diagnóstico de la zona de alarma se debe estudiar la contribución de cada parámetro al T^2 de Hotelling. Si los puntos están ubicados en una zona de alarma entonces se deben verificar las entradas. Si hay condiciones climáticas anormales o una demanda anormal entonces las condiciones de entrenamiento son extremadamente

diferentes a las actuales, por lo que no es posible concluir que existe o no un fallo. Por lo tanto, no se requiere de ninguna acción.

- i. *Si las condiciones externas son similares a las del mes de entrenamiento del modelo PCA, y la señal de alarma es generada por los parámetros C_{coef} , A_{cap} , B_{cap} , α_c , K_{c10} , entonces la batería está entrando en un proceso de pérdida de capacidad que puede deberse a: bajo nivel de electrolito, estratificación del electrolito, bajos niveles de SOC, desprendimiento (shedding), sulfatación o degradación de la materia activa, todo ello asociado con la degradación de la batería.*

Compruebe el nivel de electrolito: si el nivel es bajo, entonces llene con agua destilada hasta el nivel recomendado por el fabricante y verifique que la densidad específica de cada celda sea la especificada por el fabricante (entre 1.265 ± 0.50 kg/l y 25 °C). Aplique una carga completa (tiempo de carga total = 5 h). El objetivo es cargar la batería hasta que alcance un SOC > 90%. Cuando la batería esté cargada aplique una carga de ecualización (tiempo de carga de ecualización = 10 h) para compensar las diferencias que pueden ocurrir en el SOC de las celdas de la batería y finalmente, cambie el modo de carga a carga flotante. Si después de aplicar este procedimiento se recupera la capacidad de la batería y $T^2 < 3.2$ entonces el sistema funciona en condiciones normales. Por lo tanto, cambie al modo de carga a carga flotante. Si el nivel de electrolito no es bajo, verifique el SOC. Si el SOC está entre el 70% y el 80% aplique una carga de refuerzo hasta que la batería alcance el 85% y el 90% de su capacidad actual (el tiempo para la carga de refuerzo de la batería = 2 h). Luego realice una carga completa (tiempo de carga total = 5 h) hasta que el SOC > 90%. Si la capacidad de la batería se recupera entonces el sistema funciona en condiciones normales. Por lo tanto, cambie al modo de carga flotante. Si el SOC > 80% entonces aplique un carga de ecualización (tiempo de carga de ecualización = 10 h). Si la capacidad de la batería se recupera entonces el sistema funciona en condiciones normales. Por lo tanto, cambie al modo de carga flotante.

Si después de aplicar todos estos procedimientos la capacidad de la batería no se recupera; entonces la batería tiene una falla que puede deberse al desprendimiento de material activo de los electrodos (shedding), sulfatación o degradación de la materia activa, entre otros, que no se pueden recuperar mediante las acciones del controlador. Entonces la batería debe ser llevada a mantenimiento o en su efecto; debe ser reemplazada por otra de igual características.

- ii. *Si la señal de alarma es generada por los parámetros P_1 , P_2 , P_3 , P_4 , P_5 , α_r , entonces la batería presenta pérdidas resistivas asociadas con condiciones de funcionamiento prolongadas en SOC muy bajos que conducen a procesos de degradación como la corrosión, lo que genera un aumento en la señal de alarma, generando un incremento en la resistencia interna y por lo tanto un mayor riesgo de fallo.*

Verifique el SOC: si el SOC es muy bajo, es decir, $SOC < 60\%$ aplique una carga de refuerzo hasta que la batería esté entre el 85% y el 90% de su capacidad actual (tiempo para la carga de refuerzo de la batería = 3 h). Luego cambie de carga de refuerzo a carga completa (tiempo de carga total = 5 h). Una vez que la batería esté cargada realice una carga de ecualización (tiempo de ecualización de carga = 10 h).

Si después de aplicar este procedimiento la resistencia interna de la batería disminuye entonces el sistema funciona en condiciones normales. Por lo tanto, cambie al modo de carga flotante. Si el $SOC > 60\%$ aplique una carga de refuerzo hasta que la batería alcance el 85% y el 90% de su capacidad actual (tiempo para la carga de refuerzo de la batería = 2 h). Luego, cambie del modo de carga rápida a carga completa (tiempo de carga total = 5 h). Si la resistencia interna de la batería disminuye entonces el sistema funciona en condiciones normales. Por lo tanto, cambie al modo de carga flotante. Si después de aplicar estos procedimientos la resistencia interna no disminuye, entonces la batería tiene una falla que no puede recuperarse con las acciones del controlador. Por lo tanto, la batería debe ser reemplazada por otra de igual característica.

- iii. *Si la señal de alarma, es generada por los parámetros V_{boc} , K_{boc} , entonces es una causa de falla de la batería que no puede ser recuperada con las acciones del controlador. Por lo tanto, la batería debe llevarse a mantenimiento o en su efecto debe ser reemplazado por otra de iguales características. Si los parámetros de voltaje de circuito abierto están dentro del rango entonces el sistema funciona en condiciones normales. Por lo tanto, cambie al modo de carga flotante.*

La **Figura 5.6**, ilustra el flujo del algoritmo de diagnóstico.

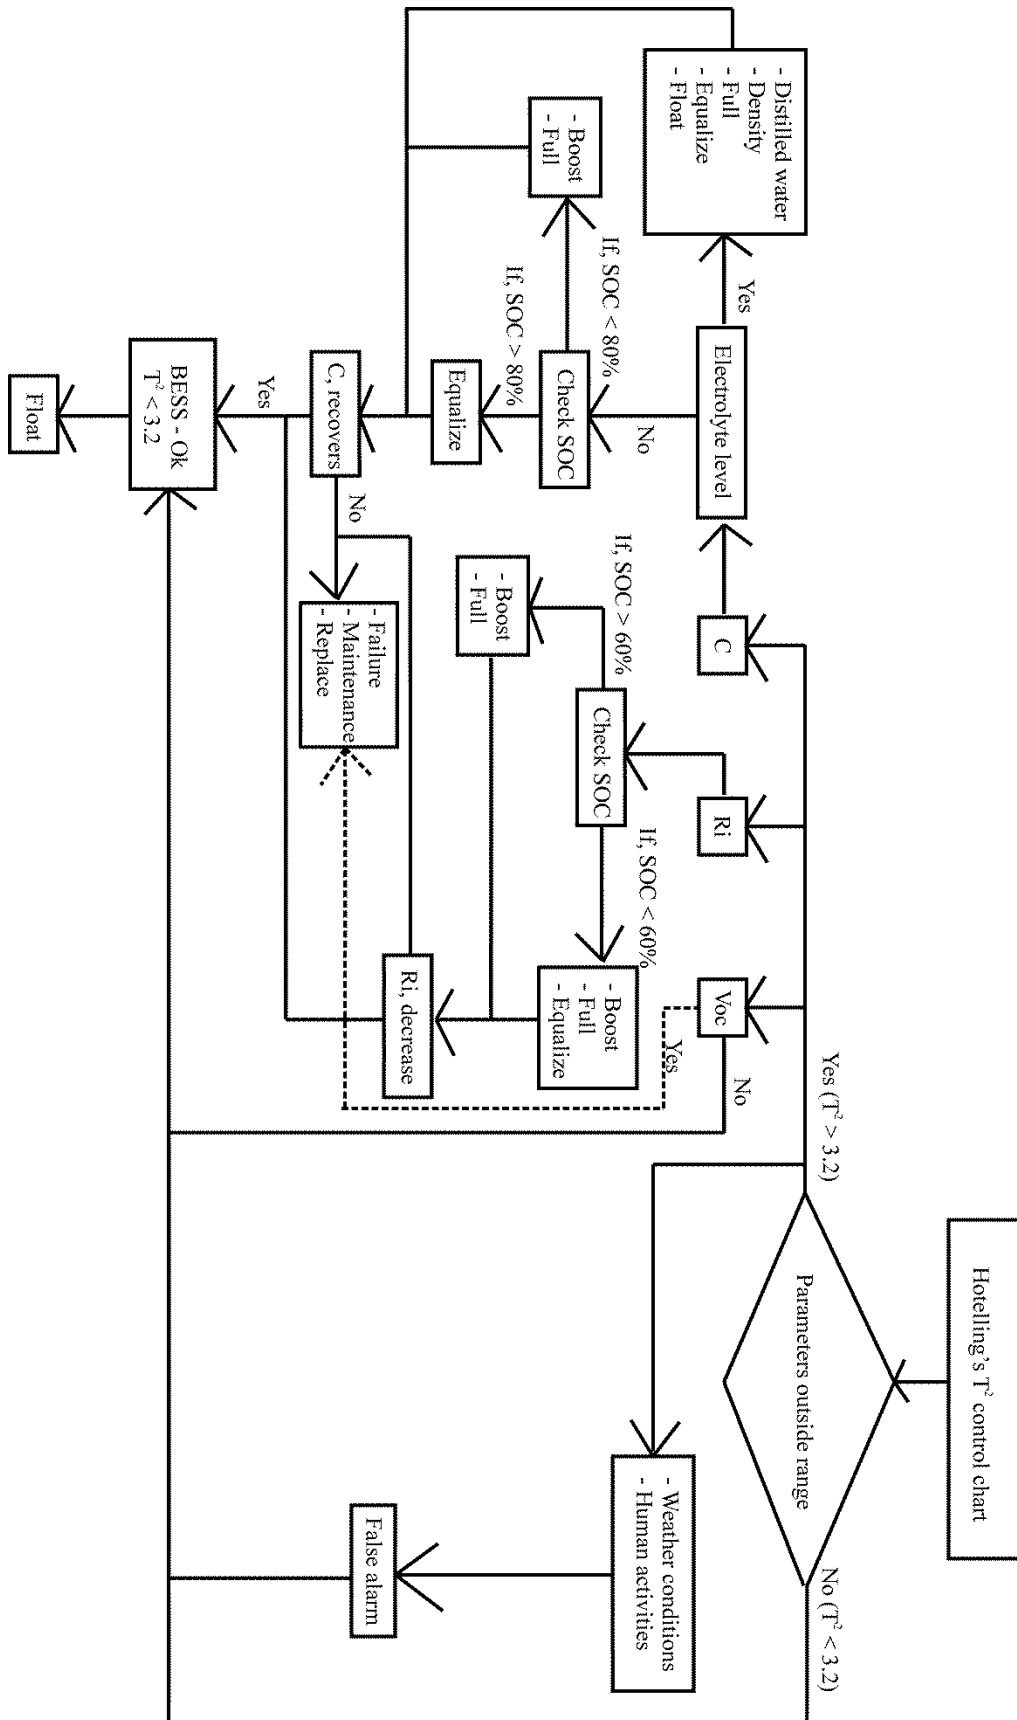


Figura 5.6. Diagrama de flujo del gráfico de control T^2 de Hotelling.

