

UNIVERSIDAD DE OVIEDO

Escuela Politécnica de Ingeniería
Departamento de Informática

Aportes a los Algoritmos de Aprendizaje Multiobjetivo para Modelos Semi-físicos de Estimación del Estado de Salud en Baterías

Yuviny Echevarría Cartaya

Tesis Doctoral
Programa de Doctorado en Informática

Tutor: Luciano Sánchez Ramos
Directores: Luciano Sánchez Ramos y
Cecilio Blanco Viejo

Junio de 2017

*”Después de escalar una montaña muy alta,
descubrimos que hay muchas otras montañas por escalar”*

- Nelson Mandela

Dedicado a mi familia,
especialmente a la memoria de mi madre.

Declaración de Autoría

El autor, Yuviny Echevarría Cartaya, declara que la presente tesis titulada, “Aportes a los Algoritmos de Aprendizaje Multiobjetivo para Modelos Semi-físicos de Estimación del Estado de Salud en Baterías” y el trabajo presentado en la misma es de mi propia autoría. Se confirma que:

- Este trabajo se realizó totalmente en mi período de formación en el Programa de Doctorado en Informática de la Universidad de Oviedo.
- Ninguna parte de esta tesis ha sido utilizada para la obtención de ningún otro grado o calificación, ni en esta ni en ninguna otra universidad.
- Se referencian las publicaciones consultadas en las cuales se han basado los aportes realizados en la presente tesis.
- No han existido conflictos de intereses con el resto de los autores de las publicaciones asociadas a la producción científica de la presente investigación.

Para que así conste, se firma la presente en la ciudad de Gijón, a 22 de junio de 2017.

Firma:

Agradecimientos

Quisiera agradecer a las personas e instituciones que me han apoyado en el desarrollo de mis habilidades intelectuales, técnicas y emocionales durante la presente investigación.

Agradezco a mis directores de tesis Luciano Sánchez Ramos y Cecilio Blanco Viejo por sus sabios consejos científico-técnicos que han servido de guía durante la investigación. He crecido profesionalmente trabajando a su lado y han despertado en mí la pasión por la investigación científica, gracias de corazón por su apoyo.

Agradezco a los profesores del Laboratorio de Baterías en la Escuela Politécnica de Ingeniería de Gijón: Gracias a Manuela González Vega por su apoyo profesional y por su incondicionalidad con mi familia; Igualmente gracias a Victor Manuel García Fernández y David Anseán González por el tiempo que me han dedicado en debates que mucho han ayudado a la presente investigación.

Gracias a los profesores Juan Carlos Viera Pérez y Antolín Hernández Battez por su ejemplo, han estado a mi lado en los momentos que más los he necesitado. Tras estos años, los considero parte de mi familia.

Gracias a mis compañeros de laboratorio: José Luis Antuña Albuerne, Yoana Fernández Pulido y Jorge Alonso del Valle. Ha sido un placer trabajar a su lado.

Gracias a mis compañeros que desde la distancia han estado pendiente de mí y me han motivado a seguir adelante en momentos de incertidumbre.

Gracias a mi esposa por acompañarme en esta aventura y darme el mayor regalo de mi vida, nuestro hijo Fabián.

Ha sido para mí un honor la oportunidad de participar en el proyecto Eureka SD el cual ha financiado la presente investigación. Este proyecto se ha desarrollado en el marco del Programa Erasmus Mundus con número de acuerdo 2013-2591 de la Unión Europea.

Resumen

Aumentar el uso de fuentes renovables de energía es de vital importancia para lograr un desarrollo sostenible. Los vehículos eléctricos se consolidan como la alternativa de automoción que más crece en los últimos años. Las baterías de Iones de Litio es la tecnología que predomina en los vehículos eléctricos. Lograr el uso óptimo de las baterías no es una tarea sencilla, las no-linealidades de los procesos electroquímicos subyacentes hacen complejo el desarrollo de modelos precisos para el diagnóstico y/o pronóstico de las condiciones en que se encuentran las baterías. Existen problemas abiertos para la ciencia en el modelado de baterías de Iones de Litio, siendo uno de estos problemas la estimación del Estado de Salud mediante modelos que puedan ser utilizados a bordo de los vehículos eléctricos. La presente tesis desarrolla nuevos modelos dinámicos que facilitan la estimación del Estado de Salud en baterías de Iones de Litio. Estos modelos semi-físicos tienen un enfoque multicriterio y se basan en el conocimiento parcial acerca de los fenómenos electroquímicos y térmicos que ocurren en las baterías.

Los modelos semi-físicos de segunda generación propuestos contienen un conjunto de ecuaciones diferenciales con bloques inteligentes embebidos. Éste enfoque reduce el número de bloques que se comportan como pequeñas cajas negras en el modelo. Los nuevos modelos son Sistemas Genético-Difuso Multiobjetivo que requieren de potentes algoritmos para el aprendizaje. El uso de estos modelos implica aproximar la primera derivada de la salida de tensión del modelo con respecto a la carga almacenada en la batería, lo cual es un procedimiento costoso y muy susceptible a pequeñas variaciones. Este elemento conlleva a que la evaluación de la función de adaptabilidad en el proceso evolutivo consuma más del noventa por ciento del tiempo de una generación completa. Además, durante el aprendizaje se genera un elevado número de soluciones resistentes a la dominación. Las dificultades encontradas en los procesos de aprendizaje de los modelos propuestos y el comportamiento promedio de los algoritmos existentes han motivado el desarrollo de extensiones a los Algoritmos Evolutivos Multiobjetivo.

La primera aportación a los algoritmos de aprendizaje en esta tesis consiste en la inyección de conocimiento en el proceso evolutivo. El mecanismo de preferencias parciales propuesto modifica ligeramente el ordenamiento de los individuos en la etapa de selección de la supervivencia. Se usa un operador basado en taylorismo para complementar los niveles de no-dominación de Pareto con un segundo orden parcial. La propuesta incluye además modernas estrategias para fomentar la diversidad de la población durante el proceso evolutivo. Los modelos aprendidos son potencialmente mejores por la presión ejercida en el proceso evolutivo. El estudio empírico realizado concluye que la propuesta obtiene mejores resultados que el resto de los algoritmos genéticos evaluados.

La segunda aportación se realiza ante la necesidad de aprender un modelo semi-físico simple para la estimación del Estado de Salud en baterías de Iones de Litio. El modelo requiere aprender

indirectamente y de manera completamente interpretable la variable latente asociada al potencial del electrodo negativo de la batería. Con el aprendizaje indirecto de expresiones analíticas mediante algoritmos que puedan ser utilizados en los vehículos eléctricos, se resuelve de manera inmediata la estimación del Estado de Salud. Ante las carencias identificados en los algoritmos de aprendizaje basados en Programación Genética Multiobjetivo se propone una extensión de estos. La propuesta hace uso de gramáticas para explotar la monotonía de la variable latente de interés, así como de modernas estrategias en la etapa de selección de la supervivencia. El algoritmo propuesto permite estimar los puntos de cambios de fase en las curvas de tensión de la batería a bajas corrientes. Desde el punto de vista práctico se corresponde con la estimación de los picos representativos de las curvas resultantes del Análisis de Capacidad Incremental facilitando el diagnóstico de Estado de Salud en las baterías. Esta aportación sirve como base a nuevas líneas de investigación en el área.

Abstract

Increasing the use of renewable energy sources reducing emissions of polluting gases to the environment is essential for achieving sustainable development. Nowadays, one of the main goals to reduce the world pollution is related to the control of carbon dioxide emissions produced by conventional engine automobiles. Electric vehicles are a good alternative to mitigate this environmental pollution problem. The efficiency of the electric vehicles, that use Li-Ion batteries, grows with the scientific innovation. Optimizing Li-Ion battery operation is not a simple task. Li-Ion batteries for automotive applications are complex and unstable dynamical systems with multiple inputs and outputs. Estimating the State of Health of the Li-Ion batteries is the major challenge for the developing of battery model. For this reason, developing of accurate estimation techniques, for battery management systems in electric vehicle, requires the concentration of the scientific community. This thesis proposes a new generation of dynamical models for the diagnosis of the State of Health in Li-Ion batteries. The models are based on partial knowledge of the electrochemical and thermodynamic phenomena defining the behavior of a Li-Ion battery.

The semi-physical models comprise a set of differential equations with intelligent elements embedded that minimize the number of small black boxes. The learning process of the resulting Multiobjective Genetic Fuzzy Systems requires powerful algorithms. Due to the necessary approximation of the first derivate of the battery voltage respect to the stored charge. This is an expensive procedure and small changes in the voltage curve cause large excursion of the first derivate. The fitness evaluation in each generation is more than the ninety percent of the consumed time. On the other hand, existing evolutionary learning processes generate a high number of dominance-resistant individuals. All this motivates two major contributions made in this thesis.

The first contribution is the knowledge injection through fuzzy preference order in to the learning process. Thus, prioritization of the individuals is altered in the survival selection stage. A tailored-made operator is used which complements Pareto Non-Dominance levels with a partial order at each level. The learned models are potentially better for the advantages of the proposed evolutive pressure mechanism. It has been shown, that accurate State of Health models for Li-Ion batteries can be obtained if a knowledge-based preference ordering of individuals is implemented. In this work, an empirical study is performed and the result of different multi and many-objectives genetic algorithms are assessed.

The second contribution is focused in the learning process of a simple semi-physical model for the State of Health estimation. This model is based on the side reactions on the electrodes that can degrade a battery. In this case, the learning process requires the indirect estimation of a latent variable with human understandable structure. The contribution extends the Multiobjective Genetic Programming-Based Learning by using different survival selection strategies suitable for this problem. The proposed algorithm Grab-MO-GaP incorporates recent advances developed

for many-objectives genetic algorithms. The proposed algorithm uses Grammatical Evolution to enforce the monotonicity of the latent variable respect to the model outputs and works as an evolutive pressure mechanism. The human-readable structures allow obtaining the location of the characteristic points of the negative electrode when the battery is being charged or discharged at a low current.

Abreviaturas

MOEFS	Sistema Evolutivos-Difuso Multiobjetivo (M ulti- O bjective E volutionary F uzzy S ystem);
FRBS	Sistema Basado en Reglas Difusas (F uzzy R ules- B ased S ystem);
GPBL	Aprendizaje Basado en Programación Genética (G enetic P rogramming B ased L earning);
MOEA	Algoritmos Evolutivos Multi-Objetivo (M ulti- O bjective E volutionary A lgorithms);
MMOOEA	Algoritmos Evolutivos para Problemas de Muchos Objetivos (M any- O bjective E volutionary A lgorithms);
MOGP	Programación Genética Multi-Objetivo (M ulti- O bjective G enetic P rogramming);
GE	Programación Genética basada en Gramatica (G rammatical E volution);
NSGA	Nondominated Sorting G enetic A lgorithm;
SPEA	S trength P areto E volutionary A lgorithm;
MOEA/D	Algoritmo Evolutivo Multiobjetivo basado en Descomposición (M ulti- O bjective E volutionary A lgorithm based on D ecomposition);
MOPSO	Optimización basada en Enjambre de Partículas Multiobjetivo (M ulti- O bjective P article S warm O ptimisation);
θ - DEA	Algoritmo Evolutivo basado en dominación- θ (θ - D ominance E volutionary A lgorithm);
θ - FPO ¹	Preferencias Parciales Difusas basadas en θ -DEA (θ - F uzzy P reference O rders);
Grab-MO-GaP ¹	G rammar- B ased M ulti- O bjective G enetic A lgorithm- P rogramming;
BMS	Sistemas de Gestión de Baterías (B attery M anagement S ystems);
SoC	Estado de Carga (S tate o f C harge);
SoH	Estado de Salud (S tate o f H ealth);
OCV	Tensión de Circuito Abierto (O pen- C ircuit V oltage);

¹Algoritmo propuesto en la presente tesis.

ICA	Análisis de la Capacidad Incremental (I ncr e mental C apacity A nalysis);
CEE	C ircuito E l e ctrico E quivalente;
LFP	Litio-Hierro-Fosfato (LiFePO₄);
MSE	Error cuadrático medio (M ean S quared E rror).
Modelos SMF	Modelos S emi- F ísicos.

Índice general

Declaración de Autoría	VI
Agradecimientos	VIII
Abreviaturas	XIV
Índice de Figuras	XVIII
Índice de Tablas	XXII
1. Planteamiento del Problema	1
1.1. Motivación	2
1.2. Problema de investigación	8
1.3. Objetivo general	9
1.4. Objetivos específicos	9
1.5. Etapas en el desarrollo de la investigación	10
1.6. Métodos de trabajo científico	13
1.7. Novedad científica	13
1.8. Valor práctico	14
1.9. Valor social	14
1.10. Estructura de la tesis	15
2. Fundamentación Teórica	19
2.1. Técnicas inteligentes en modelos dinámicos para la ingeniería	20
2.2. Computación evolutiva para el aprendizaje de modelos	21
2.2.1. Algoritmos evolutivos multiobjetivo	23
2.2.1.1. SPEA2	26
2.2.1.2. NSGA-II	27
2.2.1.3. OMOPSO	28
2.2.2. Algoritmos evolutivos para problemas de muchos-objetivos	28
2.2.2.1. MOEA/D	34
2.2.2.2. NSGA-III	34
2.2.2.3. θ -DEA	35
2.3. Modelado de baterías de Iones de Litio	37
2.3.1. Conceptos, fundamentos generales y tecnologías	38

2.3.2.	Principios en el desarrollo de modelos	44
2.3.3.	Modelos de diagnóstico del estado de carga	45
2.3.3.1.	Modelo semi-físico	49
2.3.4.	Modelos para la estimación del estado de salud	51
2.3.4.1.	Modelos basados en degradación	53
2.4.	Conclusiones parciales del capítulo	58
3.	Desarrollo de las propuestas	61
3.1.	Modelo SMF 1	63
3.1.1.	Primera salida del modelo: tensión de la batería	64
3.1.2.	Segunda salida del modelo: temperatura de la batería	65
3.1.3.	Discretización del modelo	66
3.1.4.	Caso de estudio 1: Evaluación de los MOEAs	67
3.1.5.	Caso de estudio 2: Estimación indirecta de la OCV	71
3.2.	El reto de la estimación del Estado de Salud	76
3.3.	Aportación a los Sistemas Genético-Difuso Multiobjetivo: Algoritmo θ -PFO	80
3.3.1.	Etapas de inicialización	81
3.3.2.	Etapas de apareamiento	83
3.3.3.	Etapas de selección de la supervivencia	84
3.4.	Modelo SMF 2	87
3.4.1.	Aprendizaje basado en Programación Genética Multiobjetivo	90
3.4.1.1.	MOGP y GE para reducir complejidad y la inflación	91
3.4.1.2.	Control evolutivo: dominación y elitismo	93
3.5.	Aportación al aprendizaje basado en Programación Genética Multiobjetivo: Algoritmo Grab-MO-GaP	96
3.6.	Conclusiones parciales	100
4.	Evaluación de las propuestas	103
4.1.	Juegos de datos para la experimentación	104
4.2.	Selección de medidas de comparación en MOEAs	109
4.3.	Metodología para la evaluación de las propuestas	114
4.4.	Evaluación de los MOEAs del Caso de Estudio 1	115
4.5.	Evaluación de los MOEAs en el aprendizaje del modelo SMF 1	117
4.6.	Estudio empírico de θ -FPO	121
4.7.	Estudio empírico de Grab-MO-GaP	126
4.7.1.	Definición de la gramática	127
4.7.2.	Análisis y discusión de los resultados	133
4.8.	Conclusiones parciales	138
5.	Conclusiones Generales	141
5.0.1.	Trabajo futuro	143
A.	Producción científica	145
	Bibliografía	147

Índice de figuras

1.1. Etapas del desarrollo de la investigación.	12
2.1. Estructura de los Algoritmos Evolutivos (Figura inspirada en [1]).	22
2.2. Representaciones de soluciones en un problema multicriterio de dos objetivos.	24
2.3. Relaciones de dominación basadas en Pareto.	25
2.4. Frente de Pareto de ejemplo.	25
2.5. Método de densidad utilizado en el algoritmo SPEA2.	27
2.6. Procedimiento del algoritmo NSGA-II.	28
2.7. Distribución de puntos de referencia en un espacio objetivo de tres dimensiones (Fuente [2]).	30
2.8. Soluciones de referencia en un espacio de búsqueda de dos dimensiones.	31
2.9. Enfoque de intersección de límites en un espacio objetivo de dos dimensiones (Fuente [3]).	33
2.10. Representación geométrica en un espacio objetivo normalizado de dos dimensiones del enfoque de intersección de límites basado en penalizaciones utilizados en θ -DEA (Fuente [2]).	36
2.11. Esbozo de los vehículos eléctrico (Fuente [4]).	37
2.12. Principio de funcionamiento las las baterías de Iones de Litio (Fuente [5]).	38
2.13. Método de relajación para la obtención de la OCV.	41
2.14. Pseudo-OCV.	41
2.15. Comparación de las distintas tecnologías de baterías basadas en Litio (Fuente [5]).	43
2.16. Número de publicaciones por año de las diferentes estrategias de estimación relacionadas con vehículos eléctricos y baterías (Fuente [4])	44
2.17. Protocolo de carga, reposo y descarga de una batería de LiFePO_4	45
2.18. Diferentes regímenes de descarga aplicados a un batería de LiFePO_4	46
2.19. Circuito eléctrico equivalente de los modelos semi-físicos de de primera generación.	49
2.20. Modelo semi-físico de baterías con analogía en el llenado de un tanque (Fuente [7]).	50
2.21. Salida experimental del modelo semi-físico con enfoque multicriterio de primera generación (Fuente [7]).	50
2.22. Estudio de la Resistencia Interna mediante un CEE para la estimación del SoH (Fuente [8]).	53
2.23. Análisis de la Capacidad Incremental (Fuente [9]).	54
2.24. Cambios en las curvas ICA entre el 100 % y el 90 % del SoH.	55
2.25. ICA de la curva de tensión de la batería con el protocolo de carga y descarga a corriente constante ($C/25$), ΔV a 2mV, 3mV y 4mV.	56
2.26. Análisis Diferencial de Tensión (Fuente [9]).	57

3.1. Particiones difusas de la variable Q	65
3.2. Particiones difusas de la variable T_B	65
3.3. Caso de Estudio 1: Frentes de Pareto de la experimentación con el juego de datos DS-C/3.	70
3.4. Caso de Estudio 1: Frentes de Pareto de la experimentación con el juego de datos DS-C/2.	70
3.5. Caso de Estudio 1: Frentes de Pareto de la experimentación con el juego de datos DS-C.	71
3.6. Ensayo de relajación para el caso de estudio 1.	72
3.7. Modelo basado en un circuito eléctrico equivalente propuesto por Abu-Sharkh (Fuente [12]).	72
3.8. Modelo basado en un circuito eléctrico equivalente	73
3.9. Estimación de los puntos de la OCV con el juego de datos DS-C/3.	74
3.10. Estimación de los puntos de la OCV con el juego de datos DS-C/2.	75
3.11. Estimación de los puntos de la OCV con el juego de datos DS-C.	75
3.12. Ejemplo de las diferencias en la convergencia entre la salida de un modelo y su derivada.	77
3.13. Ejemplo de la sensibilidad de las curvas ICA respecto a la salida de tensión del modelo.	78
3.14. Inicialización de las fronteras límites en el algoritmo propuesto (Fuente [10]).	82
3.15. Espaciado uniforme mediante el métodos de Das y Dennis (Fuente [10]).	82
3.16. Distribución de probabilidad del operador SBX.	83
3.17. Zonas de los niveles de no-dominación que se afectan mayormente por el uso de las preferencias parciales difusas.	85
3.18. Preferencias parciales en dos grupos de soluciones del algoritmos θ -FPO.	85
3.19. OCP de los electrodos en una celda de LiFePO_4	87
3.20. Efecto de la degradación en el electrodo negativo de una celda (Fuente [11]).	88
3.21. Ejemplo de la codificación del cromosoma para Grab-MO-GaP.	96
4.1. Celda de LiFePO_4 de European Batteries ensayada para el presente estudio.	104
4.2. Curvas a diferentes regímenes de descarga de las celdas de 42 Ah proporcionadas por European Batteries.	105
4.3. Envejecimiento de las celdas ensayadas de European Batteries en condiciones ideales.	106
4.4. Equipamiento del Laboratorio de Baterías de la Universidad de Oviedo.	106
4.5. Ensayo de relajación cada 10 % del SoC propuesto por [12] para la celda #1 (Rojo) y celda #2 (Azul).	107
4.6. Resumen de los juegos de datos para la experimentación elaborados en el Laboratorio de Baterías.	108
4.7. Ejemplo de función de logro (Fuente [13]).	109
4.8. Superposición entre las relaciones de dominación.	111
4.9. Frentes de Pareto de ejemplo para el cálculo del indicador I_{E*}	112
4.10. Codificación del cromosoma para el Sistema Genético-Difuso Multiobjetivo asociado al modelo semi-físico 1.	118
4.11. Frentes de Pareto del estudio empírico con θ -DEA y θ -FPO correspondiente a los juegos de datos DS-C, DS-C/2 y DS-C/3.	123
4.12. Frentes de Pareto en 2D de θ -DEA y θ -FPO para la experimentación realizada.	124

4.13. Ajuste de las curvas de salida de modelo de una solución del FP resultante del algoritmo propuesto θ -FPO con el juego de datos DS-C/2 como entrada.	125
4.14. Codificación del cromosoma para el Sistema de Programación-Genética-Difuso Multiobjetivo asociado al modelo semi-físico 2.	126
4.15. Reflexión horizontal de la función Logit.	129
4.16. Función Sigmoide.	130
4.17. Funciones que fundamentan la definición de la gramática para la experimentación con Grab-MO-GaP.	130
4.18. Tensión frente al SoC para identificar los cambios de pendiente.	131
4.19. Identificación de los puntos de cambio de pendiente.	132
4.20. Frentes de Pareto obtenidos de las diferentes variantes evaluadas del algoritmos propuesto Grab-MO-GaP.	133
4.21. Proyección en 2D de los FPs obtenidos con Grab-MO-GaP.	134
4.22. Ejemplo de una expresión obtenida indirectamente para el electrodo negativo. .	135
4.23. Etiquetado de los puntos de cambio de pendiente en la curva ICA.	137

Índice de tablas

2.1. Resumen de los principales diseños de los Algoritmos Evolutivos.	23
2.2. Resumen de las principales tecnología de baterías basadas en Iones de Litio. . .	43
2.3. Principales métodos adaptativos para la estimación del SoH.	53
3.1. Valores aproximados de los parámetros del modelo semi-físico para baterías. . .	68
3.2. Tabla comparativa de los métodos para la estimación de la OCV.	74
4.1. Características de las celdas ensayadas	105
4.2. Relaciones de dominación.	110
4.3. Resumen de Indicadores Unarios de Calidad para la evaluación con Frentes de Pareto óptimo conocido.	111
4.4. Ejemplo de la aplicación del indicador I_{ε^*}	113
4.5. Evaluación basada en el indicador I_{ε^+} de los MOEAs del Caso de Estudio 1. . .	115
4.6. Resumen de parámetros utilizados en los algoritmos evolutivos seleccionados para el aprendizaje del modelo SMF 1.	118
4.7. Evaluación basada en el indicador I_{ε^+} de los MOEAs seleccionados para el aprendizaje del modelo semi-físico 1.	119
4.8. Resumen de parámetros para el estudio empírico θ -FPO.	121
4.9. Evaluación basada en el indicador I_{ε^+} de los algoritmos θ -DEA y el propuesto θ -FPO.	122
4.10. Resumen de parámetros del estudio empírico con Grab-MO-GaP.	127
4.11. Parte Superior: Evaluación de los resultados mediante el Indicador Binario Aditivo de Epsilon. En la parte inferior: se complementa con información sobre diversidad de los FPs mediante la Distancia Generacional Invertida.	136
4.12. Comparación del error absoluto en Vatios entre Grab-MO-GaP y la red neuronal recurrente.	138

Capítulo 1

Planteamiento del Problema

Durante este capítulo se plantean las motivaciones de la presente investigación, enfocando al lector hacia el problema en el que se trabaja a lo largo de la tesis. Posteriormente, se expone la metodología para el desarrollo de la investigación mediante el establecimiento del objetivo general, los objetivos específicos y las preguntas científicas que serán respondidas en el desarrollo del trabajo. Finalmente se explica el hilo conductor que se ha seguido en las diferentes etapas de la investigación y la estructura de la tesis.

1.1. Motivación

Alcanzar el desarrollo sostenible plantea importantes retos para la humanidad. Los gobiernos y las empresas dedican muchos esfuerzos a disminuir el uso de combustibles fósiles y las emisiones de gases contaminantes al medio ambiente. Se ha hecho indispensable con el paso de los años aumentar el uso de las fuentes renovables de energía como el viento, el agua y la radiación solar. La disponibilidad de energía de estas fuentes renovables no es continua, se deben utilizar sistemas que faciliten la toma de decisiones minuto a minuto para la gestión de los recursos energéticos. Un complemento importante para garantizar la disponibilidad es el uso de sistemas para el almacenamiento de energía. Las baterías son un elemento clave en dichos sistemas de almacenamiento, tanto en aplicaciones que necesitan de respaldo eléctrico como en aplicaciones móviles (vehículos eléctricos, ordenadores personales, teléfonos, etc).

En las aplicaciones de automoción, donde las baterías representan una parte importante de la inversión, se debe garantizar su uso óptimo. Para este fin, los vehículos eléctricos incorporan Sistemas de Gestión de Baterías (BMS, del inglés: Battery Management Systems) que implementan modelos de diagnóstico y/o pronóstico. En el desarrollo de éstos modelos los investigadores se enfrentan a problemas que son complejos de resolver mediante métodos clásicos. Estos problemas tienen una particularidad, generalmente cuentan con un planteamiento sencillo y alta dificultad de resolución. En las ciencias y las ingenierías, de manera general, ya pasaron los años en que se encontraban soluciones sencillas a problemas sencillos. Cuando no se cuenta con métodos exactos para la resolución de problemas o su aplicación es muy costosa, las técnicas de Aprendizaje Automático han demostrado ser una poderosa alternativa para el modelado [14].

El Aprendizaje Automático es una rama de la Inteligencia Artificial que ha evolucionado sustancialmente en las últimas décadas. Éstas herramientas de modelado permiten generalizar comportamientos a partir del conocimiento extraído de los datos. Cuando el conocimiento de la dinámica de un sistema es parcial, los investigadores recurren a modelos universales, conocidos como modelos de caja negra [15]. Estos intentan prescindir del conocimiento de expertos humanos en el proceso de aprendizaje. No obstante, si los datos que describen el funcionamiento de un sistema son incompletos o imprecisos es necesario inyectar conocimiento de la dinámica de los sistemas en el aprendizaje, dando lugar a modelos de caja gris [16–18].

El conocimiento aportado al proceso de aprendizaje de modelos se puede expresar mediante diferentes formas:

- Reglas lingüísticas proporcionadas por un experto humano;
- Ecuaciones que definen la dinámica de alguno de los bloques constituyentes (p.e. modelos de Wiener [19], modelos de Hammerstein [20], etc);

- Modelos semi-físicos, los cuales están inspirados total o parcialmente en determinados fenómenos físicos (p.e. asimilar el comportamiento de una batería a un depósito de agua [6], etc);
- A través de híbridos entre modelos de caja negra y modelos basados en “primeros principios” [67].

Varios son los problemas de ingeniería que hacen uso de herramientas de Aprendizaje Automático y logran buenos resultados. Sin embargo, en otros problemas de ingeniería se hace difícil el aprendizaje por la inestabilidad de los sistemas y las no-linealidades implícitas. Éste es el caso de los modelos dinámicos asociados a las baterías de Litio. Estos modelos, al igual que otros, tiene la particularidad de contar con memoria, sus salidas dependen tanto de las entradas como del valor de las variables latentes.

En función de la utilidad del modelo y la aplicación, puede ser necesario que los elementos que se aprenden sean total o parcialmente comprensibles por los seres humanos. En algunas ocasiones es suficiente con disponer de instrumentos virtuales con los cuales se realizan simulaciones del proceso. En otras ocasiones, es necesario que la estructura del modelo o de determinados bloques internos sean interpretables. En el caso particular del aprendizaje indirecto de variables latentes en modelos dinámicos se requiere la mayor interpretabilidad posible. Un elemento que los investigadores no pierden de vista en las estrategias de aprendizaje es el equilibrio entre interpretabilidad y precisión [21].

Aprender un modelo consiste en encontrar el conjunto de parámetros que minimicen el error de predicción en una secuencia de entradas y salidas conocidas. En el aprendizaje de modelos basados en reglas lingüísticas dicho conjunto de parámetros comprende los antecedentes y consecuentes de las reglas difusas [22]. Es conocido que los Sistemas Genéticos-Difusos no son el mecanismo ideal para aprender bloques totalmente interpretables. La comprensión del conocimiento extraído mediante sistemas basados en reglas difusas puede ser muy pobre cuando no se usan particiones difusas fuertes. Aunque varios estudios logran buenos resultados facilitando la interpretabilidad del conocimiento extraído mediante reglas lingüísticas [23, 24].

Desde el punto de vista de la comprensión por los seres humanos, el aprendizaje basado en Programación Genética está un paso por delante del aprendizaje basado en reglas difusas [25]. Sus estructuras en forma de árboles facilitan la comprensión del conocimiento extraído tanto en problemas de clasificación como en problemas de regresión simbólica. El genotipo y fenotipo de la codificación del cromosoma garantiza la interpretabilidad estructural y semántica de los individuos (soluciones) para un problema determinado.

Los problemas de aprendizaje de modelos dinámicos con enfoque multicriterio van un paso más allá. La complejidad para el aprendizaje hace que las técnicas tradicionales de la Investigación de

Operaciones (optimización basada en métodos de planos cortantes o basadas en gradiente) sean poco factibles [1]. Los algoritmos de computación evolutiva para el aprendizaje multiobjetivo son los más utilizados y se encuentran en constante evolución.

En problemas multicriterio de dos o tres objetivos es conocido que los algoritmos evolutivos multiobjetivo obtienen muy buenos resultados. Los algoritmos más estudiados en problemas de estas dimensiones son NSGA-II [26] y SPEA2 [27]. Sin embargo, la convergencia de estos algoritmos y sus similares no es la misma cuando se enfrentan a problemas de muchos objetivos (cuatro o más objetivos). Incluso existen problemas de dos o tres objetivos que presentan Frentes de Pareto difíciles de aproximar, fundamentalmente por la cantidad de óptimos locales que contiene el horizonte de programación de la funciones de adaptabilidad. Varios de los problemas dinámicos que se presentan en la ingeniería requieren el aprendizaje de problemas de muchos objetivos o de Frentes de Pareto difíciles.

En los últimos años existe un interés creciente por los algoritmos evolutivos para problemas de muchos objetivos, con aplicaciones en muy diversas áreas como los sistemas de control [28, 29], la planificación de actividades de la producción [30, 31], la ingeniería de software [32], etc. El principal reto de los Algoritmos Evolutivos Multiobjetivo en el aprendizaje de modelos dinámicos es la preservación de los individuos élites como mecanismo para alcanzar el Frente de Pareto óptimo. La convergencia de estos procesos evolutivos se hace considerablemente lenta, la mayoría de los mecanismos de selección elitista de individuos emplean relaciones de dominación basadas en Frentes de Pareto como principal criterio de selección. Si el proceso de evaluación de la función de adaptabilidad consume mucho tiempo de procesamiento (como en el aprendizaje de modelos dinámicos) se hace todavía más lento el aprendizaje. En espacios de soluciones de grandes dimensiones es también un reto encontrar un equilibrio para evitar la convergencia prematura y fomentar los mecanismos de promoción de la diversidad.

En algunos problemas de aplicación se ha observado la aparición de individuos resistentes a los diferentes mecanismos de dominación, independientemente de las dimensiones y cantidad de objetivos del problema [33]. En estos procesos evolutivos, si se seleccionan individuos de forma aleatoria en una población determinada, la probabilidad de escoger soluciones no-dominadas aumenta exponencialmente respecto al número de objetivos [34]. Éste elemento es de interés para los investigadores, no es un fenómeno únicamente del aprendizaje de modelos con muchos objetivos. En problemas de aplicación con dos o tres objetivos se han encontrado individuos resistentes a la dominación [35], como se mencionó anteriormente. Algunos estudios introducen en estos procesos evolutivos un segundo nivel de ordenamiento de las soluciones basado en preferencias parciales para alcanzar el Frente de Pareto óptimo [36, 37].

Las investigaciones para combatir la aparición de soluciones resistentes a la dominación en los algoritmos evolutivos multiobjetivo se centran fundamentalmente en la etapa de selección de los

individuos que sobreviven para la siguiente generación. Los estudios se pueden agrupar en tres líneas de trabajo fundamentales:

1. La promoción de nuevas relaciones de preferencias entre los individuos [38–42].
2. La adopción de nuevos mecanismos de promoción de diversidad [31].
3. El uso de archivos externos independientes dedicados a la convergencia y la diversidad [43].

Éstas líneas de trabajo se complementan con varios enfoques no excluyentes entre sí:

- Uso de puntos de referencia bien distribuidos en el espacio de decisión para guiar la búsqueda [34].
- Descomponiendo el problema multicriterio en funciones escalares para su optimización, mediante diferentes funciones de agregación, se logra la convergencia global.
- Intersección de límites basado en penalidades [2].
- Identificación de las interacciones entre los genes (variables) durante el proceso evolutivo [44–47], así como la interacción de expertos humanos durante el proceso evolutivo para guiar la búsqueda a determinadas zonas del espacio de decisión.

En este contexto, los modelos semi-físicos (SMF) para baterías de Iones de Litio tienen un enfoque multicriterio y necesitan de potentes algoritmos de aprendizaje [6, 7]. La primera generación de modelos SMFs presentan un conjunto de bloques de sistemas basados en reglas difusas embebidos en las ecuaciones diferenciales. Estos modelos reducen al mínimo el número de pequeñas cajas negras utilizadas para representar las no-linealidades de determinados bloques y facilitan el aprendizaje indirecto de las variables latentes por su diseño. Las principales críticas que se pueden hacer a estos modelos de primera generación es que no logran el diagnóstico del Estado de Carga (SoC, del inglés, State of Charge) y del Estado de Salud (SoH, del inglés, State of Health) de las baterías. Los algoritmos de aprendizaje utilizados en estos modelos de primera generación fueron métodos ad hoc.

La presente investigación propone una segunda generación de modelos semi-físicos que facilitan el aprendizaje indirecto de las variables latentes, dentro de ellas el SoC y SoH. En el proceso de aprendizaje de los nuevos modelos se realiza la evaluación de modernos Algoritmos Evolutivos Multiobjetivo, siendo impracticables los métodos ad hoc de la primera generación. Es conocido que ningún algoritmo de aprendizaje es superior a otro para todos los tipos de problemas [48, 49], lo cual justifica que para cada problema en particular se debe realizar la evaluación de los algoritmos representativos del estado del arte.

Los algoritmos de aprendizaje para los modelos SMFs de baterías de segunda generación requieren extraer conocimiento a partir de las salidas observables sobre características electroquímicas internas de las baterías. Éstas curvas proporcionan información acerca de la capacidad de almacenamiento de energía, la disponibilidad instantánea de energía y el estado de degradación que presentan las baterías. Éstas curvas son:

- Tensión de Circuito Abierto (OCV, del inglés, Open-Circuit Voltage).
- Curva resultante del Análisis de la Capacidad Incremental (ICA, del inglés, Incremental Capacity Analysis).
- Curva resultante del Análisis de Tensión Diferencial (DVA, del inglés, Differential Voltage Analysis).

Son varios los elementos que dificultan el aprendizaje de los modelos SMFs de segunda generación propuestos. El aprendizaje indirecto de las curvas relacionadas con las variables latentes del modelo no es un tarea sencilla. Éstas curvas son muy sensibles a pequeños variaciones y repercuten significativamente en el ajuste de las salidas observables del modelo. Fundamentalmente las curvas ICA y DVA requieren de la aproximación de la primera derivada de la salida de tensión del modelo, lo cual es un proceso costoso. Teniendo como un objetivo más en el proceso multiobjetivo de aprendizaje el error que se comete en la aproximación de la primera derivada (para el diagnóstico del SoH), se ha observado que se genera un elevado número de soluciones resistentes a la dominación.

Estas dificultades encontradas en el proceso de aprendizaje de los modelos propuestos han motivado la extensión de los algoritmos de aprendizaje existentes. Dentro de las técnicas disponibles para la mejora de los procesos de aprendizaje en modelos SMFs de segunda generación, el presente estudio se centra en las siguientes:

- Evaluación del efecto de la introducción de mecanismos diseñados para aprendizaje de problemas de muchos objetivos.
- Estudio de la inyección de conocimiento mediante el uso de preferencias parciales basadas en taylorismo y evitando el sobreajuste de los modelos.
- Desarrollo de modelos SMFs con elementos de representación del conocimiento que sean totalmente interpretables, lo cual puede facilitar el aprendizaje de las variables latentes de interés en el modelo.

Este último elemento requiere la extensión de los algoritmos de aprendizaje basados en Programación Genética Multiobjetivo para hacer frente a la generación de soluciones resistentes a

la dominación y lograr la fácil comprensión del conocimiento extraído. Existen pocos trabajos donde se usen los algoritmos de Programación Genética para el aprendizaje de modelos dinámicos [68]. En la literatura consultada se observa que los algoritmos de Programación Genética han sido poco estudiados en problemas puramente multicriterio [69–71]. Los estudios en el área del aprendizaje basado en Programación Genética Multiobjetivo, en su inmensa mayoría, utilizan funciones de adaptabilidad escalares transformadas en enfoque multicriterio añadiendo objetivos relacionados con métricas de precisión y simplicidad de las expresiones a aprender [72, 73]. Los estudios realizados en esta área no incorporan estrategias modernas en la etapa de selección de la supervivencia propuesta para los Algoritmos Evolutivos Multiobjetivo.

1.2. Problema de investigación

En consecuencia con lo antes planteado, al no existir un estudio general del comportamiento de distintos algoritmos para el aprendizaje de modelos semi-físicos de baterías con enfoque multiobjetivo se derivan las siguientes **preguntas científicas de investigación**:

- ¿Cuál es el algoritmo que logra una mayor convergencia en el aprendizaje multicriterio de modelos semi-físicos de estimación del Estado de Carga y el Estado de Salud en baterías de LiFePO_4 ?
- ¿Qué efecto tendría la aplicación de modernos mecanismos de promoción de la diversidad, diseñados para problemas de muchos objetivos, en el aprendizaje de modelos semi-físicos?
- ¿Es posible extender los algoritmos de aprendizaje basado en Programación Genética Multiobjetivo con modernos mecanismos de promoción de la diversidad propuestos para problemas de muchos objetivos?
- ¿Es posible aprender indirectamente de manera totalmente interpretable, expresiones que describan importantes variables latentes en modelos semi-físicos de baterías de LiFePO_4 mediante Programación Genética Multiobjetivo basadas en gramática?

1.3. Objetivo general

El **objetivo general** de la investigación es: desarrollar nuevos algoritmos de aprendizaje basados en un enfoque multicriterio que doten a los investigadores de otras alternativas para enfrentar problemas dinámicos; particularmente que permitan el aprendizaje de modelos semi-físicos de baterías de Iones de Litio con tecnología basada en LiFePO_4 .

1.4. Objetivos específicos

Este objetivo general se desglosa en los siguientes **objetivos específicos** :

1. Desarrollar nuevos modelos semi-físicos, que puedan ser utilizados en BMSs, que permitan la estimación indirecta de variables latentes relacionadas con características electroquímicas en baterías de LiFePO_4 y de la estimación de las salidas observables.
2. Evaluar el efecto de la inyección de conocimiento, mediante preferencias parciales basadas en taylorismo en diferentes procesos evolutivos de aprendizaje de modelos Genético-Difusos Multiobjetivo, para la estimación del Estado de Carga y el Estado de Salud en baterías de LiFePO_4 .
3. Extender los algoritmos de aprendizaje basados en Programación Genética Multiobjetivo con técnicas que hagan uso de puntos de referencia en el espacio objetivo para guiar la búsqueda y de nuevas técnicas de promoción de la diversidad. Se persigue que los algoritmos resultantes permitan el aprendizaje indirecto de expresiones que describan importantes variables latentes conjuntamente con el ajuste de las salidas observables en modelos semi-físicos de baterías de LiFePO_4 .

1.5. Etapas en el desarrollo de la investigación

Durante la presente investigación se ha seguido un hilo conductor en el trabajo científico. Los resultados alcanzados en cada una de las etapas han dado paso a la siguiente fase. El diagrama de actividades que detalla las diferentes etapas puede verse en la Figura 1.1 en forma de resumen.

1. Primera etapa: identificación y caracterización del problema objeto de estudio.
 - Se estudian los modelos de Circuitos Eléctricos Equivalentes para el modelado de baterías de Iones de Litio, así como su representación en espacios de estado.
 - Igualmente se estudian los modelos semi-físicos de primera generación.
 - Se diseña un conjunto de ensayos de baterías los cuales se llevan a cabo en el Laboratorio de Baterías en la Escuela Politécnica de Ingeniería de la Universidad de Oviedo. Con los datos recolectados se procede a la creación de juegos de datos empleados en la experimentación a lo largo de la tesis.

2. Segunda etapa:
 - Se propone una segunda generación de los modelos semi-físicos para la estimación del Estado de Carga (Modelo SMF 1)
 - Se realiza la evaluación de los Algoritmos Evolutivos Multiobjetivo (MOEAs) para el aprendizaje del modelo. Mediante el análisis de los resultados se concluye que los MOEAs tienen un comportamiento promedio en la extracción de conocimiento de la dinámica del sistema.
 - En este punto se realiza un estudio numérico de la estimación indirecta de la curva de OCV con el nuevo modelo, mediante un algoritmo de aprendizaje ad-hoc.

3. Tercera etapa:
 - Se estudian las últimas novedades en las técnicas para la estimación del Estado de Salud en Baterías de Iones de Litio, identificando el ICA como una alternativa factible para la implementación en el modelo propuesto y que puede ser utilizada en los BMS.
 - El proceso de aprendizaje del modelo semi-físico 1 con la estimación del estado de salud añadido es estudiado empíricamente con MOEAs y algoritmos de evolutivos diseñados para problemas de muchos objetivo.
 - En este punto, se realiza el aporte del Algoritmo de aprendizaje basado en preferencias parciales difusas θ -FPO.