Para ilustrar el procedimiento, el monitoreo se realiza inicialmente para el mes de noviembre de 2017 (ver **Figura 5.5**). Para una mejor visualización del progreso de T^2 se utiliza una escala logarítmica. Cuanto mayor sea el valor de T^2 mayor será la distancia entre la observación y el valor objetivo.

Según el diagnóstico, el sistema muestra un comportamiento inusual en los días comprendidos entre el 12 y el 15 del mes de noviembre de 2017. Por lo tanto, el siguiente paso debe ser la identificación de las variables que han causado el comportamiento inusual y luego, tratar de explicar este comportamiento anormal. Este análisis puede realizarse observando los gráficos de contribución o analizando las proyecciones de las observaciones en el espacio de las PC. La **Figura 5.7**, muestra el gráfico de contribución al T^2 de Hotelling obtenidas para las alarmas generadas del 12 al 15 de Noviembre de 2017.




Figura 5.7. Gráfico de contribución al T^2 de Hotelling de las observaciones extremas dentro del modelo de PCA.

Según este gráfico, durante cuatro días hubo un aumento inusual en el parámetro K_{c10} en la fase de carga del BESS. Este parámetro se incluyó por primera vez en [17] y permite ajustar el modelo de batería propuesto en [18] alcanzando un error de medición más bajo entre la señal de voltaje experimental y la señal simulada del BESS. La otra forma de interpretar una alarma en el gráfico de control T^2 de Hotelling es proyectar las observaciones en el espacio de las PC; por ejemplo: el gráfico de proyecciones del mes de Noviembre (11/2017) se superpuso con el mes de entrenamiento (Octubre/2017) como se muestra en la **Figura 5.8**. Además, se presenta la **Figura 5.9**, donde se muestra una ampliación de la combinación PC 1-5, para permitir, una mejor apreciación, de la **Figura 5.8**.

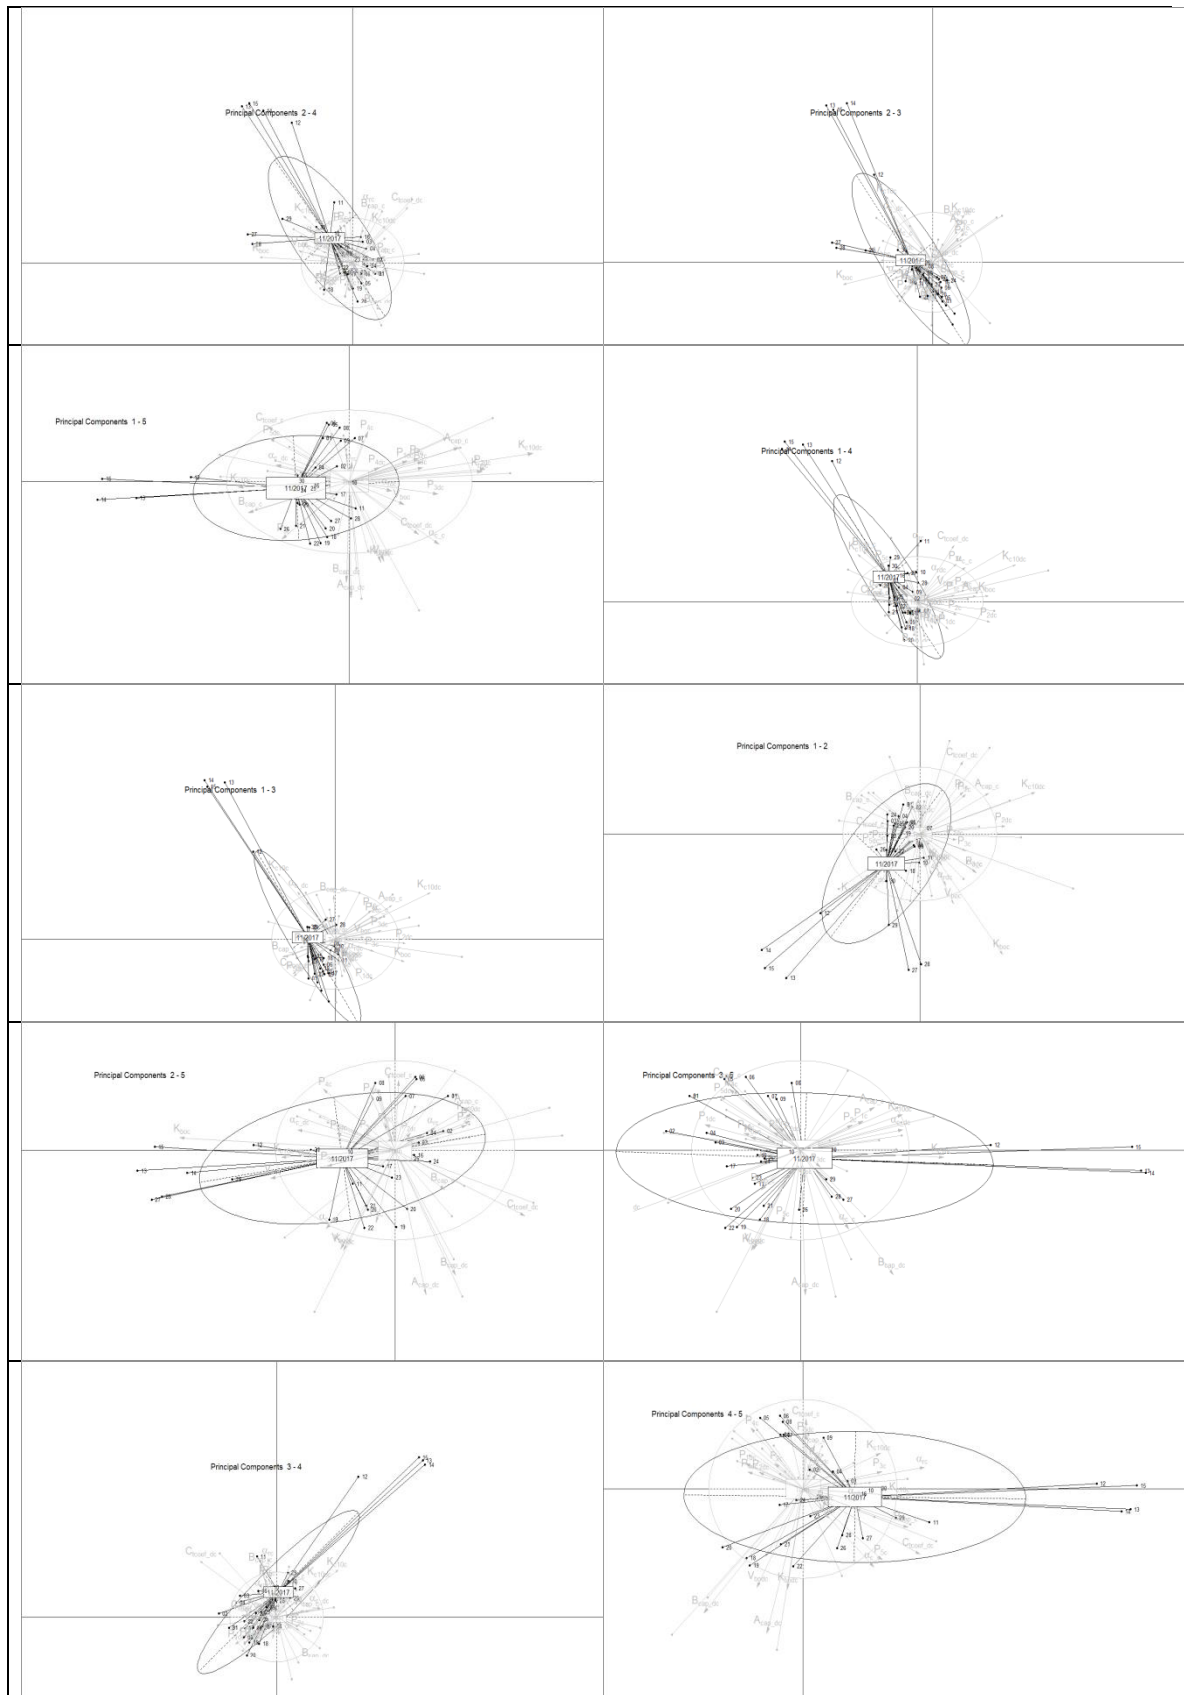


Figura 5.8. Proyecciones de las observaciones del mes de Noviembre superpuestas sobre el mes de entrenamiento.




Figura 5.9. Ampliación de las proyecciones de las observaciones del mes de Noviembre superpuestas sobre el mes de entrenamiento de la combinación de la PC 1-5.

En este mes el centroide de las observaciones se mueve en la dirección del parámetro K_{c10c} específicamente sobre los días 12 - 15, los cuales se marcaron como alarma en el gráfico de control T^2 (ver **Figura 5.5**) y coincide con el diagnóstico obtenido en los gráficos de contribución T^2 (ver **Figura 5.7**). Sin embargo, las alarmas presentadas durante estos días están asociadas con un aumento en el parámetro K_{c10} debido a un SOC por debajo del 85% lo que generó que el controlador aplicara una carga de rápida o de refuerzo.

5.6. APLICACIÓN A LA OBSERVACIÓN DE DATOS REALES.

En este punto, el modelo PCA se usa para monitorear el SOH del sistema durante un período de observación más largo, es decir, desde Noviembre de 2017 hasta Septiembre de 2018. La **Figura 5.10**, muestra el diagnóstico del T^2 de Hotelling para las nuevas observaciones establecidas.




Figura 5.10. Monitoreo de T_i^2 de Hotelling desde Noviembre de 2017 hasta Julio de 2018.

La **Figura 5.10**, muestra que en la tercera semana del mes de Diciembre se generó una señal de alarma debido a que el BESS tenía un SOC inferior al 80% lo que provocó un aumento del parámetro K_{c10} en el modo de carga. El aumento de este parámetro muestra que el BESS está entrando en un proceso de pérdida de capacidad. El controlador tarda una semana en cambiar de carga de refuerzo a carga flotante. Sin embargo, no logra bajar el nivel de alarma. Según se muestra en la **Figura 5.6**, se deberían haber aplicado las siguientes acciones: una carga de refuerzo hasta que la batería alcance el 85% y el 90% de su capacidad (tiempo para carga de refuerzo de la batería = 2 h). Luego realice una carga completa (tiempo de carga total = 5 h) hasta que el SOC > 90%. El mismo procedimiento debería haberse aplicado en el mes de Enero.