- Se finaliza la etapa con el estudio empírico del algoritmo propuesto aplicado al problema particular de la estimación de SoH en baterías de Iones de Litio. Se analizan y discuten los resultados obtenidos.

4. Cuarta etapa:

- Se propone el segundo modelo semi-físico (Modelo SMF 2) para la estimación del SoH basado en las curvas de potencial de circuito abierto de los electrodos en baterías de iones de litio.
- Se estudian los algoritmos de aprendizaje basados en Programación Genética multi-objetivo identificando carencias para el aprendizaje indirecto de expresiones analíticas
- Propuesta del Algoritmo de Aprendizaje basado en Programación Genética Multi-objetivo con el uso de gramáticas (Grab-MO-GaP). La propuesta extiende los algoritmos de MOGP con mecanismos modernos de promoción de la diversidad. La propuesta enfatiza el aprendizaje indirecto de expresiones que describen bloques relacionados con variables latentes.
- Experimentación, análisis y discusión de los resultados

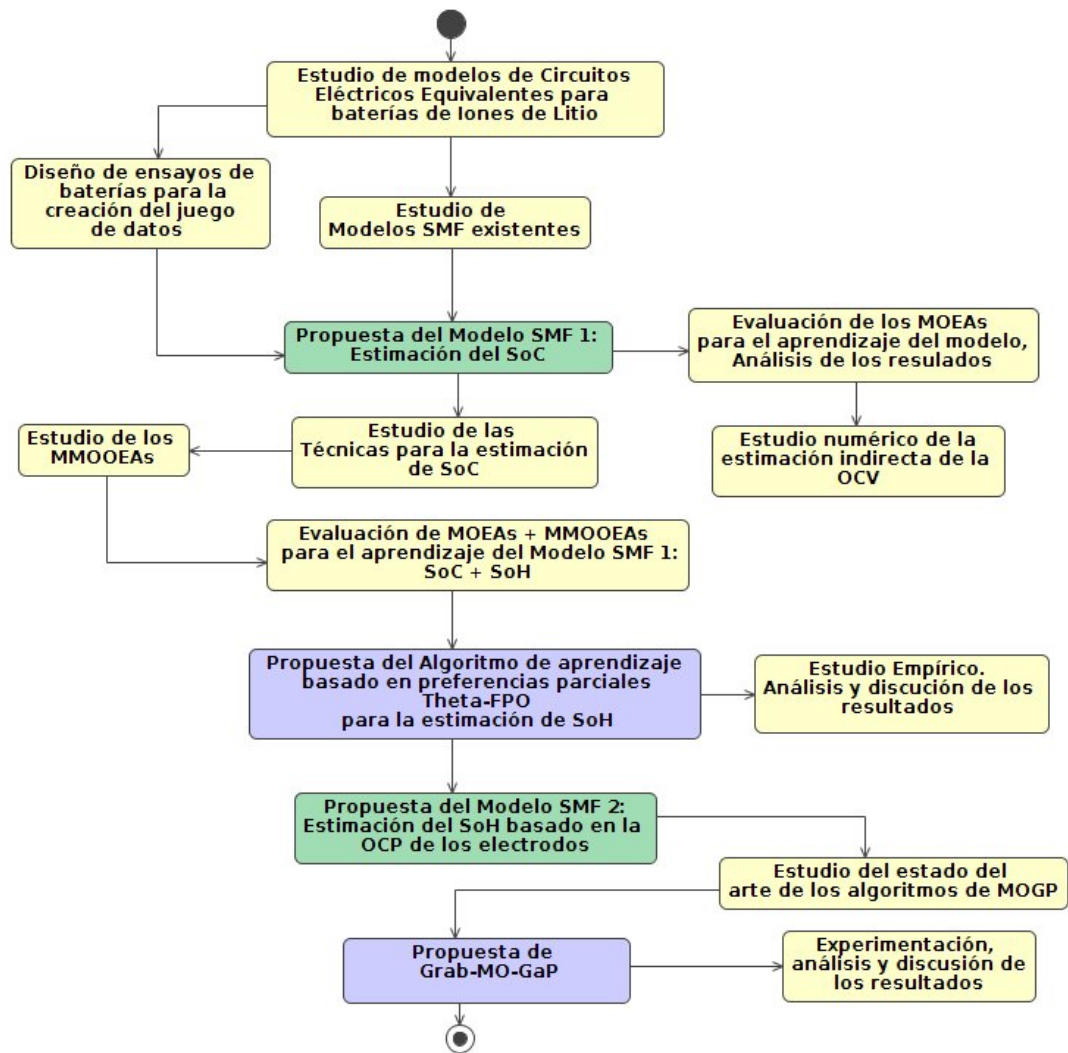


FIGURA 1.1: Etapas del desarrollo de la investigación.

1.6. Métodos de trabajo científico

Durante el desarrollo de la investigación se emplearon los siguientes métodos:

Métodos generales

- Método hipotético-deductivo: para elaborar las hipótesis y proponer líneas de trabajo a partir de resultados parciales.
- Método sistémico: para que el desarrollo de los algoritmos propuestos y su aplicación en el campo de las baterías se vea como un todo y funcione de manera armónica.
- Método histórico-lógico y dialéctico: para el estudio crítico de los trabajos anteriores tomándolos como punto de referencia.

Métodos lógicos

- Método analítico-sintético: se descompone el problema de investigación en elementos por separado y se profundiza en el estudio de cada uno de ellos, para luego sintetizarlos en la solución de las propuestas.
- Método inducción-deducción: para la confirmación teórica durante el desarrollo de la tesis.
- Método de modelación: para el desarrollo de los algoritmos a lo largo de la investigación.

Métodos empíricos

- Método coloquial: para la presentación y difusión de los resultados en eventos científicos.
- Método experimental: para comprobar la utilidad de los resultados obtenidos.

1.7. Novedad científica

Esta investigación permitió obtener resultados cuya novedad científica radica en:

1. La concepción y definición del algoritmo θ -FPO. Éste permite la inyección de conocimiento como mecanismo de presión evolutiva a través de preferencias parciales en la etapa de selección de soluciones sobrevivientes.

2. Propuesta del algoritmos Grab-MO-GaP, extendiendo así los algoritmos multiobjetivo de Programación Genética para el aprendizaje de variables latentes en modelos dinámicos. Las extensiones se realizan con mecanismos basados en la distribución de puntos de referencia en el espacio objetivo unido a modernos mecanismos de promoción de la diversidad.

1.8. Valor práctico

El valor práctico se relaciona con la aplicación de los algoritmos propuestos al problema del diagnóstico del Estado de Salud en baterías de Iones de Litio. Fundamentalmente porque las propuestas pueden ser implementadas en los BMSs de vehículos eléctricos, evitando así la necesidad de extracción de la batería para la realización de pruebas de laboratorio.

1.9. Valor social

La dimensión interna del valor social de la investigación radica en la contribución al desarrollo de otras investigaciones en áreas del Aprendizaje Automático y el modelado de baterías. Por otro lado, en la dimensión externa, se dan a conocer nuevos algoritmos que pueden ser extrapolados a problemas en distintas áreas de investigación.

1.10. Estructura de la tesis

La tesis está estructurada en cinco capítulos. A continuación de este Capítulo 1, donde se presenta la motivación de la investigación y el diseño metodológico de la misma, los siguientes capítulos se estructuran de la siguiente forma:

- En el Capítulo 2 se hace un análisis crítico de la literatura actualizada, precisando los principales aspectos conceptuales y definiciones involucrados en la investigación. Se hace una revisión exhaustiva del uso de técnicas computacionales inteligentes en problemas dinámicos de la ingeniería. Se explica, los fundamentos de los algoritmos evolutivos de aprendizaje enfatizando en problemas multicriterio. Posteriormente se hace una introducción al uso de baterías de Iones de Litio donde se detallan sus principales características y se enfatizan las no-linealidades de estos sistemas que dificultan el desarrollo de modelos de diagnóstico. El capítulo finaliza puntualizando los problemas abiertos que existen en la estimación del Estado de Salud en baterías de vehículos eléctricos.
- El Capítulo 3 desarrolla las propuestas de la presente tesis. Comienza con la introducción de los modelos semi-físicos de segunda generación. Se presenta el primer modelo para la estimación del Estado de Carga en baterías (Modelos SMF 1), en el que se evalúan los Algoritmos Evolutivos Multiobjetivo más representativos para el aprendizaje en los Sistemas Genético-Difusos Multiobjetivo.

Posteriormente se incluye en el Modelo SMF 1 un tercer objetivo relacionado con las curvas ICA para la estimación del Estado de Salud. Este elemento hace mucho más complejo el proceso de aprendizaje y establece las bases para la experimentación con nuevos mecanismos de promoción de la diversidad diseñados inicialmente para problemas de muchos objetivos. En este contexto se presenta un nuevo algoritmo (θ -FPO) que inyecta conocimiento en el proceso evolutivo mediante el uso de preferencias parciales y mejora la convergencia.

El segundo modelo semi-físico que se presenta en el capítulo (Modelo SMF 2) está directamente diseñado para la estimación del Estado de Salud en baterías de Iones de Litio. El proceso de aprendizaje de este modelo requiere desarrollar extensiones de los algoritmos de aprendizaje basados en Programación Genética Multiobjetivo. Las extensiones propuestas consisten en el uso de modernos mecanismos de promoción de diversidad unidos al uso de gramáticas como mecanismo de presión evolutiva. El algoritmo propuesto Grab-MO-GaP, facilita el aprendizaje indirecto de la variable latente que estima el potencial de circuito abierto para el electrodo negativo, de manera totalmente comprensible por los seres humanos,.

- El Capítulo 4 presenta los estudios empíricos realizados como parte de la validación de las aportaciones de la tesis. Se explican los ensayos de baterías realizados en condiciones de laboratorio para la creación del juego de datos utilizado en la experimentación.
- El Capítulo 5 presenta las conclusiones generales y las líneas de investigación para futuros trabajos.
- Finalmente se presenta la Bibliografía 6 consultada para el desarrollo de la tesis y los Anexos.

Capítulo 2

Fundamentación Teórica

En el presente capítulo se hace un análisis crítico de la literatura precisando los principales aspectos conceptuales involucrados en la investigación. De cada uno de los aspectos abordados se presenta una amplia revisión del estado del arte. Esta base teórica analizada conforma el hilo conductor para comprender las aportaciones que se presentan en la tesis. Para conveniencia del lector, el primer epígrafe contextualiza los distintos algoritmos utilizados en el modelado de problemas dinámicos, enfatizando en aplicaciones relacionadas con la ingeniería. En el segundo epígrafe se hace un análisis de los avances en la Computación Evolutiva resaltando los algoritmos multiobjetivo por la importancia que tienen para la presente tesis. A continuación se hace una introducción al uso de baterías de Iones de Litio y se explican las principales tecnologías de fabricación existentes. Se resumen los principales modelos de baterías existentes en la literatura para la estimación del Estado de Carga y el Estado de Salud. Se evidencia la necesidad de modelos precisos y de fácil comprensión, que a la vez puedan ser implementados en los sistemas de gestión de baterías incorporados en los vehículos eléctricos.

2.1. Técnicas inteligentes en modelos dinámicos para la ingeniería

Los sistemas dinámicos, muy comunes en el campo de las ingenierías, con frecuencia presentan no-linealidades en las relaciones entre los diferentes elementos de estos sistemas. Los sistemas dinámicos no-lineales pueden presentar comportamientos extremadamente complejos, llegando a ser caóticos en algunos casos. Por esta razón, es de gran importancia desarrollar herramientas computacionales eficaces que permitan identificar el mejor modelo para cada sistema dinámico en particular, obteniendo así mejores simulaciones del sistema y el control del mismo.

Un modelo se define como una representación abstracta de cierto fenómeno de la realidad. Los modelos dinámicos hacen una aproximación de la realidad que permite conocer en un instante de tiempo determinado, los estados pasados y los estados futuros de un sistema. Algunos modelos dinámicos cuentan con memoria, es decir, sus salidas dependen tanto de las entradas como del valor de las variables latentes. Un reto en el desarrollo de modelos para aplicaciones ingenieriles lo constituye la determinación de los valores iniciales de las variables de estado.

Muchos son los trabajos publicados de modelos dinámicos aplicados a problemas ingenieriles. Por solo citar algunos ejemplos, Efstratiadis [75] hace una revisión de los avances alcanzados durante una década en el área de los modelos hidrológicos. Talebi [76] estudia los modelos que describen la presión de saturación en depósitos de aceites. Mientras que, Vaidyanathan [77] publica un importante trabajo sobre el modelado para el control de los reactores nucleares de cuarta generación, conocidos como los "Tokamak".

En las últimas décadas han sido estudiadas varias técnicas basadas en Aprendizaje Automático para problemas dinámicos. Los Sistemas Basados en Reglas Difusas (FRBS, del inglés, Fuzzy Rule-Based Systems) son los más estudiados en la literatura. Además, han demostrado ser una poderosa herramienta para la extracción de conocimiento en problemas de ingeniería y en muchas otras aplicaciones. Dentro de estas se encuentran los problemas de clasificación [78] y los problemas de minería de datos [14, 22] que pueden presentarse en varios sectores como la economía, la medicina, etc.

Los Sistemas Genético Difusos surgen de la aplicación de algoritmos de computación evolutivos, especialmente Algoritmos Genéticos, para la definición o aprendizaje de los FRBSs. En estos modelos, los antecedentes y/o consecuentes de los FRBSs intervienen en el proceso evolutivo de los Algoritmos Genéticos. Es conocida la habilidad de los algoritmos de computación evolutiva en general para encontrar "buenas" soluciones en problemas de búsqueda y de optimización. Por otro lado, cuando el modelo a aprender hace uso de FRBSs y además, requiere cumplir con varios objetivos que entran en conflicto en sí, los modelos se enmarcan en los Sistemas Evolutivos-Difusos Multiobjetivo (MOEFS, del inglés, Multi-Objective Evolutionary Fuzzy Systems) [79].

En el campo de los MOEFSs se han estudiado sistemas dinámicos complejos de identificar. Dentro de estos se encuentran sistemas de grandes dimensiones [80] y sistemas caóticos de la ingeniería [81]. Según Ljung [82], en la identificación de sistemas dinámicos se debe alcanzar un equilibrio, de manera que, la descripción no sea excesivamente flexible y se evite la sobreparametrización. En los MOEFSs se continúa investigando la relación entre precisión de los modelos y la interpretabilidad de las reglas lingüísticas. Algunos estudios hacen uso de algoritmos de computación evolutiva (Programación Genética) en el modelado de sistemas dinámicos para garantizar la correcta comprensión del conocimiento extraído de estos sistemas dinámicos [83]. La siguiente sección presenta los algoritmos de aprendizaje basado en computación evolutiva.

2.2. Computación evolutiva para el aprendizaje de modelos

La Computación Evolutiva tiene varias décadas de desarrollo con buenos resultados. Es un área de investigación activa cuyos avances se extienden rápidamente a varios campos de aplicación de la ciencia y la ingeniería.

Existen varios grupos de algoritmos que forman parte de la Computación Evolutiva:

- Algoritmos Genéticos (AG) [84, 85],
- Estrategias Evolutivas (EE) [86],
- Programación Evolutiva (PE) [87],
- Programación Genética (GP, del inglés, Genetic Programming) [72],
- Evolución Diferencial (ED) [88],
- Aprendizaje de Sistemas Clasificadores (LCS; del inglés, Learning Classifier Systems) [89–91]
- Estimación de los Algoritmos de Distribución (EDA; del inglés, Estimation of Distribution Algorithms) [92].

Algunos trabajos con los cuales el autor de la presente tesis está de acuerdo ubican la Optimización Basada en Enjambre de Partículas (PSO; del inglés, Particle Swarm Optimisation) como parte de la Computación Evolutiva. La inspiración de PSO viene de la inteligencia colectiva y su terminología difiere significativamente (Enjambre, Partículas, etc). Sin embargo, el proceso de búsqueda se ajusta a la estructura de los Algoritmos Evolutivos [1].

Las diferentes etapas de los Algoritmos Evolutivos son bien clarificadas por el profesor K. Deb, estableciendo las bases para el desarrollo de nuevos algoritmos [93]. Dichas etapas se detallan a continuación. Como complemento observe la Figura 2.1.

Etapas de los Algoritmo Evolutivo:

- **Inicialización:** Genera un número de individuos (soluciones) para conformar la población inicial P , el genotipo y fenotipo de los individuos está directamente relacionado con el problema de aplicación.
- **Selección de Padres:** Se seleccionan los padres μ del conjunto P para el apareamiento.
- **Apareamiento:** Se generan los hijos λ a partir de μ padre mediante los operadores de cruzamiento y mutación.
- **Selección de Sobrevivientes:** Se escogen los individuos que pasan a la siguiente generación. Existen dos populares estrategias:
 - Estrategia generacional de actualización de la población ($\mu + \lambda$).
 - Estrategia de estado constante ($\mu = \lambda$).
- **Finalización:** Evalúa la condición de parada del proceso evolutivo.

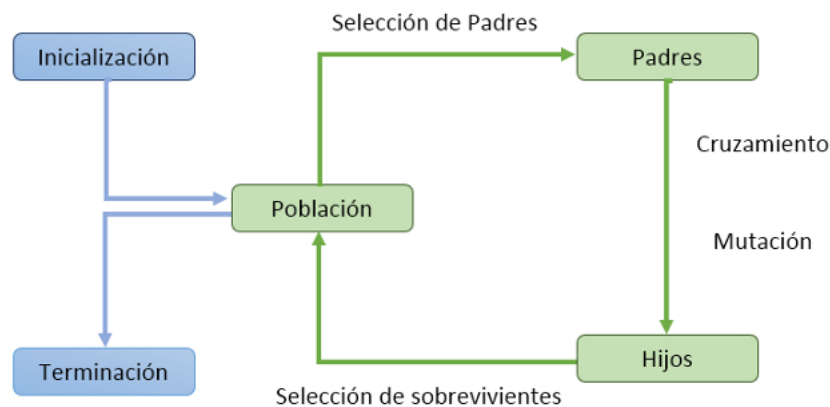


FIGURA 2.1: Estructura de los Algoritmos Evolutivos (Figura inspirada en [1]).

Por otro lado, la convergencia de los Algoritmos Evolutivos está directamente relacionada con el diseño acertado que se haga de estos y el estudio de los parámetros de cada uno de los algoritmos. El ajuste de los parámetros de un Algoritmo Evolutivo AE_x mediante un segundo algoritmo AE_y se conoce en la literatura como Meta-Algoritmos Evolutivos [94].

La Tabla 2.1 resume las principales codificaciones genéticas, operadores evolutivos y los mecanismos de selección de padres.

Representación	Binaria	Entero	Real	Árbol
Cruzamiento	1-punto n -puntos Uniforme	Cambiar alelos en el conjunto finito de posibles valores	Simple: SBX Completo: HBX Mixto: BLX- α	Sub-árboles
Mutación	Bit negado	Reajuste aleatorio Por arrastre	Uniforme No-uniforme Auto-adaptativa	Sub-árboles Mitad y mitad en rampa
Selección de padres	Por torneo; Rueda Ruleta; Uniforme; Proporcional basado en función de adaptabilidad; con probabilidades; basadas en ordenamiento			
Selección de Sobrevivientes	Actualización de la población basado en cantidad de generaciones; Elitistas; No elitistas (Primero el peor; Torneo Round-robin; Selección $(\mu + \lambda)$; Selección (μ, λ) y Selección $(\mu + \lambda)$)			

TABLA 2.1: Resumen de los principales diseños de los Algoritmos Evolutivos.

En recientes estudios se identifican modernas líneas de investigación dentro de la Computación Evolutiva. Dentro de estas se destacan:

- La extensión de los algoritmos a nuevos problemas de aplicación.
- Paralelización de los algoritmos existentes [95].
- El despliegue en escenarios distribuidos [96, 97].
- El diseño de hardware especializado para acelerar la convergencia de los algoritmos [98].
- Algoritmos Evolutivos que permiten una interacción periódica de usuarios expertos para conducir el proceso de búsqueda mediante preferencias [99].

Con el paso de los años y los buenos resultados alcanzados, la computación evolutiva se ha consagrado como los algoritmos de aprendizaje de modelos por excelencia. En sus inicios los estudios se enfocaron en el aprendizaje de modelos con funciones de adaptabilidad escalar. En los últimos años se evidencia un interés creciente en el estudio de los Algoritmos Evolutivos para el aprendizaje de modelos multicriterio. En la próxima sección se hace un revisión de los algoritmos evolutivos multiobjetivo.

2.2.1. Algoritmos evolutivos multiobjetivo

Los Algoritmos Evolutivos Multiobjetivo (MOEA; del inglés, Multiobjective Evolutionary Algorithms) se han convertido en una potente herramienta para el aprendizaje de modelos. Con el paso de los años aumenta la complejidad y las dimensiones de los problemas que pueden ser resueltos mediante estos algoritmos. El aprendizaje de modelos con un enfoque multicriterio, por la utilización de una función de adaptabilidad en forma vectorial, hace complejo el desarrollo de los algoritmos. Así, en problemas multicriterio donde se deben satisfacer varios objetivos los cuales presentan una relación competitiva entre sí, el desarrollo de MOEAs es un reto. El mayor

reto es lograr "buenas" soluciones evitando que se obtenga una buena medida de error para uno de los objetivos pero de poca precisión en el resto.

La Figura 2.2 muestra dos grupos de soluciones para un problema de dos objetivos en conflicto. Los ejes f_1 y f_2 representan la medida de error en el cumplimiento de cada objetivo. Observe que las soluciones del grupo **A** son buenas para el objetivo f_1 pero presentan poca precisión en el cumplimiento del objetivo f_2 . En las soluciones del grupo **B**, ocurre lo contrario.




FIGURA 2.2: Representaciones de soluciones en un problema multicriterio de dos objetivos.

Los problemas multicriterio tiene dos elementos que los hacen atractivos para los investigadores: tienen un planteamiento sencillo y una cierta dificultad en la resolución. Concretamente, un problema de aprendizaje multicriterio de m objetivos y n variables se define como:

$$\begin{aligned} \text{mín } F(x) &= (f_1(x), f_2(x), \dots, f_m(x))^T \\ \text{sujeto a } &x \in \Omega \end{aligned} \quad (2.1)$$

donde $x = (x_1, x_2, \dots, x_n)^T$ y Ω representa el espacio de decisión, $F : \Omega \rightarrow R^m$. El conjunto de vectores de soluciones óptimas se conoce como Frente de Pareto (FP) óptimo. Cualquier mejora en un punto del FP óptimo respecto a un objetivo significa el deterioro de al menos uno del resto de los objetivos. El correcto uso de técnicas que promuevan un equilibrio entre la diversificación y la intensificación en Ω durante la etapa de selección de sobrevivientes tiene una gran importancia en este contexto.

El concepto de Frente de Pareto fue formulado por Wilfredo Pareto en el siglo XIX. Está estrechamente relacionado con el concepto de dominación de Pareto, estrictamente hablando:

La dominación de Pareto se define a partir de una solución $x^t = (x_1^t, x_2^t, \dots, x_n^t)^T$ que domina la solución $x^u = (x_1^u, x_2^u, \dots, x_n^u)^T$ si se cumplen las siguientes condiciones:

1. $x_i^t \leq x_i^u \quad \forall x \in (1, 2, \dots, n)$
2. $\exists i \in (1, 2, \dots, n)$ tal que $x_i^t < x_i^u$

A partir de esta definición se pueden evidenciar cuatro regiones de dominación. Basado en la Figura 2.3 la solución x domina las soluciones de la región 1, no es comparable con las soluciones de las regiones 2 y 4, siendo dominada por las soluciones de la región 3.




FIGURA 2.3: Relaciones de dominación basadas en Pareto.

El Frente de Pareto óptimo contiene las soluciones que no son dominadas por ninguna otra. La Figura 2.4 muestra gráficamente el Frente de Pareto óptimo en un espacio objetivo de dos dimensiones.




FIGURA 2.4: Frente de Pareto de ejemplo.

En problemas de pocos objetivos los MOEAs se han consagrado por las ventajas que ofrecen sus diferentes enfoques elitistas basados en el Frente de Pareto. En la inmensa mayoría de los MOEAs aplicados a problemas de ingeniería se utiliza una codificación del cromosoma basado en valores reales, $x_i \in \mathbb{R}$. En estos casos, la estrategia de inicialización más usada es la selección de valores aleatorios pertenecientes a una distribución.

Las diferencias en los MOEAs se evidencian fundamentalmente en sus mecanismos de promoción de diversidad y las estrategias de asignación de la función de adaptabilidad. El esquema

de apareamiento más extendido en la literatura utiliza un operador de Recombinación Binaria Simulada (SBX; del inglés, Simulated Binary Crossover) y una mutación polinómica. El operador SBX favorece la creación de hijos cercanos a los padres. Se garantiza que se generen pequeños cambios en los hijos controlando la desviación estándar de la distribución utilizada por el operador en función de la distancia que exista entre los padres [100].

Casi todas las familias de algoritmos de la Computación Evolutiva tienen sus extensiones para enfrentar problemas multicriterio:

- Estrategias Evolutivas basadas en archivo de Pareto (PAES; Pareto archive evolution strategy) [101, 102].
- Optimización Multiobjetivo basada en Enjambre de Partículas (MPSO; del inglés, Multi-objective Particle Swarm Optimisation) [103–105].
- Evolución Diferencial Multiobjetivo (MODE) [106, 107].
- Aprendizaje de Sistemas Clasificadores Multiobjetivo [108].
- Estimación de los Algoritmos de Distribución Multiobjetivo (MEDA; del inglés, Multi-objective Estimation of Distribution Algorithms)[109].

El caso de los algoritmos basados en Programación Genética y sus extensiones para problemas multicriterio será abordado en el próximo capítulo por la importancia que tienen para la presente tesis. Seguidamente se describen brevemente los algoritmos más representativos dentro de los MOEAs.

2.2.1.1. SPEA2

Iniciando el presente siglo E. Zitzler propone SPEA2 (del inglés, Strength Pareto Evolutionary Algorithm 2) [27]. Este algoritmo se diferencia de su primera versión en la estrategia de asignación de la función de adaptabilidad, en el uso de una técnica de estimación de densidad y la mejora del mecanismo de truncamiento para la actualización de la estructura externa que almacena los individuos *no-dominados*.

El esquema de asignación de la función de adaptabilidad tiene en cuenta cuántos individuos son dominados por una solución x_i y a la vez, cuántos individuos dominan a x_i . El indicador de densidad se incorpora para discriminar entre individuos con igual valor de adaptabilidad en el proceso de ordenamiento de las soluciones. El método de estimación de la densidad por excelencia es el vecino más cercano, aunque es válido cualquier otro similar. La Figura 2.5 muestra un esbozo del método de estimación basado en el vecino más cercano.

Las soluciones no-dominadas que se generan se almacenan en la mencionada estructura externa hasta alcanzar su límite. Cuando éste se excede, interviene el mecanismo de actualización basado en truncamiento mediante el indicador de fuerza de cada uno de los individuos.




FIGURA 2.5: Método de densidad utilizado en el algoritmo SPEA2.

SPEA2 ha sido estudiado en un amplio grupo de problemas de aplicación con buenos resultados [110–112].

2.2.1.2. NSGA-II

K. Deb por su parte propone NSGA-II (del inglés, Nondominated Sorting Genetic Algorithm version 2) [26] que ha devenido como el más popular de los MOEAs. Mejora sustancialmente la complejidad computacional de su primera versión NSGA. Su característica distintiva es el ordenamiento por distintos niveles de no-dominación, los cuales pueden verse como pequeños subconjuntos de individuos. De esta forma, el primer nivel de no-dominación (l_1) contiene los individuos que no son dominados por individuos de otros niveles en una población determinada. El segundo nivel (l_2) contiene los individuos que son dominados solamente por los de l_1 y así sucesivamente. En cada generación, además de computar la función de adaptabilidad, se calcula la Distancia de Apiñamiento. Este indicador permite conocer cuan cerca está un individuo de sus vecinos, siendo útil este mecanismo para mantener la diversidad de soluciones dentro de la población. NSGA-II tiene un esquema generacional ($\mu + \lambda$) donde la selección de sobrevivientes se basa en los niveles de no-dominación haciendo un corte en los primeros N individuos, donde N representa el tamaño de la población.

La Figura 2.6 resume el procedimiento propuesto en NSGA-II. Se utiliza la notación original propuesta por el autor. P^t es la población en una generación determinada y Q^t los individuos correspondientes a la aplicación de los operadores de apareamiento en una estrategia generacional.

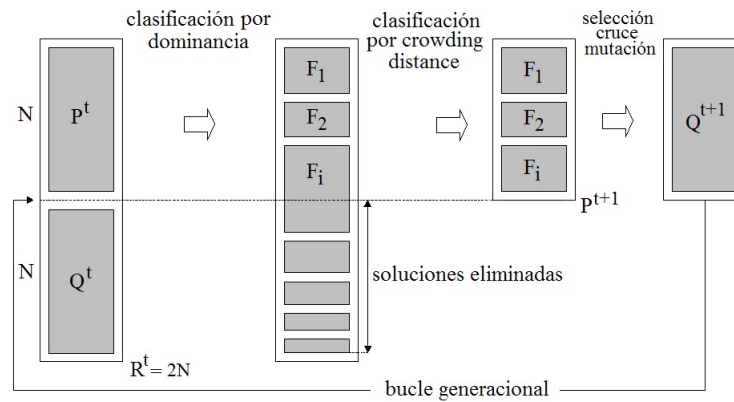


FIGURA 2.6: Procedimiento del algoritmo NSGA-II.

2.2.1.3. OMOPSO

OMOPSO es una de las variantes de la optimización basado en enjambre de partículas para problemas multicriterio. Propuesta por Reyes y Coello [104], se basa en la dominación de Pareto y el uso del factor de apiñamiento para la selección de las soluciones líderes durante el proceso de búsqueda.

En cada generación del algoritmo se selecciona una partícula (solución o individuo) que lidera el enjambre. La selección se realiza mediante un tornero binario basado en el factor de apiñamiento. El algoritmo utiliza dos archivos externos: uno para almacenar los líderes de la presente generación que guían el vuelo del resto de las soluciones en el espacio de búsqueda, el otro archivo almacena las soluciones globales.

El factor de apiñamiento se utiliza para filtrar la lista de líderes siempre que se exceda el límite máximo impuesto a esta. Únicamente se mantienen los líderes con los mejores valores de apiñamiento. En OMOPSO los autores proponen dividir la población en tres subconjuntos donde se aplican diferentes operadores de mutación en cada uno de estos subconjuntos.

2.2.2. Algoritmos evolutivos para problemas de muchos-objetivos

Los MOEAs son muy populares para problemas de dos o tres objetivos, sin embargo, en problemas de muchos-objetivos ($m \geq 4$), la calidad de las soluciones se deterioran significativamente [34]. La mayoría de los problemas multicriterio que necesitan ser resueltos en el área de la ingeniería tienen muchos objetivos. Dentro de estos encontramos: el diseño de sistemas de control [28, 29], la planificación de actividades de la producción [30, 31], la ingeniería de software [32], etc. Algunos problemas llegan a tener entre 10 y 15 objetivos [113, 114]. Se evidencia en la bibliografía que los algoritmos evolutivos para problemas de muchos-objetivos han tenido un importante auge en los últimos años [115–117].

La complejidad de los Algoritmos Evolutivos para Problemas de Muchos Objetivos (MMOOEAs; del inglés, Many-objective Evolutionary Algorithms) es alta. Cuando se tienen muchos objetivos a cumplir, la mayoría de los individuos en una población dada se convierten en no-dominados por el resto de las soluciones [33]. De manera que, si se seleccionan individuos de forma aleatoria, la probabilidad de escoger soluciones no-dominadas en una población aumenta exponencialmente respecto al número de objetivos [34]. Este aspecto deteriora considerablemente el proceso evolutivo y dentro de este, fundamentalmente, la preservación de individuos élites como mecanismo de presión para alcanzar el FP óptimo. La convergencia de los procesos evolutivos se hace considerablemente lenta ya que la mayoría de los mecanismos de selección elitista de soluciones emplean relaciones de dominación de Pareto como el principal criterio de selección. Por otro lado, en grandes dimensiones del espacio de soluciones factibles el conflicto entre diversificación e intensificación se hace mayor. En este sentido, se observa en la literatura que los mecanismos de promoción de la diversidad prefieren soluciones resistentes a la dominación [118].

En los MMOOEAs, la implementación de los mecanismos de conservación de la diversidad resulta computacionalmente costosa [119, 120]. De manera general, el costo computacional de los procesos evolutivos aumenta exponencialmente respecto a las dimensiones de un problema dado [119, 120]. Otros elementos, como la visualización de frentes en grandes dimensiones [121] y las técnicas de evaluación de la actuación de los algoritmos, se añaden a las dificultades que tienen los investigadores en este tipo de problemas [34].

Las principales ideas que se identifican en la literatura para el desarrollo de MMOOEA se expresan en la taxonomía siguiente:

1. **Nuevas relaciones de preferencia:** los mecanismos que se implementan en la etapa de selección de sobrevivientes de los algoritmos evolutivos tiene gran importancia. Muchas de las relaciones de dominación basadas en Frentes de Pareto tienen una pobre convergencia cuando se escalan a problemas de muchos objetivos, como ya se expresó anteriormente. Por este motivo, varios estudios proponen alternativas para implementar estas nuevas relaciones de preferencia: nuevos mecanismos de ordenamiento de las soluciones y/o modificaciones de las relaciones de dominación basadas en FP. Estas nuevas relaciones de preferencia alivian el efecto negativo que produce la generación de soluciones resistentes a la dominación. Igualmente, se comportan como mecanismo de presión evolutivo con el objetivo de alcanzar el FP óptimo. Se destacan en este aspecto una serie de trabajos: relaciones basadas en favores (Favor Relation) [36], Dominación basada en indicador Epsilon (ϵ -dominance) [122], Dominación de Pareto Difuso (Fuzzy Pareto Dominance) [123]. Por otro lado, trabajos como el propuesto por di Pierro [37] hacen uso de un segundo nivel de ordenamiento de las soluciones alterando ligeramente el primer nivel. Esta propuesta se conoce como Clasificación en Orden de Preferencia (Preference Order Ranking), existiendo otras alternativas [38–42].

2. **Uso de búsqueda múltiple predefinida:** varios MMOOEs están basados en este principio y se pueden implementar con varios enfoques que no son excluyentes entre sí. El primer enfoque está basado en el uso de puntos de referencia bien distribuidos en el espacio de búsqueda para una mejor convergencia hacia el FP óptimo [34]. De esta forma se le introducen restricciones al esquema de apareamiento de los individuos. La Figura 2.7 ejemplifica la distribución de puntos (referenciado como B) y las líneas de referencia (referenciado como A) para el caso particular de un problemas de tres objetivos.

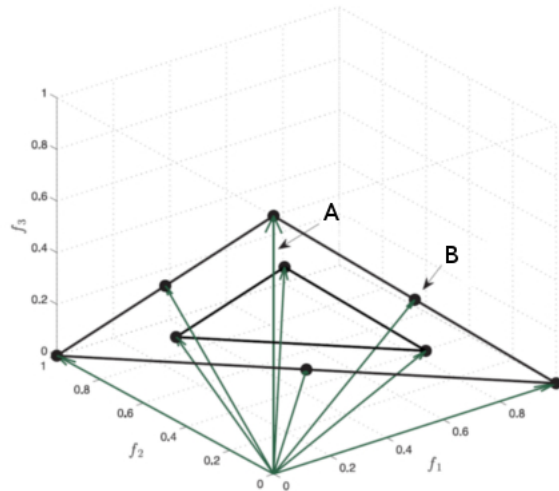


FIGURA 2.7: Distribución de puntos de referencia en un espacio objetivo de tres dimensiones (Fuente [2]).

En otros enfoques, los puntos de referencia también son utilizados para delimitar hiperplanos en el espacio de decisión y así guiar la búsqueda en un sentido u otro. Un tercer enfoque utiliza operadores de agrupamiento para delimitar que un individuo pueda aparearse con otros si y solo si pertenecen a mismo grupo [124–126]. En estos últimos enfoques es común que en cada generación se actualicen los límites superior e inferior de los valores de la función objetivo para las soluciones del FP. Conociéndose los vectores delimitadores como el Vector de Soluciones Nadir z^{nadir} y el Vector de Soluciones Ideales z^* , y siendo el límite superior $z^{nadir} = \sup_{x \in \Omega} f_i(x)$ y el límite inferior $z^* = \inf_{x \in \Omega} f_i(x) \quad \forall i = 1, \dots, m$.

La Figura 2.8 presenta un Frente de Pareto en dos dimensiones para una fácil comprensión de la ubicación de las soluciones Nadir e Ideales.

3. **Nuevos mecanismos de promoción de la diversidad:** es conocido en un espacio de decisión con muchos objetivos que los mecanismos de promoción de soluciones diversas son un factor clave [118, 127]. Algunos autores han propuestos mecanismos para una gestión eficaz de la diversidad. En este sentido, Adra y Fleming [128] proponen dos ideas experimentando con el impacto que pueden tener éstas en la convergencia para problemas de muchos objetivos. Por otro lado, Li [129] propone una modificación general del

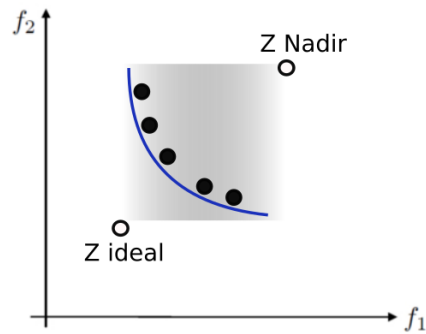


FIGURA 2.8: Soluciones de referencia en un espacio de búsqueda de dos dimensiones.

criterio de diversidad para MMOEAs basados en dominación de Pareto. Dentro de la propuesta destaca la Estimación de Densidad basada en Desplazamiento (SDE; del inglés, Shift-based Density Estimation), la cual hace un correcto equilibrio entre promoción de la diversidad y la convergencia.

4. **Uso de archivos independientes para la convergencia y la diversidad:** igualmente la idea está basada en el principio de equilibrar la convergencia y la diversidad, pero en este caso, mediante estructuras de datos separadas. El algoritmo que introdujo este enfoque en problemas multicriterio se conoce como el Algoritmo de dos archivos (Two-Archive Algorithm) [130]. Años después Wang propuso una mejora para problemas de muchos objetivos obteniendo buenos resultados [131].
5. **Enfoques basados en interacciones entre variables:** otras de las tendencias en la investigación que se refleja en la literatura es el desarrollo de técnicas para aprender las complejas interacciones entre variables y hacer uso de este conocimiento para lograr una mejor convergencia [44–47].
6. **Mecanismos de descomposición:** la idea está basada en la descomposición del problema de muchos objetivos en varios problemas con función de adaptabilidad escalar. En este sentido resaltan tres funciones de agregación:
 - **Suma Ponderada (sp).** Se considera un vector de pesos $w = (w_1, w_2, \dots, w_m)^T$ donde m representa el número de objetivos del problema. El vector de pesos debe contener valores positivos $w_i > 0$ para todo $i = (1, 2, \dots, m)$ y su suma debe ser igual a 1, $\sum_{i=1}^m w_i f_i(x)$. Entonces, el PF óptimo al problema multicriterio planteado en la Ecuación 2.1 contiene un punto dado por la solución óptima del siguiente

problema con función objetivo escalar.

$$\begin{aligned} \text{mín } g^{sp}(x|w) &= \sum_{i=1}^m w_i f_i(x) \\ \text{sujeto a } &x \in \Omega \end{aligned} \quad (2.2)$$

El uso de la notación $g^{sp}(x|w)$ propuesta en [43] enfatiza que w es el vector de coeficientes en esta función objetivo. El uso de diferentes vectores de pesos generaría el conjunto de diferentes vectores óptimos de Pareto.

- Tchebycheff (te). En este enfoque el problema de la Ecuación 2.1 se descompone en un problema escalar de optimización que tiene la siguiente forma:

$$\begin{aligned} \text{mín } g^{te}(x|w, z^*) &= \text{máx}_{1 \leq i \leq m} \{w_i |f_i(x) - z_i|\} \\ \text{sujeto a } &x \in \Omega \end{aligned} \quad (2.3)$$

donde $z^* = (z_1^*, z_2^*, \dots, z_m^*)$ representa el vector de puntos de referencia generado. La forma más común de generar este vector de puntos de referencia esta dada por la ecuación $z^* = \text{mín} \{f(x)|x \in \Omega\}$ para cada $i = (1, \dots, m)$. Es decir, para cada punto óptimo de Pareto x^* existe un vector de pesos w tal que x^* es la solución óptima de la Ecuación 2.3 y a su vez dicha solución es un Punto del FP óptimo en la Ecuación 2.1. Mediante este enfoque es posible obtener diferentes soluciones óptimas alterando ligeramente el vector de pesos.

- Enfoque de intersección de límites (il). Este enfoque busca geoméricamente los puntos de intersección del límite superior y el conjunto de líneas de referencias. En principio, el enfoque está basado en la observación de que en condiciones de regularidad (problema multiobjetivo continuo con FP convexo) los puntos de intersección que se buscan proporcionan una buena aproximación al límite superior del espacio objetivo alcanzable. Estrictamente hablando, este enfoque descompone el problema planteado en la Ecuación 2.1 en el siguiente problema escalar:

$$\begin{aligned} \text{mín } g^{il}(x|w, z^*) &= d \\ \text{sujeto a } &F(x) - z^* = dw \\ &x \in \Omega \end{aligned} \quad (2.4)$$

donde w y z^* representan igualmente los pesos y el conjunto de puntos de referencia respectivamente. La restricción $F(x) - z^* = dw$ asegura que la mejora de $F(x)$ sea en el sentido de la línea que une el origen con el punto p , en dirección a w^{z^*} y

pasando sobre z^* . La línea L une el origen de coordenadas perpendicularmente con el vector de distancia d_2 . Observe la Figura 2.9 para una mejor comprensión.