Febrero es el mes con la mayor distancia estadística entre los nuevos datos y el modelo original (alcanzando hasta 11 unidades de distancia), lo que genera una mayor tasa de alarma. Este aumento significativo se debió a trabajos realizados con equipos de soldadura dentro del LadER que llevó a que el BESS alcanzara un SOC por debajo del 70%, un aumento en la corriente superior a 2A y un aumento del parámetro P_I en el modo de descarga. Durante este período el controlador aplicó una carga de refuerzo, luego cambió a carga flotante hasta que el BESS funcionó en condiciones normales. Debido a que hubo una demanda anormal, entonces las condiciones de entrenamiento son extremadamente diferentes a las actuales, por lo que no es posible concluir que haya o no un fallo. Por lo tanto, no se requiere ninguna acción. Sin embargo, someter al BESS a tasas de descarga muy altas durante un largo período conduce a un deterioro de la salud de la batería.

En marzo las alarmas continúan en un nivel inferior. Sin embargo, entre los días 5 y 10 hay un aumento en el parámetro K_{c10} en el modo de carga. El controlador aplica una

carga de refuerzo durante 5 días hasta que alcanza un SOC igual al 97% y luego cambia a carga flotante hasta que el nivel de alarma desciende al nivel 0. Durante los primeros 15 días de Abril el BESS trabajó en condiciones normales. Sin embargo, la disminución en SOC ($< 70\%$) causó un aumento en el parámetro α_c en el modo de descarga. α_c es un parámetro que está asociado a la variación de temperatura y la capacidad de la batería. Durante este mes el controlador comienza con una carga flotante, luego pasa a una carga de refuerzo (del 10 al 18) y finalmente realiza una carga completa (del 19 al 25). Nuevamente en el mes de Mayo se trabajó con equipos de soldadura dentro del LadER. Por lo tanto, se deben aplicar las mismas acciones que en el mes de Febrero, declarando que este nivel de alarmas es falso. Entre los días 14 y 22 del mes de Junio hay alarmas causadas por el aumento del parámetro α_c en el modo de descarga. El resto de los días el BESS funciona en condiciones normales. El controlador aplica una carga flotante (de 1 a 13 días), luego aplica una carga de refuerzo (14 a 22 días) y termina con una carga flotante. Sin embargo, debido a la profundidad de descarga no controlada a la que fue sometido el BESS durante el mes de Mayo se debería haber aplicado una carga de compensación (ecualización).

Finalmente, en el mes de Julio las alarmas (de 6 a 19 días) fueron por el aumento del parámetro P_2 en el modo de carga. Durante este mes hubo un incremento significativo en la corriente del BESS ($I_{bat} > 15 \text{ A}$). El controlador aplica una carga flotante (de 1 a 9 días), luego aplica una carga de refuerzo (de 10 a 19 días) y termina con una carga de compensación (ecualización). Finalizando el mes se observa que el sistema muestra una recuperación.

Teniendo en cuenta lo planteado en la **Figura 5.6**, durante los meses de Agosto y Septiembre se realizan acciones de control y gestión de la energía que llevan al sistema de almacenamiento de energía basado en baterías a trabajar bajo condiciones normales. Durante este periodo, se monitoreo el nivel del líquido de las baterías, como también la densidad de éste. De igual forma, se aplicaron cargas de ecualización cada dos semanas con la finalidad de llevar a todas las células a niveles similares de carga y densidad, y eliminar la sulfatación que pueda haberse formado durante las condiciones de carga baja. Estas acciones, permiten devolverle a las baterías su capacidad de almacenamiento, aumentar la eficiencia y extender la vida útil.

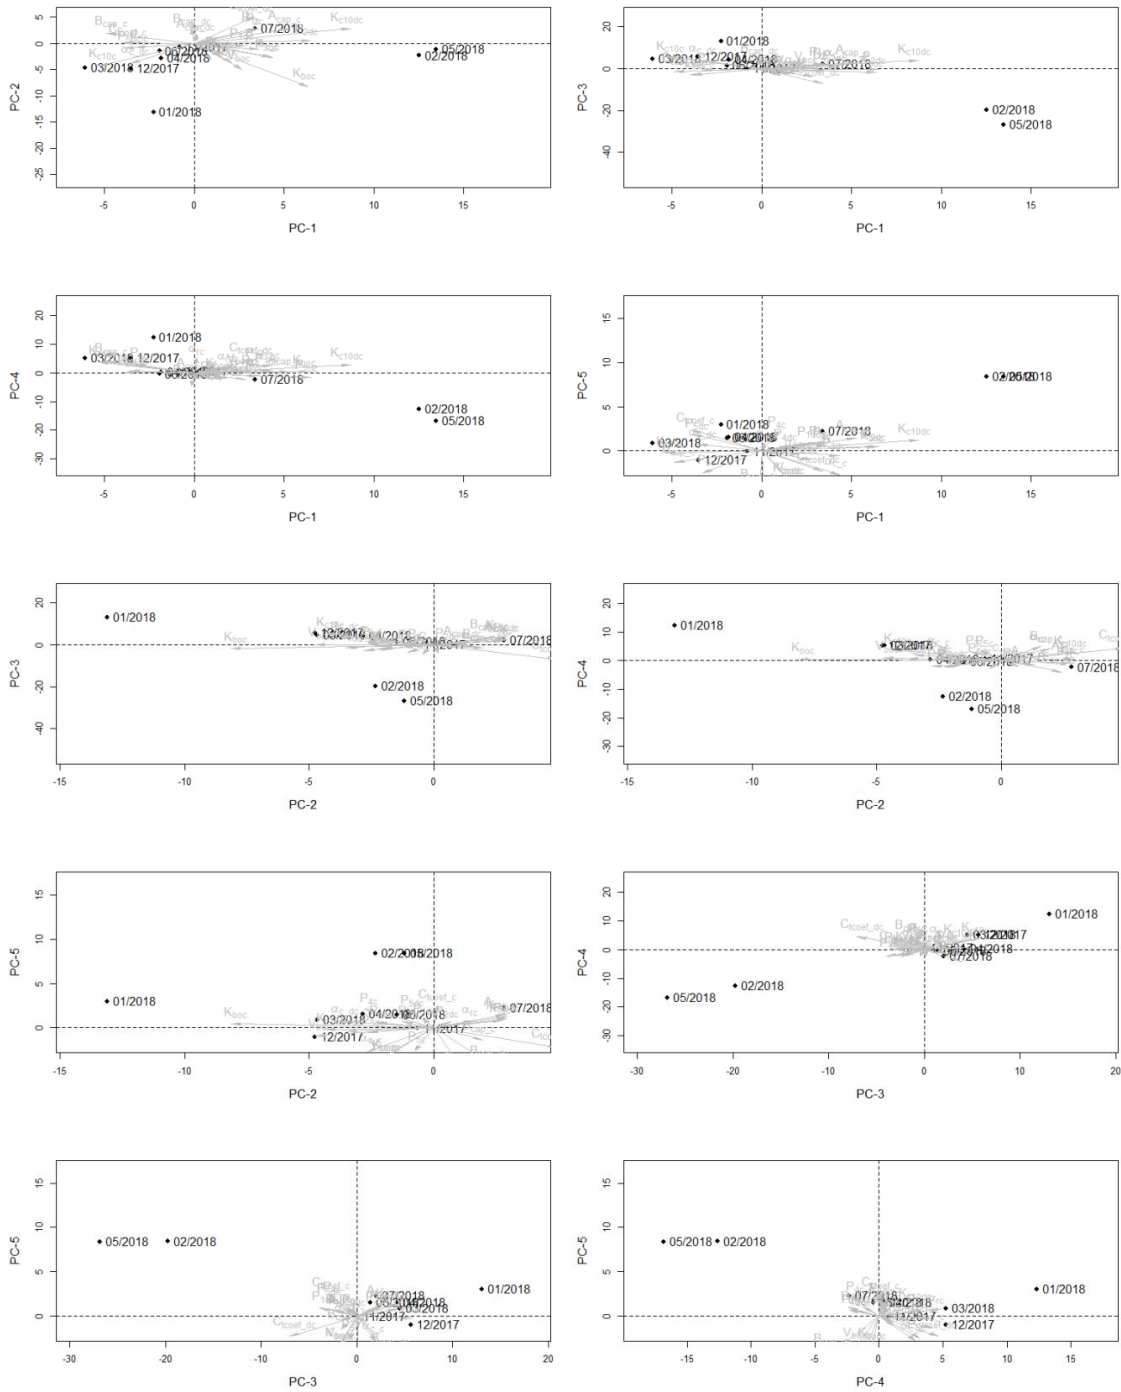


Figura 5.11. Proyecciones de los centroides de las observaciones del mes de Noviembre de 2017 a Julio de 2018 en el espacio de las PC.

El aumento inusual de estos parámetros provocó un movimiento del centroide de las observaciones (ver **Figura 5.11**) y un deterioro del SOH del BESS durante el primer semestre del año 2018 (ver **Figura 5.12**). El deterioro de la salud está relacionado con una pérdida progresiva de la capacidad operativa del BESS. Sin embargo, desde el mes de Mayo el BESS muestra recuperación en su SOH debido a que el controlador aplicó

una carga de equalización al BESS para neutralizar las diferencias que se producen en el SOC de las celdas de la batería, debido al comportamiento diferente de las celdas de la batería.

“El controlador realiza una carga de equalización, cuando la suma de todas las descargas desde la última carga de equalización es 30 veces la capacidad nominal de la batería” [38].

El SOH es estimado mediante la ecuación (27):

$$SOH = \frac{C_{actual_max}}{C_N} \times 100\% \quad (27)$$




Figura 5.12. Estimación del estado de salud (SOH) del BESS instalados en el LADER en el departamento del Chocó - Colombia.

5.7.CONCLUSIÓN

PCA es un método versátil capaz de proporcionar un diagnóstico general del BESS. El diagnóstico se basa en el estudio de los parámetros internos de la batería. Estos parámetros pueden identificarse a partir de datos reales recopilados cada día con un algoritmo evolutivo desarrollado en investigaciones anteriores. Diariamente los nuevos parámetros se proyectan sobre el modelo de PCA el cual se entrenó con un mes en donde el BESS trabajaba en condiciones normales. El análisis revela que en el último semestre del período en estudio el BESS presentó alarmas asociadas con el deterioro del SOH como resultado de los diferentes modos de operación del controlador.

El efecto sobre las proyecciones del modelo PCA es un movimiento del centroide de las observaciones con respecto al período de entrenamiento. El objetivo del controlador es la recuperación del SOH. Sin embargo, el uso de modos de carga agresivos aumenta la corriente y por lo tanto, aumenta la temperatura del BESS. De mantenerse estos aumentos por un periodo prolongado llevarían a un deterioro de la salud del BESS y por ende a un reemplazo prematuro de alguno de sus componentes. Además, el diagnóstico propuesto en este documento ha encontrado que una vez que se genera la alarma el controlador tarda varios días en realizar el cambio de carga. Por lo tanto, el uso del algoritmo de diagnóstico de PCA conducirá a un cambio más rápido en el modo de operación que permitirá recuperar la capacidad y el SOH de la batería más rápidamente, por lo que el BESS sufrirá corrientes más bajas y estabilidad en la temperatura.