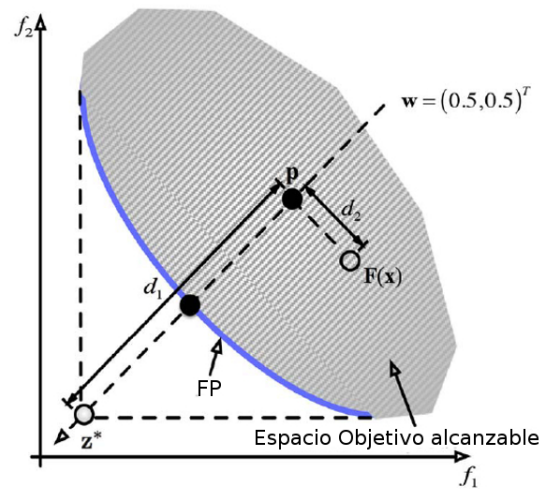


FIGURA 2.9: Enfoque de intersección de límites en un espacio objetivo de dos dimensiones (Fuente [3]).

Varias son las técnicas de descomposición de problemas con muchos objetivos que pueden ser categorizadas en el enfoque de intersección de límites, dentro de ellas el Método de Intersección de Límites Normales [132] y el Método Normalizado de Restricción Normal [133]. Posteriormente, en la Sección 2.2.2.3 se detalla un algoritmo que utiliza el enfoque de intersección de límites y suma penalizaciones al mismo.

Se destaca en la literatura de esta área de investigación estudios sobre algoritmos meméticos con aplicación en problemas de muchos objetivos [78, 134]. Estos estudios concluyen que no es necesario realizar el proceso de búsqueda local en todas y cada una de las generaciones del algoritmo evolutivo. Los algoritmos meméticos para problemas de muchos objetivos deben tener en consideración un parámetro adicional relacionado con el número de generaciones necesarias para que intervenga la búsqueda local.

En el área de investigación relativa a los MMOOEA no todo está resuelto, persisten problemas de aplicación en los cuales los MMOOEA evidencian la creación de un elevado porcentaje de soluciones resistentes a la dominación [135]. En problemas muy puntuales este fenómeno ha sido solventado inyectando conocimiento específico del dominio de aplicación para la creación de operadores genéticos con taylorismo implícito [136, 137]. La revisión de la literatura realizada evidencia que existen elementos que hacen posible la mejora de los algoritmos existentes y la propuesta de nuevas alternativas, con la premisa de que no existe un algoritmo de búsqueda que sea igual de convergente para todos los tipos de problemas [48].

Seguidamente se resaltan de manera concisa los MMOOEs más destacados en la literatura según las experimentaciones realizadas con los mismos y sus aplicaciones en diversos problemas reales.

2.2.2.1. MOEA/D

El Algoritmo Evolutivo Multiobjetivo basado en Descomposición (MOEA/D; del inglés, Multiobjective Evolutionary Algorithm Based on Decomposition) fue propuesto por Q. Zhang y H. Li a finales del año 2007 [43]. Es un algoritmo de los más representativos del enfoque de descomposición. Además de la optimización simultánea de los subproblemas en los cuales se descompone el problema multicriterio original, existen dos elementos que destacar en MOEA/D. El primero de éstos, relacionado con el apareamiento local, no es más que un mecanismo de restricción del apareamiento donde los padres λ_1 y λ_2 son seleccionados dentro de un vecindario de vectores de pesos. El segundo elemento se conoce como reemplazamiento local y realiza igualmente la etapa de actualización de la población teniendo solamente en cuenta la subpoblación compuesta por los vectores de pesos más cercanos. En otras palabras, una solución hija μ compete por sobrevivir, única y exclusivamente con sus vecinos más cercanos, para ello se computa la distancia Euclideana entre cada par de vectores de pesos.

MOEA/D ha sido estudiado en problemas de muchos objetivos y teniendo en cuenta diferentes enfoques de descomposición [135], aunque en el trabajo original se usa el enfoque de Tchebycheff. El mecanismo de promoción de la diversidad en MOEA/D está estrechamente relacionado con la correcta inicialización de los vectores de pesos. Con vectores de pesos bien distribuidos aumenta la probabilidad de obtener soluciones óptimas en los subproblemas que a su vez estén dispersas en el FP óptimo.

MOEA/D cuenta con variantes de implementación como la publicada en [138] y ha sido utilizado en algoritmos meméticos junto con una Búsqueda Local de Pareto en [139]. Por otro lado, recientemente se ha publicado el algoritmo implícito Algoritmo Evolutivo Multiobjetivo basado en Dominación y Descomposición (MOEA/DD; del inglés, Multiobjective Evolutionary Algorithm Based on Dominance and Decomposition) el cual busca un equilibrio entre la idea de la descomposición y la nuevas relaciones de dominación [3].

2.2.2.2. NSGA-III

La versión tres del Algoritmo Genético basado en No-Dominación (NSGA-III) es una extensión mejorada para problemas de muchos objetivos [34]. La gran diferencia de esta versión es que suprime el uso de la medida conocida como distancia de apiñamiento por no tener el mismo efecto en problemas de muchos objetivos [140]. NSGA-III es una implementación del enfoque

de búsqueda múltiple predefinida. Un conjunto de puntos de referencia distribuidos uniformemente sobre el espacio objetivo sirven de base para guiar la búsqueda. La población inicial es generada aleatoriamente. El esquema de apareamiento es el más extendido en los MMOEAs, operador de cruzamiento binario simulado y mutación polinómica [141].

NSGA-III introduce la normalización de los valores de la función objetivo en el rango $[0, 1]$. Este algoritmo genético tiene un enfoque generacional $(\mu + \lambda)$. En la etapa de selección de los sobrevivientes se generan los distintos niveles de no-dominación. Siguiendo con la estrategia propuesta en la anterior versión del algoritmo, los individuos del primer nivel de no-dominación l_1 tienen una alta prioridad de ser seleccionados como padres en la siguiente generación. Las soluciones en el último nivel, donde se hace el corte de las soluciones que sobreviven, son seleccionadas aplicando un operador de preservación de nichos. Este operador se basa en seleccionar los individuos que menor distancia tengan respecto a las líneas de referencia menos pobladas.

2.2.2.3. θ -DEA

Recientemente se ha propuesto un nuevo algoritmo basado en el enfoque de nuevas relaciones de dominación dentro de los algoritmos evolutivos para problemas de muchos objetivos. Adicionalmente, este algoritmo hace uso del enfoque basado en límites de intersección, introduciendo además penalizaciones. El algoritmo se conoce como θ -DEA (del inglés, θ -Dominance Evolutionary Algorithm) [2]. θ -DEA explota el esquema de evaluación de la función de adaptabilidad usado en MOEA/D y el mecanismo de promoción de la diversidad del algoritmo NSGA-III.

El tamaño de la población N en este algoritmo se computa respecto a las dimensiones del espacio objetivo m , y los parámetros de división de frontera superior H_1 y de capas internas H_2 . Igualmente, el número de puntos de referencia distribuidos en el espacio objetivo es proporcional a las dimensiones del problema y por consiguiente al tamaño de la población generada. Los puntos de referencia en θ -DEA tienen la peculiaridad de ser un vector m -dimensional $w = (w_{j,1}, w_{j,2}, \dots, w_{j,m})$ donde $j \in (1, 2, \dots, N)$. Los valores de la matriz de puntos de referencia deben cumplir $\sum_{k=1}^m w_{j,k} = 1$.

El algoritmo incorpora un proceso de normalización adaptativa pensado para problemas de aplicación donde los puntos del FP son escalados desigualmente. El proceso adaptativo tiene en cuenta el vector de soluciones ideales z^* y el vector de soluciones Nadir z^{nadir} . Estrictamente hablando, la normalización se realiza mediante la ecuación $\tilde{f}_i = \frac{f_i(x) - z_i^*}{z_i^{nadir} - z_i^*}$. En cada generación del algoritmo se actualiza el vector z^* con los mejores valores encontrados durante la búsqueda para el objetivo f_i . Por otro lado, la actualización del vector z^{nadir} no es trivial, se realiza mediante una búsqueda de los valores óptimos de una función escalar (consulte [2] para un mayor detalle).

La nueva relación de dominación (θ -dominación) usa una función de agregación con penalizaciones en las intersecciones de límites. De esta forma, la θ -dominación esta basada en las distancias $d_{j,1}$, $d_{j,2}$ y el parámetro de penalización θ . Se pueden observar en la Figura 2.10 las distancias y su notación en un espacio objetivo normalizado, similar a lo expuesto anteriormente en MOEA/D. En el caso particular de θ -DEA, la penalización en las intersecciones se computa mediante la Ecuación 2.5.

$$F_j(x) = d_{j,1}(x) + \theta d_{j,2}(x) \quad (2.5)$$




FIGURA 2.10: Representación geométrica en un espacio objetivo normalizado de dos dimensiones del enfoque de intersección de límites basado en penalizaciones utilizados en θ -DEA (Fuente [2]).

La etapa de selección de sobrevivientes en θ -DEA se hace mediante un ordenamiento de los individuos dentro de los distintos grupos de soluciones C_d . Dicho ordenamiento se realiza con los valores de la función de adaptabilidad (Ecuación 2.5) y mediante el esquema de niveles de no-dominación. En otras palabras, solamente los individuos dentro de un mismo grupo tienen una relación de competitividad. De esta forma se garantiza la preservación de la diversidad en espacios objetivo de muchas dimensiones.

2.3. Modelado de baterías de Iones de Litio

En esta sección se presentan los fundamentos generales y conceptos relacionados con el campo de las baterías. Se hace una revisión de las diferentes tecnologías de baterías basadas en Iones de Litio. Posteriormente se expone una revisión exhaustiva bibliográfica de los tipos de modelos de diagnóstico existentes. La sección finaliza resaltando las carencias identificadas en los modelos para la estimación del Estado de Salud en baterías de Iones de Litio.

En los últimos años se ha avanzado considerablemente en la optimización del uso de la energía almacenada en las baterías y en la prevención de daños [50–52]. Lograr un uso óptimo de las baterías en los vehículos eléctricos tiene mucha importancia. Aproximadamente el 40 % del costo total de estos vehículos lo representa sus baterías. El uso eficiente de la energía almacenada tiene un impacto directo la reducción de gases contaminantes al medio ambiente, así como, una mayor rentabilidad de la inversión realizada por usuario de estos vehículos.

Los vehículos eléctricos incorporan Sistemas de Gestión de Baterías (BMS, del inglés: Battery Management Systems). Estos BMSs, mediante un conjunto de software y hardware, deben garantizar el uso óptimo de las baterías [57]. Los BMSs implementan diferentes modelos de diagnóstico y pronóstico de baterías en condiciones de operación. La Figura 2.11 hace un esbozo simple de la disposición del BMS, la batería y el motor dentro de los vehículos eléctricos.




FIGURA 2.11: Esbozo de los vehículos eléctrico (Fuente [4]).

2.3.1. Conceptos, fundamentos generales y tecnologías

Una batería se define como un sistema electroquímico que transforma directamente la energía química almacenada en sus materiales activos en energía eléctrica mediante un proceso de oxidación-reducción.

El término “batería” se usa en el campo de la ingeniería, mientras que, el término “celda” se emplea comúnmente en el campo de la electroquímica. Una celda es la unidad mínima electroquímica que transforma energía química en energía eléctrica, de manera que, las baterías pueden constar de una o varias celdas conectadas en serie o en paralelo para conseguir la tensión y capacidad deseadas [142].

La Figura 2.12 muestra un esquema básico del principio de funcionamiento, donde se resaltan los siguientes elementos:




FIGURA 2.12: Principio de funcionamiento las las baterías de Iones de Litio (Fuente [5]).

Ánodo: es el electrodo por el que los electrones abandonan la solución hacia el circuito eléctrico externo.

Cátodo: es el electrodo que acepta los electrones provenientes del circuito eléctrico exterior.

Electrolito: es el conductor iónico que posibilita la circulación de corriente entre los electrodos por el interior de la batería. Los electrolitos pueden ser una solución acuosa o no acuosa. Tienen como objetivo mejorar la conductividad iónica.

Seguidamente se listan una series de definiciones asociadas al campo de las baterías. Los términos, nomenclatura y unidades específicas que se listan serán usados a lo largo del presente documento. Asimismo, se incluye el nombre de cada término en inglés, tal y como aparece en las

hojas de características y en una serie de figuras del presente trabajo tomadas de la bibliografía consultada y otras de elaboración propia.

- Capacidad (del inglés, Nominal Capacity) – (Ah): Cantidad de amperios-hora (Ah) que puede entregar una batería totalmente cargada. Este proceso de descarga se realiza en unas condiciones específicas (generalmente a temperatura ambiente de 24°C y con un régimen de descarga específico seleccionado por el fabricante). En otras palabras, refleja el tiempo en horas de una descarga a un índice de corriente determinado. En términos matemáticos se define como:

$$\text{Capacidad}(Ah) = \int_0^{t_i} i_B dt \quad (2.6)$$

- Índice C (del inglés, C Rate): Régimen de carga o descarga en amperios al que se somete un batería, expresado como un múltiplo de la capacidad nominal en amperios hora. Por ejemplo, si una batería de capacidad nominal 1Ah está cediendo 0.1A y una batería de 10Ah está entregando 1A, se dice que ambas se están descargando con un índice de C/10 ó 0.1C. Se expresa matemáticamente de la siguiente forma:

$$C = \frac{\text{Capacidad}(Ah)}{\text{Tiempo}(h)} \quad (2.7)$$

- Tensiones de corte (del inglés, Cut-off voltajes) – (V): Valor de tensión de una batería donde finaliza la carga o la descarga.
- Profundidad de descarga (DOD, del inglés, Depth of Discharge) – (%): Relación de los amperios hora descargados de una batería con respecto a su capacidad nominal.
- Densidad de energía (del inglés, Energy Density) – (Wh/l): Energía (Wh) que se puede extraer de una batería por unidad de volumen (l).
- Energía específica (del inglés, Specific Energy) – (Wh/kg): Energía (Wh) que se puede extraer de una batería por unidad de masa (kg).
- Potencia específica (del inglés, Specific Power) – (W/kg): Potencia (W) que se puede extraer de una batería por unidad de masa (kg).
- Rango de temperatura de funcionamiento (del inglés, Operating Temperature Range) – (°C): Margen de temperaturas en el que la batería puede trabajar en condiciones seguras tanto en carga como en descarga.
- Vida cíclica (del inglés, Cycle Life) : Número de ciclos, bajo unas condiciones de carga y descarga específicas, que soporta una batería antes de que su capacidad nominal disminuya por debajo de un límite específico, generalmente un 80 % de la capacidad inicial.

- Tensión de la batería (v_B , en inglés, Voltage) - (V): La tensión medida en los terminales (bornes) de la batería. Es el resultado de la diferencia de potencial entre los electrodos.
- Resistencia Interna de la Batería (del inglés, Battery Internal Resistance) - [Ω]: Oposición o resistencia al flujo de la corriente eléctrica que circula a través de la batería.

Por la importancia que tienen para el presente trabajo se resaltan un grupo de definiciones que se utilizan con mucha frecuencia en el modelado de baterías, estas son:

- Tensión de Circuito Abierto (OCV, del inglés, Open-Circuit Voltage) – (V): Es la fuerza electromotriz de la batería en un estado de carga determinado sin la circulación de corriente. La curva de la OCV es vital para el ajuste de muchos tipos de modelos de baterías, fundamentalmente los basados en circuitos eléctricos equivalentes. Varios estudios presentan ambigüedades donde no se delimita claramente los conceptos de OCV y pseudo-OCV. Esto sucede en el lenguaje utilizado por los autores para explicar sus trabajos y también en los procedimientos de obtención de las curvas.
 - La **OCV** se puede obtener mediante el método de relajación de la tensión propuesto por Abu-Sharkh en el año 2004 (ver Figura 2.13 y consulte la referencia [12]). El método consiste en aplicar corrientes a $C/25$ (o inferiores) con períodos de reposo de 4 horas aproximadamente cada 10 % del Estado de carga. Dichos períodos de reposo se deben hacer durante la carga y la descarga. Mediante éstos se logra alcanzar el equilibrio de los procesos internos y obtener la muestra de tensión al final de cada reposo.
 - La **pseudo-OCV** se obtiene igualmente aplicando corrientes de carga y descarga muy bajas. El procedimiento de obtención de la pseudo-OCV, requiere solamente de dos períodos de reposo, al finalizar la carga y al finalizar la descarga. Con estos datos experimentales obtenidos se computa la media de las curvas de tensión en carga y descarga para cada estado de carga. En la Figura 2.14 se puede apreciar la histéresis entre la carga y la descarga, lo cual denota una falta del equilibrio en las reacciones electroquímicas subyacentes.
- Estado de carga (SoC, del inglés, State of Charge) – (%): Relación entre la capacidad en amperios hora que tiene almacenada una batería y su capacidad nominal. El SoC de una batería está estrechamente relacionado con la OCV, $OCV = f(SoC)$ [143, 144].
- Estado de salud (SoH, del inglés, State of Health) – (%): El SoH refleja la condición general de una batería y su capacidad de rendimiento en comparación con las condiciones de la batería nueva. En el SoH se tiene en cuenta los cambios en la aceptación de carga, la resistencia interna y auto-descarga de las baterías. En otras palabras, indica cuánto de vida útil de la batería se ha consumido, y (en %) el número de ciclos de vida útil quedan.




FIGURA 2.13: Método de relación para la obtención de la OCV.




FIGURA 2.14: Pseudo-OCV.

Baterías de Litio

Existen varios materiales y tecnologías de fabricación de baterías. En la actualidad las baterías de Iones de Litio son las más extendida. Tienen una elevada densidad de energía (Wh/l) y energía específica (Wh/kg). Esta característica las hacen muy atractivas para su uso en aplicaciones móviles y fundamentalmente en vehículos eléctricos. Estas baterías incorporan circuitos electrónicos de control para evitar sobrecargas y/o sobredescargas con riesgo de explosión. Igualmente, el control de la temperatura de funcionamiento es de vital importancia para la prevención de accidentes.

Dentro de las baterías de Iones de Litio existen varios tecnologías:

- Litio Óxido de Cobalto (LCO, del inglés, Lithium Cobalt Oxide) - (LiCoO_2): Fue de las primeras baterías de Litio en el mercado. Es la batería más empleada en aplicaciones de electrónica de consumo, tales como los teléfonos móviles, ordenadores portátiles, etc. Se debe a su densidad de energía de hasta 490 Wh/L lo que la hace muy ligera y poco voluminosa. Su vida cíclica es la más baja de las tecnologías de litio. La densidad de energía de esta tecnología es la más elevada. Dentro de las desventaja que presenta resalta la inestabilidad térmica. En la actualidad los principales fabricantes de esta tecnologías son: Sony, Kokam, Boston Power y Saft.
- Litio Óxido de Níquel, Cobalto y Manganeso (NMC o NCM o , del inglés, Lithium Nickel Manganese Cobalt Oxide) - (LiNiMnCo_2): Presenta buen rendimiento para el bajo coste que suponen. Tienen una densidad de energía alta, buenas características de energía específica y vida cíclica. Por otro lado, pueden suministrar corrientes de pico altos. Esta característica las hacen muy atractivas para su utilización en vehículos eléctricos. Además, son más seguras por sus propiedades térmicas. Uno de los principales proveedores de este tipo de baterías es Samsung.
- Litio Óxido de Níquel, Cobalto y Aluminio (NCA , del inglés, Lithium Nickel Cobalt Aluminium Oxide) - (LiNiCoAlO_2): Presentan buenas características en términos de densidad de energía, densidad de potencia y vida cíclica. Dentro de sus características desfavorables están la baja seguridad y el alto costo. Entre los principales fabricantes de esta tecnología está Panasonic, el cual provee este tipo de baterías para los populares vehículos eléctricos de Tesla [145].
- Litio Hierro Fosfato (LFP o LiFePO_4): Es una de las tecnologías que más aceptación está teniendo en los últimos tiempos. Son el fruto de los trabajos de un grupo de investigación de la Universidad de Austin en la década de los noventa. Dentro de las características ventajosas que presentan, según [6], resaltan:
 - La seguridad, no presentan riesgo de explosión;

Tipo	Energía Específica (Wh/kg)	Ciclos de vida	Seguridad	Tiempo de Vida cíclica	Costo
LCO	110 - 190	500 - 1000	Pobre	Promedio	Alto
LMO	100 - 120	1000	Promedio	Promedio	Promedio
NCA	110 - 150	2000-3000	Baja	Alto	Alto
NMC	110 - 170	2000-3000	Baja	Bueno	Alto
LFP	90 - 115	>3000	Alta	Promedio	Promedio
LTO	60 - 75	>5000	Alta	Alto	Alto

TABLA 2.2: Resumen de las principales tecnología de baterías basadas en Iones de Litio.

- Soportan regímenes de descarga muy elevados, llegando a 30C de manera continua;
- El precio de las materias primas es bajo y se cuenta con abundantes reservas;
- Larga vida cíclica, llegando hasta los 3000 ciclos de carga-descarga sin que su capacidad nominal disminuya más del 10 % [146].

A modo de resumen de las principales tecnologías mencionadas anteriormente se puede consulta la Tabla 2.2 y la Figura 2.15.




FIGURA 2.15: Comparación de las distintas tecnologías de baterías basadas en Litio (Fuente [5]).

Considerando el análisis realizado de las diferentes tecnologías de baterías basadas en Iones de Litio, el presente trabajo empleará baterías de tecnología LFP.

2.3.2. Principios en el desarrollo de modelos

El modelado de baterías es un área activa de investigación y bien estructurada. Se aprecia en los últimos años un aumento de los trabajos científicos publicados en esta área. Cuma [4] hace un estudio bibliométrico de las publicaciones relacionadas con las distintas estrategias de estimación de los modelos. La Figura 2.16 muestra el número de publicaciones hasta el año 2014, estando la mayor parte de los trabajos relacionados con la estimación del estado de carga. En el resto de la presente sección se aborda los principales trabajos de investigación posteriores a esa fecha.

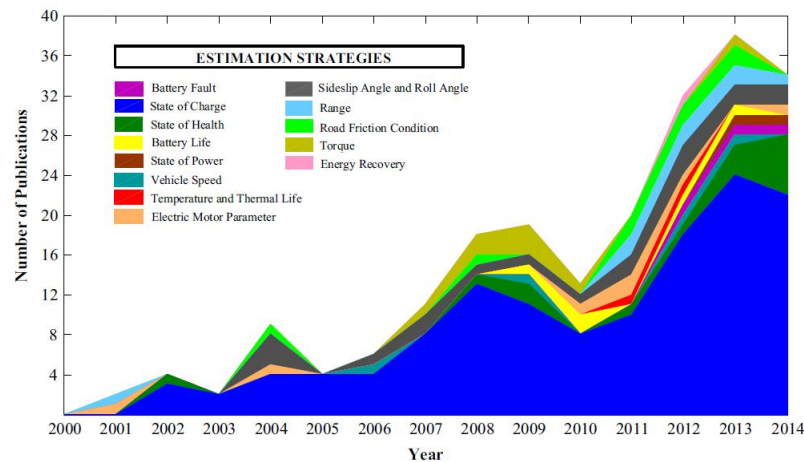


FIGURA 2.16: Número de publicaciones por año de las diferentes estrategias de estimación relacionadas con vehículos eléctricos y baterías (Fuente [4])

Las baterías de Iones de Litio son sistemas dinámicos complejos e inestables que dependen de varios factores internos y externos [57]. Estos elementos hacen que el desarrollo de modelos no sea una tarea fácil. El principal reto del modelado es reproducir las no-linealidades en el comportamiento de estos sistemas. Varios son los fenómenos electroquímicos y termodinámicos que definen el comportamiento general de las baterías en diferentes condiciones de operación [147].

Los principales aspectos a tener en cuenta para el desarrollo de modelos, con la particularidad de que puedan ser utilizados en los BMSs, son:

- Características de la batería.
- Características del hardware embebido en el control de las celdas.
- Perfiles de carga y descarga históricos.
- Condiciones de operación segura.

- Requisitos comunes de los software embebidos vehículos eléctricos.

En un sencillo protocolo de carga, reposo y descarga (Figura 2.17) de una batería basada en LFP, se pueden identificar varios elementos que hacen complejo el desarrollo de modelos:

- Altas pendientes en determinados segmentos de la curva de tensión. Durante la carga, cuando la batería está cercana a alcanzar su máximo de capacidad y durante la descarga, cuando está cercana a la descarga total.
- Elevada histéresis entre la carga y descarga.
- Curvas de tensión muy planas en función de la carga de la batería, fundamentalmente entre el 20 % y el 80 % del SoC. En este segmento aparecen pequeñas mesetas con pocos mili-voltios (mV) de diferencias entre ellas.

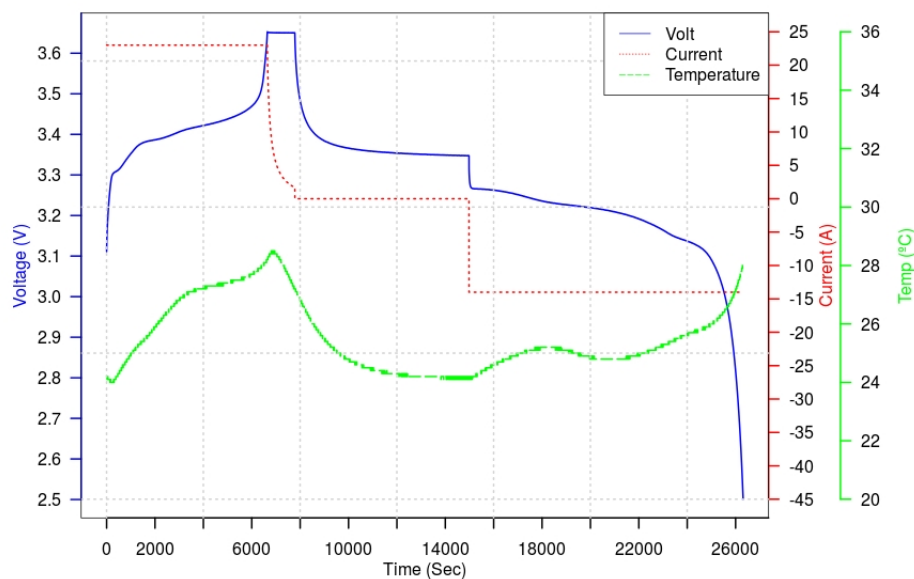


FIGURA 2.17: Protocolo de carga, reposo y descarga de una batería de LiFePO_4 .

El desarrollo de modelos precisos debe considerar también la reducción de la capacidad que se puede extraer de la batería con descargas a altas corrientes (ver Figura 2.18). Este efecto es similar a la respuesta de las baterías a condiciones de trabajo a bajas temperaturas [142].

2.3.3. Modelos de diagnóstico del estado de carga

Los primeros modelos de baterías fueron simples relaciones empíricas entre diferentes variables como: la tensión, la resistencia interna, la presión dentro de la celda o temperatura de la misma




FIGURA 2.18: Diferentes regímenes de descarga aplicados a un batería de LiFePO_4 .

[142]. Los modelos más extendidos que emplean este enfoque hacen uso de tablas de búsquedas relacionando la tensión de la batería con el estado de carga, (v_B, SoC). Estas tablas de búsquedas se conforman con datos a diferentes regímenes de descarga ($C/3$, $C/2$, C , etc) y diferentes temperaturas.

La principal desventaja que presentan estos tipos de modelos es la falta de flexibilidad para representar un enfoque sistemático. El desarrollo a base de prueba y error de estos modelos empíricos, unido a leyes generalizadas que describen el comportamiento de los materiales, ha aportado conocimientos para la mejora continua del modelado de baterías. Las leyes generales indispensables para el modelado de baterías son:

- La Ley de Ohm, resultando que la caída de tensión en una celda depende de la cantidad de corriente que fluye por ésta y la resistencia R que se ofrece al flujo de corriente:

$$v_b = i_B * R \quad (2.8)$$

- Por otro lado, mediante el efecto Joule se puede cuantificar el calor generado por la celda en los procesos de carga y descarga:

$$\Delta T = i_B^2 * R \quad (2.9)$$

Existen un grupo de técnicas de estimación del SoH que están basadas en medidas directas y pueden ser implementadas en los BMSs. Son identificadas por Waag en [57]:

1. Estimación basada en la Pseudo-OCV: puede ser eficiente para los vehículos eléctricos ya que estos son conducidos, generalmente, solo algunas horas al día. Así entonces, la batería está en reposo el tiempo suficiente como para alcanzar el equilibrio y medir la fuerza electromotriz en ese momento.
2. Estimación basada en la capacidad: cuando se conoce la capacidad de la batería, el estado inicial del SoC y se hace un conteo de los Amperios-hora en cada momento se puede tener una estimación del SoC. Cuando esto se hace por un período de tiempo prolongado tiende a ser ineficiente. Se necesita un proceso de recalibración con el tiempo. No obstante, este enfoque ha sido utilizado por el bajo coste de los sensores de corriente y que no necesita hardware para el cálculo. También puede ser utilizado en combinación con otras técnicas.
3. Estimación basada en la impedancia: esta técnica por sí sola no es un buen indicador para la estimación del SoC. Sin embargo, ha sido utilizada para este fin en los trabajos [148, 149].

La estimación del SoC basada en modelos cuenta con muchos trabajos relacionados y una variedad de enfoques. Los trabajos publicados se pueden agrupar en cuatro grandes categorías:

1. Modelos basados en primeros principios o de “caja blanca” [150] o modelos electroquímicos.
2. Modelos basados circuitos eléctricos equivalentes [56, 151, 152].
3. Modelos de “caja negra” o aproximadores universales [15]. Agrupan el uso de varios algoritmos de Aprendizaje Automático que han sido aplicados en problemas de estimación relacionados con baterías.
4. Modelos semi-físicos o modelos de “caja gris”.

Existen varios trabajos con propuestas de modelos de “caja blanca” o modelos de primeros principios [16, 153]. Estos modelos están basados en la caracterización analítica de los fenómenos electroquímicos, termodinámicos y de transporte mediante ecuaciones diferenciales. Son muy precisos y costosos en términos de recursos computacionales. Su uso práctico requiere de las especificidades técnicas utilizadas en la construcción de las baterías, así como un importante número de parámetros de fabricación. Sin embargo, la inmensa mayoría de los fabricantes no facilita este tipo de información. Las hojas de características de las baterías no cuentan con este nivel de detalle. Este elemento reduce significativamente el uso de este enfoque para su uso en BMSs.

Los circuitos eléctricos equivalentes (CEE) han sido una herramienta de modelado muy utilizada para aproximar las no-linealidades de las baterías. Los circuitos que contienen elementos

resistivos y capacitivos son los más extendidos [154–157]. En [158] se incluye el efecto de las no-linealidades en la capacidad.

Hu [56], por su parte, realiza un importante estudio comparativo de diferentes modelos eléctricos donde se concluye que para baterías de LiFePO_4 un CEE de resistivo-capacitivo de primer orden con histéresis de un estado, obtiene mejor ajuste que el resto de los 11 modelos estudiados. Otros estudios como [159, 160] se enfocan hacia el comportamiento térmico de las baterías. Por otra parte, modelos dinámicos como [159, 161–163] estudian la respuesta de la batería ante cambios repentinos de intensidad de carga o consumo.

Los CEE para la estimación del SoC se implementan mediante modelos basados en espacio de estados [164, 165]. El modelado mediante CEE está estrechamente relacionado con el uso de filtros adaptativos. Estos filtros ajustan los estado internos del modelo en función de las diferencias entre las predicciones y los valores medidos sobre la batería. Los filtros adaptativos más utilizados en el campo de las baterías son:

- Filtros de Kalman [166, 167], incluyendo sus variantes.
- Filtro de cuadratura de Gauss-Hermite [168],
- Método de mínimos cuadrados [169].

El uso de CEE tiene algunas desventajas.

- Generalmente no reproducen los efectos que ocurren en ausencia de corriente o en etapas de corriente constante,
- En su gran mayoría, ignora el efecto de la temperatura en las baterías,

Los modelos de caja negra aplicados a baterías, como en el resto de aplicaciones, no requieren de conocimiento sobre el dominio. Estos modelos inteligentes se han empleado para reproducir el comportamiento de las baterías solamente a partir del tratamiento de los datos relacionados con sus principales variables [170–172]. No obstante, tienen limitaciones para extrapolar los casos no representados en los datos de entrenamiento [173]. En el modelado de baterías de Iones de Litios esta limitación se hace mayor. La principal razón es que por las características de estos sistemas es imposible obtener un amplio abanico de datos (conjunto de entrenamiento) representativos de todas las condiciones de operaciones de las baterías. De este modo, el uso de aproximadores universales como las redes neuronales recurrentes presentan un comportamiento promedio [174, 175].

Otros algoritmos de Aprendizaje Automático e híbridos entre diferentes enfoques han sido utilizados en el modelado de baterías de litio [176]. Dentro de éstos se encuentran las Máquinas

de Soporte Vectorial [177] y modelos basados en lógica difusa [18], entre otras técnicas. Estas pueden ser consultadas en las revisiones realizadas por Cuma y Rezvanianani [4, 178].

2.3.3.1. Modelo semi-físico

Los modelos de caja gris o modelos semi-físicos son conceptualmente simples [16, 17]. Los modelos semi-físicos (SMF) para baterías de Iones de Litio fueron propuestos por Sánchez y Banco en [6, 7]. Estos modelos SMFs de primera generación implementan la metodología propuesta en [179]. Cuentan con bloques compuestos por sistemas basados en reglas difusas embebidos en un conjunto de ecuaciones diferenciales. Su enfoque combina la flexibilidad de los modelos inteligentes con la simplicidad de diseño de los circuitos equivalentes (ver Figura 2.19). Se reduce al mínimo el número de pequeñas cajas negras utilizadas para representar las no-linealidades de determinados bloques.

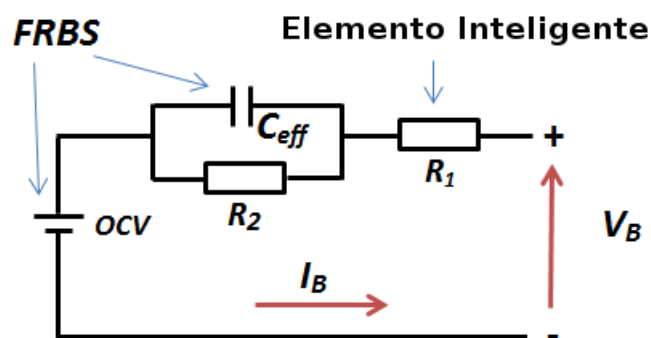


FIGURA 2.19: Circuito eléctrico equivalente de los modelos semi-físicos de de primera generación.

Estos modelos SMFs de primera generación inyectan conocimiento previo sobre la dinámica del sistema restringiendo los grados de libertad. La propuesta de Blanco considera el llenado de un tanque de agua con las paredes flexibles o de goma para explicar el modelo de estimación de la salida de tensión y la carga almacenada en la batería (ver Figura 2.20 y consulte Referencia [6]).

El modelo SMF propuesto por Sánchez es más completo, tiene un enfoque multicriterio. Se aproxima la tensión de salida de la batería y la temperatura de la celda, además de la carga de la batería que no es observable directamente como salida del sistema. Se ha realizado un profundo estudio numérico evidenciando la superioridad de este modelo SMF en comparación con un grupo de modelos de primeros principios y modelos de caja negra del estado de arte. La Figura 2.21 muestra el ajuste de las curvas de salida del modelo SMF de primera generación.




FIGURA 2.20: Modelo semi-físico de baterías con analogía en el llenado de un tanque (Fuente [7]).




FIGURA 2.21: Salida experimental del modelo semi-físico con enfoque multicriterio de primera generación (Fuente [7]).

Observe en la Figura 2.21 que este modelo SMF de primera generación es capaz de estimar el comportamiento de las zonas de reposo en carga y descarga (zonas de corriente cero).

2.3.4. Modelos para la estimación del estado de salud

La estimación del Estado de Salud es el mayor reto que tienen los investigadores e ingenieros en el modelado de baterías [53, 180, 181]. En la mayoría de las aplicaciones una celda o batería se considera desechable (para reciclar) cuando se reduce su capacidad a un 80 % de la inicial. Los fabricantes y los usuarios de baterías de Iones de Litio tienen la expectativa de que el tiempo de vida útil sea superior a los 10 años y más de 1000 ciclos de carga y descarga.

Es conocido que varios son los factores que influyen en el envejecimiento de las baterías:

- La pérdida de Litio en las celdas y la pérdida de material activo dentro del electrodo negativo [11].
- Uso de la batería en condiciones de temperaturas extremas ($temp < 5^{\circ}C$ y $temp > 35^{\circ}C$, dependiendo de cada tecnología).
- El uso de altos índices de descargas (2C, 3C, etc).
- Elevados índices de profundidad de descarga (DoD).
- Condiciones de almacenamiento poco adecuadas.

El diagnóstico a bordo de los vehículos eléctricos del SoH facilita una valiosa información para saber el momento indicado en que se debe cambiar la batería. Los modelos de estimación del SoH que pueden ser usados en los BMSs deben ser capaces de pronosticar el comportamiento anormal de la batería. El diagnóstico del estado de envejecimiento mediante el uso de modelos no es sencillo. El SoH no se puede conocer directamente con ningún tipo de medida directa sobre las baterías [180], sin tener en cuenta las pruebas invasivas. La existencia de fenómenos “silenciosos” en el deterioro de las baterías, sumada a la alta sensibilidad de las técnicas de estimación más usadas redondean la complejidad en la estimación del SoH [9], estas técnicas serán explicadas a lo largo de la presente sección.

Los primeros modelos de estimación relacionados con el SoH simplemente hacían uso de tablas de búsquedas que relacionaban el SoH con el tiempo de vida útil restante para una celda [57]. Estos modelos empíricos están basados en datos obtenidos mediante técnicas experimentales con ciclos de carga simples. Los mecanismos de estimación son simples, almacenan el tiempo de vida útil restante y comparan este punto con el conocimiento previo que se tiene del envejecimiento en celdas similares. Este grupo de técnicas experimentales tienen ventajas y desventajas las cuales se deben tener en cuenta para su uso o no en una aplicación determinada:

- Ventajas:

- Bajo costo.
- Pueden ser utilizados en BMSs.
- No requieren altas capacidades de procesamiento.
- Desventajas:
 - Baja precisión en la estimación del SoH.
 - Necesitan de un número significativo de curvas de referencia.

Varios son los modelos basados en medidas directa para la estimación del SoH que se encuentran en la literatura. Los dos más extendidos están basados en la impedancia y la resistencia interna de la batería [182, 183].

Los métodos basado en la impedancia estiman las pérdidas de energía durante la operación de las baterías. Esto métodos se agrupan en:

- Métodos basados en impedancia espectroscópica electroquímica [184–186].
- Métodos basados en primeros principios [187].

Por otro lado, los métodos basados en la resistencia interna son utilizados para evaluar la degradación de la resistencia de la batería durante los cambios de corriente/tensión. Las baterías se someten a una experimentación extensa en condiciones de laboratorio para determinar la función de correlación de la resistencia interna, la temperatura y el SoC [188]. La Figura 2.22 muestra la relación entre la resistencia interna en el eje de las abscisas y el SoH en el eje de las ordenadas para diferentes estados de carga.

En la literatura consultada se identifica una fuerte presencia de modelos basados en métodos adaptativos. Se presentan a continuación las ventajas y desventajas de estos modelos:

- Ventajas:
 - Buena precisión.
 - Se puede aplicar a todo tipo de tecnología de baterías.
- Desventajas:
 - Alto coste computacional, aunque con el paso de los años y la disminución de la relación costo por capacidad de procesamiento, no supone un problema.
 - Dificultades para su implementación en los BMSs [180].

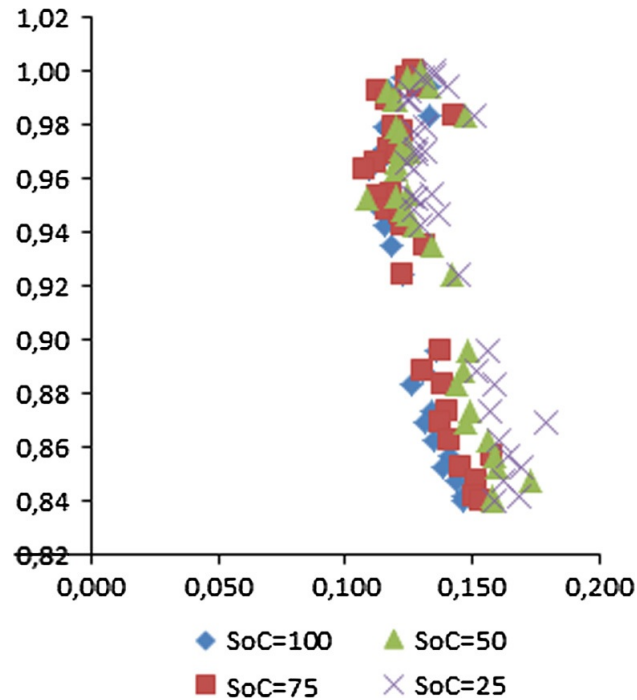


FIGURA 2.22: Estudio de la Resistencia Interna mediante un CEE para la estimación del SoH (Fuente [8]).

Método	Referencias
Circuitos eléctricos equivalente + filtros del Kalman	[189, 190]
Observadores	[191]
Basados en Lógica Difusa	[192, 193]
Mínimos Cuadrados	[194]

TABLA 2.3: Principales métodos adaptativos para la estimación del SoH.

La Tabla 2.3 muestra un resumen de los principales trabajos relacionados con los métodos adaptativos para la estimación del SoH.

La precisión de estos métodos adaptativos tiene una fuerte dependencia de los modelos de estimación del SoH que se adopten. En la actualidad no son la referencia en los estudios de envejecimiento.

2.3.4.1. Modelos basados en degradación

Los modelos más completos que se aprecian en la literatura consultada para la estimación del SoH están basados en los fenómenos de degradación de las celdas [8, 181, 195]. Concretamente, los investigadores se han concentrado en el estudio del proceso de intercalación de Litio y cómo se manifiesta este en las curvas observables en las baterías.

Estos métodos pueden ser utilizados tanto en condiciones de laboratorio como en condiciones de operación dentro del BMS de los vehículos electrónicos [196, 197]. Existen dos alternativas dentro de estos métodos:

1. Análisis de la Capacidad Incremental (ICA, del inglés, Incremental Capacity Analysis)
2. Análisis Diferencial de Tensión (DVA, del inglés, Differential Voltage Analysis)

ICA

Hace más de una década que se ha propuesto esta técnica electroquímica. Permite detectar cambios con gran sensibilidad durante el ciclo de vida de una celda [53, 198]. La característica distintiva del ICA son los picos obtenidos al computar la función de la Ecuación 2.10.

$$ICA = f(V) = \frac{\Delta Q}{\Delta V_B} \quad [Ah/V] \quad (2.10)$$

Donde Q representa la capacidad cargada de la batería en Amperios-hora (Ah) y V_B la tensión en bornes de la batería. En otras palabras, la curva ICA transforma la gráfica de tensión respecto a la capacidad cargada ($V_b - Q$) como se muestra en la Figura 2.23. Note las diferencias existentes entre el inicio (BOL, Beginning of Life) y el fin de la vida útil de la batería (EOL, End of Life).




FIGURA 2.23: Análisis de la Capacidad Incremental (Fuente [9]).

Los puntos de mayor cambio de pendiente en la curva de tensión en carga y descarga corresponden con los picos en las curvas ICA. El cálculo de la derivada, directamente de los datos

de salida de un modelo, es una tarea costosa y muy sensible. Los modelos que incorporen el ICA deben ser precisos [54, 55]. El algoritmo necesario para la obtención de la curva ICA hace uso de métodos de interpolación. La Interpolación Lineal es suficiente para lograr curvas que permitan el correcto análisis.

El tamaño de los diferentes picos y sus respectivas áreas bajo curva permiten un análisis especializado de los diferentes procesos que ocurren con el envejecimiento de la celda. Estos procesos son:

- Pérdida de Litio en la celda.
- Pérdida de material activo en el ánodo.
- Pérdida de capacidad de la celda.

Para el uso del ICA en modelos de estimación del SoH y su evaluación para ser implementados en un BMS, es suficiente conocer que con el envejecimiento disminuye el área bajo la curva. Lo que se evidencia de forma más precisa en los picos de la curva ICA. Observe que la Figura 2.24 muestra el ICA de una batería entre el 100 % y el 90 % de su capacidad.

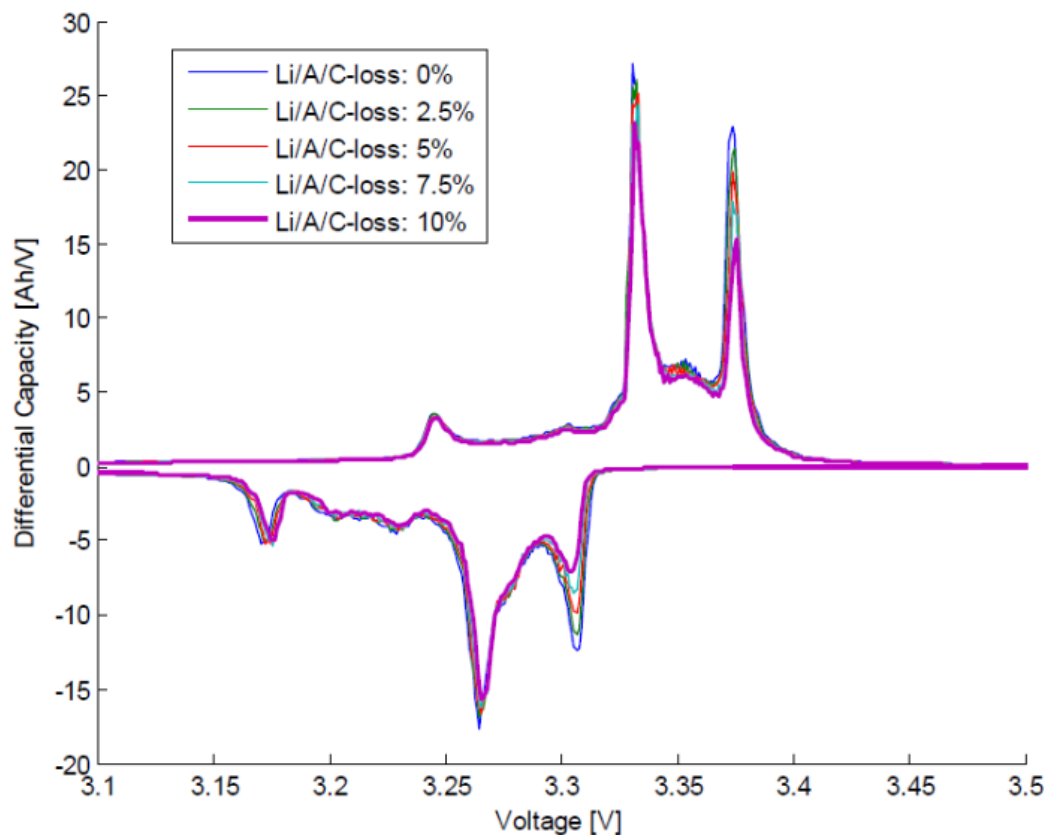


FIGURA 2.24: Cambios en las curvas ICA entre el 100 % y el 90 % del SoH.

Mediante un protocolo de carga y descarga a $C/25$ se obtienen los datos experimentales para la identificación más exacta posible de la degradación de una celda [199]. La Figura 2.25 muestra los picos ideales a diferentes ΔV . Se puede apreciar que el valor ΔV igual a 4mV es ideal para el ICA por la limpieza con que se muestran los cinco picos asociados al ICA en baterías basadas en Iones de Litio.

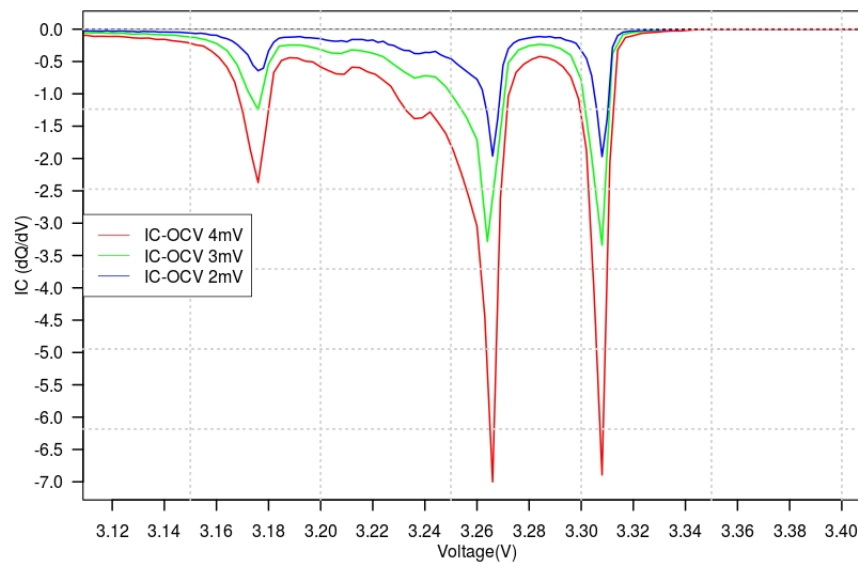


FIGURA 2.25: ICA de la curva de tensión de la batería con el protocolo de carga y descarga a corriente constante ($C/25$), ΔV a 2mV, 3mV y 4mV.

DVA

El Análisis Diferencial de Tensión es muy similar al ICA. En este caso se define mediante la Ecuación 2.11.

$$DVA = f(Q) = \frac{\Delta V_B}{\Delta Q} \quad [V/Ah] \quad (2.11)$$

Las curvas resultantes son muy diferentes a las del ICA pero igualmente permiten la estimación del SoH basado en la pérdida de capacidad. Un pico en el espectro de DVA denota un cambio relativamente rápido en la tensión. Estos cambios están relacionados con las diferentes etapas de intercalación de Litio en los electrodos. Además para la correcta identificación de los picos es necesario el flujo de corriente a niveles bajos para evitar el sobrepotencial asociado al transporte de la masa de Litio. En la Figura 2.26 se pueden observar los dos picos más significativos del DVA.

Varios autores han trabajado en modelos que hacen uso del ICA o el DVA como mecanismos de estimación del envejecimiento [194, 200, 201]. Wang [195] propone un nuevo algoritmo para




FIGURA 2.26: Análisis Diferencial de Tensión (Fuente [9]).

calcular las curvas DVA usando una versión mejorada del Método de Mínimos Cuadrados. Feng [197] expone los elementos que complejizan la implementación del ICA y DVA en condiciones de operación de los vehículos:

- Se requiere que los instrumentos de medición de la tensión sean suficientemente precisos.
- Los modelos de estimación deben obtener muy buenos ajustes de las curvas de salida con respecto a las reales.

En la actualidad se considera que la estimación del SoH mediante modelos que puedan ser implementados en BMSs es un problema abierto para la ciencia [8, 181, 195]. Hasta la fecha no se pueden extrapolar los resultados obtenidos con modelos basados en degradación en una celda para un conjunto de estas. El desarrollo de modelos que permitan encontrar los puntos de cambio de pendiente en las curvas ICA o DVA dotaría a los investigadores en el área de nuevas alternativas para enfrentar estos problemas y abriría nuevas líneas de trabajo.

2.4. Conclusiones parciales del capítulo

El análisis realizado en el presente capítulo conduce a una serie de conclusiones:

- Los sistemas dinámicos son un reto para el desarrollo de modelos. La inyección de conocimiento en el desarrollo de los modelos es una importante alternativa para lograr buenos ajustes.
- Los Algoritmos Evolutivos Multiobjetivo para el aprendizaje encuentran dificultades con los modelos dinámicos. La existencia de soluciones resistentes a la dominación en la etapa de selección de sobrevivientes es una de las dificultades más frecuentes.
- Los problemas de diagnóstico en baterías de Iones de Litio son de actualidad. La inestabilidad de estos sistemas dificultan el aprendizaje de modelos. La estimación del Estado de Salud en estas baterías es un reto para los investigadores, especialmente el desarrollo de modelos que puedan ser utilizados en BMSs.
- Los modelos semi-físicos presentan varias ventajas en el modelado: son capaces de explotar conocimiento parcial de la dinámica de los sistemas y establecer bloques relacionados con variables latentes para su aprendizaje indirecto.
- Varias son las tecnologías de batería basadas en Iones de Litio. La tecnología basada en LiFePO_4 presenta una buena aceptación para su uso en vehículos eléctricos teniendo en cuenta su relación coste-beneficio.

Capítulo 3

Desarrollo de las propuestas

El presente capítulo comienza introduciendo los modelos semi-físicos de segunda generación. El primer modelo que se presenta (Modelo SMF 1) reformula los modelos de la generación anterior para facilitar el aprendizaje indirecto de las variables latentes que son útiles en el análisis ingenieril. Específicamente el Modelo SMF 1 permite la estimación del estado de carga de la batería mediante la relación $SoC = f(OCV)$. Seguidamente se presenta la evaluación de varios Algoritmos Evolutivos Multiobjetivo para el aprendizaje del modelo propuesto. Además, se presenta un caso de estudio que compara la habilidad del nuevo modelo para el aprendizaje indirecto de la OCV con métodos del estado del arte para este fin.

El segundo epígrafe del presente capítulo propone incorporar la estimación del Estado de Salud al Modelo SMF 1. La introducción de un tercer objetivo relacionado con la primera derivada de la salida de tensión del modelo, aumenta significativamente la complejidad del aprendizaje. En el Sistema Genético-Difuso Multiobjetivo resultante se identifican puntos en común con problemas de muchos objetivos. Tras una evaluación más completa, que incluye algoritmos de aprendizaje basados en computación evolutiva para problemas de muchos objetivos, se identifica que se generan con mucha frecuencia soluciones resistentes a la dominación.

Seguidamente se presenta una extensión de los algoritmos de aprendizaje basados en computación evolutiva. El algoritmo propuesto lleva el nombre de θ -FPO. Introduce el uso de preferencias parciales a través de un segundo nivel de ordenación de las soluciones no-dominadas en el proceso de selección de la supervivencia. θ -FPO incorpora conocimiento basado en taylorismo en el proceso de aprendizaje del modelo SMF 1 mejorando la convergencia del resto de los MOEAs y MMOOEAs.

El segundo modelo semi-físico que se presenta en el capítulo (Modelo SMF 2) está diseñado directamente para la estimación del Estado de Salud en baterías de Iones de Litio. El epígrafe dedicado a este modelo hace un análisis de la literatura sobre las alternativas de algoritmos de

aprendizaje para este modelo. Se evidencia la necesidad de extender los algoritmos de aprendizaje basados en Programación Genética Multiobjetivo. En este contexto se propone el algoritmo Grab-MO-GaP, permitiendo el aprendizaje de manera indirecta de expresiones relacionadas con variables latentes del modelo. Destaca entre las aportaciones del nuevo algoritmo Grab-MO-GaP el uso de gramáticas como mecanismo de presión evolutiva explotando la comonotonía entre las salidas observables del modelo y las variables latentes a aprender, además del uso de mecanismos de promoción de diversidad y de puntos de referencia en el espacios objetivo para conducir la búsqueda. El capítulo finaliza con una serie de conclusiones parciales.

3.1. Modelo SMF 1

El modelo SMF 1 presentado en esta sección es una extensión de los modelos de primera generación [6, 7, 179]. Como se ha explicado, estos comprenden un conjunto de ecuaciones diferenciales que contienen bloques inteligentes embebidos. La principal razón para reformular el modelo propuesto por Sánchez [7] es lograr el diagnóstico eficiente del Estado de Carga de las baterías mediante su relación con la curva *OCV*. En el modelo original no se tiene un elemento de representación del conocimiento explícitamente relacionado con la variable latente *OCV*, el ajuste solo se concentraba en la tensión de salida de la batería y la temperatura.

Las entradas del nuevo modelo son:

1. La corriente i_B aplicada a la batería teniendo en cuenta su signo.
2. La temperatura ambiente T_A .

Las salidas observables del modelo son:

1. La tensión de la batería v_B .
2. La temperatura de la batería T_B .

Mientras que las variables de estado son:

1. La carga de la batería Q ,
2. La temperatura de la batería T_B ,
3. El sobrepotencial η .

Para lograr la estimación de la *OCV*, el principal concepto que debe cambiar con respecto a los modelos de primera generación es el uso de la constante τ para limitar la velocidad del proceso electroquímico. En este caso la τ dependerá de la corriente i_B que circula por la batería, Ecuación 3.1.

$$\tau(i_B) = \begin{cases} \tau_+ & \text{cuando } i_B > 0 \\ \tau_0 & \text{cuando } i_B = 0 \\ \tau_- & \text{cuando } i_B < 0 \end{cases} \quad (3.1)$$

Por otro lado, se modifica el mecanismo para modelar la ineficiencia del condensador. En los modelos SMFs de primera generación se modelaba mediante una resistencia en paralelo R_2 . En este caso, se asume que una pequeña fracción (ϵ) de la carga se pierde, Ecuación 3.2:

$$i_B^* = \begin{cases} i_B \cdot (1 - \varepsilon) & \text{en carga} \\ i_B \cdot (1 + \varepsilon) & \text{en descarga.} \end{cases} \quad (3.2)$$

Estos pequeños cambios permiten simular el paso de corrientes muy bajas por el sistema. Estos índices bajos de corriente son necesarios para evitar el sobrepotencial en los procesos de carga y descarga. De esta forma la determinación de la *OCV* se puede realizar a través de un instrumento virtual sobre el modelo aprendido.

3.1.1. Primera salida del modelo: tensión de la batería

La tensión de la batería es la primera salida observable del modelo y se define mediante la Ecuación 3.3.

$$v_B = i_B^* R_1 + OCV(Q) + \eta(Q, T_B, i_B^*) \quad (3.3)$$

Donde, R_1 es la resistencia en serie. La *OCV* es una variable latente modelada por medio de FRBS que depende únicamente de la carga almacenada en la batería Q , la cual es dependiente del tiempo. La función $\eta(Q, T_B, i_B^*)$ evoluciona en el tiempo mediante las ecuaciones 3.4 y 3.5, $f(Q, T_B, i_B^*)$ representa el sobrepotencial en los procesos de carga y descarga de las baterías. Esta función

$$\dot{\eta} = -\tau(i_B^*) \cdot (\eta - f(Q, T_B, i_B^*) \cdot i_B^*) \quad (3.4)$$

$$f(Q, T_B, i_B^*) \cdot i_B^* = \begin{cases} f^+(Q, T_B) \cdot i_B^* & \text{en carga } i_B^* > 0 \\ f^-(Q, T_B) \cdot i_B^* & \text{en descarga } i_B^* < 0 \end{cases} \quad (3.5)$$

Las funciones f^+ y f^- en la Ecuación 3.5 son FRBSs que dependen de la carga y la temperatura de funcionamiento de la batería.

Las FRBSs a lo largo de todo el modelo están compuestas por particiones difusas fuertes. Las variables difusas Q y T_B se describen mediante la menor cantidad de términos lingüísticos posibles (en este caso 8). Se hace uso de 6 conjuntos difusos triangulares unidos a dos conjuntos trapezoidales en los extremos derecho e izquierdo de la representación (ver Figura 3.1 y Figura 3.2).

Los posibles valores de la variable lingüística Q son: “MUY BAJA CARGA” (MB-Q), “BAJA CARGA” (B-Q), “CUASI-BAJA CARGA” (CB-Q), “CARGA MEDIA BAJA” (MMB-Q), “CARGA MEDIA ALTA” (MA-Q), “CUASI ALTA CARGA” (CA-Q), “ALTA CARGA” (A-Q)

y “MUY ALTA CARGA” (MM-Q). Por otro lado, los términos lingüísticos de la variable T_B están basados en el “aumento de la temperatura” (AT), siguiendo el mismo patrón de la variable anterior resulta: MB-AT, B-AT, CB-AT, MMB-AT, MA-AT, CA-AT, A-AT y MM-AT. Concluyendo con la variable difusa restante, se tiene que la corriente i_B hace uso de tres términos lingüísticos: “POSITIVA”, “CERO” y “NEGATIVA”.

Las reglas difusas del modelo semi-físico 1 son del tipo Takagi-Sugeno-Kang de orden cero, los antecedentes son combinaciones de sentencias mediante *AND*. Tomando de ejemplo una regla aleatoria de $f^+(Q, T_B)$, se tiene:

Si Q es MUY BAJA y T_B es ALTO-AUMENTO-de-TEMP. entonces $f^+(Q, T_B) = 0,3$




FIGURA 3.1: Particiones difusas de la variable Q .

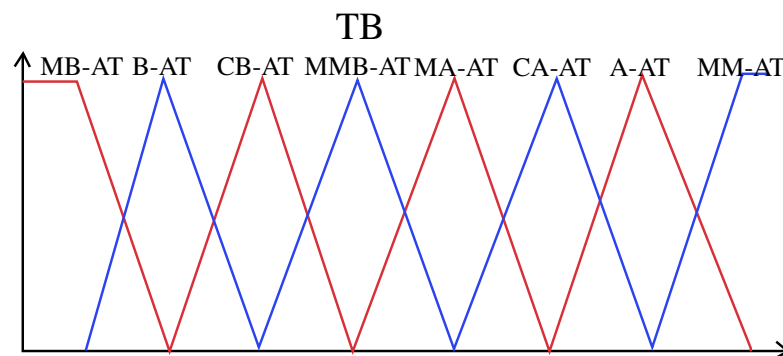


FIGURA 3.2: Particiones difusas de la variable T_B .

3.1.2. Segunda salida del modelo: temperatura de la batería

El balance térmico de la baterías se simplifica respecto a la primera generación de los modelos para una mejor comprensión y facilitar el proceso de aprendizaje. En este caso el balance térmico es modelado mediante la Ecuación Diferencial 3.6.

$$\dot{T}_B = [\alpha(Q_{T_B}, i_B) + \beta T_B] \cdot i_B^2 + \gamma \cdot (T_B - T_A) \quad (3.6)$$

Donde la FRBS α depende del signo de la corriente y del estado de carga. En este caso, los puntos de cambio de regla sobre el SoC de $\alpha(Q_{T_B}, i_B)$ son diferentes a los de la salida anterior, por tanto, se identifica como SoC-temperatura Q_{T_B} ; $Q_{T_B} \neq Q$.

$$\alpha(Q_{T_B}, i_B) = \begin{cases} \alpha^+(Q_{T_B}, i_B) \cdot i_B & \text{en carga } i_B > 0 \\ \alpha^-(Q_{T_B}, i_B) \cdot i_B & \text{en descarga } i_B < 0 \end{cases} \quad (3.7)$$

Las constantes β y γ están relacionadas con la velocidad de enfriamiento y calentamiento del sistema. El término $i_B^2 \cdot [\alpha(Q_{T_B}, i_B) + \beta T_B]$ modela el calentamiento interno de la batería durante la circulación de corriente por ésta, partiendo del principio del efecto Joule. Los términos lingüísticos de la variable difusa Q_{T_B} se conforman a partir de la *capacidad de la carga almacenada para generar calor* (Q-GC). De esta forma se definen los valores: MB-Q-GC, B-Q-GC, CB-Q-GC, MB-Q-GC, MA-Q-GC, CA-Q-GC, A-Q-GC y MM-Q-GC (siguen el mismo patrón de las FRBSs en las Figuras 3.2 y 3.1).

3.1.3. Discretización del modelo

Aprender el modelo semi-físico 1 requiere de la discretización de las variables relacionadas en las ecuaciones 3.2, 3.3, 3.4 y 3.6. Las variables son:

- corriente i_B ,
- tensión v_B ,
- temperatura ambiente T_A ,
- temperatura de la batería T_B ,
- carga de la batería Q ,
- sobrepotencial η ,
- SoC-temperatura Q_{T_B} ,
- OCV .

En el presente estudio se selecciona el Método Implícito de Euler (Método paso atrás) que es adecuado para sistemas lentos como las baterías. Conociendo el valor inicial de cada una de las

variables continuas $y(t_0) = 0$, la aproximación de la ecuación diferencial $\dot{y} = f(t, y)$ se obtiene mediante la Ecuación 3.8, donde h representa el tamaño de los pasos, $h = \Delta t$.

$$y_{k+1} = y_k + hf(t_{k+1}, y_{k+1}) \quad (3.8)$$

El resultado de la aplicación del método se presenta en las ecuaciones 3.9, 3.10, 3.11 y 3.12.

$$i_B^*(t) = \begin{cases} i_B(t) \cdot (1 - \varepsilon) & i_B(t) \geq 0 \\ i_B(t) \cdot (1 + \varepsilon) & i_B(t) < 0 \end{cases} \quad (3.9)$$

$$v_B(t) = i_B^*(t)R_1 + OCV(Q(t)) + \eta(t) \quad (3.10)$$

$$\eta(t + \Delta t) = \frac{\eta(t) + \Delta t \cdot \tau(i_{B(t+\Delta t)}^*) \cdot i_B^* \cdot f(Q_{t+\Delta t}, T_{B_{t+\Delta t}}, i_{B_{t+\Delta t}}^*)}{1 + \tau(i_{B_{t+\Delta t}}^*)\Delta t} \quad (3.11)$$

$$T_B(t + \Delta t) = \frac{T_B(t) + \Delta t \cdot (\alpha(Q_{T_{B(t+\Delta t)}}, i_{B_{t+\Delta t}})i_B^2(t + \Delta t) - \gamma T_B(t + \Delta t))}{1 - \Delta t \cdot (\beta i_B^2(t + \Delta t) - \gamma)} \quad (3.12)$$

Finalmente, a modo de resumen, la Tabla 3.1 presenta los parámetros del modelo con valores aproximados de posibles ajustes. En la próxima sección se presenta un caso de estudio que evalúa un grupo de algoritmos de aprendizaje para aprender estos parámetros. Observaciones empíricas del proceso de aprendizaje del modelo descrito sugieren que es una tarea difícil. Pequeñas variaciones en cualquiera de los parámetros repercuten significativamente en el ajuste del modelo.

3.1.4. Caso de estudio 1: Evaluación de los MOEAs

El presente caso de estudio tiene como objetivo realizar observaciones empíricas de comportamiento de varios algoritmos de aprendizaje basados en MOEAs. La lista de algoritmos no es completa, el criterio de selección de estos algoritmos está dado por la popularidad de los MOEAs en estudios relacionados con problemas de ingeniería. Los algoritmos seleccionados en el presente caso de estudios son:

- SPEA2 [27],
- NSGA-II [26],
- OMOPSO [104]

Parámetro	Valores aproximados
R_1	4.91 m Ω
Particiones difusas para la entrada Q	(0.0107, 0.5806, 2.8196, 6.3618, 19.5995, 33.8978, 39.7233, 44.2158)
Particiones difusas para la salida $OCV(Q)$	(3.05693, 3.18376, 3.20498, 3.25055, 3.29191, 3.32809, 3.35265, 3.38472)
τ_+	5.1e-3
τ_0	0.6e-3
τ_-	5.5e-3
Particiones difusas para la entrada T_B basado en los picos de aumento respecto al ambiente	(0.0107, 3.5806, 7.8196, 12.3618, 16.0107, 22.5806, 28.2196, 33.0361)
Particiones difusas para la salida $f^+(Q, T_B)$	(0, 0.00247648, 0, 0.000403406, 0, 0, 0.00260066, 0.1757)
Particiones difusas para la salida $f^-(Q, T_B)$	(0, -0.0279622, -0.00767872, -0.00248692, 0, 0, 0, -0.00175083)
Particiones difusas para la entrada Q_{T_B}	(2.68E-4, 8.52E-6, 0.3608, 0.6018, 2.4398, 3.6380, 3.9999, 4.3448)
Particiones difusas para la salida $\alpha^+(Q_{T_B}, i_B)$	(0.0784, 0.8456, 1.5540, 1.5426, 1.5134, 1.4468, 1.9194, 1.1594)
Particiones difusas para la salida $\alpha^-(Q_{T_B}, i_B)$	(0.0852, 1.9915, 1.9999, 1.6760, 1.3340, 1.5628, 1.4895, 1.9999)
Constante β	-4.6413
Constante γ	1.8677
Valor inicial de la tensión v_{B_0}	2.5 V
Valor inicial del sobrepotencial η_0	0
Carga inicial de la batería Q_0	0
Valor inicial del OCV OCV_0	2.5 V
Valor inicial de la temperatura ambiente T_{A_0}	23 °C
Valor inicial de la temperatura de la batería T_{B_0}	23 °C
Valor inicial de la SoC-temperatura $Q_{T_{B_0}}$	0

TABLA 3.1: Valores aproximados de los parámetros del modelo semi-físico para baterías.

Para la evaluación de estos algoritmos se establecen parámetros similares para cada uno de los algoritmos. El tamaño de la población escogida es de 100 individuos, las probabilidades de cruzamiento y de mutación son fijadas en 0.9 y 0.1 respectivamente.

Además de estos MOEAs, el presente caso de estudio incluye el algoritmo de aprendizaje ad hoc que se utiliza en la primera generación de los modelos semi-físicos [7]. Este algoritmo cuenta con dos etapas. La primera etapa hace una búsqueda basada en una versión multiobjetivo del algoritmo Recocido Simulado (Simulated Annealing). La segunda etapa hace uso de una estrategia de búsqueda local para el ajuste final del modelo. El proceso de búsqueda local utiliza una función objetivo escalar. Dicha función es la suma ponderada de los errores para cada uno de los objetivos con igual peso para cada uno de ellos.

Aprender el modelo MSF 1 consiste en encontrar los parámetros del modelo que están recogidos

en la Tabla 3.1. Concretamente, aprender el modelo SMF 1 consiste en resolver el problema multicriterio de la Ecuación 3.13.

$$\begin{aligned} \text{mín } F(x) &= (\text{MSE}_{V_B}(x), \text{MSE}_{T_B}(x))^T \\ x &\in \Omega \end{aligned} \quad (3.13)$$

Sujeto a las siguientes restricciones:

- $R_1 > 0$;
- $\tau_+ > 0$, $\tau_- > 0$ y $\tau_0 > 0$;
- El conjunto de valores que definen la función $OCV(Q)$ son monótonicamente crecientes respecto a la carga Q ;

Las funciones de error mediante mínimos cuadrados (MSE; de inglés, Mean Square Error) que están relacionadas con cada uno de los objetivos, se detallan en las ecuaciones 3.14 y 3.15.

$$\text{MSE}_{V_B}(x) = \frac{1}{\text{NP}} \sum_{i=1}^{\text{NP}} \{V_B(t_0 + i\Delta t) - V_B^{\text{TRUE}}(t_0 + i\Delta t)\}^2 \quad (3.14)$$

$$\text{MSE}_{T_B}(x) = \frac{1}{\text{NP}} \sum_{i=1}^{\text{NP}} \{T_B(t_0 + i\Delta t) - T_B^{\text{TRUE}}(t_0 + i\Delta t)\}^2 \quad (3.15)$$

Donde NP representa el número de muestras de las variables V_B y T_B desde $t_0 = 0$ hasta t . El presente caso de estudio utiliza tres juegos de datos de elaboración propia para la evaluación de los algoritmos. Los detalles de la elaboración de los juegos de datos, así como las características de las baterías ensayadas se exponen en el siguiente capítulo (Epígrafe 4.1). A lo largo de este caso de estudio simplemente se identificarán los juegos de datos como: DS-C/3, DS-C/2 y DS-C. En esta notación se utiliza DS (del inglés, Data Set) y la segunda parte C/3 se refiere al régimen de descarga utilizada en el ensayo.

La evaluación numérica del presente caso de estudio se expone en el capítulo siguiente (Sección 4.2). Se realizará después de discutir los diferentes indicadores de calidad para la comparación de Frentes de Pareto. Las Figuras 3.3, 3.4 y 3.5 muestran los FPs obtenidos la evaluación de los algoritmos sobre los juegos de datos DS-C/3, DS-C/2 y DS-C respectivamente. Estos FPs han sido conformados mediante la acumulación de las soluciones no-dominadas en 20 ejecuciones de cada algoritmo para cada juego de datos.

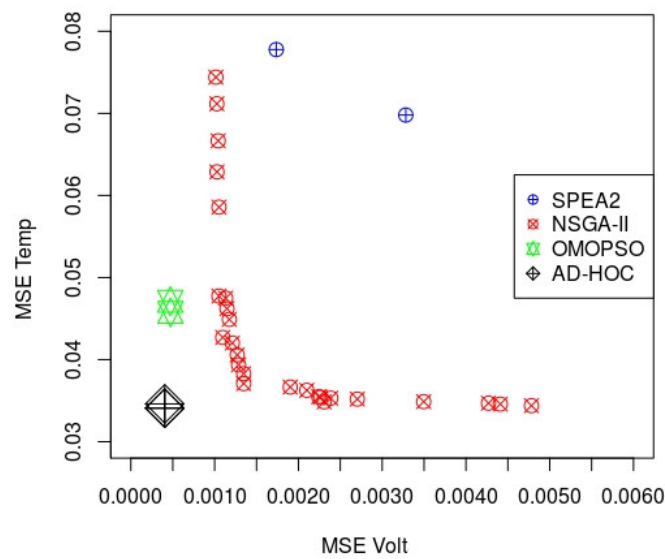


FIGURA 3.3: Caso de Estudio 1: Frentes de Pareto de la experimentación con el juego de datos DS-C/3.

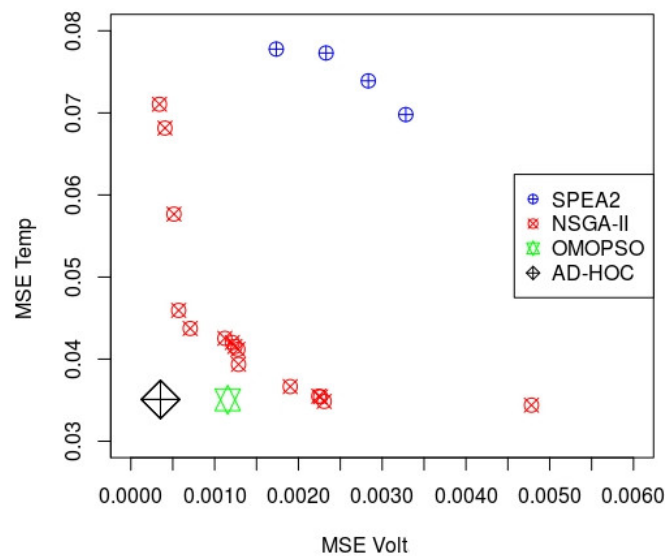


FIGURA 3.4: Caso de Estudio 1: Frentes de Pareto de la experimentación con el juego de datos DS-C/2.

En los FPs resultantes se puede observar que los MOEAs tienen un resultado promedio. No mejoran el algoritmo ad hoc de la primera generación de modelos SMFs. El algoritmo NSGA-II obtiene FPs con mayor número de soluciones no-dominadas, para este caso de estudio. El algoritmo SPEA2 no tiene una buena convergencia respecto al resto. Durante la experimentación se observa que la evaluación de la función de adaptabilidad consume un gran porcentaje del tiempo de procesamiento requerido para completar una generación.

Por otro lado, el presente caso de estudio evidencia la complejidad del proceso de aprendizaje del modelo semi-físico 1. Los procesos evolutivos requieren de una minuciosa definición de los

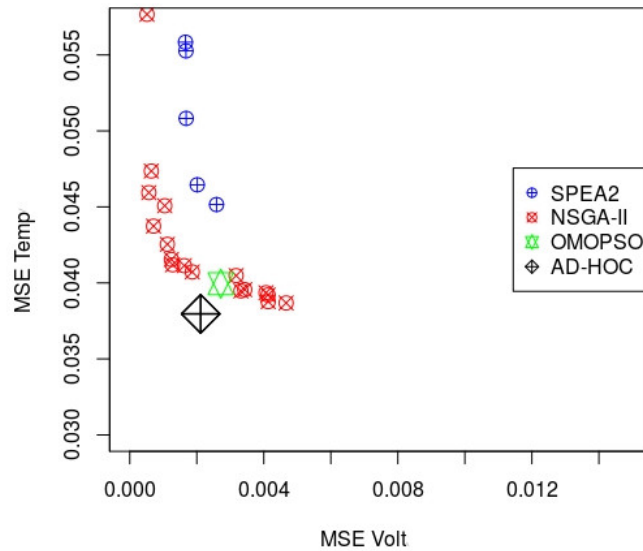


FIGURA 3.5: Caso de Estudio 1: Frentes de Pareto de la experimentación con el juego de datos DS-C.

límites superiores e inferiores de cada uno de los parámetros del modelo. La definición de estos límites también debe evitar el sobreajuste del modelo.

3.1.5. Caso de estudio 2: Estimación indirecta de la OCV

El presente caso de estudio analiza el aprendizaje indirecto de la variable latente del modelo que representa la *OCV* de la batería. La estimación de la *OCV* se realiza mediante un instrumento virtual que consiste en hacer circular por el modelo aprendido una corriente muy baja que evita el sobrepotencial. El caso de estudio hace un análisis numérico de la precisión del sistema basado en reglas difusas $OCV(Q)$ en la Ecuación 3.3 del modelo. Las habilidades del modelo SMF 1 para el aprendizaje indirecto se comparan con los métodos del estado del arte para la estimación de la *OCV*. En este estudio se retoma el algoritmo de aprendizaje ad hoc de la primera generación de modelos SMFs, que hasta el momento es la mejor alternativa.

La aportación práctica del presente caso de estudio está dada por la reducción del tiempo de ensayo y el procedimiento para la determinación de la *OCV*. En condiciones de laboratorio, para obtener los puntos de la *OCV* en estado de equilibrio se consumen más de 90 horas de ensayo. Este tiempo está relacionado con el ensayo de relajación para la correcta estimación de la *OCV* que ha sido propuesto por Abu-Sharkh [12]. Consiste en hacer períodos de reposo, de 4 horas, cada 10 % del SoC durante la carga y la descarga. Al final de estos períodos de reposo se toma la muestra de los puntos de la *OCV*, como se explicó en el capítulo anterior (ver Figura 3.6).




FIGURA 3.6: Ensayo de relajación para el caso de estudio 1.

Para evaluar la precisión de los resultados de la simulación sobre el modelo SMF 1, en el presente caso de estudio se seleccionan los siguientes modelos del estado del arte:

1. El propio modelo propuesto por Abu-Sharkh. Está basado en un circuito eléctrico equivalente como se puede observar en la Figura 3.7. En el circuito la resistencia R_p modela la auto-descarga de la batería. El diodo Zener unido a la sección resistivo-capacitiva compuesta por R_{long} y C_{long} modela la caída de tensión constante en el tiempo que se observa en el ensayo. La resistencia R_{long} es la encargada de predecir el comportamiento del sistema a bajas corrientes, R_{long} es mucho mayor que R_{01} . El segundo nivel resistivo-capacitivo compuesto por R_{12} y C_{12} es típico en los modelos de los circuitos eléctricos equivalentes para simular el movimiento lento del Litio entre los electrodos.




FIGURA 3.7: Modelo basado en un circuito eléctrico equivalente propuesto por Abu-Sharkh (Fuente [12]).

2. El segundo modelo seleccionado del estado del arte para la estimación de la *OCV* es el propuesto por Xu [202]. El modelo utiliza un circuito de Randles (Figura 3.8) con un mecanismo de ajuste adaptativo de los parámetros mediante un Algoritmo Genético.




FIGURA 3.8: Modelo basado en un circuito eléctrico equivalente .

Como en el caso de estudio anterior, los juegos de datos utilizados para el aprendizaje son identificados como: DS-C/3, DS-C/2 y DS-C. Observe los resultados del aprendizaje indirecto de la *OCV* mediante el modelo SMF 1 en las figuras 3.9, 3.10 y 3.11. Las gráficas muestran en rojo (línea continua) la tensión de la batería respecto a la carga del ensayo de relajación. En líneas discontinuas se muestra la histéresis entre los procesos de carga y descarga para los regímenes C/3, C/2 y C. Observe además en estas figuras la diferencia entre los puntos de la *OCV* de los datos experimentales (ensayo de relajación) y los obtenidos mediante el aprendizaje indirecto con el modelo SMF 1.

La precisión de la estimación realizada es competitiva con los métodos especializados. Se mejora la precisión de la estimación en el rango entre el 10 % y 90 % del SoC. En los extremos del estados de carga ($0\% < SoC < 10\%$ y $90\% < SoC < 100\%$) todos los métodos estudiados comparten las mismas dificultades de precisión. Desde el punto de vista práctico, una batería generalmente se utiliza en el rango entre 10 % y el 90 % del SoC.

Para el análisis estadístico de los resultados se han utilizado pruebas no paramétricas. El método de estimación indirecta propuesto es comparado con los métodos de Abu-Sharkh y de Xu para determinar si existen diferencias significativas con cada uno de estos. Se aplica la prueba de Pairwise Mann-Whitney con valor de probabilidad 0.05 y las hipótesis siguientes (planteadas de forma general para las dos comparaciones):

- H_0 : Las diferencias que existen entre la obtención de la *OCV* mediante el modelo SMF 1 y el método propuesto por (Abu-Sharkh ó Xu) se deben al azar.
- H_1 : Existen diferencias significativas entre la obtención de la *OCV* mediante el modelo SMF 1 y el método propuesto por (Abu-Sharkh ó Xu).

Los resultados de la prueba se resumen en la Tabla 3.2. Se muestran los valores de error promedio en la experimentación con los juegos de datos DS-C/3, DS-C/2 y DS-C para cada uno de los métodos. El método propuesto es mejor en todos los casos. Los valores de probabilidad (*p-values*) en las dos comparaciones son menores al nivel de significación por lo que se acepta la hipótesis alternativa. Las pruebas muestran estadísticamente que existen diferencias significativas en los resultados obtenidos con el método propuesto y los métodos de Abu-Sharkh y Xu.

Entrada	Modelo SMF 1	Método de Xu	p-value	Método de AbuSharkh	p-value
DS-C/3	0.0117	0.0181	0.0001	0.0192	1e-05
DS-C/2	0.0115	0.0188	1e-05	0.0173	6e-05
DS-C	0.0186	0.0188	1e-05	0.0188	1e-05

TABLA 3.2: Tabla comparativa de los métodos para la estimación de la OCV.




FIGURA 3.9: Estimación de los puntos de la OCV con el juego de datos DS-C/3.




FIGURA 3.10: Estimación de los puntos de la OCV con el juego de datos DS-C/2.




FIGURA 3.11: Estimación de los puntos de la OCV con el juego de datos DS-C.

3.2. El reto de la estimación del Estado de Salud

Con el objetivo de incorporar la habilidad de estimar el Estado de Salud en el modelo semi-físico 1 se retoman los mecanismos de degradación explicados en el capítulo anterior (Sección 2.3.4). En dicha sección se detallaron las ventajas que tienen los modelos de estimación basados en degradación para extraer información de los distintos procesos de degradación de las baterías de Iones de Litio y la estimación del SoH. Las dos técnicas que se explicaron fueron el Análisis de la Capacidad Incremental (ICA) y el Análisis Diferencial de Tensión (DVA).

Desde el punto de vista del desarrollo de un modelo, dependiendo de la función de error que se utilice para la aproximación, se debe seleccionar una alternativa u otra. En el DVA se debe computar la distancia entre las líneas al extremo de la curva, la cual se desplaza sobre el eje de las abscisas hacia el origen de coordenadas con las pérdida de capacidad de la celda (revisite Figura 2.26 y Figura 2.23 para una mejor comprensión). En el presente estudio se selecciona la otra alternativa, el ICA es la técnica más completa para la extracción de información sobre los procesos silenciosos que ocurren durante el envejecimiento de las celdas [54, 55]. Se considera además, que la curva ICA se complementa mejor con el uso del error cuadrático medio en el proceso de aprendizaje. Con el envejecimiento de las baterías los picos de la curva ICA van disminuyendo de tamaño y el MSE aumenta proporcionalmente.

El ajuste de la primera derivada de la salida de un modelo dinámico no es tarea sencilla. Un modelo puede converger a los datos de entrada y salida utilizados para el aprendizaje y al mismo tiempo, las derivadas de los datos y de las salidas del modelo pueden ser muy diferentes. La Figura 3.12 muestra la salida discretizada de un modelo para aproximar la función *seno* y el error; observe que el error puede hacerse arbitrario en determinados intervalos.