La metodología presentada también permite la detección de falsas alarmas en el BESS como las registradas en los meses de Febrero y Mayo. Por lo tanto, no se debe tomar ningún correctivo si el algoritmo se eleva a un diagnóstico de falsa alarma.

REFERENCIAS

- [1] Plan de desarrollo departamental del Chocó, 2016-2019.
http://uvsalud.univalle.edu.co/planificacion_territorial/pdd_2016_2019/plan_de_desarrollo_departamental_del_choco_2016_2019.pdf
- [2]
[https://es.wikipedia.org/wiki/Choc%C3%B3#/media/File:Colombia_Choc%C3%B3_lo_cation_map_\(adm_colored\).svg](https://es.wikipedia.org/wiki/Choc%C3%B3#/media/File:Colombia_Choc%C3%B3_lo_cation_map_(adm_colored).svg)
- [3] <http://agenciadenoticias.unal.edu.co/detalle/article/sistema-hibrido-facilitaria-llevar-energia-al-choco.html#images-4>
- [4] Centro Nacional de Monitoreo - IPSE. http://190.216.196.84/ps_cnm/
- [5] Khalilpour, R.; Vassallo, A. Planning and operation scheduling of PV-battery systems: A novel methodology. *Renew. Sustain. Energy Rev.* **2016**, *53*, 194–208.
- [6] Yang, Z.; Zhang, J.; Kintner-Meyer, M.C.; Lu, X.; Choi, D.; Lemmon, J.P.; Liu, J. Electrochemical energy storage for green grid. *Chem. Rev.* **2011**, *111*, 3577–3613.
- [7] Bamgbopa, M.O.; Almheiri, S.; Sun, H. Prospects of recently developed membraneless cell designs for redox flow batteries. *Renew. Sustain. Energy Rev.* **2017**, *70*, 506–518.
- [8] Sayigh, A. (Ed.) *Renewable Energy in the Service of Mankind Vol I: Selected Topics from the World Renewable Energy Congress WREC 2014*; Springer: Berlin, Germany, 2015.
- [9] Armstrong, S.; Glavin, M.E.; Hurley, W.G. Comparison of battery charging algorithms for stand-alone photovoltaic systems. In Proceedings of the 2008 Power Electronics Specialists Conference (PESC 2008), Rhodes, Greece, 15–19 June 2008; pp. 1469–1475.
- [10] Koohi-Kamali, S.; Tyagi, V.V.; Rahim, N.A.; Panwar, N.L.; Mokhlis, H. Emergence of energy storage technologies as the solution for reliable operation of smart power systems: A review. *Renew. Sustain. Energy Rev.* **2013**, *25*, 135–165.
- [11] Emerging energy storage technologies in Europe. Rapport Frost & Sullivan; 2003.
- [12] Kousksou, T.; Bruel, P.; Jamil, A.; El Rhafiki, T.; Zeraouli, Y. Energy storage: Applications and challenges. *Sol. Energy Mater. Sol. Cells* **2014**, *120*, 59–80.

- [13] Akinyele, D.; Belikov, J.; Levron, Y. Battery Storage Technologies for Electrical Applications: Impact in Stand-Alone Photovoltaic Systems. *Energies* **2017**, *10*, 1760.
- [14] Kaldellis, J.K.; Zafirakis, D.; Kavadias, K. Techno-economic comparison of energy storage systems for island autonomous electrical networks. *Renew. Sustain. Energy Rev.* **2009**, *13*, 378–392.
- [15] Ferreira, H.L.; Garde, R.; Fulli, G.; Kling, W.; Lopes, J.P. Characterization of electrical energy storage technologies. *Energy* **2013**, *53*, 288–298.
- [16] Chen, H.; Cong, T.N.; Yang, W.; Tan, C.; Li, Y.; Ding, Y. Progress in electrical energy storage system: A critical review. *Prog. Nat. Sci.* **2009**, *19*, 291–312.
- [17] Díaz-González, F.; Sumper, A.; Gomis-Bellmunt, O.; Villafáfila-Robles, R. A review of energy storage technologies for wind power applications. *Renew. Sustain. Energy Rev.* **2012**, *16*, 2154–2171.
- [18] Evans, A.; Strezov, V.; Evans, T.J. Assessment of utility energy storage options for increased renewable energy penetration. *Renew. Sustain. Energy Rev.* **2012**, *16*, 4141–4147.
- [19] Sedighnejad, H.; Iqbal, T.; Quaicoe, J. Compressed air energy storage system control and performance assessment using energy harvested index. *Electronics* **2014**, *3*, 1–21.
- [20] Alotto, P.; Guarnieri, M.; Moro, F. Redox flow batteries for the storage of renewable energy: A review. *Renew. Sustain. Energy Rev.* **2014**, *29*, 325–335.
- [21] Nikdel, M. Various battery models for various simulation studies and applications. *Renew. Sustain. Energy Rev.* **2014**, *32*, 477–485.
- [22] Hoppmann, J.; Volland, J.; Schmidt, T.S.; Hoffmann, V.H. The economic viability of battery storage for residential solar photovoltaic systems—A review and a simulation model. *Renew. Sustain. Energy Rev.* **2014**, *39*, 1101–1118.
- [23] Hesse, H.C.; Martins, R.; Musilek, P.; Naumann, M.; Truong, C.N.; Jossen, A. Economic optimization of component sizing for residential battery storage systems. *Energies* **2017**, *10*, 835.
- [24] Fathima, H.; Palanisamy, K. Optimized sizing, selection, and economic analysis of battery energy storage for grid-connected wind-PV hybrid system. *Model. Simul. Eng.* **2015**, *2015*, 16.

- [25] Battke, B.; Schmidt, T.S.; Grosspietsch, D.; Hoffmann, V.H. A review and probabilistic model of lifecycle costs of stationary batteries in multiple applications. *Renew. Sustain. Energy Rev.* **2013**, *25*, 240–250.
- [26] Luo, X.; Wang, J.; Dooner, M.; Clarke, J. Overview of current development in electrical energy storage technologies and the application potential in power system operation. *Appl. Energy* **2015**, *137*, 511–536.
- [27] Dekka, A.; Ghaffari, R.; Venkatesh, B.; Wu, B. A survey on energy storage technologies in power systems. In Proceedings of the Electrical Power and Energy Conference (EPEC), London, ON, Canada, 26–28 October 2015; pp. 105–111.
- [28] Hsieh, H.-I.; Tsai, C.-Y.; Hsieh, G.-C. Photovoltaic burp charge system on energy-saving configuration by smart charge management. *IEEE Trans. Power Electron.* **2014**, *29*, 1777–1790.
- [29] Dakkak, M.; Hasan, A. A charge controller based on microcontroller in stand-alone photovoltaic systems. *Energy Procedia* **2012**, *19*, 87–90.
- [30] Eldahab, Y.E.A.; Saad, N.H.; Zekry, A. Enhancing the design of battery charging controllers for photovoltaic systems. *Renew. Sustain. Energy Rev.* **2016**, *58*, 646–655.
- [31] Bandara, G.; Ivanov, R.; Gishin, S. Intelligent fuzzy controller for a lead-acid battery charger. In Proceedings of the 1999 IEEE International Conference on Systems, Man, and Cybernetics (SMC'99), Tokyo, Japan, 12–15 October 1999; pp. 185–189.
- [32] Hua, C.-C.; Lin, M.-Y. A study of charging control of lead-acid battery for electric vehicles. In Proceedings of the 2000 IEEE International Symposium on Industrial Electronics (ISIE 2000), Cholula, Puebla, Mexico, 4–8 December 2000; pp. 135–140.
- [33] Ayoub, E.; Karami, N. Review on the charging techniques of a li-ion battery. In Proceedings of the Third International Conference on Technological Advances in Electrical, Electronics and Computer Engineering (TAEECE), Beirut, Lebanon, 29 April–1 May 2015; pp. 50–55.
- [34] Rand, D.A.J.; Moseley, P.T.; Rand, D.A.J.; Moseley, P.T.; Garche, J.; Parker, C.D. *Valve Regulated Lead Acid Batteries*; Elsevier: New York, NY, USA, 2004; ISBN 0-4445-0746-9.

- [35] Lin, F.J.; Huang, M.S.; Yeh, P.Y.; Tsai, H.C.; Kuan, C.H. DSP-based probabilistic fuzzy neural network control for Li-ion battery charger. *IEEE Trans. Power Electron.* **2012**, *27*, 3782–3794.
- [36] Hua, A.C.-C.; Syue, B.Z.-W. Charge and discharge characteristics of lead-acid battery and LiFePO₄ battery. In Proceedings of the IEEE 2010 International Power Electronics Conference (IPEC), Sapporo, Japan, 21–24 June 2010; pp. 1478–1483.
- [37] Lee, C.S.; Lin, H.C.; Lai, S.-Y. Development of fast large lead-acid battery charging system using multi-state strategy. *Int. J. Comput. Consum. Control* **2013**, *2*, 56–65.
- [38] Lin, H.C.; He, Y.J.; Liu, C.W. Design of an Efficient Battery Charging System Based on Ideal Multi-State Strategy. In Proceedings of the IEEE 2016 International Symposium on Computer, Consumer and Control (IS3C), Xi'an, China, 4–6 July 2016; pp. 956–959.
- [39] Yan, J.; Xu, G.; Qian, H.; Xu, Y.; Song, Z. Model predictive control-based fast charging for vehicular batteries. *Energies* **2011**, *4*, 1178–1196.
- [40] Wong, Y.S.; Hurley, W.G.; Wölfle, W.H. Charge regimes for valve-regulated lead-acid batteries: Performance overview inclusive of temperature compensation. *J. Power Sources* **2008**, *183*, 783–791.
- [41] Rossinot, E.; Lefrou, C.; Dalard, F.; Cun, J.P. Batteries in standby applications: Comparison of alternate mode versus floating. *J. Power Sources* **2001**, *101*, 27–34.
- [42] Chen, L.-R. Design of duty-varied voltage pulse charger for improving Li-ion battery-charging response. *IEEE Trans. Ind. Electron.* **2009**, *56*, 480–487.
- [43] Liu, C.L.; Chiu, Y.S.; Liu, Y.H.; Ho, Y.H.; Huang, S.S. Optimization of a fuzzy-logic-control-based five-stage battery charger using a fuzzy-based taguchi method. *Energies* **2013**, *6*, 3528–3547.
- [44] Huang, S.-J.; Huang, B.-G.; Pai, F.-S. Fast Charge Strategy Based on the Characterization and Evaluation of LiFePO₄ Batteries. *IEEE Trans. Power Electron.* **2013**, *28*, 1555–1562.
- [45] Liu, Y.-H.; Teng, J.-H. Design and implementation of a fully-digital Lithium-Ion battery charger. In Proceedings of the 2006 IEEE Region 10 Conference (TENCON 2006), Hongkong, China, 14–17 November 2006; pp. 1–4.
- [46] Linden, D.; Reddy, T.B. *Handbook of Batteries*, 3rd ed.; McGraw Hill: New York, NY, USA, 2002.

- [47] Nasser, K. Negative Pulse Charging: Myths and Facts. Available online: http://www.batterypoweronline.com/images/PDFs_articles_whitepaper_appros/powerdesigners.pdf (Accessed on 3 May 2017).
- [48] Li, S.; Zhang, C.; Xie, S. Research on fast charge method for lead-acid electric vehicle batteries. In Proceedings of the IEEE International Workshop on Intelligent Systems and Applications ISA 2009, Wuhan, China, 23–24 May 2009; pp. 1–5.
- [49] James, M.; Grummett, J.; Rowan, M.; Newman, J. Application of pulse charging techniques to submarine lead-acid batteries. *J. Power Sources* **2006**, *162*, 878–883.
- [50] Battery Application & Technology. Available online: https://www.engineersedge.com/battery/trickle_charging.htm (Accessed on 5 April 2018).
- [51] Chuang, Y.C.; Ke, Y.L.; Chuang, H.S.; Chang, S.Y. Battery float charge technique using parallel-loaded resonant converter for discontinuous conduction operation. *IEEE Trans. Ind. Appl.* **2012**, *48*, 1070–1078.
- [52] Battery Charging Methods. Available online: http://www1.labvolt.com/publications/Exercises/86351-00_4.pdf (Accessed on 5 April 2018).
- [53] Battery Management of the SunnyIsland. Available online: http://files.sma.de/dl/7910/SI_Batteriemanagement-TI-en-21.pdf (Accessed on 22 June 2017).
- [54] Zadeh, L.A. Fuzzy sets. *Inf. Control* **1965**, *8*, 338–353.
- [55] Hsieh, G.-C.; Chen, L.-R.; Huang, K.-S. Fuzzy-controlled Li-ion battery charge system with active state-of-charge controller. *IEEE Trans. Ind. Electron.* **2001**, *48*, 585–593.
- [56] Precup, R.-E.; Hellendoorn, H. A survey on industrial applications of fuzzy control. *Comput. Ind.* **2011**, *62*, 213–226.
- [57] Liu, C.-L.; Chen, J.-H.; Liu, Y.H.; Yang, Z.-Z. An asymmetrical fuzzy-logic-control-based MPPT algorithm for photovoltaic systems. *Energies* **2014**, *7*, 2177–2193.
- [58] Gdaim, S.; Mtibaa, A.; Mimouni, M.F. Design and experimental implementation of DTC of an induction machine based on fuzzy logic control on FPGA. *IEEE Trans. Fuzzy Syst.* **2015**, *23*, 644–655.

- [59] Bago, J.C.; Galán, S.G.; Aguilera, J.; Velasco, J.R.; Magdalena, L. Fuzzy controller applications in stand-alone photovoltaic systems. *Mathw. Soft Comput.* **2008**, *9*, 85–105.
- [60] Nik Ismail, N.F.; Musirin, I.; Baharom, R.; Johari, D. Fuzzy logic controller on DC/DC boost converter. In Proceedings of the 2010 IEEE International Conference on Power and Energy (PECon), Kuala Lumpur, Malaysia, 29 November–1 December 2010; pp. 661–666.
- [61] Swathika, R.; Ram, R.G.; Kalaichelvi, V.; Karthikeyan, R. Application of fuzzy logic for charging control of lead-acid battery in stand-alone solar photovoltaic system. In Proceedings of the 2013 International Conference on Green Computing, Communication and Conservation of Energy (ICGCE), Chennai, India, 12–14 December 2013; pp. 377–381.
- [62] Mattavelli, P.; Rossetto, L.; Spiazzi, G.; Tenti, P. General-purpose fuzzy controller for dc/dc converters. In Proceedings of the Tenth Annual 1995 IEEE Applied Power Electronics Conference and Exposition (APEC'95), Dallas, TX, USA, 5–9 March 1995; pp. 723–730.
- [63] Eker, I.; Torun, Y. Fuzzy logic control to be conventional method. *Energy Convers. Manag.* **2006**, *47*, 377–394.
- [64] Rahim, N.A.; Mekhilef, S.; Chan, E.L.; Ping, H.W. Fuzzy-controlled battery charger state-of-charge controller. *Int. J. Model. Simul.* **2006**, *26*, 106–111.
- [65] Huang, C.H.; Huang, C.C.; Ou, T.C.; Lu, K.H.; Hong, C.M. Intelligent fuzzy logic controller for a solar charging system. In Proceedings of the IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM 2009), Singapore, 14–17 July 2009; pp. 1412–1417.
- [66] Yarn, K.F.; Wu, K.K.; Chung, L.Y. Fuzzy logic control of Photovoltaic Lead-Acid Charging System. *Adv. Mater. Res.* **2011**, *219–220*, 941–944.
- [67] Kim, J.Y.; Kim, H.M.; Kim, S.K.; Jeon, J.H.; Choi, H.K. Designing an energy storage system fuzzy PID controller for microgrid islanded operation. *Energies* **2011**, *4*, 1443–1460.
- [68] Haoran, Z. H. A. O., Qiuwei, W. U., Chengshan, W. A. N. G., Cheng, L., & Rasmussen, C. N. Fuzzy logic based coordinated control of battery energy storage system and dispatchable distributed generation for microgrid. *J. Mod. Power Syst. Clean Energy* **2015**, *3*, 422–428.

- [69] Welch, R.L.; Venayagamoorthy, G.K. Energy dispatch fuzzy controller for a grid-independent photovoltaic system. *Energy Convers. Manag.* **2010**, *51*, 928–937.
- [70] Welch, R.L.; Venayagamoorthy, G.K. Comparison of two optimal control strategies for a grid independent photovoltaic system. In Proceedings of the Conference Record of the 2006 IEEE 41st IAS Annual Meeting Industry Applications Conference, Tampa, FL, USA, 8–12 October 2006; pp. 1120–1127.
- [71] Wang, F.-S.; Suo, X.-S. Research on Batterys charging system based on the Fuzzy control. In Proceedings of the 2nd International Conference on Computer Science and E-lectronics Engineering, Hangzhou, China, 22–23 March 2013.
- [72] Safari, S.; Ardehali, M.M.; Sirizi, M.J. Particle swarm optimization based fuzzy logic controller for autonomous green power energy system with hydrogen storage. *Energy Convers. Manag.* **2013**, *65*, 41–49.
- [73] Berrazouane, S.; Mohammedi, K. Parameter optimization via cuckoo optimization algorithm of fuzzy controller for energy management of a hybrid power system. *Energy Convers. Manag.* **2014**, *78*, 652–660.
- [74] Aristizábal, A. J., Hernán Ospina, D., Castañeda, M., Zapata, S., & Banguero, E. Fuzzy logic energy management for a microgrid with storage battery. *International Journal of Ambient Energy*, 2018, p. 1-9.
- [75] Yin, Y.; Luo, X.; Guo, S.; Zhou, Z.; Wang, J. A battery charging control strategy for renewable energy generation systems. In Proceedings of the World Congress on Engineering, London, UK, 2–4 July 2008; pp. 2–4.
- [76] Arcos-Aviles, D.; Pascual, J.; Marroyo, L.; Sanchis, P.; Guinjoan, F. Fuzzy logic-based energy management system design for residential grid-connected microgrids. *IEEE Trans. Smart Grid* **2016**, *9*, 530–543.
- [77] Derrouazin, A.; Aillerie, M.; Mekakia-Maaza, N.; Charles, J.P. Fuzzy logic controller versus classical logic controller for residential hybrid solar-wind-storage energy system. *AIP Conf. Proc.* **2016**, *1758*, 030055.
- [78] Paliwal, P.; Patidar, N.P.; Nema, R.K. Fuzzy logic based determination of battery charging efficiency applied to hybrid power system. *J. World Acad. Eng. Sci. Technol.* **2012**, *71*, 1164–1168.
- [79] Teo, T.T.; Logenthiran, T.; Woo, W.L.; Abidi, K. Fuzzy logic control of energy storage system in microgrid operation. In Proceedings of the 2016 IEEE Innovative Smart Grid Technologies-Asia (ISGT-Asia), Melbourne, VIC, Australia, 28 November–1 December 2016; pp. 65–70.

- [80] Hussain, A.; Bui, V.H.; Kim, H.-M. Fuzzy Logic-Based Operation of Battery Energy Storage Systems (BESSs) for Enhancing the Resiliency of Hybrid Microgrids. *Energies* **2017**, *10*, 271.
- [81] Maciejowski, J.M. *Predictive Control: With Constraints*; Pearson Education: Upper Saddle River, NJ, USA, 2002; ISBN 0 201 39823 0.
- [82] Ferrarini, L.; Mantovani, G.; Costanzo, G.T. A Distributed Model predictive control approach for the integration of flexible loads, storage and renewables. In Proceedings of the 2014 IEEE 23rd International Symposium on Industrial Electronics (ISIE), Istanbul, Turkey, 1–4 June 2014; pp. 1700–1705.
- [83] Camacho, E.F.; Alba, C.B. *Model Predictive Control*; Springer Science & Business Media: New York, NY, USA, 2013.
- [84] Qin, S.J.; Badgwell, T.A. A survey of industrial model predictive control technology. *Control Eng. Pract.* **2003**, *11*, 733–764.
- [85] Geyer, T.; Papafotiou, G.; Morari, M. Hybrid model predictive control of the step-down DC–DC converter. *IEEE Trans. Control Syst. Technol.* **2008**, *16*, 1112–1124.
- [86] Cortes, P.; Rodriguez, J.; Antoniewicz, P.; Kazmierkowski, M. Direct power control of an AFE using predictive control. *IEEE Trans. Power Electron.* **2008**, *23*, 2516–2523.
- [87] Xie, Y.H.; Ghaemi, R.; Sun, J.; Freudenberg, J.S. Implicit model predictive control of a full bridge DC–DC converter. *IEEE Trans. Power Electron.* **2009**, *24*, 2704–2713.
- [88] Quevedo, D.E.; Aguilera, R.P.; Perez, M.A.; Cortés, P.; Lizana, R. Model predictive control of an AFE rectifier with dynamic references. *IEEE Trans. Power Electron.* **2012**, *27*, 3128–3136.
- [89] Townsend, C.D.; Summers, T.J.; Betz, R.E. Multigoal heuristic model predictive control technique applied to a cascaded H-bridge StatCom. *IEEE Trans. Power Electron.* **2012**, *27*, 1191–1200.
- [90] Chen, H.; Allgöwer, F. Nonlinear model predictive control schemes with guaranteed stability. In *Nonlinear Model Based Process Control*; Springer: Dordrecht, The Netherland, 1998; pp. 465–494.
- [91] Perez, E.; Beltran, H.; Aparicio, N.; Rodriguez, P. Predictive power control for PV plants with energy storage. *IEEE Trans. Sustain. Energy* **2013**, *4*, 482–490.