Por otro lado, para ilustrar la complejidad de la aproximación de la primera derivada de la salida de tensión en el modelo SMF 1 observe la Figura 3.13. Observe que pequeños cambios en la salida de tensión del modelo repercuten significativamente en las curvas ICA.

Definiendo el problema de aprender el modelo SMF 1 para la estimación del SoC y el SoH con el uso de ICA, se tiene la Ecuación 3.16.

$$\begin{aligned} \text{mín } F(x) &= (\text{MSE}_{V_B}(x), \text{MSE}_{T_B}(x), \text{MSE}_{ICA}(x))^T \\ & x \in \Omega \end{aligned} \quad (3.16)$$

Las funciones de error para las salidas de tensión y temperatura en el modelo fueron definidas en las ecuaciones 3.14 y 3.15. El error cuadrático medio del ICA del modelo respecto a la de los datos experimentales se define en la Ecuación 3.17.

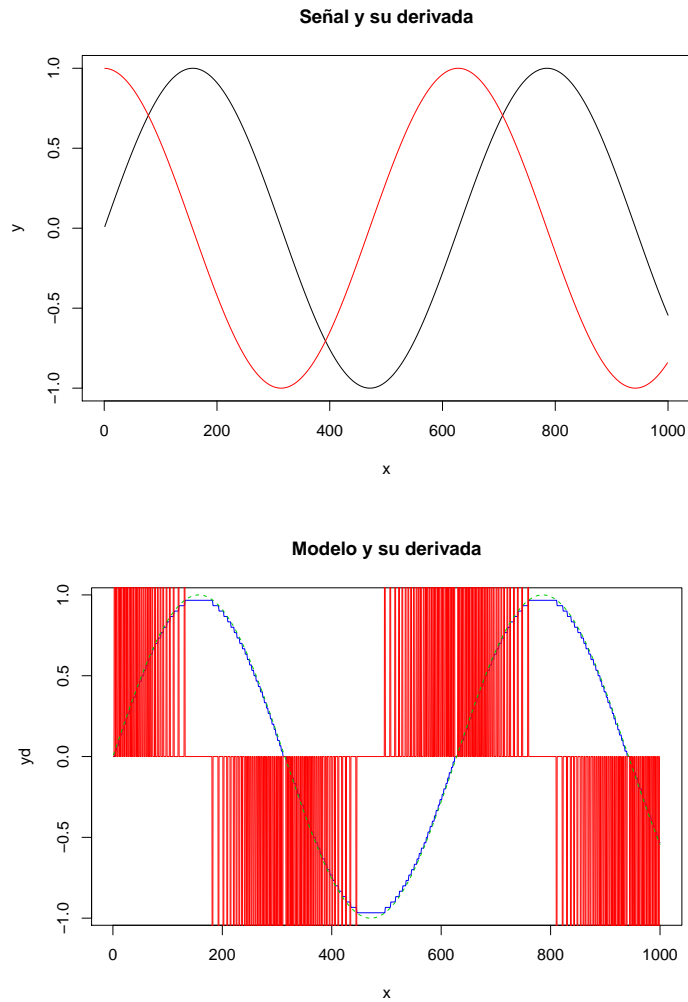


FIGURA 3.12: Ejemplo de las diferencias en la convergencia entre la salida de un modelo y su derivada.

$$\text{MSE}_{\text{ICA}}(x) = \frac{1}{\text{MP}} \sum_{i=1}^{\text{MP}} \{ \text{ICA}(v_0 + i\Delta v) - \text{ICA}^{\text{TRUE}}(v_0 + i\Delta v) \}^2 \quad (3.17)$$

MP representa el número de pasos desde v_0 hasta v .

Una vez formalizado matemáticamente el problema de aprender el modelo semi-físico 1 con la habilidad de estimar el Estado de Carga y el Estado de Salud (Ecuación 3.16), el algoritmo de aprendizaje ad hoc utilizado en el caso de estudio 2 es impracticable para el nuevo problema, no permitiría una correcta exploración del espacio de búsqueda. Por otro lado, realizando algunas observaciones empíricas del proceso de aprendizaje con MOEAs se identifican varios elementos que hacen todavía más complejo el proceso. El Sistema Genético-Difuso Multiobjetivo que se presenta tiene varias características que hacen que no sea estándar:




FIGURA 3.13: Ejemplo de la sensibilidad de las curvas ICA respecto a la salida de tensión del modelo.

- La evaluación de la función de adaptabilidad consume un tiempo de procesamiento elevado, aproximadamente el 90 % del tiempo que se tarda en terminar una generación completa.
- Los operadores de apareamiento no garantizan soluciones hijas cercanas a los padres debido a pequeños cambios en los parámetros del modelo que devuelven individuos muy alejados de los padres en el espacio de decisión. Por este motivo, y para lograr la convergencia es vital el uso de operadores de apareamiento acotados, se debe seleccionar cuidadosamente el rango de cada gen.
- El proceso de aprendizaje deber tener en cuenta tres criterios que no son homogéneos en cuanto a sensibilidad.
- Por otro lado y no menos importante, el tercer objetivo relacionado con el error en el ICA tiene un carácter destructivo. El cómputo de la primera derivada de la salida de tensión del modelo respecto a la carga almacenada en la batería se comporta prácticamente como una función generadora de ruido, lo cual conduce a una aproximación prácticamente aleatoria.

Finalmente, se ha identificado que durante los procesos evolutivos para el aprendizaje del modelo SMF 1, cuando se añade la capacidad de estimación del SoH, se genera un elevado número de soluciones que son resistentes a los mecanismos de dominación. Este elemento, unido a los explicados anteriormente, sugiere que el problema del aprendizaje del modelo tiene varios puntos en común con problemas de muchos objetivos. Por tanto, se demandan algoritmos de aprendizaje que cuenten con mecanismos eficientes de promoción de la diversidad, los cuales requieran

el mínimo posible de evaluaciones de la función de adaptabilidad. En este escenario, la inyección de conocimiento en el proceso evolutivo para lograr una mayor convergencia puede ser una buena alternativa.

3.3. Aportación a los Sistemas Genético-Difuso Multiobjetivo: Algoritmo θ -PFO

En la presente sección se presenta un nuevo algoritmo de computación evolutiva que inyecta conocimiento en el proceso de búsqueda mediante preferencias parciales. La propuesta se centra en combatir la generación de individuos resistentes a la dominación que se presentan en problemas de aprendizaje de modelos dinámicos y otros campos. La idea de esta extensión a los Sistemas Genético-Difuso Multiobjetivo surge de las dificultades observadas en el aprendizaje del modelo semi-físico 1 para la estimación del Estado de Carga y el Estado de Salud en baterías de Iones de Litio, explicado en las secciones anteriores.

De manera general, en las aplicaciones de Aprendizaje Automático no importa el esfuerzo que se realice por aprender un modelo. En el caso particular del aprendizaje de modelos semi-físicos para ser utilizados en BMSs existen una serie de restricciones. Se requiere de algoritmos de aprendizaje que ajusten el modelo sistemáticamente y en el menor número de generaciones posible. En el algoritmo que se propone en esta sección busca la precisión necesaria en el ajuste del modelo y, a la vez, evita el sobreajuste. La presencia de sobreajuste en el modelo impediría la extrapolación de los modelos aprendidos a condiciones de trabajo que no hayan estado reflejadas en los datos de entrenamiento.

El algoritmo propuesto está basado en la relación de dominación propuesta por Yuan [2] (dominación- θ). La inyección de conocimiento altera ligeramente, mediante preferencias parciales, el ordenamiento de los individuos en la etapa de selección de la supervivencia. Concretamente, modifica los niveles de no-dominación dentro de los diferentes grupos de individuos que se generan en el espacio de búsqueda. El nuevo algoritmo se ha identificado con el nombre de θ -FPO (FPO, del inglés, Fuzzy Preference Order).

En el área de los MOEAs, para el aprendizaje se ha trabajado en la definición de nuevas relaciones de dominación entre los individuos y en nuevas estrategias para favorecer la diversidad, entre otros enfoques. La introducción de preferencias parciales como mecanismos de presión evolutiva ha sido estudiada por di Pierro [37] proponiendo el algoritmo de Clasificación en Orden de Preferencia (Preference Order Ranking). Otros trabajos sobre la modificación de diferentes relaciones elitistas de dominación basadas en Frentes de Pareto se pueden encontrar en la referencias [36, 38–42, 122, 123].

A pesar de los avances obtenidos, persisten problemas de aplicación con Frentes de Pareto complicados de aproximar. Estos peculiares FP son independientes de las dimensiones del problema, generalmente están asociados a problemas de muchos objetivos pero también se han reportado en problemas con menor número de criterios [203]. Sin duda, el elevado número de mínimos locales en el horizonte de las funciones de adaptabilidad es un hándicap para la convergencia

de los algoritmos de aprendizaje basados en computación evolutiva. No obstante, en opinión del autor de la presente tesis, la presencia de un elevado número de individuos resistentes a la dominación, así como el alto consumo de tiempo en la evaluación de las funciones de adaptabilidad, son los elementos que más contribuyen a la complejidad de los procesos de aprendizaje de modelos dinámicos.

El Algoritmo 1 detalla la propuesta.

Algorithm 1: θ -FPO

```

1  $\Lambda \leftarrow$  Inicializar_Puntos_de_Referencia()
2  $P_0 \leftarrow$  Inicializar_Población()
3  $P_0 \leftarrow$  Evaluar_Población()
4  $Z^* \leftarrow$  Inicializar_Puntos_Ideales()
5  $Z^{nadir} \leftarrow$  Inicializar_Puntos_Nadir()
6 for  $t \leftarrow 0$  hasta Condición de parada do
7    $Q_t \leftarrow$  CrearPoblaciónHija()
8    $R_t \leftarrow P_t \cup Q_t$ 
9    $S_t \leftarrow$  Obtener_Niveles_de_No-dominación( $R_t$ )
10  Actualizar_Puntos_Ideales( $S_t$ )
11   $C \leftarrow$  Aplicar_Operador_de_Agrupamiento( $S_t, \Lambda$ )
12   $[F_1, F_2, \dots] \leftarrow$  Ordenación- $\theta$ -FPO( $S_t, C$ )
13  while  $|P_{t+1}| + |F_i| < N$  do
14     $P_{t+1} \leftarrow P_{t+1} \cup F_i$ 
15     $i \leftarrow i + 1$ 
16   $t \leftarrow t + 1$ 

```

El algoritmo se puede dividir en tres etapas para su discusión: Etapa de inicialización, Etapa de apareamiento, Etapa de selección de la supervivencia.

3.3.1. Etapa de inicialización

El algoritmo comienza por la etapa de inicialización donde se computa el tamaño de la población N a partir de los parámetros H_1 , H_2 y la cantidad de objetivos m mediante la Ecuación 3.18. Los parámetros H_1 y H_2 representan las divisiones de la frontera superior y de las capas internas respectivamente, siguiendo la propuesta del algoritmo base θ -DEA. La Figura 3.14 muestra la disposición de las fronteras en un espacio objetivo tri-dimensional ($m = 3$) con los parámetros $H_1 = 2$ y $H_2 = 1$.

$$N = \binom{H_1 + m - 1}{m - 1} + \binom{H_2 + m - 1}{m - 1} \quad (3.18)$$

Seguidamente se genera el vector de puntos de referencia $\Lambda = (\lambda_1, \lambda_2, \dots, \lambda_N)^T$ para guiar la búsqueda en el espacio objetivo. Los puntos de referencia se distribuyen uniformemente a

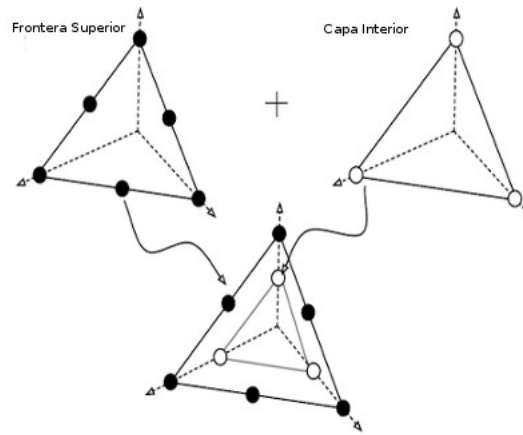


FIGURA 3.14: Inicialización de las fronteras límites en el algoritmo propuesto (Fuente [10]).

lo largo del espacio objetivo. Para este fin se hace uso del enfoque sistemático propuesto por Das y Dennis [204]. Es el mismo mecanismo utilizado en los algoritmos MOEA/D y NSGA-III. Geométricamente, $\lambda_1, \lambda_2, \dots, \lambda_N$ se posicionan en el hiperplano $\sum_{i=1}^m f_i = 1$. La Figura 3.15 ejemplifica la distribución uniforme de los puntos para una frontera superior, con $H_1 = 4$. En el ejemplo se deben generar 15 puntos, $\binom{4+3-1}{3-1} = 15$. La correcta disposición de los 15 puntos se logra mediante el vector de pesos w_1 y su factor de espaciado uniforme ($\frac{1}{H_1} = \frac{1}{4} = 0,25$).




FIGURA 3.15: Espaciado uniforme mediante el métodos de Das y Dennis (Fuente [10]).

La inicialización de la población se hace de forma aleatoria entre los límites definidos para cada gen x_i . Una vez inicializada la población se localiza el conjunto de puntos Nadir z_i^{nadir} y el conjuntos de puntos ideales z_i^* .

3.3.2. Etapa de apareamiento

En la etapa de apareamiento se crea la población hija aplicando el operador de cruzamiento binario simulado (SBX) y el operador de mutación polinómica. El operador SBX genera dos hijos (h^a y h^b) a partir de dos padres (x^a y x^b). La distancia en el espacio de búsqueda es muy cercana entre una generación y otra. Los hijos se generan mediante las Ecuaciones 3.19 y 3.20.

$$h_i^a = 0,5 \left[(1 + \tilde{\beta})x_i^a + (1 - \tilde{\beta})x_i^b \right] \quad (3.19)$$

$$h_i^b = 0,5 \left[(1 - \tilde{\beta})x_i^a + (1 + \tilde{\beta})x_i^b \right] \quad (3.20)$$

Donde $i = 1, 2, \dots, n$ y $\tilde{\beta}$ es un valor seleccionado aleatoriamente de la distribución de probabilidad $c(\beta)$. La Ecuación 3.21 define la distribución.

$$c(\beta) = \begin{cases} 0,5(u+1)\beta^u & \text{para } \beta \leq 1 \\ 0,5(u+1)\frac{1}{\beta^{u+2}} & \text{para } \beta > 1 \end{cases} \quad (3.21)$$

El índice de la distribución u es un número positivo, β depende de u . El índice se puede interpretar como el factor de propagación en el espacio objetivo de los hijos respecto a los padres. Valores pequeños de u conllevan la obtención de una distribución más uniforme. Sin embargo, con valores elevados de u se favorece la creación de hijos muy cercanos a los padres ($15 < u < 25$). En la Figura 3.16 muestra la distribución de probabilidad definida para el operador SBX.




FIGURA 3.16: Distribución de probabilidad del operador SBX.

3.3.3. Etapa de selección de la supervivencia

Continuando las etapas del algoritmos θ -FPO, el operador de agrupamiento se aplica en un escenario donde el espacio objetivo debe ser normalizado. Esta normalización se realiza mediante la Ecuación 3.22.

$$\tilde{f}_i = \frac{f_i(x) - z_i^*}{z_i^{nadir} - z_i^*} \quad (3.22)$$

El operador de agrupamiento asigna cada individuo x al grupo C_j con el que tenga menor valor de distancia $d_{j,2}$. Las distancias $d_{j,1}$ y $d_{j,2}$ se definen mediante las ecuaciones 3.23 y 3.24. No sufren ninguna modificación respecto a las utilizadas originalmente en el algoritmo θ -DEA (revisite Epígrafe 2.2.2.3 Figura 2.10 para una ilustración de estas distancias en un espacio objetivo de dos dimensiones).

$$d_{j,1}(x) = \| \tilde{f}(x)\lambda_j \| / \| \lambda_j \| \quad (3.23)$$

$$d_{j,2}(x) = \| \tilde{f}(x) - d_{j,1}(x)(\lambda_j / \| \lambda_j \|) \| \quad (3.24)$$

En estas ecuaciones $j \in (1, 2, \dots, N)$.

Una vez que los individuos son agrupados se introduce la aportación del algoritmo θ -FPO. Se modifica ligeramente el ordenamiento de las soluciones dentro de cada grupo C_j . Los niveles de no-dominación F_1, F_2, \dots, F_N son alterados por el factor $\psi(x)$. Este factor inyecta conocimiento basado en taylorismo en la función de penalización de intersección de límites del algoritmo base. La función de adaptabilidad para la creación de los nuevos niveles se define en la Ecuación 3.25.

$$F_j(x) = [d_{j,1}(x) + \theta d_{j,2}(x)] * \psi(x) \quad (3.25)$$

El nuevo factor es responsable de que determinadas soluciones que podían pertenecer inicialmente al primer nivel de no-dominación se muevan al segundo y viceversa, sucediendo lo mismo en los límites de cada uno de los niveles de no-dominación. La Figura 3.17 muestra las regiones donde mayormente afecta el uso de las preferencias parciales introducidas. Igualmente, la Figura 3.18 complementa la anterior, mostrando cómo afecta la propuesta al ordenamiento de las soluciones que pertenecen a dos hipotéticos grupos de soluciones etiquetados como A y B.




FIGURA 3.17: Zonas de los niveles de no-dominación que se afectan mayormente por el uso de las preferencias parciales difusas.

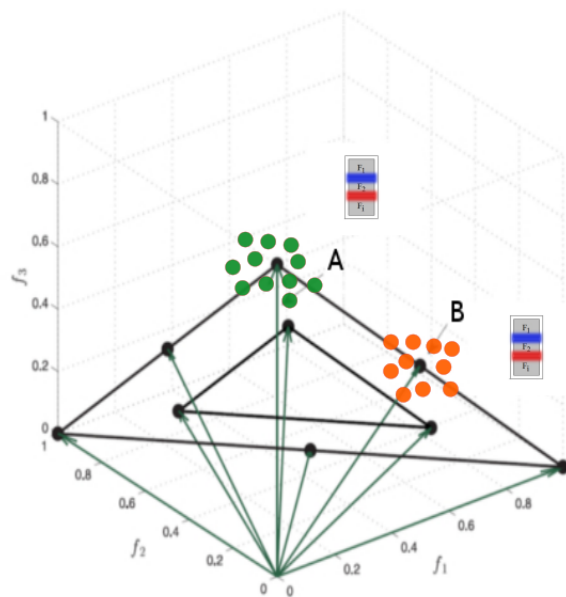


FIGURA 3.18: Preferencias parciales en dos grupos de soluciones del algoritmos θ -FPO.

El parámetro $\psi(x)$, en el caso particular del problema de aprendizaje del modelo SMF 1, altera ligeramente el ordenamiento de los individuos sin quebrantar la θ -dominación y su mecanismo de promoción de la diversidad.

$\psi(x)$ se define como el error que presenta el FRBS $OCV(Q)$ de la Ecuación 3.3 para un individuo x . Estrictamente hablando, el valor de $\psi(x)$ es el error de la función $OCV(Q)$ respecto a los puntos reales de la OCV obtenidos mediante el ensayo de relajación propuesto por Abu-Sharkh. Este fue explicado detenidamente en el caso de estudio 2 de la sección anterior. La

Ecuación 3.26 define el factor basado en el MSE.

$$\psi(x) = E_{OCV} = 1/24 \sum_{k=1}^{24} \{OCV(Q_0 + k\Delta Q) - OCV_k^{TRUE}\}^2 \quad (3.26)$$

La propuesta del algoritmo θ -FPO conlleva a la siguiente pregunta: ¿Es posible aliviar los efectos negativos que producen la generación de soluciones resistentes a la dominación en el problema de aprendizaje del modelo SMF 1? En el próximo capítulo de experimentación se le dará respuesta a esta pregunta.

3.4. Modelo SMF 2

El segundo modelo semi-físico desarrollado en esta tesis es un modelo simple para el diagnóstico del Estado de Salud en baterías de Iones de Litio. Explora el conocimiento parcial que se tiene sobre las reacciones secundarias que ocurren a nivel de electrodo en las celdas. Estos tipos de sistemas que presentan bloques internos conocidos y otros con incertidumbre, no se abordan con mucha frecuencia en la literatura. El objetivo del modelo SMF 2 es establecer las bases para encontrar expresiones analíticas que describan la variable latente del modelo asociada al electrodo negativo. Estas expresiones deben aprenderse indirectamente a partir de los pares de entrada y salida del sistema. Si se lograra este objetivo, el modelo podría ser utilizado en BMSs y se tendría una estimación del SoH a lo largo de la vida útil de la batería.

En la literatura de modelado de baterías existen trabajos que proporcionan expresiones analíticas que describen el potencial de los electrodos positivo y negativos [74]. Sin embargo, estas expresiones no se modifican con el envejecimiento de la celda y no se adaptan a los cambios de fase que ocurren en el potencial del electrodo negativo con la degradación de las baterías.

La Figura 3.19 muestra la base de conocimiento que se tiene del sistema, se puede observar el Potencial de Circuito Abierto (OCP; del inglés, Open-Circuit Potential) de una batería. Este potencial se descompone en los potenciales de los electrodos positivo y negativo (PE y NE; del inglés, "Positive Electrode" y "Negative Electrode", respectivamente).




FIGURA 3.19: OCP de los electrodos en una celda de LiFePO_4 .

Es conocido que los mecanismos de degradación ocurren fundamentalmente en el compuesto de intercalación de Grafito (GIC, del inglés, Graphite Intercalation Compounds) perteneciente

al electrodo negativo, mientras que el patrón del electrodo positivo (LFP) se puede considerar invariante en el tiempo porque sus cambios son prácticamente imperceptibles [9, 11, 53, 55]. Los cambios que ocurren en el electrodo negativo durante la degradación repercuten directamente en el desplazamiento y contracción respecto al estado de carga (eje de las abscisas, Figura 3.20), mientras que el desplazamiento del potencial del electrodo positivo es imperceptible.




FIGURA 3.20: Efecto de la degradación en el electrodo negativo de una celda (Fuente [11]).

Con este principio de base, se decide desarrollar el nuevo modelo semi-físico de segunda generación que también tiene un enfoque multicriterio. Las entradas del modelo SMF 2 son:

- La corriente i_B .
- La temperatura ambiente T_A .

Las salidas son:

- La tensión de la batería v_B .
- La temperatura de funcionamiento de la celda T_B .
- La curva ICA obtenida a partir de la primera derivada del la salida de tensión.

En el presente modelo SMF 2 se presta especial atención a las siguientes variables latentes:

- La carga almacenada en la batería Q .

- La cantidad de Litio en el electrodo positivo Q_{PE} .
- La cantidad de Litio en el electrodo negativo Q_{NE} .
- La expresión que describe el potencial electrodo negativo $NE(Q_{NE})$.

La curva OCV de la batería, así como las curvas OCP de cada electrodo se obtendrán de la estructura del modelo. La OCV y la OCP son funciones de la carga Q . Con la circulación de corrientes muy bajas por la batería las diferencias entre la curva de OCP y la OCV son prácticamente imperceptible. La Ecuación 3.4 establece la relación entre la OCV y el potencial de circuito abierto del electrodo positivo y del electrodo negativo.

$$OCV = PE(Q_{PE}) - NE(Q_{NE}) \quad (3.27)$$

Si la corriente fuese baja o moderada, entonces se tiene que la salida de la tensión del modelo v_B se obtiene mediante la Ecuación 3.28:

$$v_B = PE(Q_{PE}) - NE(Q_{NE}) + R * i_B \quad (3.28)$$

Donde el término $R * i_B$ modela la cantidad de Litio que está disuelto en el electrolito para ser transportado desde el electrodo compuesto por LFP (electrodo positivo) hasta el compuesto de intercalación de grafito (electrodo negativo) durante la carga ($i_B > 0$). Durante la descarga ($i_B < 0$) ocurre el fenómeno opuesto.

En el presente modelo se propone, adicionalmente, que la concentración de Litio en los electrodos se aproxime con un modelo lineal mediante los coeficientes r_p, s_p, r_n y s_n . Se tiene en cuenta la capacidad de cada electrodo y la cantidad inicial de Litio que está presente en estos:

$$Q_{PE} = r_p * Q + s_p \quad (3.29)$$

$$Q_{NE} = r_n * Q + s_n \quad (3.30)$$

Por otro lado, la salida del modelo relacionada con la temperatura de la batería T_B hace uso de la misma ecuación del modelo semi-físico 1 que fue definida en la Ecuación 3.6.

Formalizando el problema de aprendizaje asociado al presente modelo, los tres objetivos son:

1. Error cuadrático medio entre la salida de tensión real y la salida del modelo v_B (Ecuación 3.28.)
2. Error cuadrático medio entre la temperatura de la batería y la salida del modelo T_B (Ecuación 3.6).

3. Error cuadrático medio de las curvas ICA obtenidas de la salida de tensión real y de la salida de modelo.

Como se puede observar, el modelo SMF 2 presenta una particularidad: se necesitan aprender expresiones analíticas de manera indirecta para el electrodo negativo, además de aprenderse los antecedentes y consecuentes de bloques basados en FRBSs. Estos últimos bloques están relacionados con la salida de temperatura del modelo. Por este motivo, el autor de la presente tesis define el proceso de aprendizaje del modelo SMF 2 como un *Sistema de Programación Genética-Difuso Multiobjetivo*.

El aprendizaje basado en Programación Genética Multiobjetivo es la técnica que más se ajusta a los requisitos del modelo [49, 73]. En la próxima sección se hace una revisión exhaustiva de la bibliografía relacionada con los algoritmos de Programación Genética Multiobjetivo.

3.4.1. Aprendizaje basado en Programación Genética Multiobjetivo

De manera general, los algoritmos de aprendizaje basados en Programación Genética (PG, del inglés, Genetic Programming) han sido bien estudiados en problemas de clasificación y de regresión simbólica [205]. Sin embargo, existen pocos trabajos donde se usen estos algoritmos para el aprendizaje de modelos dinámicos [68] y muy pocos estudios en problemas puramente multicriterio [69–71].

Es conocido que el aprendizaje basado en Programación Genética se ubica por encima de los sistemas basados en reglas por las facilidades que ofrece para la comprensión del conocimiento extraído [25]. En varios problemas relacionados con la ingeniería se necesitan de estas facilidades de interpretación que brindan los algoritmos de aprendizaje basados en PG. Para ingenieros y analistas de sistemas es de mucha utilidad contar con expresiones analíticas que describan ciertos fenómenos mediante un número finito de símbolos.

Los algoritmos de aprendizaje basados en Programación Genética Multiobjetivo (MOGP, del inglés, Multi-Objective Genetic Programming) reportados en la literatura, en su inmensa mayoría, usan funciones de adaptabilidad escalares transformadas en enfoque multicriterio añadiendo objetivos relacionados con la precisión y la simplicidad de las expresiones a aprender [72, 73]. La principal motivación que ha sustentado estos estudios ha sido el desarrollo de mecanismos para evitar la inflación excesiva de los árboles, lo que se conoce como técnicas anti-inflación.

Es un verdadero reto en el aprendizaje basado en MOGP, de manera general, la correcta gestión de los genotipos para guiar las búsquedas hacia fenotipos factibles en el espacio objetivo [206]. En este sentido, los Algoritmos de Programación Genética basada en Gramáticas ofrecen varias

ventajas debido a su modularidad para representar restricciones complejas en diferentes dominios de aplicación [207–209]. Estos algoritmos basados en gramáticas también son conocidos en la literatura como algoritmos de Evolución Gramatical (GE, del inglés, Grammatical Evolution).

La Evolución Gramatical cuenta con un mecanismo de presión evolutiva para guiar el proceso de aprendizaje, aunque ésta no está exenta de críticas. Uno de las principales críticas que recibe la GE es el carácter destructivo de sus operadores de cruzamiento. Es por ello que varios estudios están enfocados en la definición de nuevos operadores genéticos, los cuales mediante pequeños cambios en el genotipo de un individuo disminuyan la probabilidad de realizar grandes cambios en el fenotipo [206, 210–212].

En la literatura consultada sobre aplicaciones exitosas de la Evolución Gramatical resalta su utilización para aumentar la interpretabilidad de sistemas basados en reglas lingüísticas [213–215]. Sin embargo, en el campo de la Evolución Gramatical multiobjetivo (y en la MOGP en general) se identifica una falta de profundidad en los estudios realizados.

A continuación se expone una revisión crítica de los trabajos existentes agrupados en dos partes. Primero, algoritmos de aprendizaje multicriterio como técnicas de control anti-inflación. Segundo, estudios relacionados con nuevas relaciones de dominación. En esta revisión se presta especial atención al tratamiento de soluciones resistentes a la dominación.

3.4.1.1. MOGP y GE para reducir complejidad y la inflación

Los trabajos en MOGP, generalmente, han resuelto problemas uni-objetivo añadiéndole otras metas a cumplir para evitar la inflación de los árboles, se pueden consultar en [69, 83, 216–218]. En estos estudios las medidas de complejidad se añaden como criterios al proceso evolutivo y, de esta forma, guiar la búsqueda a soluciones precisas donde las expresiones aprendidas sean lo más simples posible.

Estas medidas de complejidad tienen una importancia vital cuando los modelos a aprender requieren ser completamente interpretables. En este sentido, Vladislavlevas [216] estudia el orden de no-linearidad como medida de complejidad añadida al proceso de aprendizaje. En este estudio se experimenta con dos estrategias basadas en Pareto en la etapa de selección de la supervivencia. De esta forma, el estudio hace un balance entre la exploración e intensificación en el espacio objetivo en problemas de regresión simbólica. Como resultado se obtienen expresiones de fácil comprensión y basadas en árboles compactos.

Siguiendo con este enfoque del uso de medidas de complejidad en MOGP, otros autores proponen aprender los modelos en dos etapas para que estos sean más precisos y con expresiones más simples. Giri [83] define un proceso de aprendizaje en dos etapas con aplicación en un problema químico de separación cromatográfica. La primera etapa minimiza el error de entrenamiento a

través de la optimización con función escalar. La segunda etapa continúa con el aprendizaje del modelo buscando un equilibrio entre complejidad y exactitud del mismo para limitar la inflación.

Howard y D'Angelo [219] propusieron en la década de los noventa el algoritmo GaP, híbrido entre un Algoritmo Genético y la Programación Genética. Se resalta la capacidad de este algoritmo como una poderosa herramienta para el modelado donde es importante aprender tanto expresiones interpretables como cadenas de parámetros. El algoritmo GaP se ha extendido a problemas de aprendizaje multicriterio [220].

Por su parte Ni [217] estudia los operadores de mutación específicos de la PG para un grupo de problemas de regresión simbólica. El trabajo diseña una experimentación evaluando la efectividad de los operadores en problemas mono-criterio y multi-criterio. Usa una estrategia generacional ($\mu + \lambda$) para la etapa de selección de sobrevivientes en el 50 % de las iteraciones y para el resto una estrategia de etapa constante ($\mu = \lambda$). Los objetivos del problema estudiado fueron:

1. El error cuadrático medio del conjunto de entrenamiento.
2. El número total de nodos en el árbol.

El mismo autor Ni, en un trabajo posterior, propone el uso de la regularización de Tikhonov sumado al conteo del número de nodos como medida de complejidad. Este último estudio concluye que la inclusión de esta medida de complejidad mejora el error medio en una selección de funciones [218].

También explotando el esquema de etapa constante ($\mu = \lambda$), Nag propone ASMiGP [69] (ASMiGP, del inglés, Archive Based steady stage micro PG). La inicialización de individuos en este estudio comprende el ordenamiento en niveles de no-dominación de la población, perdurando para el proceso evolutivo solo los pertenecientes al primer nivel. Adicionalmente, en este estudio se etiquetan los individuos como “masculinos” y “femeninos” y posteriormente el operador de cruzamiento tiene una orientación heterosexual favoreciendo la creación de los hijos cercanos a la “madre”. Entendiendo que los individuos “femeninos” indican soluciones cercanas al FP. El proceso de selección de sobrevivientes también incluye dos etapas donde la dominación tiene mayor importancia que la diversificación. Otro elemento distintivo en este proceso es el uso de una estrategia de truncamiento de archivos. La experimentación tiene lugar en un problema de clasificación con tres objetivos:

1. Número de falsos positivos.
2. Número de falsos negativos.
3. Número de nodos hojas en el árbol.

Cercano al enfoque del trabajo anterior, los algoritmos de MOGP han sido usados para tareas de identificación de sistemas [205]. La aplicación específica de este estudio es la identificación automatizada de modelos de turbinas de viento. Igualmente, la precisión del modelo solamente está presente en el primer objetivo, el resto de los criterios fueron reservados para guiar el proceso evolutivo a soluciones compactas. Este estudio incluye una codificación especial del cromosoma con una condición booleana en el genotipo (codificación epigenética), la cual permite activar los genes que han sido seleccionados para un proceso de búsqueda local implícita. Dicho proceso se realiza con el algoritmo Escalador de Montañas para obtener buenos resultados y reducir la complejidad. El problema de regresión simbólica multiobjetivo de este trabajo contiene tres objetivos:

1. Medida de precisión.
2. Complejidad del modelo.
3. Antigüedad del programa.

Este último se utiliza para prevenir convergencia prematura. El mecanismo para la selección de sobrevivientes usado en el estudio fue SPEA2.

Finalmente se resalta que la Programación Genética Multiobjetivo basada en Gramática no requiere de un tratamiento especial de manera independiente a lo expuesto en la presente sección. Comparte los mismos pros y contras de la MOGP, siendo pocos los estudios en este campo [221, 222]. Como sucede también con la combinación del enfoque hiper-heurístico y la Evolución Gramatical Multiobjetivo [223].

3.4.1.2. Control evolutivo: dominación y elitismo

La idea del taylorismo ha sido aplicada en estudios con operadores para la MOGP en varios tipos de problemas. Bhowan hace una incursión en MOGP de las estrategias para la selección de supervivientes propuestas en los algoritmos SPEA2 y NSGA-II [224]. La aplicación de este estudio es un problema peculiar de clasificación con datos desequilibrados, donde se aplican diferentes meta-clasificadores. El método de inicialización de soluciones y de mutación conocido como "método de rampa de mitad y mitad" se aplica en esta implementación. El algoritmo resultante utiliza un enfoque generacional ($\mu + \lambda$). El trabajo de Bhowan concluye en primer lugar que en el problema de aplicación estudiado, SPEA2 obtiene mejores resultados que NSGA-II. Segundo, advierte de la importancia de encontrar estrategias correctas de evaluación de la función de adaptabilidad en los MOGP.

Continuando con estudios enfocados en MOGP para problemas de clasificación que implementan operadores especializados se resalta el publicado en [225]. Se propone un algoritmo de

aprendizaje basado en programación multi-expresión aplicado a un problema multicriterio de clasificación de cáncer de mama. Igualmente, esta propuesta busca un equilibrio entre precisión de las soluciones y simplicidad. Por otro lado, diferentes enfoques de MOGPs se evidencian en problemas como la obtención de medidas de similitud en juegos de datos de entrenamiento [226] y la resolución de problemas de agente de fútbol [227]. En el campo de la transformación de rasgos para incrementar la precisión de clasificadores basados en PG encontramos la propuesta de Hiroyasu [228].

Uno de los esfuerzos más completos para la evaluación de diferentes MOPGs en problemas de clasificación ha sido realizado por Wang [229]. El problema abordado es conocido en la literatura como problema de gestión de las características de funcionamiento del receptor (ROC; the Receiver Operating Characteristic). La lista de mecanismos para la selección de sobrevivientes utilizada incluye el algoritmo MOEA/D además de los conocidos SPEA2 y NSGA-II. Este estudio resalta que los operadores clásicos de mutación basados en árboles de PG resultan muy disruptivos en el problema estudiado. Es por ello que se propone un esquema de apareamiento basado en operadores específico para el problema. En este trabajo se concluye que el mecanismo de selección de sobrevivientes propuesto en NSGA-II es el que mejores resultados devuelve.

En los estudios relacionados con los algoritmos de MOGPs aplicados a problemas de clasificación los resultados son similares. Tsakonas estudia los mecanismos de promoción de diversidad para MOGP basados en gramática para problemas de regresión simbólica [25]. La principal idea del estudio fue la utilización de diferentes fases de entrenamiento de manera independiente con una etapa inicial de búsqueda local en común para todas las fases. Las combinaciones se llevan a cabo usando un enfoque multicriterio donde los objetivos a minimizar son:

1. La precisión mediante el error de mínimos cuadrados.
2. La media de los coeficientes de correlación residual.

En un estudio similar, Rezaee [71] minimiza dos objetivos en un problema de optimización de circuitos electrónicos con múltiples salidas. Los objetivos a minimizar de este trabajo fueron:

1. En número de compuertas lógicas para una determinada tabla veritativa.
2. El tiempo de retardo del circuito.

Finalmente, Olague realiza una síntesis automática de operadores para el análisis de imágenes [70]. El estudio de Olague tiene un enfoque multicriterio con tres objetivos:

1. Estabilidad.

2. Dispersión de puntos.
3. Alto contenido de información.

La estrategia de selección de sobrevivientes con la que se experimentó fue SPEA2, obteniendo buenos resultados.

Por último, se observa en la literatura que han emergido nuevos enfoques para la selección automatizada de elementos heurísticos para el control evolutivo. El nuevo enfoque se conoce como hiper-heurístico (HH) y es definido por Burke como "heurísticas para seleccionar heurísticas"[230]. HH opera en un espacio de búsqueda de heurísticas por encima del espacio de búsqueda del dominio del problema subyacente. Nguyen [231] ha aplicado este enfoque HH en un problema dinámico multicriterio de planificación de actividades industriales cooperando con un algoritmo de PG. Tres son las heurísticas de bajo nivel que se evalúan en el estudio:

- SPEA2.
- NSGA-II.
- MOEA basado en distancias armónicas.

El estudio de Nguyen propone dos nuevos modelos como resultado del aprendizaje: el método de PG multiobjetivo con hiperheurística (MO-GPHH; Multi-Objective Genetic Programming with hyper-heuristics) y la Evolución cooperativa multiobjetivo diversificada (DMOCC; Diversified Multi-Objective Cooperative Evolution). La principal conclusión expuesta por Nguyen es la habilidad de los algoritmos basados en PG para el modelado de conocimiento en dominios complejos de aplicación mediante programas o reglas de fácil comprensión.

3.5. Aportación al aprendizaje basado en Programación Genética Multiobjetivo: Algoritmo Grab-MO-GaP

La presente sección propone extensiones a los Algoritmos Multiobjetivo de Programación Genética. La propuesta surge de la necesidad de algoritmos eficaces para aprender el modelo SMF 2. Aprender el modelo consiste en resolver el problema de optimización multicriterio descrito anteriormente. La particularidad de este proceso de aprendizaje está dada por la necesidad de obtener indirectamente elementos inteligentes de fácil comprensión para los seres humanos (expresiones analíticas).

Las extensiones propuestas enfatizan en el aprendizaje indirecto de variables latentes mediante la Programación Genética basada en gramática. El uso de gramáticas interviene como mecanismo de presión evolutivo en el proceso de aprendizaje, y saca partido de la co-monotonía entre las salidas del modelo y la variable latente a aprender de manera interpretable. Adicionalmente, las extensiones propuestas están diseñadas para hacer frente al elevado número de soluciones resistentes a la dominación que se generan en determinados procesos evolutivos [115].

El algoritmo propuesto introduce modernos mecanismos en la etapa de selección de la supervivencia. Incluye mecanismos que han sido propuestos para promover la diversidad en las soluciones para problemas de muchos objetivos. Estos mecanismos no han sido estudiados en algoritmos de aprendizaje basados en Programación Genética Multiobjetivo. Concretamente, se propone utilizar un conjunto de puntos de referencia bien distribuidos en el espacio objetivo, además del enfoque de intersección de límites y nuevas relaciones de dominación. Estos mecanismos han sido introducidos en los algoritmos genéticos NSGA-III [34] y θ -DEA [2].

El algoritmo de aprendizaje propuesto es conocido como Grab-MO-GaP (del inglés, Grammar-Based Multi-Objective Genetic Algorithm-Programming). El nombre del algoritmos es un juego de palabras y abreviaturas que en inglés significa: “*agarrar la brecha de los multiobjetivos*”. En la Figura 3.21 se puede apreciar un ejemplo de la codificación del cromosoma para la propuesta. Observe que el cromosoma cuenta con dos segmentos, segmento cadena (valores reales: a,b,c,d,n,m,z) y el segmento basado en árbol.




FIGURA 3.21: Ejemplo de la codificación del cromosoma para Grab-MO-GaP.

La definición de la gramática para guiar el proceso de aprendizaje es una etapa importante en la implementación de la propuesta. Debe garantizar la correcta gestión de los genotipos en el proceso evolutivo conduciendo la búsqueda hacia fenotipos factibles en el espacio objetivo, lo que se traduce en expresiones algebraicas válidas. En el proceso de aprendizaje indirecto del algoritmo propuesto se utiliza la gramática como mecanismo para explotar la co-monotonía entre las salidas observables y las variables latentes a aprender.

El Algoritmo 2 detalla la propuesta de Grab-MO-GaP. La lista de parámetros de entrada está compuesta por:

1. El problema Pr , en el cual es evaluado cada individuo.
2. Un algoritmo evolutivo multiobjetivo MOEA, así como su lista de parámetros asociados $MOEA_{\theta} = \{\theta_1, \theta_2, \dots, \theta_p\}$.
3. El número máximo de generaciones g para el algoritmo.
4. Los operadores de apareamiento. Donde el operador de cruzamiento y de mutación hacen uso de dos probabilidades cada uno, una para el segmento basado en árboles y otra para el segmento de la cadena de parámetros. Las probabilidades son identificadas como p_{hlx} ; p_{llx} para el operador de cruzamiento y p_{hlm} ; p_{llm} para la mutación.
5. Un operador de búsqueda local (LS), que se aplica durante ils iteraciones.

Algorithm 2: Grab-MO-GaP

Input: Pr ; MOEA; $MOEA_{\theta}$; g ; p_{hlx} ; p_{llx} ; p_{hlm} ; p_{llm} ; LS ; ils

```

1 pop ← Inicializar_Población()
2 Inicializar_Puntos_de_Referencia()
3 Evaluar_Población()
4 for  $i \leftarrow 0$  hasta  $g$  do
5   MOEA.Procedimiento_Pre_Apareamiento()
6   MOEA.Selección_Padres()
7   GaP.Cruzamiento(  $hlp$ ,  $llp$  )
8   GaP.Mutación(  $hlp$ ,  $llp$  )
9   Evaluar_Individuos_Generados()
10  for  $j \leftarrow 0$  to  $ils$  do
11    Búsqueda_Local()
12  MOEA.Selección_Sobrevivientes()
  
```

Seguidamente se detallan las distintas etapas del algoritmo propuesto:

- **Etapas de Inicialización:** Se generan los individuos que forman parte de la población inicial. El segmento de los cromosomas basado en árboles se genera aleatoriamente usando

el método de rampa de mitad y mitad. El tamaño de los árboles no excederá el parámetro de profundidad máxima. El segmento de números reales se inicializa seleccionando valores aleatorios de una Distribución Uniforme entre los límites lb y ub .

Adicionalmente, en esta etapa se inicializan los elementos necesarios para la ejecución de los MOEAs. Por ejemplo, en el caso particular del algoritmo θ -DEA, su lista de parámetros $MOEA_{\theta}$ contiene los valores $\{H_1, H_2\}$, los cuales representan las divisiones entre los límites y entre las capas internas, respectivamente. A partir de estos valores se generan tres conjuntos: los puntos de referencia, el conjunto de límites superior z^{nadir} y el conjunto de soluciones ideales z^* . Como resultado de los hiperplanos lineales generados se ubican los puntos de referencia en el espacio de soluciones factibles.

- **Pre-Apareamiento:** Este procedimiento asegura que en cada generación del algoritmo propuesto se recalculen algunos valores necesarios para aplicar los operadores de cruzamiento, mutación y para la etapa de selección de la supervivencia. Continuando con el ejemplo anterior (para el caso de θ -DEA), el procedimiento requiere la actualización del conjunto de soluciones ideales y la aplicación de un operador de agrupamiento de los individuos.
- **Cruzamiento:** Mediante una estrategia de selección por torneo en una sub-población de siete individuos escogidos aleatoriamente se obtienen dos padres para el cruzamiento. El operador de cruzamiento en Grab-MO-GaP se divide en tres etapas.
 - Primero, se cruzan los segmentos de los individuos que representan las cadenas de valores reales. Concretamente, se aplica el operador de Cruzamiento Binario Simulado (SBX) con un índice de distribución amplio y con probabilidad p_{hlx} .
 - Segundo, el operador de cruzamiento para el segmento basado en árboles se aplica con una probabilidad independiente, p_{ulx} . Este operador tiene su peculiaridad por estar sustentado sobre la Programación Genética basada en gramática. La implementación del cruzamiento respetando la gramática se realiza de la siguiente forma: cada individuo tiene asociado un vector de valores enteros con longitud arbitraria. El cruzamiento de los vectores de enteros se realiza mediante los operadores clásicos de cruzamiento en uno, dos o n-puntos (en Grab-MO-GaP se utilizan dos puntos). Seguidamente, para seleccionar la alternativa de cada regla gramatical se selecciona un entero al azar y éste se divide entre el número de cláusulas de la regla; el resto de la división indica la cláusula que se escoge para la conformación de individuos hijos. Luego es sencillo el proceso de obtención del árbol equivalente respetando las reglas escogidas dentro de la gramática definida.
 - Tercero, se aplica el operador de búsqueda local. Éste es vital para garantizar que en el operador de cruzamiento global genere hijos los más cercanos a los padres posible. El operador de búsqueda local optimiza única y exclusivamente los valores

numéricos comprendidos en el segmento de valores reales que apuntan a determinados nodos dentro del segmento con representación de árbol.

- **Mutación:** El operador de mutación tiene un esquema independiente para cada segmento del cromosoma con diferentes probabilidades, p_{hlm} y p_{lum} . En la cadena de valores reales se implementa una mutación polinómica con un índice de distribución amplio [232]. La mutación de la parte basada en árbol se realiza cambiando una regla seleccionada aleatoriamente basándose en la gramática predefinida.
- **Selección de la Supervivencia:** El algoritmo propuesto Grab-MO-GaP hace uso de diferentes estrategias de selección de los individuos que sobreviven en una generación determinada. Las estrategias comprenden diferentes técnicas de promoción de diversidad, evitando así la generación de individuos con buen ajuste en uno de los objetivos, pero con pésimos resultados en el resto. Se incluyen en la propuesta enfoques pensados para problemas de aprendizajes multicriterio y otros diseñados para problemas de muchos-objetivos. Concretamente, el algoritmo propuesto hace uso de los mecanismos de dominación basados en Frentes de Pareto que se proponen en los algoritmos SPEA2 [27], NSGA-II [26], NSGA-3 [34], MOEA/D [43] y θ DEA [2].

Como resultado de las extensiones propuestas en el algoritmo se tienen cinco variantes que se diferencian en las estrategias utilizadas en la selección de sobrevivientes. Se identifican como:

1. Grab-MO-GaP-SPEA2.
2. Grab-MO-GaP-NSGAI.
3. Grab-MO-GaP-NSGA-3.
4. Grab-MO-GaP-MOEA/D.
5. Grab-MO-GaP- θ DEA.

En la próximo capítulo se realizará un estudio empírico de estas variantes del algoritmo propuesto para el aprendizaje del modelos SMF 2, el estudio responde las siguientes interrogantes: ¿Es posible aprender indirectamente expresiones analíticas que describan el potencial del electrodo negativo mediante el Modelo SMF 2? ¿Qué estrategia en la etapa de selección de la supervivencia obtiene mejores resultados dentro de las variantes del algoritmo Grab-MO-GaP?

3.6. Conclusiones parciales

Las propuestas desarrolladas en el presente capítulo conducen a una serie de conclusiones parciales:

- Se presenta una segunda generación de modelos semi-físicos para baterías de Iones de Litio. El primer modelo semi-físico presentado en este capítulo facilita el aprendizaje indirecto de variables latentes con el uso de bloques inteligentes basados en FRBSs. Específicamente, permite la estimación del estado de carga mediante la relación $SoC = f(OCV)$.
- La incorporación de un tercer objetivo para la estimación del Estado de Salud en el proceso de aprendizaje de modelo SMF 1 aumenta sustancialmente la complejidad. La evaluación de los principales algoritmos evolutivos multiobjetivo permite corroborar la existencia de un elevado número de individuos resistentes a la dominación. Este elemento hace que se experimente además con algoritmos que implementan modernos mecanismos de promoción de la diversidad. Estos algoritmos fueron originalmente diseñados para problemas de muchos objetivos.
- Se ha propuesto la inyección de conocimiento mediante preferencias parciales como mecanismo de presión evolutiva en el proceso de aprendizaje del modelo SMF 1. El algoritmo propuesto se le ha llamado θ -FPO. Está enfocado en combatir la generación de individuos resistentes a la dominación, en reducir el número de generaciones necesarias para el aprendizaje y de esta forma permitir su uso en la estimación del SoH en los BMSs de los vehículos eléctricos.
- Ha sido propuesto un segundo modelo semi-físico que simplifica la estimación del Estado de Salud en baterías de Iones de Litio con regímenes de carga y descarga a corrientes moderadas. El modelo está basado en el conocimiento parcial del potencial de los electrodos y el efecto de la degradación sobre estos. El modelo SMF 2 requiere de algoritmos de aprendizaje basado en Programación Genética Multiobjetivo para estimar de manera indirecta expresiones que permitan identificar los cambios que ocurren en el electrodo negativo.
- Tras una exhaustiva revisión de los algoritmos existentes para el aprendizaje basado en programación genética multiobjetivo y la identificación de carencias en esta área, se ha propuesto extensiones que enfatizan en el aprendizaje indirecto de variables latentes mediante la Programación Genética Multiobjetivo basada en gramática. El uso de gramáticas interviene como mecanismo de presión evolutivo en el proceso de aprendizaje y explota la co-monotonía entre las salidas del modelo y la variable latente a aprender. Se obtienen expresiones analíticas de fácil comprensión por los seres humanos.

Capítulo 4

Evaluación de las propuestas

El presente capítulo explica los protocolos de carga y descarga de baterías elaborados para recolectar los juegos de datos que son utilizados en la experimentación. Se detallan las características de las celdas de LiFePO_4 ensayadas, así como el equipamiento utilizado en el laboratorio de baterías de la Universidad de Oviedo. Seguidamente se discute sobre las diferentes metodologías e indicadores de comparación de algoritmos de aprendizaje multiobjetivo. Se selecciona para la evaluación de las propuestas la conformación del Super Frente de Pareto complementado con el Indicador Binario Aditivo de Epsilon.

La experimentación y discusión de los resultados comienza mostrando la evaluación numérica pendiente del caso de estudio número 1. Seguidamente se presenta el estudio empírico para la evaluación del algoritmo propuesto θ -FPO. El análisis de los resultados obtenidos en este estudio presenta evidencias gráficas y numéricas de la superioridad del uso de preferencias parciales para el aprendizaje del modelo SMF 1. Finalmente se presenta el estudio empírico de las extensiones propuestas a los algoritmos de aprendizaje basados en Programación Genética Multiobjetivo.

4.1. Juegos de datos para la experimentación

Los juegos de datos para la experimentación a lo largo del presente trabajo son de fuente propia. Estos datos se han utilizado en los trabajos que forman parte de la producción científica de la presente tesis. Los juegos de datos han sido publicados en [233] para su difusión entre la comunidad científica internacional.

En el Aprendizaje Automático existen importantes bases de datos que sirven a los investigadores para comparar sus resultados de experimentación. Una de las más conocidas es el Repositorio de Aprendizaje Automático de la Universidad de Irvine, California (UCI Machine Learning Repository ¹). Este repositorio no cuenta con juegos de datos relacionados con protocolos de carga y descarga de baterías de Iones de Litio u otras tecnologías. En repositorios similares dedicados al Aprendizaje Automático tampoco se tiene conocimiento de juegos de datos relacionados con baterías.

La elaboración de los juegos de datos se ha llevado a cabo en el laboratorio de baterías de la Universidad de Oviedo, en el que se han ensayado dos celdas de tecnología LiFePO_4 del fabricante European Batteries (ver Figura 4.1).



FIGURA 4.1: Celda de LiFePO_4 de European Batteries ensayada para el presente estudio.

¹<http://mlr.cs.umass.edu/ml/>

	Celda #1	Celda #2
Capacidad	45.47 Ah	46.95
Peso	1010 g	1008 g
Energía consumida en carga a C/25	150.90 Wh	155.86 Wh
Eficiencia media en carga/descarga a C/25	99.59 %	99.59 %

TABLA 4.1: Características de las celdas ensayadas

La hoja de características que brinda el fabricante indica que la capacidad nominal de las celdas es de 42 Ah (a C/5 y 22°C) y la tensión nominal de funcionamiento es de 3.2 V. Además, la tensión de corte en carga y descarga es de 3.65 V y 2.0 V respectivamente. Las dimensiones de las celdas son: alto 275 mm, largo 166.5 mm y ancho 13.3 mm. La Tabla 4.1 complementa la información de las características de las celdas #1 y #2.

La Figura 4.2 muestra las curvas de tensión proporcionadas por el fabricante a diferentes índices de descarga en condiciones de temperatura de 22°C. La Figura 4.3 por su parte, muestra la pérdida de capacidad de una celda prototipo sometida a protocolos continuos de carga y descarga en condiciones ideales. Estos protocolos consistieron en ciclos de carga y descarga a corriente constante con índice a C/2 ($\approx 20A$) y una profundidad de descarga del 100 %.




FIGURA 4.2: Curvas a diferentes regímenes de descarga de las celdas de 42 Ah proporcionadas por European Batteries.

El núcleo del equipamiento especializado del laboratorio de baterías es el Sistema de Pruebas de Baterías SBT 10050 de la marca PEC. También, se cuenta con una cámara térmica de la marca Memmert, concretamente el modelo ICP 750 (ver Figura 4.4).




FIGURA 4.3: Envejecimiento de las celdas ensayadas de European Batteries en condiciones ideales.



FIGURA 4.4: Equipamiento del Laboratorio de Baterías de la Universidad de Oviedo.

En una etapa inicial de las pruebas de laboratorio todo el equipamiento fue calibrado mediante los mecanismos recomendados por los fabricantes. De esta forma se garantiza la fiabilidad de las muestras a tomar en los ensayos para la elaboración de los juegos de datos.

Los primeros ciclos de carga y descarga de las celdas siguieron las normas de acondicionamiento propuestas por el USABC (de inglés, United States Advanced Battery Council) [143]. Estas normas, establecen que es necesario realizar tres ciclos de descarga a corriente constante a regímenes, $C/3$, $C/2$ y C . En todos estos ciclos el protocolo de carga utilizado debe ser el recomendado por el fabricante. En el caso de las celdas ensayadas, la carga recomendada consiste

en aplicar corriente constante a $C/2$ (21A) hasta alcanzar la tensión de corte (3.65 V). Seguidamente se pasa a una etapa de carga a tensión constante hasta que la corriente decrece a $C/25$. Una vez finalizado este proceso de acondicionamiento se considera que las celdas son estables si su capacidad no disminuye por encima del 2 % en tres ciclos consecutivos de carga estándar y descarga a $C/3$. Este proceso fue corroborado al finalizar el acondicionamiento de las celdas utilizadas.

En este punto se cargaron y descargaron la celdas a razón de $C/25$ para así obtener los datos de referencia para la capacidad de las celdas. Posteriormente, mediante el protocolo propuesto por Abu-Sharkh se determinan los puntos de la tensión de circuito abierto cada 10 % del SoC. En el caso particular de las celdas utilizadas, los pasos durante la carga y la descarga fueron de 4460 mAh. En la Figura 4.5 se muestra los puntos obtenidos para cada una de las celdas.




FIGURA 4.5: Ensayo de relajación cada 10 % del SoC propuesto por [12] para la celda #1 (Rojo) y celda #2 (Azul).

Finalmente, una serie de ensayos con carga estándar y descargas a corriente constante $C/3$, $C/2$ y C (14A, 21A y 42A) completan los juegos de datos para la experimentación. En esta etapa se hace un muestreo a 2Hz de las variables corriente, tensión, temperatura de la batería y temperatura de la cámara (considerada la temperatura ambiente). La Figura 4.6 muestra los tres juegos de datos que se identifican como: DS- $C/3$, DS- $C/2$ y DS- C . En la columna derecha de la Figura 4.6 se muestra las respectivas curvas ICAs obtenidas en los segmentos de descargas.

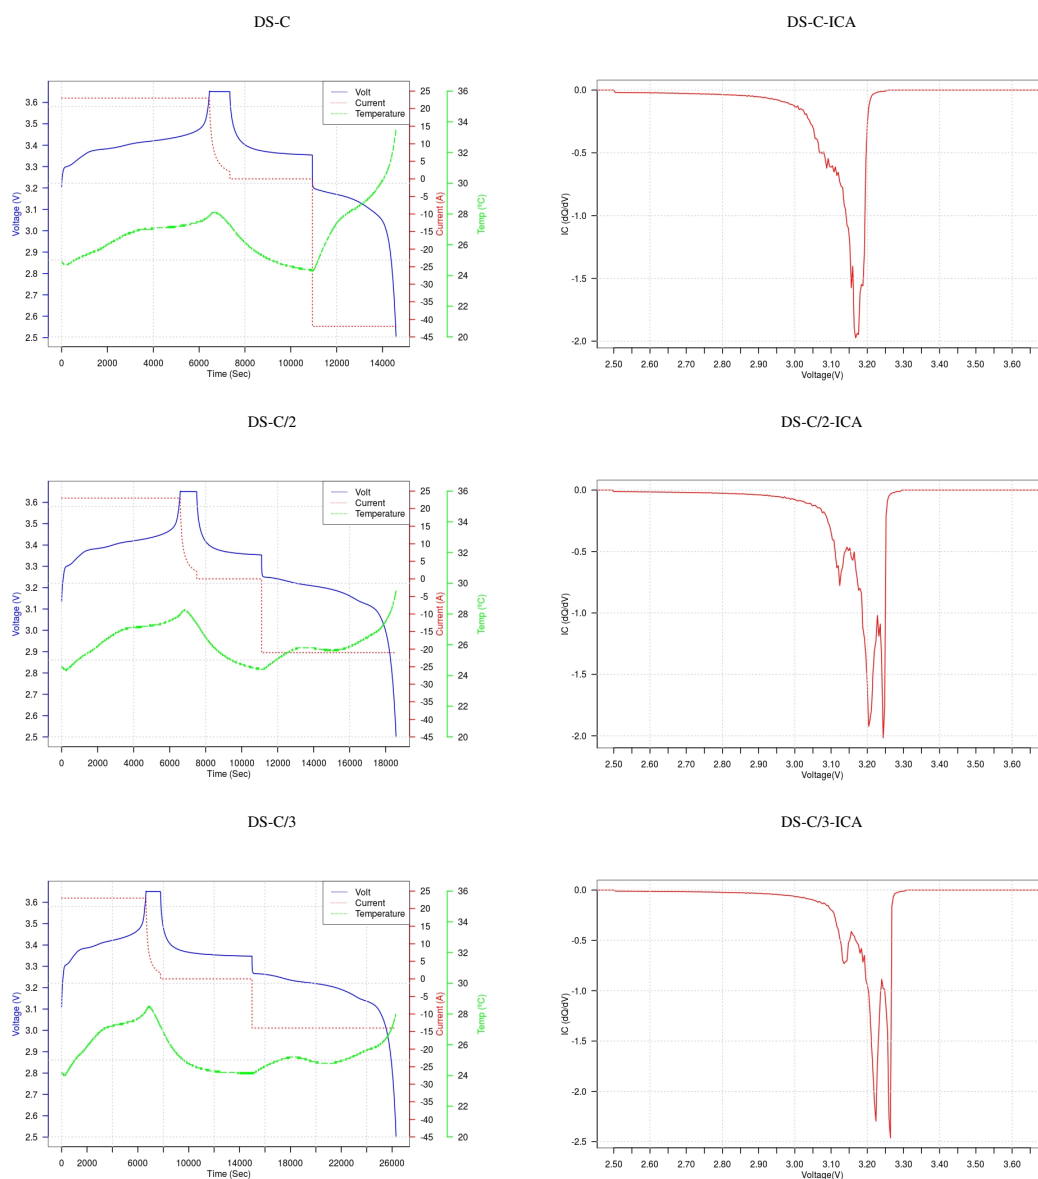


FIGURA 4.6: Resumen de los juegos de datos para la experimentación elaborados en el Laboratorio de Baterías.

4.2. Selección de medidas de comparación en MOEAs

En la presente sección se hace un revisión de las medidas de comparación de los algoritmos de aprendizajes basados en computación evolutiva multiobjetivo. En general, se puede lograr un análisis teórico comparativo de los Frentes de Pareto resultantes de los procesos evolutivos. Sin embargo, dependiendo del indicador seleccionado se hacen simplificaciones que reducen en cierta medida la utilidad de los resultados. La evaluación de los algoritmos de aprendizaje multiobjetivo requiere de varias ejecuciones de cada uno de ellos y su posterior análisis.

En la literatura consultada se aprecian varios enfoques de estudios comparativos basados en medidas. Los enfoques más destacados están relacionados con los conceptos siguientes:

- **Función de logro:** las evaluaciones basadas en este enfoque requieren la recolección de datos estadísticos en cada generación de los MOEAs. Además se requiere conocer el Frente de Pareto óptimo de cada problema. Su principal característica es la presentación gráfica de la efectividad del proceso de búsqueda. La función de logro generalmente no es evaluada para un indicador de calidad específico porque esto conllevaría un consumo elevado de memoria.

La Figura 4.7 muestra los contornos de la función de logro obtenida para varias ejecuciones independientes de un MOEAs aplicados a un problema de control bi-objetivo. La intensidad del sombreado corresponde a la magnitud de las diferencias entre las ejecuciones.




FIGURA 4.7: Ejemplo de función de logro (Fuente [13]).

- Relaciones de dominación: los estudios comparativos basados en las relaciones de dominación entre pares de FPs son muy frecuentes. Igualmente es necesario conocer el FP óptimo como referencia para las comparaciones y el posterior ordenamiento de los MOEAs en un problema determinado. Estadísticamente, la prueba de suma de clasificación de Wilcoxon (o prueba de Mann-Whitney) es la más utilizada para la comparación de dos MOEAs mediante este enfoque. Cuando los estudios comparativos comprenden más de dos MOEAs la alternativa estadística es la prueba de clasificación de Kruskal-Wallis.

Como el concepto de *no-dominación* es una de las relaciones más destacadas de este enfoque, la Tabla 4.2 extiende la definición que se presentó en el capítulo anterior. La tabla presenta los símbolos para identificar los tipos de relaciones que serán utilizados a lo largo del presente capítulo.

Relación	Símbolo	Concepto
Dominación estricta	$A \succ\prec B$	toda solución $b \in B$ es dominada estrictamente por al menos una solución $a \in A$
Dominación	$A \succ B$	toda solución $b \in B$ es dominada por al menos una solución $a \in A$
Mejor	$A \triangleright B$ ó $B \triangleleft A$	toda solución $b \in B$ es dominada débilmente por al menos una solución $a \in A$ y $A \neq B$
Incomparable	$A \parallel B$	Incomparables, ni A domina débilmente a B, ni B domina débilmente a A
Indiferente	$A \sim B$	A domina débilmente a B y a la vez, B domina débilmente a A

TABLA 4.2: Relaciones de dominación.

La Figura 4.8 muestra gráficamente la existencia de superposición entre las relaciones de dominación que se han explicado en la tabla.

- Indicadores de calidad: este enfoque es el más extendido en la literatura consultada para la comparación de MOEAs. Incluso es un área de investigación activa el desarrollo de algoritmos de aprendizaje basados en indicadores. Estos permiten incorporar preferencias en el proceso evolutivo.

Estos indicadores o métricas de calidad requieren de definiciones muy precisas para cada uno de ellos. Se pueden dividir en dos grandes grupos: indicadores unitarios e indicadores binarios.

Los indicadores unitarios son muy utilizados para la comparación de algoritmos sobre juegos de datos de funciones reales. Entre los grupos de funciones que se han convertido en un estándar *de facto* en esta área de investigación se encuentran las conocidas como




FIGURA 4.8: Superposición entre las relaciones de dominación.

Indicador unario

Distancia Generacional

Distancia Generacional Invertida

Hiper-área

Espaciado

Hiper-volumen

Generación de vectores globales no-denominados

Máximo error en el Frente de Pareto.

TABLA 4.3: Resumen de Indicadores Unarios de Calidad para la evaluación con Frentes de Pareto óptimo conocido.

ZDT y DTLZ. Las siglas se deben a las iniciales de sus autores Zitzler-Deb-Thiele (ZDT) [234]; y por otro lado, Deb-Thiele-Laumanns-Zitzler (DTLZ) [235]. En estos grupos de funciones convexas y no-convexas es conocido el FP óptimo para cada caso.

Dentro de los indicadores unitarios el más utilizado es el indicador de Distancia Generacional Invertida (IGD, del inglés; Inverted Generational Distance). El IGD es una métrica que evidencia la diversidad en un FP y su aproximación al FP óptimo. La Tabla 4.3 resume los principales indicadores unitarios que se encuentran en la literatura [13].

Por otro lado, se recurre a los indicadores binarios fundamentalmente cuando no se conoce el FP óptimo. En la mayoría de los problemas multicriterio asociados al campo de las ingenierías no se conoce el FP óptimo. Por su importancia para el presente trabajo el resto de la sección está dedicada a estos indicadores.

Zitzler [236, 237] hace una revisión de las técnicas cuantitativas para la evaluación de algoritmos multiobjetivo. Como resultado de este estudio se proponen los indicadores binarios:

- Indicador Binario Aditivo de *Epsilon* ϵ ($I_{\epsilon+}$)
- Indicador Binario Multiplicativo de *Epsilon* ($I_{\epsilon*}$)

Estos indicadores expresan geoméricamente el mínimo valor ϵ que se puede sumar (o multiplicar en el caso de I_{ϵ^*}) a cada valor objetivo en un punto b del Frente de Pareto B ($b \in B$) de manera que el valor resultante continúe dominando ligeramente por todos los puntos $a_j \in A$, $j = (1, \dots, m)$.

Concretamente, los I_{ϵ^+} y I_{ϵ^*} se definen en la Ecuación 4.1 y 4.1.

$$I_{\epsilon^+}(A, B) = \inf_{\epsilon \in \mathbb{R}} \{ \forall b \in B \exists a \in A : a \succeq_{\epsilon^+} b \} \quad (4.1)$$

$$I_{\epsilon^*}(A, B) = \inf_{\epsilon \in \mathbb{R}} \{ \forall b \in B \exists a \in A : a \succeq_{\epsilon^*} b \} \quad (4.2)$$

Donde $A, B \in \Omega$. Una vez comprendidas las definiciones de $I_{\epsilon^+}(A, B)$ y $I_{\epsilon^*}(A, B)$ el cálculo se realiza mediante la Ecuaciones 4.3 y 4.4.

$$I_{\epsilon^+}(A, B) = \min_{b \in B} \min_{a \in A} \max_{1 \leq i \leq n} a_i - b_i \quad (4.3)$$

$$I_{\epsilon^*}(A, B) = \min_{b \in B} \min_{a \in A} \max_{1 \leq i \leq n} \frac{a_i}{b_i} \quad (4.4)$$

Para ejemplificar el cálculo de estos indicadores se selecciona el indicador I_{ϵ^*} . El ejemplo consiste en la evaluación de los Frentes de Pareto A_1 , A_2 , A_3 y P que se muestran en la Figura 4.9. Observe que los ejes indican exactamente a que valor corresponde cada una de las soluciones. Así entonces, del cálculo de $I_{\epsilon^*}(A_1, A_2)$ resulta el valor 1; de $I_{\epsilon^*}(A_1, A_3)$ resulta 9/10, etc. La Tabla 4.4 muestra todos los valores calculados según el indicador.




FIGURA 4.9: Frentes de Pareto de ejemplo para el cálculo del indicador I_{ϵ^*} .

B	A			
	A ₁	A ₂	A ₃	P
A ₁	1	2	2	1/2
A ₂	1	1	3/2	3/7
A ₃	9/10	1	1	1/3
P	4	4	6	1

TABLA 4.4: Ejemplo de la aplicación del indicador I_{ϵ^*} .

Finalmente, mediante el análisis realizado en la presente sección se selecciona para los estudios empíricos de los algoritmos propuestos el Indicador Aditivo Binario I_{ϵ^+} . Las relaciones de dominación que se establecen con el uso de este se identifican como:

- Si $I_{\epsilon^+}(A, B) < 0$, A domina estrictamente B ($A \succ\prec B$).
- Si $I_{\epsilon^+}(A, B) \leq 0$ y $I_{\epsilon^+}(B, A) > 0$ entonces evidencia que A supera a B ($A \triangleleft B$).
- Si $I_{\epsilon^+}(A, B) = 0$ y $I_{\epsilon^+}(B, A) = 0$, entonces A y B representan el mismo FP.
- En el caso extremo que ambos indicadores sean positivo los FPs A y B son incomparables entre sí ($A \parallel B$).

La próxima sección establece la metodología para la experimentación que se complementará con el indicador seleccionado.

4.3. Metodología para la evaluación de las propuestas

Una vez discutido los diferentes indicadores para la evaluación de algoritmos de aprendizaje, se establece la metodología para la experimentación que se usará en el presente estudio. Por un lado se tienen los juegos de datos DS-C/3, DS-C/2 y DS-C cuya elaboración fue explicada en las secciones precedentes y, por otro lado, se cuenta con los datos de los ensayos de referencia a C/25 y el ensayo de relajación para cada una de las celdas ensayadas.

La metodología de evaluación consiste en la ejecución de los diferentes algoritmos de aprendizaje un cierto número de veces con cada uno de los juegos de datos. Durante esta serie de ejecuciones, que pueden ser 10 o 20 según el caso, se propone recolectar el *Super Frente de Pareto*. Este peculiar FP agruparía las soluciones no-dominadas de la suma de los FP obtenidos en cada una de las ejecuciones.

La decisión de evaluar los diferentes algoritmos mediante el Super Frente de Pareto no es la única alternativa. Sin embargo, en el presente estudio se considera que la complementación de esta técnica con el indicador binario aditivo ($I_{\epsilon+}$) es la más completa. Indirectamente contiene otros enfoques como la evaluación de las soluciones más representativas de cada objetivo en los Frentes de Pareto, u otros enfoques [237].

4.4. Evaluación del los MOEAs del Caso de Estudio 1

Una vez presentada la metodología escogida para la evaluación de los algoritmos de aprendizaje se realiza la evaluación empírica del primer caso de estudio del capítulo anterior (Sección 3.1.4). En este caso, los algoritmos evolutivos seleccionados para el aprendizaje del modelo SMF 1 se complementan con el método ad hoc utilizado en la primera versión de los modelos semi-físicos.

Los algoritmos evaluados en el caso de estudios 1 se listan a continuación:

- SPEA2 [27].
- NSGA-II [26].
- OMOPSO [104].
- AD HOC [7].

Los resultados obtenidos en el caso de estudio fueron publicados en [238]. La Tabla 4.5 muestra las evaluaciones basadas en el indicador ($I_{\epsilon+}$) para cada par de algoritmos.

		A = SPEA2		A = NSGA-II		A = OMOPSO		A = AD-HOC	
		$I_{\epsilon+}(A, B)$	relation	$I_{\epsilon+}(A, B)$	relation	$I_{\epsilon+}(A, B)$	relation	$I_{\epsilon+}(A, B)$	relation
DS-C	B = SPEA2	0	=	0.0066		0.0052		0.0072	
	B = NSGA-II	-0.0010	<	0	=	5.32E-4		0.0015	
	B = OMOPSO	0.0011		0.0023	<	0	=	0.0020	
	B = AD-HOC	5.368E-4		0.0017		-5.999E-4	<	0	=
DS-C/2	B = SPEA2	0	=	0.0354		0.0347		0.0346	
	B = NSGA-II	-2.151E-4	<	0	=	0.0010		0.0015	
	B = OMOPSO	6.197E-4		8.348E-4		0		8.291E-4	
	B = AD-HOC	-1.831E-4	<	6.925E-4		4.406E-5		0	=
DS-C/3	B = SPEA2	0	=	0.0354		0.0240		0.0357	
	B = NSGA-II	4.366E-4		0	=	6.256E-4		0.0018	
	B = OMOPSO	-8.528E-4	<	0.0115		0	=	0.0116E-4	
	B = AD-HOC	-1.521E-4	<	-1.623E-4	<	-6.184E-5	<	0	=

TABLA 4.5: Evaluación basada en el indicador $I_{\epsilon+}$ de los MOEAs del Caso de Estudio 1.

Observe en la Tabla 4.5 la evaluación de las relaciones de dominación que se presentan en la matriz triangular inferior para cada una de las dimensiones. Estas dimensiones (DS-C/3, DS-C/2 y DS-C) son el conjunto de filas que corresponden los diferentes algoritmos evaluados para cada uno de los juegos de datos. En cada relación de dominación expuesta en la matriz triangular inferior se tiene en cuenta los valores de $I_{\epsilon+}(A, B)$ y $I_{\epsilon+}(B, A)$.

En el caso de la evaluación con el juego de datos DS-C observe que predominan los FPs que son incomparables entre sí mediante el indicador seleccionado. Solamente destaca el algoritmo

NSGA-II por encima de SPEA2. Por otro lado, el algoritmo de aprendizaje ad hoc supera al algoritmo OMOPSO en este juego de datos. Para una mejor comprensión de los resultados se deben visitar los Frentes de Pareto obtenidos en el caso de estudio que fueron mostrados en las Figuras 3.3; 3.4 y 3.5.

En las evaluaciones con el juego de datos DS-C/2 igualmente predominan los FPs incomparables. Solo hay dos casos en los que se tienen claros ganadores, NSGA-II supera a SPEA2 y por otro lado, el algoritmo de aprendizaje ad hoc también supera a SPEA2.

En la dimensión correspondiente al juego de datos DS-C/3 si hay un claro ganador que es el algoritmo ad hoc. Observe que éste supera a cada uno de los algoritmos restantes. Obtiene buenos resultados también el algoritmo OMOPSO superando a SPEA2. En este caso particular, no se repite el mismo patrón de superioridad entre NSGA-II y SPEA2.

Haciendo un análisis conclusivo de los resultados obtenidos en el caso de estudio 1, recordando que solamente se tienen dos objetivos por cumplir, el algoritmo ad hoc propuesto en la primera generación de los modelos semi-físicos sigue siendo competitivo. Ahora bien, con la incorporación de la estimación del estado de salud este algoritmo es impracticable. Esta experimentación ha servido para corroborar la complejidad del proceso de aprendizaje y el elevado tiempo de procesamiento que ocupa la evaluación de la función de adaptabilidad.

4.5. Evaluación de los MOEAs en el aprendizaje del modelo SMF 1

En la presente sección se realiza la experimentación con los algoritmos de aprendizaje más representativos de cada uno de los diferentes enfoques de investigación en la Computación Evolutiva Multiobjetivo. En este caso se debe aprender el modelo SMF 1 con la inclusión de la estimación del estado de salud. Como se explicó en el capítulo anterior, la aproximación de la primera derivada de la salida de tensión del modelo (ICA) aumenta significativamente la complejidad del proceso de aprendizaje. Las características de este particular proceso de aprendizaje presentan un Sistema Genético-Difuso Multiobjetivo que no es estándar. El problema multicriterio de aprendizaje se planteó como:

$$\text{mín } F(x) = (\text{MSE}_{V_B}(x), \text{MSE}_{T_B}(x), \text{MSE}_{ICA}(x))^T$$

En observaciones realizadas del proceso de aprendizaje se ha identificado que este problema tiene puntos en común con problemas de muchos objetivos. Entre los puntos de similitud más destacados está el elevado número de soluciones resistentes a la dominación que aparecen en cada generación de los algoritmos. Muchos son los algoritmos evolutivos para aprender modelos multiobjetivos y de muchos objetivos. La selección de los algoritmos a evaluar en el presente estudio incluye los más populares en la ciencia y la ingeniería. A la vez, se selecciona un algoritmo representativo por cada uno de los enfoques de búsqueda más estudiados en los últimos años para espacio objetivos de grandes dimensiones (descritos en las Sección 2.2).

En este contexto, los algoritmos seleccionados son:

- SPEA2 [27].
- NSGA-II [26].
- OMOPSO [104].
- MOEA/D [43].
- NSGA-III [34].
- θ -DEA [2].

El algoritmo ad hoc utilizado en la experimentación del caso de estudio 1 es impracticable en este problema de aprendizaje. La principal razón es la presencia de tres objetivos en el proceso de aprendizaje. El algoritmo ad hoc no permitiría una correcta exploración del espacio de búsqueda y llevaría a una convergencia prematura hacia un mínimo local.

Los parámetros de cada uno de los algoritmos evaluados han sido ajustados mediante prueba y error en diferentes experimentos precedentes. Los algoritmos comprenden el uso de poblaciones de tamaño similar en todos los casos. Las probabilidades de cruzamiento y mutación han sido las mismas. La Tabla 4.6 resume los parámetros que comparten los diferentes algoritmos evaluados en la experimentación.

Parámetro	Valor
Generaciones	100 000
Tamaño de la población	≈ 60
Probabilidad de cruzamiento	0.9
Probabilidad de mutación	0.01

TABLA 4.6: Resumen de parámetros utilizados en los algoritmos evolutivos seleccionados para el aprendizaje del modelo SMF 1.

El genotipo y fenotipo de la codificación del cromosoma para el aprendizaje del modelo semi-físico 1 se presenta en Figura 4.10.

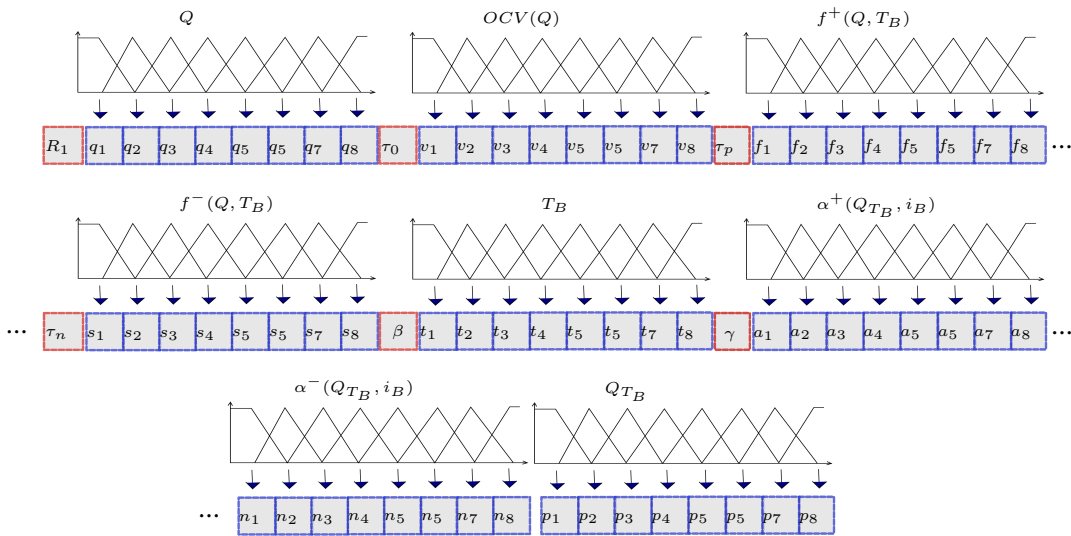


FIGURA 4.10: Codificación del cromosoma para el Sistema Genético-Difuso Multiobjetivo asociado al modelo semi-físico 1.

Para la experimentación se ha seguido la metodología explicada anteriormente. Se ha conformado el Super Frente de Pareto en 20 ejecuciones de cada uno de los algoritmos con cada uno de los tres juegos de datos como entrada (DS-C/3, DS-C/2 y DS-C). La Tabla 4.7 muestra la evaluación basada en el indicador $I_{\varepsilon+}$.

	A = SPEA2	A = NSGA-II	A = OMOPSO	A = NSGA-III	A = MOEA/D	A = θ -DEA
	$I_{e+}(A, B)$	$I_{e+}(A, B)$	$I_{e+}(A, B)$	$I_{e+}(A, B)$	$I_{e+}(A, B)$	$I_{e+}(A, B)$
	relation	relation	relation	relation	relation	relation
DS-C	B = SPEA2	0	0.000532	0.000558	-0.001456	0.001601
	B = NSGA-II	0.006690	0.005207	0.007084	0.004785	0.007207
	B = OMOPSO	0.002396	0	0.002274	-0.000422	0.002000
	B = NSGA-III	0.001583	-0.000259	0	-0.000232	0.003054
	B = MOEA/D	0.003939	0.002679	0.002127	0	0.004127
	B = θ -DEA	-0.001396	-0.000137	-0.001000	-0.001274	-0.002422
DS-C/2	B = SPEA2	0	0.001087	-0.000127	0.001572	0.001570
	B = NSGA-II	0.035407	0.034758	0.034171	0.034715	0.034714
	B = OMOPSO	0.000835	0	0.000581	0.000620	0.000802
	B = NSGA-III	0.002588	0.000041	0	0.003107	0.003289
	B = MOEA/D	0.000691	-4.6E-07	0.000043	0	0.000207
	B = θ -DEA	-0.000693	-0.000182	-0.000044	-0.000117	-0.000001
DS-C/3	B = SPEA2	0	0.000437	0.001225	0.001539	0.001839
	B = NSGA-II	0.035424	0	0.034108	0.034715	0.035714
	B = OMOPSO	0.011514	-0.000085	0	0.010677	0.011676
	B = NSGA-III	0.001444	-0.000301	-0.000216	0	0.000645
	B = MOEA/D	0.000836	-0.000020	0.000065	0	0.000999
	B = θ -DEA	-0.000162	-0.000152	-0.000067	-0.000149	-0.000132

TABLE 4.7: Evaluación basada en el indicador I_{e+} de los MOEAs seleccionados para el aprendizaje del modelo semi-físico 1.

Para el análisis de los resultados numéricos de la evaluación, se debe observar la tabla de resultados teniendo en cuenta cada una de las dimensiones pertenecientes a cada uno de los juegos de datos. Como en el caso de estudio de la sección anterior, la matriz triangular inferior en cada una de las dimensiones muestra la relación de dominación entre los FPs.

En la primera dimensión de la tabla correspondiente a la experimentación con el juego de datos DS-C se pueden resaltar varios aspectos. El desempeño de los MOEAs tienen un comportamiento promedio, el algoritmo NSGA-II supera a SPEA2 en esta dimensión en particular. El algoritmo MOEA/D no obtiene buenos resultados en la evaluación, es superado por SPEA2, OMOPSO, NSGA-III y θ -DEA. Observe que los algoritmos que hacen uso de puntos de referencia en el espacio de búsqueda como estrategia para fomentar la diversidad obtienen buenos resultados en la evaluación. A pesar de los tres objetivos del problema de aprendizaje, el algoritmo NSGA-III supera a NSGA-II en esta primera dimensión. Una mención especial en la evaluación la tiene el algoritmo θ -DEA: éste supera al resto de los algoritmos en la experimentación en esta primera dimensión y también en el resto.

En las dimensiones DS-C/2 y DS-C/3 aumentan los FPs que son incomparables entre sí. Sin embargo, se mantienen varios patrones en las relaciones de dominación con respecto a la dimensión anterior. Igualmente, el algoritmo que mejor desempeño presenta es θ -DEA. En la dimensión DS-C/3 el algoritmo NSGA-II es superado por el resto a excepción de SPEA2. Para un análisis detallado de la tabla de resultados observe que se resaltan en negritas los valores cuando un algoritmo es mejor de otro.