- [92] Sultana, W.R.; Sahoo, S.K.; Sukchai, S.; Yamuna, S.; Venkatesh, D. A review on state of art development of model predictive control for renewable energy applications. *Renew. Sustain. Energy Rev.* **2017**, *76*, 391–406.
- [93] Pezeshki, H.; Wolfs, P.; Ledwich, G. A model predictive approach for community battery energy storage system optimization. In Proceedings of the 2014 IEEE PES General Meeting|Conference & Exposition, National Harbor, MD, USA, 27–31 July 2014; pp. 1–5.
- [94] Dizqah, A.M.; Maheri, A.; Busawon, K.; Kamjoo, A. A multivariable optimal energy management strategy for standalone dc microgrids. *IEEE Trans. Power Syst.* **2015**, *30*, 2278–2287.
- [95] Morstyn, T.; Hredzak, B.; Agelidis, V.G. Dynamic optimal power flow for DC microgrids with distributed battery energy storage systems. In Proceedings of the 2016 IEEE Energy Conversion Congress and Exposition (ECCE), Milwaukee, WI, USA, 18–22 September 2016; pp. 1–6.
- [96] Morstyn, T.; Hredzak, B.; Aguilera, R.P.; Agelidis, V.G. Model predictive control for Distributed Microgrid Battery Energy Storage Systems. *IEEE Trans. Control Syst. Technol.* **2018**, *26*, 1107–1114.
- [97] Kujundžić, G.; Ileš, Š.; Matuško, J.; Vašak, M. Optimal charging of valve-regulated lead-acid batteries based on model predictive control. *Appl. Energy* **2017**, *187*, 189–202.
- [98] Zeng, P.P.; Wu, Z.; Zhang, X.P.; Liang, C.; Zhang, Y. Model predictive control for energy storage systems in a network with high penetration of renewable energy and limited export capacity. In Proceedings of the 2014 IEEE Power Systems Computation Conference (PSCC), Wroclaw, Poland, 18–22 August 2014; pp. 1–7.
- [99] Li, C.-T.; Peng, H.; Sun, J. Predictive control and sizing of energy storage to mitigate wind power intermittency. *Wind Energy* **2016**, *19*, 437–451.
- [100] Khalid, M.; Savkin, A.V. Model predictive control based efficient operation of battery energy storage system for primary frequency control. In Proceedings of the 2010 IEEE 11th International Conference on Control Automation Robotics & Vision (ICARCV), Singapore, 7–10 December 2010; pp. 2248–2252.
- [101] Khalid, M.; Savkin, A.V. An optimal operation of wind energy storage system for frequency control based on model predictive control. *Renew. Energy* **2012**, *48*, 127–132.

- [102] Wang, T.; Kamath, H.; Willard, S. Control and optimization of grid-tied photovoltaic storage systems using model predictive control. *IEEE Trans. Smart Grid* **2014**, *5*, 1010–1017.
- [103] Petrollese, M.; Valverde, L.; Cocco, D.; Cau, G.; Guerra, J. Real-time integration of optimal generation scheduling with MPC for the energy management of a renewable hydrogen-based microgrid. *Appl. Energy* **2016**, *166*, 96–106.
- [104] Matthiss, B.; Müller, D.; Binder, J.; Pietruschka, D. Model Predictive Control Schemes for PV-Storage Systems to Increase Grid Compatibility and Optimise Energy Costs. In Proceedings of the 29th European Photovoltaic Solar Energy Conference and Exhibition, Amsterdam, The Netherlands, 22–26 September 2014; pp. 3581–3586.
- [105] Kim, J.; Nikitenkov, D. Fuzzy logic-controlled online state-of-health (SOH) prediction in large format LiMn₂O₄ cell for energy storage system (ESS) applications. In Proceedings of the 2014 IEEE International Conference on Industrial Technology (ICIT), Busan, South Korea, 26 February–1 March 2014; pp. 474–479.
- [106] Li, X.; Yan, H. Fuzzy logic-based coordinated control method for multi-type battery energy storage systems. *Artif. Intell. Rev.* **2018**, *49*, 227–243.
- [107] Li, X.; Li, N.; Jia, X.; Hui, D. Fuzzy logic based smoothing control of wind/PV generation output fluctuations with battery energy storage system. In Proceedings of the 2011 International Conference on Electrical Machines and Systems (ICEMS), Beijing, China, 20–23 August 2011; pp. 1–5.
- [108] Banguero, E.; Correcher, A.; Pérez-Navarro, Á.; Morant, F.; Aristizabal, A. A Review on Battery Charging and Discharging Control Strategies: Application to Renewable Energy Systems. *Energies* **2018**, *11*, 1021.
- [109] Hadjipaschalis, A. Poullikkas, y V. Efthimiou, «Overview of current and future energy storage technologies for electric power applications», *Renew. Sustain. Energy Rev.*, vol. 13, n.º 6, pp. 1513-1522, ago. 2009.
- [110] Ebner, E., Gelbke, M., Zena, E., Wieger, M., & Börger, A. Temperature-dependent formation of vertical concentration gradients in lead-acid-batteries under pSoC operation—Part 2: Sulfate analysis. *Electrochimica Acta*, 2018, vol. 262, p. 144-152.
- [111] Bogno, B., Sawicki, J. P., Salame, T., Aillerie, M., Saint-Eve, F., Hamandjoda, O., & Tibi, B. Improvement of safety, longevity and performance of lead acid battery

in off-grid PV systems. *International Journal of Hydrogen Energy*, 2017, vol. 42, no 5, p. 3466-3478.

[112] Salari, Mahmoud; Malekshah, Emad Hasani; Malekshah, Masoud Hasani. Hydrothermal analysis of transient natural convection in a finned cavity filled with sulfuric acid-water (25–75%) for applications in high-performance lead-acid batteries–Numerical study. *Thermal Science and Engineering Progress*, 2017, vol. 4, p. 241-251.

[113] Settelein, J.; Lorrmann, H.; SEXTL, G. Evaluating the lead affinity of graphite additives in lead-acid batteries by electrochemical deposition. *Electrochimica Acta*, 2017, vol. 233, p. 173-180.

[114] Tsang, K.M.; Chan, W.L.; Wong, Y.K.; Sun, L. Lithium-ion battery models for computer simulation. In *Proceedings of the 2010 IEEE International Conference on Automation and Logistics (ICAL)*, Hong Kong/Macau, China, 16–20 August 2010; pp. 98–102.

[115] Zhu, W.H.; Zhu, Y.; Tatarchuk, B.J. A simplified equivalent circuit model for simulation of Pb-acid batteries at load for energy storage application. *Energy Convers. Manag.* **2011**, 52, 2794–2799.

[116] Fendri, D.; Chaabene, M. Dynamic model to follow the state of charge of a lead-acid battery connected to photovoltaic panel. *Energy Convers. Manag.* **2012**, 64, 587–593.

[117] Hittinger, E.; Wiley, T.; Kluza, J.; Whitacre, J. Evaluating the value of batteries in microgrid electricity systems using an improved Energy Systems Model. *Energy Convers. Manag.* **2015**, 89, 458–472.

[118] Ansari, A.B.; Esfahanian, V.; Torabi, F. Discharge, rest and charge simulation of lead-acid batteries using an efficient reduced order model based on proper orthogonal decomposition. *Appl. Energy* **2016**, 173, 152–167.

[119] Mirzapour, F., Lakzaei, M., Varamini, G., Teimourian, M., & Ghadimi, N. A new prediction model of battery and wind-solar output in hybrid power system. *Journal of Ambient Intelligence and Humanized Computing*, 2017, p. 1-11.

[120] Zou, C., Zhang, L., Hu, X., Wang, Z., Wik, T., & Pecht, M. A review of fractional-order techniques applied to lithium-ion batteries, lead-acid batteries, and supercapacitors. *Journal of Power Sources*, 2018, vol. 390, p. 286-296.

- [121] Büngeler, J., Cattaneo, E., Riegel, B., & Sauer, D. U. Advantages in energy efficiency of flooded lead-acid batteries when using partial state of charge operation. *Journal of Power Sources*, 2018, vol. 375, p. 53-58.
- [122] Li, J., Wang, X., Zhang, Z., Le Blond, S., Yang, Q., Zhang, M., & Yuan, W. Analysis of a new design of the hybrid energy storage system used in the residential m-CHP systems. *Applied Energy*, 2017, vol. 187, p. 169-179.
- [123] Badeda, J., Huck, M., Sauer, D. U., Kabzinski, J., & Wirth, J. Basics of lead–acid battery modelling and simulation. In *Lead-Acid Batteries for Future Automobiles*. 2017. p. 463-507.
- [124] Cugnet, Mikael; Liaw, Bor Yann. Effect of discharge rate on charging a lead-acid battery simulated by mathematical model. *Journal of Power Sources*, 2011, vol. 196, no 7, p. 3414-3419.
- [125] Yang, Y., Ye, Q., Tung, L. J., Greenleaf, M., & Li, H. Integrated size and energy management design of battery storage to enhance grid integration of large-scale PV power plants. *IEEE Transactions on Industrial Electronics*, 2018, vol. 65, no 1, p. 394-402.
- [126] Layadi, T. M., Champenois, G., Mostefai, M., & Abbes, D. Lifetime estimation tool of lead–acid batteries for hybrid power sources design. *Simulation Modelling Practice and Theory*, 2015, vol. 54, p. 36-48.
- [127] Li, Y., Shen, Z., Ray, A., & Rahn, C. D. Real-time estimation of lead-acid battery parameters: A dynamic data-driven approach. *Journal of Power Sources*, 2014, vol. 268, p. 758-764.
- [128] Esfahanian, Vahid; Ansari, Amir Babak; Torabi, Farschad. Simulation of lead-acid battery using model order reduction. *Journal of Power Sources*, 2015, vol. 279, p. 294-305.
- [129] Zhang, Jinlong; Xia, Chaoying. State-of-charge estimation of valve regulated lead acid battery based on multi-state Unscented Kalman Filter. *International Journal of Electrical Power & Energy Systems*, 2011, vol. 33, no 3, p. 472-476.
- [130] Achaibou, N.; Haddadi, M.; Malek, A. Modeling of lead acid batteries in PV systems. *Energy Procedia* 2012, 18, 538–544.
- [131] Achaibou, N.; Haddadi, M.; Malek, A. Lead acid batteries simulation including experimental validation. *J. Power Sources* 2008, 185, 1484–1491.

- [132] Wei, Z.; Meng, S.; Xiong, B.; Ji, D.; Tseng, K.J. Enhanced online model identification and state of charge estimation for lithium-ion battery with a FBCRLS based observer. *Appl. Energy* 2016, 181, 332–341.
- [133] Devarakonda, L.; Hu, T. Algebraic method for parameter identification of circuit models for batteries under non-zero initial condition. *J. Power Sources* 2014, 268, 928–940.
- [134] Selmani, A.; Outanoute, M.; Lachhab, A.; Guerbaoui, M.; Bouchikhi, B. Performance Evaluation of Modelling and Simulation of Lead Acid Batteries for Photovoltaic Applications. *Int. J. Power Electron. Drive Syst.* 2016, 7, 472–480.
- [135] Wei, Z.; Zhao, J.; Ji, D.; Tseng, K.J. A multi-timescale estimator for battery state of charge and capacity dual estimation based on an online identified model. *Appl. Energy* 2017, 204, 1264–1274.
- [136] Wei, Z.; Bhattarai, A.; Zou, C.; Meng, S.; Lim, T.M.; Skyllas-Kazacos, M. Real-time monitoring of capacity loss for vanadium redox flow battery. *J. Power Sources* 2018, 390, 261–269.
- [137] Copetti, J.B.; Lorenzo, E.; Chenlo, F. A general battery model for PV system simulation. *Prog. Photovolt. Res. Appl.* **1993**, 1, 283–292.
- [138] Thirugnanam, K.; Ezhil TP, E.R.J.; Singh, M.; Kumar, P. Mathematical modeling of Li-ion battery using genetic algorithm approach for V2G applications. *IEEE Trans. Energy Convers.* 2014, 29, 332–343.
- [139] Chen, Z.; Mi, C.C.; Fu, Y.; Xu, J.; Gong, X. Online battery state of health estimation based on Genetic Algorithm for electric and hybrid vehicle applications. *J. Power Sources* 2013, 240, 184–192.
- [140] Liu, W.; Liu, L.; Chung, I.-Y.; Cartes, D.A. Real-time particle swarm optimization based parameter identification applied to permanent magnet synchronous machine. *Appl. Soft Comput.* 2011, 11, 2556–2564.
- [141] Guo, L.; Meng, Z.; Sun, Y.; Wang, L. Parameter identification and sensitivity analysis of solar cell models with cat swarm optimization algorithm. *Energy Convers. Manag.* 2016, 108, 520–528.
- [142] Nyarko, E.K.; Scitovski, R. Solving the parameter identification problem of mathematical models using genetic algorithms. *Appl. Math. Comput.* 2004, 153, 651–658.
- [143] García-Triviño, P.; Gil-Mena, A.J.; Llorens-Iborra, F.; García-Vázquez, C.A.; Fernández-Ramírez, L.M.; Jurado, F. Power control based on particle swarm

optimization of grid-connected inverter for hybrid renewable energy system. *Energy Convers. Manag.* 2015, 91, 83–92.

[144] Guasch, D.; Silvestre, S. Dynamic battery model for photovoltaic applications. *Prog. Photovolt. Res. Appl.* 2003, 11, 193–206.

[145] Blaifi, S.; Moulahoum, S.; Colak, I.; Merrouche, W. An enhanced dynamic model of battery using genetic algorithm suitable for photovoltaic applications. *Appl. Energy* 2016, 169, 888–898.

[146] Blaifi, S.; Moulahoum, S.; Colak, I.; Merrouche, W. Monitoring and enhanced dynamic modeling of battery by genetic algorithm using LabVIEW applied in photovoltaic system. *Electr. Eng.* 2017, 100, 1021–1038.

[147] Blaifi, S.; Moulahoum, S.; Kabache, N.; Colak, I. An improved dynamic battery model suitable for photovoltaic applications. In *Proceedings of the 2015 International Conference on Renewable Energy Research and Applications (ICRERA)*, Palermo, Italy, 22–25 November 2015; pp. 694–698.

[148] Yang, X.S.; Deb, S. Cuckoo Search via Lévy flights. In *Proceedings of the 2009 World Congress on Nature Biologically Inspired Computing (NaBIC)*, Coimbatore, India, 9–11 December 2009; pp. 210–214.

[149] Yang, X.-S.; Deb, S. Engineering optimisation by cuckoo search. *Int. J. Math. Model. Numer. Optim.* 2010, 1, 330–343.

[150] Gandomi, A.H.; Yang, X.-S.; Alavi, A.H. Cuckoo search algorithm: A metaheuristic approach to solve structural optimization problems. *Eng. Comput.* 2013, 29, 17–35.

[151] Fister, I., Jr.; Yang, X.-S.; Fister, I.; Brest, J.; Fister, D. A Brief Review of Nature-Inspired Algorithms for Optimization. *arXiv* 2013.

[152] Banguero, Edison; Aristizábal, Andrés Julián; Murillo, William. A Verification Study for Grid-Connected 20 kW Solar PV System Operating in Chocó, Colombia. *Energy Procedia*, 2017, vol. 141, p. 96-101.

[153] Banguero Edison, Agudelo A. Hector D; Aristizabal Andrés Julián; Ospina Daniel; Renewable microgrid operational results and economic evaluation using RETScreenTM. *International Journal of Electrical and Computer Engineering (IJECE)*. Vol 9. No 2. <http://doi.org/10.11591/ijece.v9i2.pp%25p>

[154] Burgos, D. Estimación del estado de carga para un banco de baterías basada en modelación difusa y filtro extendido de Kalman. *Universidad de Chile*, 2013.

- [155] Rivera-Barrera, Juan; Muñoz-Galeano, Nicolás; Sarmiento-Maldonado, Henry. SOC estimation for lithium-ion batteries: review and future challenges. *Electronics*, 2017, vol. 6, no 4, p. 102.
- [156] Chang, Wen-Yeau. The state of charge estimating methods for battery: A review. *ISRN Applied Mathematics*, 2013, vol. 2013.
- [157] Hannan, M. A., Lipu, M. H., Hussain, A., & Mohamed, A. A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations. *Renewable and Sustainable Energy Reviews*, 2017, vol. 78, p. 834-854.
- [158] Jeon, Seonwoo; Yun, Jae-Jung; Bae, Sungwoo. Comparative study on the battery state-of-charge estimation method. *Indian Journal of Science and Technology*, 2015, vol. 8, no 26.
- [159] Plett, G. L. (2006). Sigma-point Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1: Introduction and state estimation. *Journal of Power Sources*, 161(2), 1356-1368.
- [160] Plett, G. L. (2006). Sigma-point Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 2: Simultaneous state and parameter estimation. *Journal of power sources*, 161(2), 1369-1384.
- [161] Li, J., Barillas, J. K., Guenther, C., & Danzer, M. A. (2013). A comparative study of state of charge estimation algorithms for LiFePO₄ batteries used in electric vehicles. *Journal of power sources*, 230, 244-250.
- [162] Sepasi, Saeed; Ghorbani, Reza; LIAW, Bor Yann. A novel on-board state-of-charge estimation method for aged Li-ion batteries based on model adaptive extended Kalman filter. *Journal of Power Sources*, 2014, vol. 245, p. 337-344.
- [163] Kim, I. S. (2010). A technique for estimating the state of health of lithium batteries through a dual-sliding-mode observer. *IEEE Transactions on Power Electronics*, 25(4), 1013-1022.
- [164] Widodo, A., Shim, M. C., Caesarendra, W., & Yang, B. S. (2011). Intelligent prognostics for battery health monitoring based on sample entropy. *Expert Systems with Applications*, 38(9), 11763-11769.
- [165] Zou, Y., Hu, X., Ma, H., & Li, S. E. (2015). Combined state of charge and state of health estimation over lithium-ion battery cell cycle lifespan for electric vehicles. *Journal of Power Sources*, 273, 793-803.

- [166] Eberhart, Russell; Kennedy, James. A new optimizer using particle swarm theory. *En Micro Machine and Human Science*, 1995. MHS'95., Proceedings of the Sixth International Symposium on. IEEE, 1995. p. 39-43.
- [167] Shi, Y. (2001). Particle swarm optimization: developments, applications and resources. In *Proceedings of the 2001 Congress on Evolutionary Computation (IEEE Cat. No. 01TH8546)* (Vol. 1, pp. 81-86). IEEE.
- [168] Rahman, Md Ashiqur; Anwar, Sohel; Izadian, Afshin. Electrochemical model parameter identification of a lithium-ion battery using particle swarm optimization method. *Journal of Power Sources*, 2016, vol. 307, p. 86-97.
- [169] Yang, X., Chen, L., Xu, X., Wang, W., Xu, Q., Lin, Y., & Zhou, Z. (2017). Parameter identification of electrochemical model for vehicular lithium-ion battery based on particle swarm optimization. *Energies*, 10(11), 1811.
- [170] Kai, H., Yong-Fang, G., Zhi-Gang, L., Hsiung-Cheng, L., & Ling-Ling, L. (2018). Development of Accurate Lithium-Ion Battery Model Based on Adaptive Random Disturbance PSO Algorithm. *Mathematical Problems in Engineering*, 2018.
- [171] Venter, G., & Sobieszczanski-Sobieski, J. (2003). Particle swarm optimization. *AIAA journal*, 41(8), 1583-1589.
- [172] Li, X., Wang, J., & Yin, M. (2014). Enhancing the performance of cuckoo search algorithm using orthogonal learning method. *Neural Computing and Applications*, 24(6), 1233-1247.
- [173] Yang, X. S., & Deb, S. (2014). Cuckoo search: recent advances and applications. *Neural Computing and Applications*, 24(1), 169-174.
- [174] Wang, G. G., Gandomi, A. H., Zhao, X., & Chu, H. C. E. (2016). Hybridizing harmony search algorithm with cuckoo search for global numerical optimization. *Soft Computing*, 20(1), 273-285.
- [175] Shehab, M., Khader, A. T., & Al-Betar, M. A. (2017). A survey on applications and variants of the cuckoo search algorithm. *Applied Soft Computing*, 61, 1041-1059.
- [176] Li, Q., Chen, W., Wang, Y., Liu, S., & Jia, J. (2011). Parameter identification for PEM fuel-cell mechanism model based on effective informed adaptive particle swarm optimization. *IEEE Transactions on Industrial Electronics*, 58(6), 2410-2419.
- [177] Ye, Meiyong; Wang, Xiaodong; Xu, Yousheng. Parameter identification for proton exchange membrane fuel cell model using particle swarm optimization. *International journal of hydrogen energy*, 2009, vol. 34, no 2, p. 981-989.