Teniendo en cuenta la experimentación realizada en la presente sección, a continuación se listan un grupo de observaciones extraídas:

- El aprendizaje del modelo semi-físico 1 es un proceso costoso. El tiempo de evaluación de la función de adaptabilidad se ha calculado que es aproximadamente el 90 % de una generación de los MOEAs evaluados.
- En el proceso evolutivo se genera una cantidad elevada de individuos resistentes a la dominación. Los algoritmos inicialmente diseñados para problemas de muchos objetivos son los que mejor comportamiento presentan.
- Pequeñas mejoras en la función de adaptabilidad (basados en el MSE) repercuten significativamente en el ajuste del modelo. Por otro lado, es un hándicap en los procesos evolutivos el hecho de que para un mismo MSE se tienen infinitas combinaciones de parámetros del modelo.
- Finalmente, la experimentación realizada permite evidenciar que el problema de aprendizaje asociado al modelo semi-físico 1 tiene puntos en común con problemas de muchos

objetivos (como se ha mencionado). El hecho de que el algoritmo que mejor comportamiento presenta sea θ -DEA es una prueba irrefutable. Dicho algoritmo y su mecanismo de promoción de la diversidad, unido a la nueva relación de dominación que utiliza, facilitan su convergencia por encima de algoritmos que han sido muy eficaces en problemas de dos o tres objetivos (NSGA-II y SPEA2). No se debe olvidar el carácter destructivo que presenta el tercer objetivo relacionado con la primera derivada de la salida de tensión del modelo.

En la próxima sección se presenta el estudio empírico del algoritmo propuesto θ -FPO. Este se compara solamente con θ -DEA, para una mejor comprensión de la evaluación.

4.6. Estudio empírico de θ -FPO

En la presente sección se sigue la metodología de experimentación propuesta. Se ha diseñado el experimento lanzando diez ejecuciones de los algoritmos θ -DEA y el propuesto θ -FPO. Para un mejor análisis de la propuesta se ha decidido que el presente estudio empírico solamente incluya estos dos algoritmos. Considerando la evaluación realizada en la sección anterior el algoritmo θ -DEA es superior al resto. El presente estudio responde a la pregunta: ¿Es posible mejorar el aprendizaje del algoritmo θ -DEA con la inyección de conocimiento en el proceso evolutivo para el caso particular del aprendizaje del modelo semi-físico 1? La Tabla resume los principales parámetros utilizados para el experimentación con θ -DEA y θ -FPO.

Parámetro	Valor
Generaciones	50 000
H_1	4
H_2	3
θ	2
Probabilidad de cruzamiento	0.9
Índice de distribución del operador de cruzamiento (SBX)	20
Probabilidad de mutación	0.01
Índice de distribución del operador de mutación polinómica	20

TABLA 4.8: Resumen de parámetros para el estudio empírico θ -FPO.

Observe en la tabla que el número de generaciones utilizados como condición de parada en este estudio, es la mitad de las generaciones utilizadas en la evaluación a los MOEAs presentados en la sección anterior. Los resultados obtenidos en las diferentes dimensiones del juego de datos se pueden observar en la Tabla 4.9. Se evidencia numéricamente que la inyección de conocimiento mejora el proceso de aprendizaje del algoritmo base. En la práctica, este resultado facilitaría la implementación del algoritmo propuesto en un BMS.

		A = θ -DEA		A = θ -FPO	
		$I_{\epsilon+}(A, B)$	relation	$I_{\epsilon+}(A, B)$	relation
DS-C	B = θ -DEA	0	=	0.021061	
	B = θ -FPO	-4.7690E-4	\triangleleft	0	=
DS-C2	B = θ -DEA	0	=	0.002399	
	B = θ -FPO	-2.7692E-5	\triangleleft	0	=
DS-C3	B = θ -DEA	0	=	0.061406	
	B = θ -FPO	-0.004166	\triangleleft	0	=

TABLA 4.9: Evaluación basada en el indicador $I_{\epsilon+}$ de los algoritmos θ -DEA y el propuesto θ -FPO.

En la Figura 4.11 se observan los diferentes Frentes de Pareto obtenidos en la experimentación. Los tres FP corresponden, de arriba hacia abajo, a la experimentación con los juegos de datos correspondientes a DS-C, DS-C/2 y DS-C/3. Los ejes de los cubos identificados con $MSE(Vb)$, $MSE(Tb)$ y $MSE(ICA)$ corresponden a los errores computados con las ecuaciones 3.14, 3.15 y 3.17. Observe que la precisión de los ajustes es diferente en términos de cifras significativas para cada objetivo. Este efecto está relacionado con la unidad de medida en cada caso, el máximo error en la salida de tensión es 20mV, mientras que en el caso de la temperatura es de 0.5 °C.

Los tres Frentes de Pareto de la Figura 4.11 respaldados con la evaluación numérica son una evidencia empírica de la mejora en la calidad de las soluciones obtenidas con el uso de preferencias parciales. Los diferentes FPs se detallan en dos dimensiones en la Figura 4.12. La columna izquierda corresponde a la dimensión DS-C del juego de datos, la columna central a DS-C/2 y la columna derecha a DS-C/3.

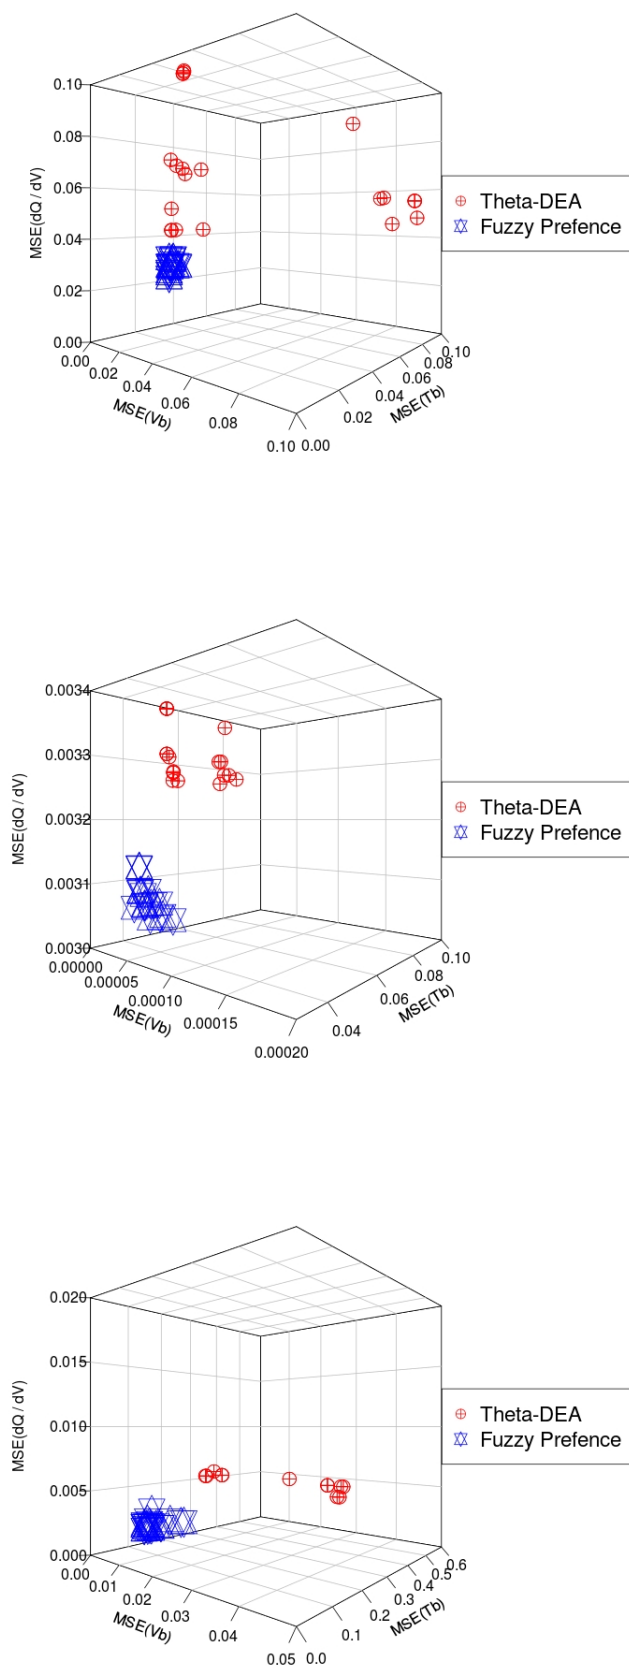


FIGURA 4.11: Frentes de Pareto del estudio empírico con θ -DEA y θ -FPO correspondiente a los juegos de datos DS-C, DS-C/2 y DS-C/3.

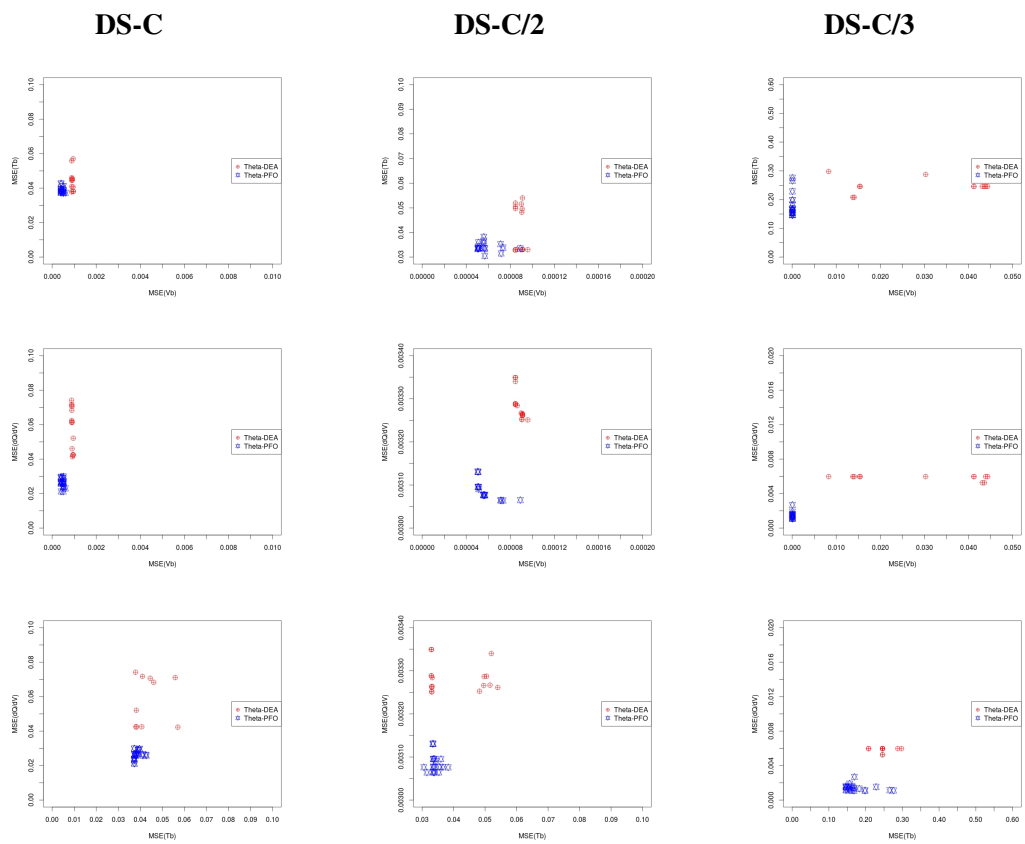


FIGURA 4.12: Frentes de Pareto en 2D de θ -DEA y θ -PFO para la experimentación realizada.

Finalmente la Figura 4.13 muestra los ajustes de las diferentes curvas de salida del Sistema Genético-Difuso Multiobjetivo asociado al modelo semi-físico 1. Dichos resultados son una muestra de la precisión de las soluciones encontradas con el uso de preferencias parciales. No se debe olvidar que ninguna solución del Frente de Pareto es superior a otra. La solución de la Figura 4.13 fue escogida al azar del FP obtenido con el algoritmo θ -FPO y el juego de datos DS-C/2 como entrada.




FIGURA 4.13: Ajuste de las curvas de salida de modelo de una solución del FP resultante del algoritmo propuesto θ -FPO con el juego de datos DS-C/2 como entrada.

4.7. Estudio empírico de Grab-MO-GaP

En la presente sección se realiza la evaluación de las extensiones propuestas a los algoritmos de Programación Genética Multiobjetivo. Como se ha explicado, el aprendizaje del modelo semi-físico 2 requiere de un diseño minucioso de:

- La codificación del cromosoma.
- La gramática que conducirá la búsqueda.
- Los parámetros del algoritmo.

Cada uno de estos elementos serán explicado en el Sistema de Programación-Genética-Difuso Multiobjetivo asociado al presente estudio empírico. Dentro de la presente sección se hace énfasis en la interpretabilidad del conocimiento extraído por las extensiones propuestas. Particularmente, en las expresiones analíticas que se aprenden indirectamente y están asociadas a la curva OCP del electrodo negativo en el modelo semi-físico 2.

La Figura 4.14 muestra la codificación cromosomática para el aprendizaje del modelo SMF 2. Ésta codificación es similar a la propuesta por Howard en el algoritmo GaP (Genetic Algorithm-Programming) [219]. El cromosoma cuenta con dos partes: el segmento asociado a la estructura de datos mediante árboles y el segmento asociado a la cadena de valores reales.

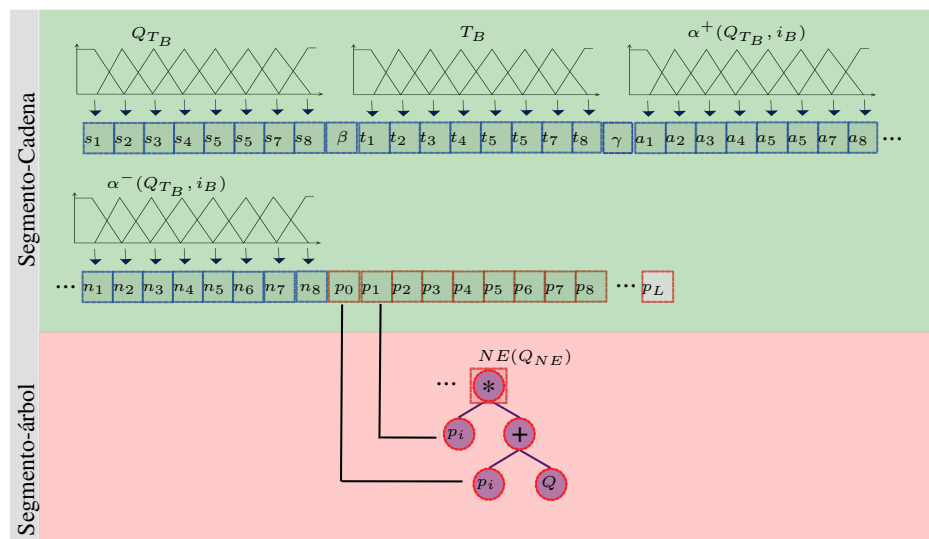


FIGURA 4.14: Codificación del cromosoma para el Sistema de Programación-Genética-Difuso Multiobjetivo asociado al modelo semi-físico 2.

Como se puede observar en la codificación, el segmento cadena contiene los valores asociados a los antecedentes y consecuentes de las FRBSs que intervienen en la salida de temperatura del

modelo. Por otro lado, Grab-MO-GaP no utiliza constantes aleatorias efímeras dentro del segmento asociado a la estructura de datos basada en árboles. Observe que en su lugar se utilizan símbolos del segmento cadena que apuntan a determinados nodos del árbol, conjunto de símbolos $p = (p_1, p_2, \dots, p_L)$. Estos valores reales participan en el cruzamiento y mutación a nivel del segmento cadena y también el proceso de búsqueda local.

El diseño experimental para la evaluación de Grab-MO-GaP respeta la metodología seguida a lo largo de este capítulo. En este caso, las diferentes variantes del algoritmo fueron ejecutadas veinte veces haciendo un compendio de las soluciones no-dominadas a lo largo de todas las ejecuciones. En la mitad de estas ejecuciones se hace uso de los datos pertenecientes a la primera celda ensayada (Bat #1) y el resto con la segunda celda (Bat #2). De cada una de estas celdas se utilizan los datos del régimen de carga y descarga a C/25.

Las diferentes variantes del algoritmo propuesto (Grab-MO-GaP-SPEA2, Grab-MO-GaP-NSGAI, Grab-MO-GaP-NSGA-3, Grab-MO-GaP-MOEA/D y Grab-MO-GaP- θ DEA) utilizan el mismo tamaño de la población, al igual que el resto de los parámetros. La Tabla 4.10 resume los parámetros para la experimentación. El algoritmo de búsqueda local utilizado ha sido una variante del algoritmo de Nelder y Mead propuesta por Tom Rowan, conocida con el nombre de "Subplex"[239].

Parámetro	Valor
Generaciones	50 000
Tamaño de la población	≈ 60
Iteraciones en la Búsqueda Local $ipls$	25
Probabilidad de cruzamiento en el segmento cadena P_{hlx}	0.9
Probabilidad de cruzamiento en el segmento de árbol P_{llx}	0.8
Probabilidad de mutación en el segmento cadena P_{hlm}	0.01
Probabilidad de mutación en el segmento de árbol P_{llx}	0.01

TABLA 4.10: Resumen de parámetros del estudio empírico con Grab-MO-GaP.

4.7.1. Definición de la gramática

La definición de la gramática es una importante decisión de diseño en la implementación exitosa de las extensiones propuestas. La correcta gestión de los genotipos a través de gramáticas garantiza fenotipos factibles para el problema de aprendizaje que se trabaja. La gramática dentro de Grab-MO-GaP está estrechamente relacionada con el aprendizaje indirecto de las variables latentes.

La definición de la gramática para el aprendizaje de la OCP del electrodo negativo en el modelo semi-físico 2 debe explotar el conocimiento parcial que se tiene sobre los fenómenos electroquímicos subyacentes. La curva de salida observable relacionada con la tensión de la batería

(v_B) es co-monótona con la OCP del electrodo positivo. Esta curva de potencial del electrodo positivo es conocida y prácticamente no cambia con la degradación (en el presente estudio se considera constante en el tiempo). Por otro lado, la curva de OCP del electrodo negativo es monótono decreciente en todo su dominio y por tanto es antitona con la salida de tensión, revise la Figura 3.19 para una mejor comprensión. Ésta curva de la OCP del electrodo negativo cambia con el envejecimiento de la batería, se desplaza y se modifican ligeramente sus puntos de cambios de pendiente. De lograrse el aprendizaje indirecto de esta curva mediante expresiones analítica, se resuelve de inmediato el problema de la estimación del SoH.

Para la presente experimentación los datos de la curva del electrodo positivo fueron extraídos del *toolbox Alawa* de MatlabTM, herramienta desarrollada por la Universidad de Hawaii. Alawa implementa un modelo para el diagnóstico y pronóstico del SoC y el SoH [199]. Además, recolecta mucha información sobre experimentos invasivos que se han realizado en diferentes tecnologías de baterías basadas en Iones de Litio. El procedimiento para la obtención de los datos consiste en separar los compuestos del ánodo y el cátodo realizando ensayos que para obtener la diferencia de potencial de cada uno de los compuestos frente al Litio en su estado puro.

Sobre esta base, para la definición de la gramática, se explican a continuación las funciones de referencias que se han seleccionado para modelar el patrón del electrodo negativo y sus cambios de pendiente.

Primero, la gramática debe hacer uso de una función *Logit*, Ecuación 4.5. Ésta función es la inversa de la función Logística o función *Sigmoide*.

$$\text{logit}(x) = \log\left(\frac{x}{1-x}\right) \quad (4.5)$$

La Figura 4.15 muestra la gráfica de la reflexión horizontal de la función Logit que servirá de patrón base para el electrodo negativo a aprender.

Segundo, deben añadirse a patrón que establece la función anterior los cambios de pendiente asociados al electrodo negativo. Estos repercuten directamente en los cambios de pendiente en la salida de tensión del modelo. Para este fin, la gramática debe hacer uso de la versatilidad de la función Sigmoide (Ecuación 4.6).

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (4.6)$$

En su forma general la función Sigmoide es definida mediante la Ecuación 4.7.

$$\text{sigmoid}^g(x) = A + \frac{B - A}{1 + W e^{-K(x - X_m)}} \quad (4.7)$$




FIGURA 4.15: Reflexión horizontal de la función Logit.

Donde las constantes A , B , W , K y X_m representan:

- A : La asíntota inferior.
- B : La asíntota superior.
- W : Está relacionada con el valor de $\text{sigmoid}^g(0)$.
- K : Es el índice de crecimiento.
- X_m : es el punto medio de la función en el eje de las abscisas.

La Figura 4.16 muestra una función Sigmoide estándar con $A = 0$, $B = 1$ y $X_m = 0$.

Sobre estas funciones se basa la definición de la gramática para el aprendizaje del algoritmo Grab-MO-GaP. Seguidamente se presenta un ejemplo hipotético que facilitará la comprensión de la gramática que se define. Mediante este ejemplo se explica el mecanismo que se utilizará para identificar los picos de la curva ICA a partir de la estructura del modelo aprendido, particularmente del aprendizaje indirecto del OCP perteneciente al electrodo negativo.

La Figura 4.17 muestra las curvas de los diferentes potenciales para una batería de 45 Ah. Se establece hipotéticamente el potencial del electrodo positivo (PE) constante en 3.4 V. El electrodo negativo (NE) es modelado mediante la resta de la funciones Logit reflejada horizontalmente con una función Sigmoide, ambas funciones deben ser escaladas. Estas funciones dependen de la carga de la batería según el modelo semi-físico 2 (en este ejemplo no se asume el modelo lineal de las cargas). Observe en la figura que las flechas indican el cambio de pendiente de las




FIGURA 4.16: Función Sigmoide.

curvas del electrodo negativo y la tensión de la batería. En estas regiones se centra el análisis para la identificación de los picos en las curvas ICA. Seguidamente se muestran las ecuaciones correspondientes al ejemplo, donde se asume que:




FIGURA 4.17: Funciones que fundamentan la definición de la gramática para la experimentación con Grab-MO-GaP.

$$v_B = PE - NE(Q_{NE})$$

$$PE = 3,4V$$

$$NE(Q_{NE}) = \text{Logit}^{scal}(Q_{NE}) - \text{Sigmoid}^{scal}(Q_{NE})$$

$$Q_{NE} = Q$$

$$\text{Logit}^{scal}(Q_{NE}) = \log\left(\frac{Q_{NE}}{1 - Q_{NE}}\right)$$

$$\text{Sigmoid}^{scal}(Q_{NE}) = \frac{1}{1 + e^{-100(Q_{NE}-0,4)}}$$

Para facilitar el análisis de la salida de tensión y sus cambios de pendiente en este ejemplo, se invierten los ejes de coordenadas en la Figura 4.18.




FIGURA 4.18: Tensión frente al SoC para identificar los cambios de pendiente.

A partir de estos datos se realiza el análisis ICA y se determinan los picos característicos que se muestran en la Figura 4.19. Éstos se corresponden con los puntos donde comienza el crecimiento de la función Sigmoide, y donde culmina se pueden obtener de forma simétrica a partir de X_m y el factor de crecimiento K . En el presente ejemplo los puntos de cambio de tensión que corresponden con los picos de la curva ICA: $v_1 = 3,126$ V que se alcanza para el $SoC = 32,05$ % y $v_2 = 3,24$ V correspondiente al $SoC = 50,97$ %.

Desde el punto de la aplicación práctica, la correcta localización de los cambios de pendiente en la salida de tensión del modelo es de mucha utilidad para la estimación del SoH. Esto es solo posible proponiendo que el perfil de tensión del electrodo negativo sea una cadena válida en la gramática presentada en el Listado 4.1.




FIGURA 4.19: Identificación de los puntos de cambio de pendiente.

```

INICIO ::= POS * logit(Q_SCAL) - POS - STEPS
STEPS ::= POS |
        POS * q |
        POS * STEPS |
        STEPS + STEPS |
        sigmoid(Q_SCAL) |
Q_SCAL ::= POS * q - POS
POS ::= p0 | p2 | ... | p24

```

LISTADO 4.1: Gramática definida para estudio empírico con Grab-MO-GaP

Ésta gramática garantiza la obtención de expresiones que se corresponden con curvas monótonas decrecientes para el electrodo negativo. Todos los modelos válidos restan a la reflexión horizontal de la función Logit funciones monótonas crecientes, estas pueden ser:

- Función Sigmoide.
- Función de la carga de la batería q por una constante.
- Suma de funciones monótona creciente.

- Productos de una constante por función monótona creciente.

En la gramática, el conjunto de símbolos terminales desde p_0 hasta p_{24} son valores positivos.

4.7.2. Análisis y discusión de los resultados

Los resultados obtenidos en las diferentes variantes del algoritmo propuesto se evalúan en la presente sección. Los Frentes de Pareto obtenidos mediante la experimentación se muestran en la Figura 4.20.




FIGURA 4.20: Frentes de Pareto obtenidos de las diferentes variantes evaluadas del algoritmos propuesto Grab-MO-GaP.

Para un análisis detallado, en la Figura 4.21 se descomponen los FPs en dos dimensiones.

Observe que los FPs son una evidencia gráfica que las estrategias de selección de la supervivencia utilizadas en Grab-MO-GaP-SPEA2 y Grab-MO-GaP-NSGA-II obtienen FPs dispersos en el espacio de decisión. Por otro lado, el resto de las alternativas Grab-MO-GaP-NSGA-3, Grab-MO-GaP-MOEA/D y Grab-MO-GaP-ThetaDEA encuentran FPs concentrados. El estudio permite observar que las estrategias que hacen uso de puntos de referencia en el espacio de búsqueda y de nuevos mecanismos de promoción de la diversidad obtienen modelos potencialmente superiores al resto.




FIGURA 4.21: Proyección en 2D de los FPs obtenidos con Grab-MO-GaP.

Numéricamente la Tabla 4.11, en su primera parte, muestra la comparativa mediante el indicador de calidad binario que se ha utilizado a lo largo del presente capítulo ($I_{\epsilon+}$). En la segunda parte de la Tabla 4.11 se muestra adicionalmente el indicador de Distancia Generacional Invertida $IGD(A, B)$. Este indicador proporciona información complementaria sobre la diversidad de los FPs obtenidos.

A partir del análisis numérico de los resultados, se debe resaltar que los resultados alcanzados con las variantes Grab-MO-GaP-SPEA2 y Grab-MO-GaP-NSGA-II no dominan a ninguna de las restantes. La variante del algoritmo que mejores resultados alcanza en la presente experimentación es Grab-MO-GaP-NSGA-3.

Para la evaluación de las expresiones analíticas aprendidas indirectamente se selecciona aleatoriamente un individuo del FP obtenido por el algoritmo Grab-MO-GaP-NSGA-3. La Figura 4.22 muestra la expresión obtenida que describe el electrodo negativo.




FIGURA 4.22: Ejemplo de una expresión obtenida indirectamente para el electrodo negativo.

Haciendo una evaluación de las expresiones analíticas aprendidas indirectamente se observa que generalmente se identifican dos o cuatro de los cinco picos de la curva ICA. Si se toma como referencia la Figura 4.23, las expresiones aprendidas indirectamente identifican los picos 2, 3, 4 y 5 en el mejor de los casos. En otros individuos solo se identifican los puntos 4 y 5. La

	A = Grab-MO-GaP-SPEA2	A = Grab-MO-GaP-NSGA-II	A = Grab-MO-GaP-NSGA-3	A = Grab-MO-GaP-MOEA/D	A = Grab-MO-GaP- θ DEA
	$I_{c+}(A, B)$	$I_{c+}(A, B)$	$I_{c+}(A, B)$	$I_{c+}(A, B)$	$I_{c+}(A, B)$
	relation	relation	relation	relation	relation
B = Grab-MO-GaP-SPEA2	0	0.042963	0.050633	0.047121	0.044606
B = Grab-MO-GaP-NSGA-II	0.001319	0	0.031650	0.010031	0.021061
B = Grab-MO-GaP-NSGA-3	-0.014538	-0.007669	0	-3.401E-4	-1.555E-4
B = Grab-MO-GaP-MOEA/D	-0.008463	-0.004158	0.021867	0	0.011278
B = Grab-MO-GaP- θ DEA	-0.014382	-0.001642	0.010588	0.002515	0
	<	<	Δ	\parallel	=
	=	=	=	=	=
	\parallel	∇	∇	∇	∇
	<	<	<	<	<
	<	<	<	<	<

	A = Grab-MO-GaP-SPEA2	A = Grab-MO-GaP-NSGA-II	A = Grab-MO-GaP-NSGA-3	A = Grab-MO-GaP-MOEA/D	A = Grab-MO-GaP- θ DEA
	$IGD(A, B)$	$IGD(A, B)$	$IGD(A, B)$	$IGD(A, B)$	$IGD(A, B)$
	relation	relation	relation	relation	relation
B = Grab-MO-GaP-SPEA2	0	0.011668	0.013865	0.010969	0.011326
B = Grab-MO-GaP-NSGA-II	0.010879	0	0.007705	0.003129	0.004139
B = Grab-MO-GaP-NSGA-3	0.020926	0.016336	0	0.005385	0.003577
B = Grab-MO-GaP-MOEA/D	0.013899	0.010898	0.004990	0	0.001423
B = Grab-MO-GaP- θ DEA	0.017720	0.011958	0.002517	0.001497	0
	=	=	=	=	=
	<	<	<	<	<
	<	<	<	<	<
	<	<	<	<	<
	<	<	<	<	<

TABLA 4.11: Parte Superior: Evaluación de los resultados mediante el Indicador Binario Aditivo de Epsilon. En la parte inferior: se complementa con información sobre diversidad de los FPs mediante la Distancia Generacional Invertida.

precisión y el número de picos localizados por el modelo decrece cuando la corriente es alta. Si la corriente es alta, los cambios en la pendiente son suavizados por los efectos cinéticos de la batería y la colocación de las sigmoides no será fiable.




FIGURA 4.23: Etiquetado de los puntos de cambio de pendiente en la curva ICA.

En el presente estudio empírico no se profundiza numéricamente en la precisión de las expresiones aprendidas indirectamente por dos motivos fundamentales:

1. No se cuenta con datos de la curva de OCP del electrodo negativo en las celdas utilizadas en la experimentación.
2. Se respeta la naturaleza del aprendizaje multiobjetivo donde ninguna de las soluciones de los FP es superior. En este sentido, la discriminación de soluciones de un FP por no identificar la mayor cantidad de puntos de cambio de pendiente entraría en contradicción con el enfoque multiobjetivo del algoritmo propuesto Grab-MO-GaP.

Finalmente, teniendo en cuenta que el Sistema de Programación-Genética-Difuso Multiobjetivo y su aplicación en el modelo semi-físico 2 no tiene contrapartes en la literatura con las que pueda compararse, con el fin de obtener una referencia numérica de la calidad del método propuesto ha sido utilizada una red neuronal recurrente para aprender un modelo dinámico de la batería.

Dicho modelo es una red neuronal LSTM (del inglés, Long Short Term Memory) con 50 nodos ocultos y una capa lineal de salida. Las entradas han sido la corriente i_B y la carga de la batería Q . La estimación neuronal de la curva OCV se obtuvo simulando un ciclo a $C/25$ con el modelo aprendido. La red neuronal tiene la particularidad de que el conjunto de entrenamiento y el de experimentación es el mismo. La Tabla 4.12 resume los resultados obtenidos donde se aprecia numéricamente la superioridad del modelo propuesto en la experimentación realizada.

Batería	Grab-MO-GaP	LSTM
bat #1	0.00458	0.00781
bat #2	0.00470	0.00786

TABLA 4.12: Comparación del error absoluto en Vatios entre Grab-MO-GaP y la red neuronal recurrente.

4.8. Conclusiones parciales

En el presente capítulo se explicó detalladamente la elaboración de los juegos de datos utilizados en la experimentación. Luego se realizó un análisis de las diferentes metodologías e indicadores de comparación de algoritmos de aprendizaje para modelos multicriterio. Se seleccionó para la evaluación de las propuestas la acumulación del Super Frente de Pareto y el uso del Indicador Binario Aditivo de Epsilon.

En el estudio empírico de los MOEAs para el aprendizaje del modelo SMF 1 se identificó que:

- El aprendizaje de este modelo es un proceso costoso.
- En el proceso evolutivo genera una cantidad elevada de individuos resistentes a la dominación.
- Pequeñas mejoras en la función de adaptabilidad (basados en el MSE) repercuten significativamente en el ajuste del modelo.

El estudio del algoritmo propuesto θ -FPO permitió evaluar las ventajas de la inyección de conocimiento en el aprendizaje del modelo. La propuesta mejora los resultados del resto de los algoritmos evaluados.

Por otro lado, según el estudio realizado con el algoritmo Grab-MO-GaP para el aprendizaje del modelo semi-físico 2 se concluye que:

- El algoritmo propuesto facilita el aprendizaje indirecto de variables latentes con expresiones de fácil comprensión.
- En las diferentes variantes del algoritmo se destaca Grab-MO-GaP-NSGA-3 como la variante que mejor converge en la experimentación realizada.
- El método propuesto es competitivo con otros modelos inteligentes y es el punto de partida de nuevas líneas de investigación.

Capítulo 5

Conclusiones Generales

Como resultado de la presente investigación se desarrollaron nuevos algoritmos de aprendizaje con enfoque multicriterio. Las aportaciones realizadas dotan a los investigadores de otras alternativas para enfrentar problemas dinámicos. Particularmente, los algoritmos propuestos encontraron buenas soluciones en el aprendizaje de modelos semi-físicos de baterías de Iones de Litio, lo cual responde al objetivo general planteado pues:

1. Los modelos semi-físicos de segunda generación propuestos facilitan el aprendizaje indirecto de las variables latentes como el Estado de Carga y Estado de Salud. Aprender el Sistema Genético-Difuso Multiobjetivo no-estándar asociado al modelo semi-físico 1 no ha sido sencillo. La complejidad del proceso de aprendizaje está fundamentalmente asociada al elevado número de individuos resistentes a la dominación que se generan durante el proceso evolutivo.

Se ha propuesto el modelo semi-físico 2, que permite simplificar el diagnóstico del estado de salud de baterías de Iones de Litio. Se ha realizado un profundo análisis de la literatura identificando carencias en los algoritmos necesarios para este modelo. El Sistema de Programación-Genética-Difusa Multiobjetivo asociado al modelo requirió de la extensión de los algoritmos existentes.

2. Se ha propuesto el algoritmo θ -FPO, el cual permite la inyección de conocimiento en el proceso evolutivo mediante preferencias parciales. Con esta propuesta se establecen nuevos mecanismos de presión evolutiva en el proceso de aprendizaje. La inyección de conocimiento planteada permite enfrentar la complejidad del proceso de aprendizaje. En el estudio empírico realizado se evidencia una mejor convergencia del algoritmo propuesto. Se requiere menor número de generaciones para el aprendizaje, lo cual es ventajoso para la implementación práctica en BMSs de vehículos eléctricos, así como para la extrapolación de los resultados a zonas que no estuvieron representadas en los juegos de datos de la experimentación.

3. El algoritmo propuesto Grab-MO-GaP introdujo modernos mecanismo en la etapa de selección de la supervivencia para el aprendizaje multiobjetivo basado en Evolución Gramatical. El estudio empírico realizado evidencia la habilidad del algoritmo propuesto para el aprendizaje indirecto de variables latentes del modelo. Este proceso saca provecho de la co-monotonía entre las variables latentes a aprender y las salidas observables del modelo.

5.0.1. Trabajo futuro

La presente investigación tendrá su continuidad en varias líneas de trabajo que se listan a continuación:

- Desde un punto de vista de aplicación práctica, los resultados de la investigación sugieren que los algoritmos para el aprendizaje de modelos semi-físicos pueden aplicarse con éxito en BMSs para vehículos eléctricos. Esta es una línea de trabajo derivada de la presente tesis.
- Se trabajará en mejoras en Grab-MO-GaP enfocados al aprendizaje indirecto de expresiones para ambos electrodos al unísono y con corriente más elevadas.
- Se trabajará estudiando la aplicación de los algoritmos propuestos a otros problemas dinámicos de la ciencia y la ingeniería. En este sentido, el desarrollo de los algoritmos debe estar enfocado a problemas complejos donde se generan un elevado número de soluciones resistentes a la dominación. La identificación de posibles interacciones entre las variables que puede estar presentes en los modelos es una interesante área de trabajo.
- Finalmente, al autor de la presente tesis le interesa estudiar los algoritmos hiper-heurísticos para el aprendizaje de modelos dinámicos.

Apéndice A

Producción científica

La producción científica de la presente investigación se comprende por la publicación de los trabajos que se lista a continuación. Se incluyen contribuciones en revistas científicas y congresos, todos sometidos a procesos de revisión por pares.

1. Y. Echevarría, I. Couso, D. Anseán, C. Blanco, and L. Sánchez, “Using fuzzy preference orderings in θ -dominance with application to health monitoring of Li-Ion batteries” in *Journal of Multiple-Valued Logic and Soft Computing*, IN PRESS, 2016.
2. Y. Echevarría, L. Sánchez, and C. Blanco, “Genetic Fuzzy Modelling of Li-Ion Batteries Through a Combination of Theta-DEA and Knowledge-Based Preference Ordering” in *Advances in Artificial Intelligence*, Springer International Publishing, pp. 310–320, 2016.
3. Y. Echevarría, L. Sánchez, and C. Blanco, “Assessment of Multi-Objective Optimization Algorithms for parametric identification of a Li-Ion battery model” *Lecture Notes in Computer Science*. vol. 9648, pp. 250–260, 2016.

Se complementa la producción científica con los siguientes trabajos sometidos a procesos de revisión:

1. Y. Echevarría, C. Blanco, and L. Sánchez, “Learning Human-Understandable Models for the Health Assessment of Li-Ion Batteries through Multi-Objective Genetic Programming”, SUBMITTED to *Engineering Applications of Artificial Intelligence*, 2017.
2. L. Sánchez, I. Couso, J. Otero, Y. Echevarría, and D. Anseán, “Condition monitoring of Li-Ion batteries through soft sensors for cyber-physical vehicle systems”, SUBMITTED to *Journal of Sensors*, 2017.

Bibliografía

- [1] A. E. Eiben and J. E. Smith. *Introduction to Evolutionary Computing*. Natural Computing Series. Springer Berlin Heidelberg, Berlin, Heidelberg, 2015. ISBN 978-3-662-44873-1. doi: 10.1007/978-3-662-44874-8.
- [2] Yuan Yuan, Hua Xu, Bo Wang, and Xin Yao. A New Dominance Relation-Based Evolutionary Algorithm for Many-Objective Optimization. *IEEE Transactions on Evolutionary Computation*, 20(1):16–37, 2016. ISSN 1089778X. doi: 10.1109/TEVC.2015.2420112.
- [3] Ke Li, Kalyanmoy Deb, Qingfu Zhang, and Sam Kwong. An evolutionary many-objective optimization algorithm based on dominance and decomposition. *IEEE Transactions on Evolutionary Computation*, 19(5):694–716, 2015. ISSN 1089778X. doi: 10.1109/TEVC.2014.2373386.
- [4] Mehmet Ugras Cuma and Tahsin Koroglu. A comprehensive review on estimation strategies used in hybrid and battery electric vehicles. *Renewable and Sustainable Energy Reviews*, 42:517–531, 2015. ISSN 13640321. doi: 10.1016/j.rser.2014.10.047.
- [5] Ana-Irina Stan, Maciej Swierczynski, Daniel-Ioan Stroe, Remus Teodorescu, and Soren Juhl Andreasen. Lithium ion battery chemistries from renewable energy storage to automotive and back-up power applications — An overview. In *2014 International Conference on Optimization of Electrical and Electronic Equipment (OPTIM)*, pages 713–720. IEEE, 2014. ISBN 978-1-4799-5183-3. doi: 10.1109/OPTIM.2014.6850936.
- [6] Cecilio Blanco, Luciano Sanchez, Manuela Gonzalez, Juan C. Anton, Victor Garcia, and Juan C. Viera. An equivalent circuit model with variable effective capacity for LiFePO₄ batteries. *IEEE Transactions on Vehicular Technology*, 63(8):3592–3599, 2014. ISSN 00189545. doi: 10.1109/TVT.2014.2309394.
- [7] Luciano Sanchez, Cecilio Blanco, Juan C. Anton, Victor Garcia, Manuela Gonzalez, and Juan C. Viera. A variable effective capacity model for LiFePO₄ traction batteries using computational intelligence techniques. *IEEE Transactions on Industrial Electronics*, 62(1):555–563, 2015. ISSN 02780046. doi: 10.1109/TIE.2014.2327552.

- [8] Celil Ozkurt, Fatih Camci, Vepa Atamuradov, and Christopher Odorry. Integration of sampling based battery state of health estimation method in electric vehicles. *Applied Energy*, 175:356–367, 2016. ISSN 03062619. doi: 10.1016/j.apenergy.2016.05.037.
- [9] Jens Groot. *State-of-health estimation of Li-ion batteries: cycle life test methods*. PhD thesis, CHalmers University of Technology, 2012.
- [10] Zhe Zheng, Hai Lin Liu, and Lei Chen. An evolutionary many-objective optimization algorithm based on population decomposition and reference distance. *6th International Conference on Information Science and Technology, ICIST 2016*, 19(5):388–393, 2016. doi: 10.1109/ICIST.2016.7483444.
- [11] David Ansean. *High power li-Ion battery performance: a mechanistic analysis of aging*. PhD thesis, Universidad de Oviedo, 2015.
- [12] Suleiman Abu-Sharkh and Dennis Doerffel. Rapid test and non-linear model characterisation of solid-state lithium-ion batteries. *Journal of Power Sources*, 130(1-2): 266–274, 2004. ISSN 03787753. doi: 10.1016/j.jpowsour.2003.12.001.
- [13] Carlos Coello, Gary Lamont, and David Veldhuizen. *Evolutionary Algorithms for Solving Multi-Objective Problems*, volume 5. Springer, 2007. ISBN 978-0-387-33254-3.
- [14] Francisco Herrera. Genetic fuzzy systems: Taxonomy, current research trends and prospects. *Evolutionary Intelligence*, 1(1):27–46, 2008. ISSN 18645909. doi: 10.1007/s12065-007-0001-5.
- [15] Juan Carlos Alvarez. Support Vector Machines Used to Estimate the Battery State of Charge. *IEEE Trans*, 28(12):5919–5926, 2013.
- [16] J Sjöberg, Q Zhang, L Ljung, A Benveniste, B Delyon, P Glorennec, H Hjalmarsson, and A Juditsky. Nonlinear nlack-nox modeling in system identification: a unified overview. *Automatica*, 31(12):1691–1724, 1995.
- [17] T Johansen. Identification of non linear systems structure and parameters using regime decomposition. *Automatica*, 31:321–326, 1995.
- [18] Claudio Burgos, Doris Sáez, Marcos E. Orchard, and Roberto Cárdenas. Fuzzy modelling for the state-of-charge estimation of lead-acid batteries. *Journal of Power Sources*, 274:355–366, 2015. ISSN 03787753. doi: 10.1016/j.jpowsour.2014.10.036.
- [19] Martin Schetzen. Nonlinear system modelling and analysis from the volterra and wiener perspective. In *Lecture Notes in Control and Information Sciences*, volume 404, pages 13–24. Springer, 2010. ISBN 9781849965125. doi: 10.1007/978-1-84996-513-2_2.