- [178] R. Valentini, N. Dang, M. Levorato, y E. Bozorgzadeh, «Modeling and control battery aging in energy harvesting systems», en *2015 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, 2015, pp. 515-520.
- [179] L. Tao, J. Ma, Y. Cheng, A. Noktehdan, J. Chong, y C. Lu, «A review of stochastic battery models and health management», *Renew. Sustain. Energy Rev.*, vol. 80, pp. 716–732, 2017.
- [180] M. Talha, F. Asghar, y S. H. Kim, «A Neural Network-Based Robust Online SOC and SOH Estimation for Sealed Lead–Acid Batteries in Renewable Systems», *Arab. J. Sci. Eng.*, pp. 1–13, 2018.
- [181] T.-T. Nguyen, V.-L. Tran, y W. Choi, «Development of the intelligent charger with battery state-of-health estimation using online impedance spectroscopy», in *Industrial Electronics (ISIE), 2014 IEEE 23rd International Symposium on*, 2014, pp. 454–458.
- [182] L. Ungurean, G. Cârstoiu, M. V. Micea, and V. Groza, «Battery state of health estimation: a structured review of models, methods and commercial devices», *Int. J. Energy Res.*, vol. 41, n.o 2, pp. 151–181, 2017.
- [183] K. S. Ng, C.-S. Moo, Y.-P. Chen, y Y.-C. Hsieh, «Enhanced coulomb counting method for estimating state- of-charge and state-of-health of lithium-ion batteries», *Appl. Energy*, vol. 86, n.o 9, pp. 1506-1511, sep. 2009.
- [184] W. Waag, C. Fleischer, and D. U. Sauer, «Adaptive online prediction of the available power of lithium-ion batteries», *J. Power Sources*, vol. 242, pp. 548–559, 2013.
- [185] C. Aksakal y A. Sisman, «On the Compatibility of Electric Equivalent Circuit Models for Enhanced Flooded Lead Acid Batteries Based on Electrochemical Impedance Spectroscopy», *Energies*, vol. 11, n.o 1, p. 118, 2018.
- [186] K. Vignarooban *et al.*, «State of health determination of sealed lead acid batteries under various operating conditions», *Sustain. Energy Technol. Assess.*, vol. 18, pp. 134–139, 2016.
- [187] N.-T. Tran, A. B. Khan, y W. Choi, «State of charge and state of health estimation of agm vrla batteries by employing a dual extended kalman filter and an arx model for online parameter estimation», *Energies*, vol. 10, n.o 1, p. 137, 2017.
- [188] C. Weng, J. Sun, y H. Peng, «Model parametrization and adaptation based on the invariance of support vectors with applications to battery state-of-health monitoring», *IEEE Trans. Veh. Technol.*, vol. 64, n.o 9, pp. 3908–3917, 2015.

- [189] P.-H. Michel y V. Heiries, «An adaptive sigma point kalman filter hybridized by support vector machine algorithm for battery SoC and SoH estimation», in *Vehicular Technology Conference (VTC Spring), 2015 IEEE81st*, 2015, pp. 1–7.
- [190] Z. Guo, X. Qiu, G. Hou, B. Y. Liaw, y C. Zhang, «State of health estimation for lithium ion batteries based on charging curves», *J. Power Sources*, vol. 249, pp. 457–462, 2014.
- [191] H.-T. Lin, T.-J. Liang, y S.-M. Chen, «Estimation of battery state of health using probabilistic neural network», *IEEE Trans. Ind. Inform.*, vol. 9, n.o 2, pp. 679–685, 2013.
- [192] X. Zhang, Y. Wang, C. Liu, y Z. Chen, «A novel approach of battery pack state of health estimation using artificial intelligence optimization algorithm», *J. Power Sources*, vol. 376, pp. 191–199, 2018.
- [193] M. Bercibar, I. Gandiaga, I. Villarreal, N. Omar, J. Van Mierlo, y P. Van den Bossche, «Critical review of state of health estimation methods of Li-ion batteries for real applications», *Renew. Sustain. Energy Rev.*, vol. 56, pp. 572–587, 2016.
- [194] H.E Ariza Chacón,; E. Banguero,; A. Correcher,; Á. Pérez-Navarro,; F. Morant,. Modelling, Parameters Identification and Experimental Validation of a Lead Acid Battery Bank Using Evolutionary Algorithms. *Energies*. 11(9), 2361; <https://doi.org/10.3390/en11092361> (registering DOI). 2018.
- [195] World Energy Outlook (WEO-2017) Special Report: Energy Access Outlook- International Energy Agency (IEA).
https://www.iea.org/publications/freepublications/publication/WEO2017SpecialReport_EnergyAccessOutlook.pdf [Accessed on 03.05.2018]
- [196] Perera, A. T. D., Attalage, R. A., Perera, K. K. C. K., & Dassanayake, V. P. C. (2013). Designing standalone hybrid energy systems minimizing initial investment, life cycle cost and pollutant emission. *Energy*, 54, 220-230.
- [197] Krieger, E. M., Cannarella, J., & Arnold, C. B. (2013). A comparison of lead-acid and lithium-based battery behavior and capacity fade in off-grid renewable charging applications. *Energy*, 60, 492-500.
- [198] Dali, M., Belhadj, J., & Roboam, X. (2010). Hybrid solar–wind system with battery storage operating in grid-connected and standalone mode: control and energy management–experimental investigation. *Energy*, 35(6), 2587-2595.

- [199] Astaneh, Majid, et al. A novel framework for optimization of size and control strategy of lithium-ion battery based off-grid renewable energy systems. *Energy Conversion and Management*, 2018, vol. 175, p. 99-111.
- [200] Nge, C. L., Ranaweera, I. U., Midtgård, O. M., & Norum, L. (2019). A real-time energy management system for smart grid integrated photovoltaic generation with battery storage. *Renewable energy*, 130, 774-785.
- [201] Dhundhara, Sandeep; Verma, Yajvender Pal; Williams, Arthur. Techno-economic analysis of the lithium-ion and lead-acid battery in microgrid systems. *Energy Conversion and Management*, 2018, vol. 177, p. 122-142.
- [202] Pillot, C. (2015, March). The rechargeable battery market and main trends 2014–2025. In 31st International Battery Seminar & Exhibit. (Available from: http://www.avicenne.com/pdf/Fort_Lauderdale_Tutorial_C_Pillot_March2015.pdf). [Accessed on 03.07.2018].
- [203] Yang, J., Hu, C., Wang, H., Yang, K., Liu, J. B., & Yan, H. (2017). Review on the research of failure modes and mechanism for lead–acid batteries. *International Journal of Energy Research*, 41(3), 336-352.
- [204] J. Li, Optimal sizing of grid-connected photovoltaic battery systems for residential houses in Australia, *Renewable Energy* (2018).<https://doi.org/10.1016/j.renene.2018.09.099>
- [205] Marchildon, Jacques; Doumbia, Mamadou Lamine; Agbossou, Kodjo. SOC and SOH characterisation of lead acid batteries. In *Industrial Electronics Society, IECON 2015-41st Annual Conference of the IEEE*. IEEE, 2015. p. 001442-001446.
- [206] Li, X., Shu, X., Shen, J., Xiao, R., Yan, W., & Chen, Z. An on-board remaining useful life estimation algorithm for lithium-ion batteries of electric vehicles. *Energies*, 2017, vol. 10, no 5, p. 691.
- [207] Gao, Z., Cecati, C., & Ding, S. X. (2015). A survey of fault diagnosis and fault-tolerant techniques—Part I: Fault diagnosis with model-based and signal-based approaches. *IEEE Transactions on Industrial Electronics*, 62(6), 3757-3767.
- [208] Ferrer, A. (2007). Multivariate statistical process control based on principal component analysis (MSPC-PCA): Some reflections and a case study in an autobody assembly process. *Quality Engineering*, 19(4), 311-325.
- [209] Jiang, Q., Yan, X., & Zhao, W. (2013). Fault detection and diagnosis in chemical processes using sensitive principal component analysis. *Industrial & Engineering Chemistry Research*, 52(4), 1635-1644.

- [210] Fan, J., & Wang, Y. (2014). Fault detection and diagnosis of non-linear non-Gaussian dynamic processes using kernel dynamic independent component analysis. *Information Sciences*, 259, 369-379.
- [211] Garcia-Alvarez, D., Fuente, M. J., & Sainz, G. I. (2012). Fault detection and isolation in transient states using principal component analysis. *Journal of Process Control*, 22(3), 551-563.
- [212] Rahmani, M., & Atia, G. K. (2017). Coherence pursuit: Fast, simple, and robust principal component analysis. *IEEE Transactions on Signal Processing*, 65(23), 6260-6275.
- [213] Bro, R., & Smilde, A. K. (2014). Principal component analysis. *Analytical Methods*, 6(9), 2812-2831.
- [214] Granato, D., Santos, J. S., Escher, G. B., Ferreira, B. L., & Maggio, R. M. (2017). Use of principal component analysis (PCA) and hierarchical cluster analysis (HCA) for multivariate association between bioactive compounds and functional properties in foods: A critical perspective. *Trends in Food Science & Technology*.
- [215] Soh, W., Kim, H., & Yum, B. J. (2018). Application of kernel principal component analysis to multi-characteristic parameter design problems. *Annals of Operations Research*, 263(1-2), 69-91.
- [216] Deng, X., Tian, X., Chen, S., & Harris, C. J. (2018). Nonlinear process fault diagnosis based on serial principal component analysis. *IEEE transactions on neural networks and learning systems*, 29(3), 560-572.
- [217] De Ketelaere, B., Hubert, M., & Schmitt, E. (2015). Overview of PCA-based statistical process-monitoring methods for time-dependent, high-dimensional data. *Journal of Quality Technology*, 47(4), 318-335.
- [218] Vanhatalo, E., Kulahci, M., & Bergquist, B. (2017). On the structure of dynamic principal component analysis used in statistical process monitoring. *Chemometrics and Intelligent Laboratory Systems*, 167, 1-11.
- [219] Zhao, C., Wang, F., Gao, F., Lu, N., & Jia, M. (2007). Adaptive monitoring method for batch processes based on phase dissimilarity updating with limited modeling data. *Industrial & engineering chemistry research*, 46(14), 4943-4953.
- [220] Nomikos, P., & MacGregor, J. F. (1995). Multivariate SPC charts for monitoring batch processes. *Technometrics*, 37(1), 41-59.