- [20] M. Rébillat, R. Hajrya, and N. Mechbal. Nonlinear structural damage detection based on cascade of Hammerstein models. *Mechanical Systems and Signal Processing*, 48(1-2): 247–259, 2014. ISSN 10961216 08883270. doi: 10.1016/j.ymssp.2014.03.009.
- [21] M. J. Gacto, R. Alcalá, and F. Herrera. Interpretability of linguistic fuzzy rule-based systems: An overview of interpretability measures. *Information Sciences*, 181(20): 4340–4360, 2011. ISSN 00200255. doi: 10.1016/j.ins.2011.02.021.
- [22] Michela Fazzolari, Rafael Alcala, Yusuke Nojima, Hisao Ishibuchi, and Francisco Herrera. A review of the application of multiobjective evolutionary fuzzy systems: Current status and further directions. *IEEE Transactions on Fuzzy Systems*, 21(1):45–65, 2013. ISSN 10636706. doi: 10.1109/TFUZZ.2012.2201338.
- [23] Athanasios Tsakonas. Local and global optimization for Takagi-Sugeno fuzzy system by memetic genetic programming. *Expert Systems with Applications*, 40(8):3282–3298, 2013. ISSN 09574174. doi: 10.1016/j.eswa.2012.12.099.
- [24] David P. Pancho, Jose M. Alonso, Oscar Cordon, Arnaud Quirin, and Luis Magdalena. Fingrams: Visual representations of fuzzy rule-based inference for expert analysis of comprehensibility. *IEEE Transactions on Fuzzy Systems*, 21(6):1133–1149, 2013. ISSN 10636706. doi: 10.1109/TFUZZ.2013.2245130.
- [25] Athanasios Tsakonas. An analysis of accuracy-diversity trade-off for hybrid combined system with multiobjective predictor selection. *Applied Intelligence*, 40(4):710–723, 2014. ISSN 0924669X. doi: 10.1007/s10489-013-0507-8.
- [26] Kalyanmoy Deb, Amrit Pratap, Sameer Agarwal, and T. Meyarivan. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2):182–197, 2002. ISSN 1089778X. doi: 10.1109/4235.996017.
- [27] Eckart Zitzler, Marco Laumanns, and Lothar Thiele. SPEA2: Improving the Strength Pareto Evolutionary Algorithm. *Evolutionary Methods for Design Optimization and Control with Applications to Industrial Problems*, pages 95–100, 2001. ISSN 03772217. doi: 10.1.1.28.7571.
- [28] Peter J Fleming, Robin C Purshouse, and Robert J Lygoe. Many-Objective Optimization: An Engineering Design Perspective. In *Evolutionary Multi-Criterion Optimization: Third International Conference Proceedings*, pages 14–32. Springer, 2005. ISBN 978-3-540-31880-4. doi: 10.1007/b106458.
- [29] V. Khare, X. Yao, and K. Deb. Performance Scaling of Multi-objective Evolutionary Algorithms. In *International Conference on Evolutionary Multi-Criterion Optimization*, pages 376–390. Springer, 2003. ISBN 978-3-540-01869-8. doi: 10.1007/3-540-36970-8_27.

- [30] André Süßflow, Nicole Drechsler, and Rolf Drechsler. Robust {M}ulti-Objective {O}ptimization in {H}igh {D}imensional {S}paces. In *Evolutionary Multi-Criterion Optimization, 4th International Conference, EMO 2007*, pages 715–726. Springer, 2007.
- [31] Yuan Yuan and Hua Xu. Multiobjective Flexible Job Shop Scheduling Using Memetic Algorithms. *IEEE Transactions on Automation Science and Engineering*, 12(1):1–18, 2013. ISSN 1545-5955. doi: 10.1109/TASE.2013.2274517.
- [32] Kata Praditwong, Mark Harman, and Xin Yao. Software Module Clustering as a Multi – Objective Search Problem. *IEEE Transactions on Software Engineering*, 37(2):1–26, 2009.
- [33] Tinkle Chugh, Yaochu Jin, Kaisa Miettinen, Jussi Hakanen, and Karthik Sindhya. A Surrogate-assisted Reference Vector Guided Evolutionary Algorithm for Computationally Expensive Many-objective Optimization. *IEEE Transactions on Evolutionary Computation*, 20(5):1–1, 2016. ISSN 1089-778X. doi: 10.1109/TEVC.2016.2622301.
- [34] Kalyanmoy Deb and Himanshu Jain. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, Part I: Solving problems with box constraints. *IEEE Transactions on Evolutionary Computation*, 18(4): 577–601, 2014. ISSN 1089778X. doi: 10.1109/TEVC.2013.2281535.
- [35] Ke Li, Sam Kwong, Qingfu Zhang, and Kalyanmoy Deb. Inter-Relationship Based Selection for Decomposition Multiobjective Optimization. *IEEE transactions on cybernetics*, 45(5):1–11, 2015.
- [36] Nicole Drechsler, Rolf Drechsler, and Bernd Becker. Multi-objective {O}ptimisation {B}ased on {R}elation {\em Favour}. In *First International Conference on Evolutionary Multi-Criterion Optimization*, pages 154–166. Springer, 2001. doi: 10.1007/3-540-44719-9_11.
- [37] Francesco di Pierro, Soon-Thiam Khu, and Dragan A. Savic. An Investigation on Preference Ordering Ranking Scheme in Multiobjective Evolutionary Optimization. *IEEE Trans. on Evolutionary Comp.*, 11(1):17–45, 2007.
- [38] S. Yang, M. Li, X. Liu, and J. Zheng. A grid-based evolutionary algorithm for many-objective optimization. *IEEE Transactions on Evolutionary Computation*, 17(5): 721–736, 2013. ISSN 1089778X. doi: 10.1109/TEVC.2012.2227145.
- [39] Xiufen Zou, Yu Chen, Minzhong Liu, and Lishan Kang. A new evolutionary algorithm for solving many-objective optimization problems. *IEEE transactions on systems, man, and cybernetics. Part B, Cybernetics : a publication of the IEEE Systems, Man, and*

- Cybernetics Society*, 38(5):1402–1412, 2008. ISSN 1941-0492. doi: 10.1109/TSMCB.2008.926329.
- [40] Saku Kukkonen and Jouni A Lampinen. Ranking-Dominance and Many-Objective Optimization. In *Cec'07*, pages 3983–3990. IEEE, 2007. doi: 10.1109/CEC.2007.4424990.
- [41] Proteek Chandan Roy, Md Monirul Islam, Kazuyuki Murase, and Xin Yao. Evolutionary Path Control Strategy for Solving Many-Objective Optimization Problem. *IEEE Transactions on Cybernetics*, 45(4):702–715, 2015. ISSN 21682267. doi: 10.1109/TCYB.2014.2334632.
- [42] Antonio López, Carlos A. Coello Coello, Akira Oyama, and Kozo Fujii. An alternative preference relation to deal with many-objective optimization problems. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, volume 7811 LNCS, pages 291–306. Springer, 2013. ISBN 9783642371394. doi: 10.1007/978-3-642-37140-0_24.
- [43] Qingfu Zhang and Hui Li. MOEA/D: A multiobjective evolutionary algorithm based on decomposition. *IEEE Transactions on Evolutionary Computation*, 11(6):712–731, 2007. ISSN 1089778X. doi: 10.1109/TEVC.2007.892759.
- [44] Kalyanmoy Deb, Ankur Sinha, and Saku Kukkonen. Multi-objective test problems, linkages, and evolutionary methodologies. In *Proceedings of the 8th annual conference on Genetic and evolutionary computation - GECCO '06*, number January, page 1141, New York, New York, USA, 2006. ACM Press. ISBN 1595931864. doi: 10.1145/1143997.1144179.
- [45] Ke Li, Mohammad Nabi Omidvar, Kalyanmoy Deb, and Xin Yao. Variable interaction in multi-objective optimization problems. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, volume 9921 LNCS, pages 399–409. Springer, 2016. ISBN 9783319458229. doi: 10.1007/978-3-319-45823-6_37.
- [46] Mohammad Nabi Omidvar, Xiaodong Li, Yi Mei, and Xin Yao. Cooperative co-evolution with differential grouping for large scale optimization. *IEEE Transactions on Evolutionary Computation*, 18(3):378–393, 2014. ISSN 1089778X. doi: 10.1109/TEVC.2013.2281543.
- [47] Xiaoliang Ma, Fang Liu, Yutao Qi, Xiaodong Wang, Lingling Li, Licheng Jiao, Minglei Yin, and Maoguo Gong. A Multiobjective Evolutionary Algorithm Based on Decision Variable Analyses for Multiobjective Optimization Problems with Large-Scale

- Variables. *IEEE Transactions on Evolutionary Computation*, 20(2):275–298, 2016. ISSN 1089778X. doi: 10.1109/TEVC.2015.2455812.
- [48] David H. Wolpert and William G. Macready. No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, 1(1):67–82, 1997. ISSN 1089778X. doi: 10.1109/4235.585893.
- [49] Riccardo Poli, Mario Graff, and NF McPhee. Free lunches for function and program induction. In *Proceedings of the tenth ACM SIGEVO . . .*, page 183, New York, New York, USA, 2009. ACM Press. ISBN 9781605584140. doi: 10.1145/1527125.1527148.
- [50] Liang Rui Chen, Shing Lih Wu, Deng Tswen Shieh, and Tsair Rong Chen. Sinusoidal-ripple-current charging strategy and optimal charging frequency study for Li-ion batteries. *IEEE Transactions on Industrial Electronics*, 60(1):88–97, 2013. ISSN 02780046. doi: 10.1109/TIE.2012.2186106.
- [51] Saeid Haghbin, Sonja Lundmark, Mats Alakula, and Ola Carlson. Grid-connected integrated battery chargers in vehicle applications: Review and new solution. *IEEE Transactions on Industrial Electronics*, 60(2):459–473, 2013. ISSN 02780046. doi: 10.1109/TIE.2012.2187414.
- [52] Murat Yilmaz and Philip Krein. Review of Charging Power Levels and Infrastructure for Plug-In Electric and Hybrid Vehicles and Commentary on Unidirectional Charging. *Ieee.*, 28(5):2151–2169, 2012. ISSN 08858993. doi: 10.1109/IEVC.2012.6183208.
- [53] D. Anseán, M. Dubarry, A. Devie, B. Y. Liaw, V. M. García, J. C. Viera, and M. González. Fast charging technique for high power LiFePO₄ batteries: A mechanistic analysis of aging. *Journal of Power Sources*, 321:201–209, 2016. ISSN 03787753. doi: 10.1016/j.jpowsour.2016.04.140.
- [54] Caihao Weng, Yujia Cui, Jing Sun, and Huei Peng. On-board state of health monitoring of lithium-ion batteries using incremental capacity analysis with support vector regression. *Journal of Power Sources*, 235:36–44, 2013. ISSN 03787753. doi: 10.1016/j.jpowsour.2013.02.012.
- [55] Soichiro Torai, Masaru Nakagomi, Satoshi Yoshitake, Shuichiro Yamaguchi, and Noboru Oyama. State-of-health estimation of LiFePO₄/graphite batteries based on a model using differential capacity. *Journal of Power Sources*, 306:62–69, 2016. ISSN 03787753. doi: 10.1016/j.jpowsour.2015.11.070.
- [56] Xiaosong Hu, Shengbo Li, and Huei Peng. A comparative study of equivalent circuit models for Li-ion batteries. *Journal of Power Sources*, 198:359–367, 2012. ISSN 03787753. doi: 10.1016/j.jpowsour.2011.10.013.

- [57] Wladislaw Waag, Christian Fleischer, and Dirk Uwe Sauer. Critical review of the methods for monitoring of lithium-ion batteries in electric and hybrid vehicles. *Journal of Power Sources*, 258:321–339, 2014. ISSN 03787753. doi: 10.1016/j.jpowsour.2014.02.064.
- [58] Yujie Wang, Chenbin Zhang, and Zonghai Chen. A method for state-of-charge estimation of LiFePO₄ batteries at dynamic currents and temperatures using particle filter. *Journal of Power Sources*, 279:306–311, 2015. ISSN 03787753. doi: 10.1016/j.jpowsour.2015.01.005.
- [59] Ziyou Song, Heath Hofmann, Jianqiu Li, Xuebing Han, and Minggao Ouyang. Optimization for a hybrid energy storage system in electric vehicles using dynamic programming approach. *Applied Energy*, 139:151–162, 2015. ISSN 03062619. doi: 10.1016/j.apenergy.2014.11.020.
- [60] Saeed Sepasi, Reza Ghorbani, and Bor Yann Liaw. Inline state of health estimation of lithium-ion batteries using state of charge calculation. *Journal of Power Sources*, 299: 246–254, 2015. ISSN 03787753. doi: 10.1016/j.jpowsour.2015.08.091.
- [61] Ziyou Song, Heath Hofmann, Jianqiu Li, Jun Hou, Xiaowu Zhang, and Minggao Ouyang. The optimization of a hybrid energy storage system at subzero temperatures: Energy management strategy design and battery heating requirement analysis. *Applied Energy*, 159:576–588, 2015. ISSN 03062619. doi: 10.1016/j.apenergy.2015.08.120.
- [62] Letao Zhu, Zechang Sun, Haifeng Dai, and Xuezhe Wei. A novel modeling methodology of open circuit voltage hysteresis for LiFePO₄ batteries based on an adaptive discrete Preisach model. *Applied Energy*, 155:91–109, 2015. ISSN 03062619. doi: 10.1016/j.apenergy.2015.05.103.
- [63] Hong Wen He, Yong Zhi Zhang, Rui Xiong, and Chun Wang. A novel Gaussian model based battery state estimation approach: State-of-Energy. *Applied Energy*, 151:41–48, 2015. ISSN 03062619. doi: 10.1016/j.apenergy.2015.04.062.
- [64] Van Huan Duong, Hany Ayad Bastawrous, Kai Chin Lim, Khay Wai See, Peng Zhang, and Shi Xue Dou. Online state of charge and model parameters estimation of the LiFePO₄ battery in electric vehicles using multiple adaptive forgetting factors recursive least-squares. *Journal of Power Sources*, 296:215–224, 2015. ISSN 03787753. doi: 10.1016/j.jpowsour.2015.07.041.
- [65] Minggao Ouyang, Zhengyu Chu, Languang Lu, Jianqiu Li, Xuebing Han, Xuning Feng, and Guangming Liu. Low temperature aging mechanism identification and lithium deposition in a large format lithium iron phosphate battery for different charge profiles.

- Journal of Power Sources*, 286:309–320, 2015. ISSN 03787753. doi: 10.1016/j.jpowsour.2015.03.178.
- [66] Andrés Suárez-García, Víctor Alfonsín, Santiago Urréjola, and Ángel Sánchez. Optimal parametrization of electrodynamical battery model using model selection criteria. *Journal of Power Sources*, 285:119–130, 2015. ISSN 03787753. doi: 10.1016/j.jpowsour.2015.03.076.
- [67] Cheng Zhang, Kang Li, Lei Pei, and Chunbo Zhu. An integrated approach for real-time model-based state-of-charge estimation of lithium-ion batteries. *Journal of Power Sources*, 283:24–36, 2015. ISSN 03787753. doi: 10.1016/j.jpowsour.2015.02.099.
- [68] José R. Villar, Enrique A. De La Cal, Javier Sedano, and Marco A. García Tamargo. Simple heuristics for enhancing GP learning. *Logic Journal of the IGPL*, 23(3): 472–484, 2014. ISSN 13689894. doi: 10.1093/jigpal/jzv003.
- [69] Kaustuv Nag and Nikhil R. Pal. A Multiobjective Genetic Programming-Based Ensemble for Simultaneous Feature Selection and Classification. *IEEE Transactions on Cybernetics*, 46(2):499–510, 2016. ISSN 21682267. doi: 10.1109/TCYB.2015.2404806.
- [70] Gustavo Olague and Leonardo Trujillo. Interest point detection through multiobjective genetic programming. *Applied Soft Computing Journal*, 12(8):2566–2582, 2012. ISSN 15684946. doi: 10.1016/j.asoc.2012.03.058.
- [71] Razieh Rezaee, Mahboobeh Houshmand, and Monireh Houshmand. Multi-objective optimization of QCA circuits with multiple outputs using genetic programming. *Genetic Programming and Evolvable Machines*, 14(1):95–118, 2013. ISSN 13892576. doi: 10.1007/s10710-012-9173-6.
- [72] William B Langdon Riccardo Poli and Nicholas F McPhee. *A Field Guide to Genetic Programming*. 2008. ISBN 978-1-4092-0073-4.
- [73] Riccardo Poli, Leonardo Vanneschi, William B. Langdon, and Nicholas Freitag McPhee. Theoretical results in genetic programming: The next ten years? *Genetic Programming and Evolvable Machines*, 11(3-4):285–320, 2010. ISSN 13892576. doi: 10.1007/s10710-010-9110-5.
- [74] M. Safari and C. Delacourt. Aging of a Commercial Graphite/LiFePO₄ Cell. *Journal of The Electrochemical Society*, 158(10):A1123, 2011. ISSN 00134651. doi: 10.1149/1.3614529.
- [75] Andreas Efstratiadis and Demetris Koutsoyiannis. One decade of multi-objective calibration approaches in hydrological modelling: a review. *Hydrological Sciences Journal*, 55(1):58–78, 2010. ISSN 0262-6667. doi: 10.1080/02626660903526292.

- [76] Roya Talebi, Mohammad M. Ghiasi, Hossein Talebi, Mehrdad Mohammadyian, Sohrab Zendejboudi, Milad Arabloo, and Alireza Bahadori. Application of soft computing approaches for modeling saturation pressure of reservoir oils. *Journal of Natural Gas Science and Engineering*, 20:8–15, 2014. ISSN 18755100. doi: 10.1016/j.jngse.2014.04.023.
- [77] Sundarapandian Vaidyanathan. Dynamics and control of Tokamak system with symmetric and magnetically confined plasma. *Int J ChemTech Res*, 8(6):795–803, 2015.
- [78] Xinye Cai, Xin Cheng, Zhun Fan, Erik Goodman, and Lisong Wang. An adaptive memetic framework for multi-objective combinatorial optimization problems: studies on software next release and travelling salesman problems. *Soft Computing*, 21(9): 2215–2236, 2017. ISSN 14337479. doi: 10.1007/s00500-015-1921-0.
- [79] Hisao Ishibuchi and Yusuke Nojima. Multiobjective Genetic Fuzzy Systems. In *Computational Intelligence, Collaboration, Fusion and Emergence*, pages 131–173. Springer, 2009. ISBN 9783662435052. doi: 10.1007/978-3-662-43505-2_77.
- [80] M. J. Gacto, M. Galende, R. Alcalá, and F. Herrera. METSK-HDe: A multiobjective evolutionary algorithm to learn accurate TSK-fuzzy systems in high-dimensional and large-scale regression problems. *Information Sciences*, 276:63–79, 2014. ISSN 00200255. doi: 10.1016/j.ins.2014.02.047.
- [81] Quanmin Zhu and Ahmad Taher. *Studies in Fuzziness and Soft Computing Complex System Modelling and Control Through Intelligent Soft Computations*. Springer, 2015. ISBN 9783319128825.
- [82] Ljung. perspectives on system identification ljung - Google Search. *Annual Reviews in Control*, 34(1):1–12, 2010.
- [83] Brijesh Kumar Giri, Jussi Hakanen, Kaisa Miettinen, and Nirupam Chakraborti. Genetic programming through bi-objective genetic algorithms with a study of a simulated moving bed process involving multiple objectives. *Applied Soft Computing Journal*, 13(5):2613–2623, 2013. ISSN 15684946. doi: 10.1016/j.asoc.2012.11.025.
- [84] David E Goldberg. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley Longman Publishing Co., Inc., 1986. ISBN 0201157675.
- [85] David E. Goldberg and John H. Holland. Genetic Algorithms and Machine Learning. *Machine Learning*, 3(2):95–99, 1988. ISSN 15730565. doi: 10.1023/A:1022602019183.
- [86] Hans-Georg Beyer and Hans-Paul Schwefel. Evolution strategies – A comprehensive introduction. *Natural Computing*, 1(1):3 – 52, 2002. ISSN 1572-9796. doi: 10.1023/A:1015059928466.

- [87] Xin Yao, Yong Liu, and Guangming Lin. Evolutionary programming made faster. *IEEE Transactions on Evolutionary Computation*, 3(2):82–102, 1999. ISSN 1089778X. doi: 10.1109/4235.771163.
- [88] R Storn and K Price. Differential Evolution — A simple and efficient adaptive scheme for global optimization over continuous spaces. *#Jgo#*, 11(4):341–359, 1997. ISSN 10754946.
- [89] Pier Luca Lanzi. Learning classifier systems: Then and now. *Evolutionary Intelligence*, 1(1):63–82, 2008. ISSN 18645909. doi: 10.1007/s12065-007-0003-3.
- [90] Gang Chen, Colin I.J. Douch, and Mengjie Zhang. Accuracy-based learning classifier systems for multistep reinforcement learning: A fuzzy logic approach to handling continuous inputs and learning continuous actions. *IEEE Transactions on Evolutionary Computation*, 20(6):953–971, 2016. ISSN 1089778X. doi: 10.1109/TEVC.2016.2560139.
- [91] Tim Kovacs. Learning Classifier Systems. In *Springer Handbook of Computational Intelligence*, pages 19–61. Springer, 2004. ISBN 978-1-4471-1058-3. doi: 10.1007/978-0-85729-416-6_2.
- [92] Pan Peter A N Bosman and Dirk Thierens. Expanding From Discrete To Continuous Estimation Of Distribution Algorithms: The {IDEA}. In *Parallel Problem Solving from Nature – {PPSN VI}*, volume 1, pages 767–776. Springer, Berlin, Heidelberg, 2000. ISBN 3-540-41056-2. doi: 10.1007/3-540-45356-3_75.
- [93] K. Deb. A population-based algorithm-generator for real-parameter optimization. *Soft Computing*, 9(4):236–253, 2005. ISSN 14327643. doi: 10.1007/s00500-004-0377-4.
- [94] Eduardo Segredo, Eduardo Lalla-Ruiz, Emma Hart, Ben Paechter, and Stefan Voß. Hybridisation of evolutionary algorithms through hyper-heuristics for global continuous optimisation. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, volume 10079 LNCS, pages 296–305. Springer, 2016. ISBN 9783319503486. doi: 10.1007/978-3-319-50349-3_25.
- [95] Xin-yuan Zhang, Student Member, Jun Zhang, Senior Member, and Yue-jiao Gong. Kuhn – Munkres Parallel Genetic Algorithm for the Set Cover Problem and Its Application to Large-Scale Wireless Sensor Networks. *IEEE Transactions on Evolutionary Computation*, 20(5):695–710, 2016.
- [96] Qingfu Zhang and Jing-jing Li. Distributed evolutionary algorithms and their models : A survey of the. *Applied Soft Computing Journal*, 34(2013):286–300, 2015. ISSN 1568-4946. doi: 10.1016/j.asoc.2015.04.061.

- [97] Theodore C. Belding. The Distributed Genetic Algorithm Revisited. 1995.
- [98] Agoston E. Eiben and Jim Smith. From evolutionary computation to the evolution of things. *Nature*, 521(7553):476–482, 2015. ISSN 0028-0836. doi: 10.1038/nature14544.
- [99] Jurgen Branke, Salvatore Greco, Roman Slowinski, and Piotr Zielniewicz. Learning Value Functions in Interactive Evolutionary Multiobjective Optimization. *IEEE Transactions on Evolutionary Computation*, 19(1):88–102, 2015. ISSN 1089-778X. doi: 10.1109/TEVC.2014.2303783.
- [100] Kalyanmoy Deb and Ram Bhushan Agrawal. Simulated Binary Crossover for Continuous Search Space. *Complex Systems*, 9(3):1–34, 1994. ISSN 08912513. doi: 10.1.1.26.8485Cached.
- [101] J. Knowles and D. Corne. The Pareto archived evolution strategy: a new baseline algorithm for Pareto multiobjective optimisation. In *Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406)*, volume 1, pages 98–105. IEEE, 1999. ISBN 0-7803-5536-9. doi: 10.1109/CEC.1999.781913.
- [102] Shahin Rostami and Ferrante Neri. Covariance matrix adaptation pareto archived evolution strategy with hypervolume-sorted adaptive grid algorithm. *Integrated Computer-Aided Engineering*, 23(4):313–329, 2016. ISSN 18758835. doi: 10.3233/ICA-160529.
- [103] M. Clerc and J. Kennedy. The particle swarm - explosion, stability, and convergence in a multidimensional complex space. *IEEE Transactions on Evolutionary Computation*, 6(1):58–73, 2002. ISSN 1089-778X. doi: 10.1109/4235.985692.
- [104] Margarita Reyes Sierra and Carlos A Coello Coello. LNCS 3410 - Improving PSO-Based Multi-objective Optimization Using Crowding, Mutation and ϵ -Dominance. In *Lecture Notes in Computer Science*, volume 1, pages 505–519. 2005. ISBN 978-3-540-31880-4. doi: 10.1007/978-3-540-31880-4_{_}35.
- [105] Cai Dai, Yuping Wang, and Miao Ye. A new multi-objective particle swarm optimization algorithm based on decomposition. *Information Sciences*, 325:541–557, 2015. ISSN 00200255. doi: 10.1016/j.ins.2015.07.018.
- [106] M. Basu. Multi-objective optimal reactive power dispatch using multi-objective differential evolution. *International Journal of Electrical Power & Energy Systems*, 82: 213–224, 2016. ISSN 01420615. doi: 10.1016/j.ijepes.2016.03.024.
- [107] Nikos Giannopoulos and Andreas C. Nearchou. Bi-criteria scheduling against restrictive common due dates using a multi-objective differential evolution algorithm. *IMA Journal*

- of Management Mathematics*, 3:dpw015, 2016. ISSN 1471-678X. doi: 10.1093/imaman/dpw015.
- [108] Marian B. Gorzałczany and Filip Rudziński. A multi-objective genetic optimization for fast, fuzzy rule-based credit classification with balanced accuracy and interpretability. *Applied Soft Computing Journal*, 40:206–220, 2016. ISSN 15684946. doi: 10.1016/j.asoc.2015.11.037.
- [109] Elham Mohagheghi and Mohammad-R Akbarzadeh-T. Multi-objective Estimation of Distribution Algorithm based on Voronoi and local search. In *Computer and Knowledge Engineering (ICCKE), 2016 6th International Conference on*, pages 54–59. IEEE, 2016.
- [110] Kuldeep Kumar Khajwaniya and Vibha Tiwari. Satellite image denoising using Weiner filter with SPEA2 algorithm. In *Proceedings of 2015 IEEE 9th International Conference on Intelligent Systems and Control, ISCO 2015*, pages 1–6. IEEE, 2015. ISBN 9781479964802. doi: 10.1109/ISCO.2015.7282324.
- [111] Bhargav Gadhvi, Vimal Savsani, and Vivek Patel. Multi-Objective Optimization of Vehicle Passive Suspension System Using NSGA-II, SPEA2 and PESA-II. *Procedia Technology*, 23:361–368, 2016. ISSN 22120173. doi: 10.1016/j.protcy.2016.03.038.
- [112] Meng Qinchao, Qiao Junfei, and Yang Cuili. Multi-objective Design of the Water Distribution Systems Using SPEA2. In *Control Conference (CCC), 2016 35th Chinese*, pages 2778–2783. IEEE, 2016. ISBN 2013110311001. doi: 10.1109/ChiCC.2016.7553785.
- [113] Oliver Chikumbo, Erik Goodman, and Kalyanmoy Deb. Approximating a multi-dimensional Pareto front for a land use management problem: A modified MOEA with an epigenetic silencing metaphor. In *2012 IEEE Congress on Evolutionary Computation, CEC 2012*, pages 1–9. IEEE, 2012. ISBN 9781467315098. doi: 10.1109/CEC.2012.6256170.
- [114] Carlos a Coello Coello and Gary B Lamont. *Applications Of Multi-Objective Evolutionary Algorithms*, volume 1. World Scientific, 2004. ISBN 981-256-106-4.
- [115] Radhia Azzouz, Slim Bechikh, and Lamjed Ben Said. Dynamic Multi-objective Optimization Using Evolutionary Algorithms: A Survey. In *Recent Advances in Evolutionary Multi-objective Optimization*, pages 31–70. Springer, 2017. ISBN 978-3-319-42977-9. doi: 10.1007/978-3-319-42978-6_2.
- [116] Bingdong Li, Student Member, Ke Tang, and Senior Member. Stochastic Ranking Algorithm for Many-Objective Optimization Based on Multiple Indicators. *IEEE Transactions on Evolutionary Computation*, 20(6):924–938, 2016.

- [117] Zhenan He and Gary Yen. Many-Objective Evolutionary Algorithms Based on Coordinated Selection Strategy. *IEEE Transactions on Evolutionary Computation*, 2016.
- [118] R.C. Purshouse and P.J. Fleming. On the evolutionary optimisation of many conflicting objectives. *IEEE Transactions on Evolutionary Computation*, 11(6):770–784, 2007.
- [119] Philip Hingston, Lyndon While, Senior Member, Phil Hingston, and Luigi Barone. A Faster Algorithm for Calculating Hypervolume Lyndon While A Faster Algorithm for Calculating Hypervolume. *IEEE transactions on evolutionary computation*, 10(2006): 29–38, 2011.
- [120] Eckart Zitzler and Lothar Thiele. Multiobjective evolutionary algorithms:a comparative case study and the strength pareto approach. *IEEE Trans. Evol. Comp.*, 3(4):257–271, 1999.
- [121] Zhenan He and Gary G. Yen. Visualization and Performance Metric in Many-Objective Optimization. *IEEE Transactions on Evolutionary Computation*, 20(3):386–402, 2016. ISSN 1089778X. doi: 10.1109/TEVC.2015.2472283.
- [122] Marco Laumanns, Lothar Thiele, Kalyanmoy Deb, and Eckart Zitzler. Combining Convergence and Diversity in Evolutionary Multiobjective Optimization. *Evolutionary Computation*, 10(3):263–282, 2002. ISSN 1063-6560. doi: 10.1162/106365602760234108.
- [123] M. Farina and P. Amato. A fuzzy definition of ‘optimality’ for many-criteria optimization problems. *IEEE Transactions on Systems, Man, and Cybernetics Part A:Systems and Humans.*, 34(3):315–326, 2004. ISSN 10834427. doi: 10.1109/TSMCA.2004.824873.
- [124] K. Sindhya, K. Miettinen, and K. Deb. A Hybrid Framework for Evolutionary Multi-Objective Optimization. *IEEE Transactions on Evolutionary Computation*, 17(4): 495–511, 2013. ISSN 1089-778X. doi: 10.1109/TEVC.2012.2204403.
- [125] Yutao Qi, Xiaoliang Ma, Fang Liu, Licheng Jiao, Jianyong Sun, and Jianshe Wu. MOEA/D with Adaptive Weight Adjustment. *Evolutionary Computation*, 22(2): 231–264, 2013. ISSN 1063-6560. doi: 10.1162/EVCO_a.00109.
- [126] Aimin Zhou, Qingfu Zhang, and Yaochu Jin. Approximating the set of pareto-optimal solutions in both the decision and objective spaces by an estimation of distribution algorithm. *IEEE Transactions on Evolutionary Computation*, 13(5):1167–1189, 2009. ISSN 1089778X. doi: 10.1109/TEVC.2009.2021467.
- [127] Mario Köppen and Kaori Yoshida. Substitute Distance Assignments in NSGA-II for Handling Many-Objective Optimization Problems. In *Emo07*, pages 727–741. Springer, 2007. ISBN 978-3-540-70927-5. doi: 10.1007/978-3-540-70928-2_55.

- [128] Salem F Adra and Peter J Fleming. Diversity Management in Evolutionary. *IEEE Transactions on Evolutionary Computation*, 15(2):183–195, 2011. ISSN 1089778X. doi: 10.1109/TEVC.2010.2058117.
- [129] Miqing Li, Shengxiang Yang, and Xiaohui Liu. Shift-based density estimation for pareto-based algorithms in many-objective optimization. *IEEE Transactions on Evolutionary Computation*, 18(3):348–365, 2014. ISSN 1089778X. doi: 10.1109/TEVC.2013.2262178.
- [130] Bingdong Li, Jinlong Li, Ke Tang, and Xin Yao. An improved Two Archive Algorithm for Many-Objective optimization. In *Proceedings of the 2014 IEEE Congress on Evolutionary Computation, CEC 2014*, pages 2869–2876. IEEE, 2014. ISBN 9781479914883. doi: 10.1109/CEC.2014.6900491.
- [131] Handing Wang, Licheng Jiao, and Xin Yao. Two_Arch2: An improved two-archive algorithm for many-objective optimization. *IEEE Transactions on Evolutionary Computation*, 19(4):524–541, 2015.
- [132] Indraneel Das and J. E. Dennis. Normal-Boundary Intersection: A New Method for Generating the Pareto Surface in Nonlinear Multicriteria Optimization Problems. *SIAM Journal on Optimization*, 8(3):631–657, 1998. ISSN 1052-6234. doi: 10.1137/S1052623496307510.
- [133] A. Messac, A. Ismail-Yahaya, and C. A. Mattson. The normalized normal constraint method for generating the Pareto frontier. *Structural and Multidisciplinary Optimization*, 25(2):86–98, 2003. ISSN 1615147X. doi: 10.1007/s00158-002-0276-1.
- [134] Benjamin Lacroix, Daniel Molina, and Francisco Herrera. Region-based memetic algorithm with archive for multimodal optimisation. *Information Sciences*, 367-368: 719–746, 2016. ISSN 00200255. doi: 10.1016/j.ins.2016.05.049.
- [135] Hui Li and Qingfu Zhang. Multiobjective Optimization Problems With Complicated Pareto Sets, MOEA/D and NSGA-II. *IEEE Transactions on Evolutionary Computation*, 13(2):284–302, 2009. ISSN 1941-0026. doi: 10.1109/TEVC.2008.925798.
- [136] R.K. Kesharwani, S.K. Panda, and S.K. Pal. Multi Objective Optimization of Friction Stir Welding Parameters for Joining of Two Dissimilar Thin Aluminum Sheets. *Procedia Materials Science*, 6:178–187, 2014. ISSN 22118128. doi: 10.1016/j.mspro.2014.07.022.
- [137] S. Monghasemi, M.R. Nikoo, M.A. Khaksar Fasaee, and J. Adamowski. A novel multi criteria decision making model for optimizing time-cost-quality trade-off problems in construction projects. *Expert Systems with Applications*, 42(6):3089–3104, 2015. ISSN 09574174. doi: 10.1016/j.eswa.2014.11.032.

- [138] Chih Ming Chen, Ying Ping Chen, and Qingfu Zhang. Enhancing MOEA/D with guided mutation and priority update for multi-objective optimization. In *2009 IEEE Congress on Evolutionary Computation, CEC 2009*, pages 209–216. IEEE, 2009. ISBN 9781424429592. doi: 10.1109/CEC.2009.4982950.
- [139] Vui Ann Shim, Kay Chen Tan, and Huajin Tang. Adaptive Memetic Computing for Evolutionary Multiobjective Optimization. *IEEE Transactions on Cybernetics*, 45(4): 610–621, 2015. ISSN 21682267. doi: 10.1109/TCYB.2014.2331994.
- [140] Saku Kukkonen and Kalyanmoy Deb. Improved Pruning of Non-Dominated Solutions Based on Crowding Distance for Bi-Objective Optimization Problems. In *Proceedings of the IEEE Congress on Evolutionary Computation*, pages 1179–1186. IEEE, 2006. ISBN 0-7803-9487-9. doi: 10.1109/CEC.2006.1688443.
- [141] Kalyanmoy Deb and Ram Bhushan Agrawal. Simulated Binary Crossover for Continuous Search Space. *Complex Systems*, 9(2):1–34, 1994. ISSN 08912513. doi: 10.1.1.26.8485Cached.
- [142] Thomas B. Reddy and David. Linden. *Linden's handbook of batteries*. Fourth edition, 2011. ISBN 9780071624213.
- [143] USABC. Electric Vehicle Battery Test Procedures Manual Rev. 2. Technical report, 1996.
- [144] Fei Feng, Rengui Lu, Guo Wei, and Chunbo Zhu. Online Estimation of Model Parameters and State of Charge of LiFePO₄ Batteries Using a Novel Open-Circuit Voltage at Various Ambient Temperatures. *Energies*, 8(4):2950–2976, 2015. ISSN 1996-1073. doi: 10.3390/en8042950.
- [145] Thomas Fisher. What Goes into A Tesla Model S Battery—And What It May Cost. *Green Car Reports*, 2013.
- [146] Matilda Klett, Rickard Eriksson, Jens Groot, Pontus Svens, Katarzyna Ciosek Högström, Rakel Wreland Lindström, Helena Berg, Torbjörn Gustafson, Göran Lindbergh, and Kristina Edström. Non-uniform aging of cycled commercial LiFePO₄//graphite cylindrical cells revealed by post-mortem analysis. *Journal of Power Sources*, 257(1):126–137, 2014. ISSN 03787753. doi: 10.1016/j.jpowsour.2014.01.105.
- [147] Masaki Yoshio, Ralph J. Brodd, and Akiya Kozawa. *Lithium-ion batteries: Science and technologies*. Springer New York, New York, NY, 2009. ISBN 9780387344447. doi: 10.1007/978-0-387-34445-4.
- [148] Weilin Luo, Chao Lv, Lixin Wang, and Chao Liu. Study on impedance model of Li-ion battery. In *Proceedings of the 2011 6th IEEE Conference on Industrial Electronics and*

- Applications, ICIEA 2011*, pages 1943–1947. IEEE, 2011. ISBN 9781424487554. doi: 10.1109/ICIEA.2011.5975910.
- [149] S. Buller, M. Thele, R.W. De Doncker, and E. Karden. Impedance-Based Simulation Models of Supercapacitors and Lithium-ion Batteries for Power Electronic Applications. In *IEEE Industry Applications Magazine*, volume 11, pages 742–747. IEEE, 2005. ISBN 0-7803-7883-0. doi: 10.1109/MIA.2005.1405828.
- [150] Reinhardt Klein, Nalin A. Chaturvedi, Jake Christensen, Jasim Ahmed, Rolf Findeisen, and Aleksandar Kojic. Electrochemical model based observer design for a lithium-ion battery. *IEEE Transactions on Control Systems Technology*, 21(2):289–301, 2013. ISSN 10636536. doi: 10.1109/TCST.2011.2178604.
- [151] Geobal. A technique for estimating the state of health of lithium batteries through a RVM observer. *EEE Trans. Power Electron*, 25(25):1013–1022, 2010.
- [152] Habiballah Rahimi-Eichi, Federico Baronti, and Mo Yuen Chow. Online adaptive parameter identification and state-of-charge coestimation for lithium-polymer battery cells. *IEEE Transactions on Industrial Electronics*, 61(4):2053–2061, 2014. ISSN 02780046. doi: 10.1109/TIE.2013.2263774.
- [153] Myounggu Park, Xiangchun Zhang, Myoungdo Chung, Gregory B. Less, and Ann Marie Sastry. A review of conduction phenomena in Li ion batteries. *Journal of Power Sources*, 195(24):7904–7929, 2010. ISSN 03787753.
- [154] Jiucui Zhang, Song Ci, Hamid Sharif, and Mahmoud Alahmad. An enhanced circuit-based model for single-cell battery. In *Applied Power Electronics Conference and Exposition (APEC), 2010 Twenty-Fifth Annual IEEE*, pages 672–675. IEEE, 2010.
- [155] Wengen Gao, Ming Jiang, and Youming Hou. Research on PNGV model parameter identification of LiFePO₄ Li-ion battery based on FMRLS. In *Proceedings of the 2011 6th IEEE Conference on Industrial Electronics and Applications, ICIEA 2011*, pages 2294–2297. IEEE, 2011. ISBN 9781424487554. doi: 10.1109/ICIEA.2011.5975974.
- [156] P Ramadass, Bala Haran, Ralph White, and Branko N Popov. Mathematical modeling of the capacity fade of Li - ion cells. *Journal of Power Sources*, 123(2):230–240, 2003. doi: 10.1016/S0378-7753(03)00531-7.
- [157] Min Chen, Student Member, and Gabriel A Rinc. Accurate Electrical Battery Model Capable of Predicting Runtime and I – V Performance. *IEEE transactions on energy conversion*, 21(2):504–511, 2006. ISSN 08858969. doi: 10.1109/TEC.2006.874229.
- [158] Taesic Kim, Student Member, and Wei Qiao. A Hybrid Battery Model Capable of Capturing Dynamic Circuit Characteristics and Nonlinear Capacity Effects. *IEEE Transactions on Energy Conversion*, 26(4):1172–1180, 2011.

- [159] Sachin Bhide and Taehyun Shim. Novel predictive electric Li-ion battery model incorporating thermal and rate factor effects. *IEEE Transactions on Vehicular Technology*, 60(3):819–829, 2011. ISSN 00189545. doi: 10.1109/TVT.2010.2103333.
- [160] Christophe Forgez, Dinh Vinh Do, Guy Friedrich, Mathieu Morcrette, and Charles Delacourt. Thermal modeling of a cylindrical LiFePO₄ graphite lithium-ion battery. *Journal of Power Sources*, 195(9):2961–2968, 2010. ISSN 03787753. doi: 10.1016/j.jpowsour.2009.10.105.
- [161] Laurianne Ménard, Guillaume Fontès, and Stéphan Astier. Dynamic energy model of a lithium-ion battery. *Math. Comput. Simul.*, 81(2):327–339, 2010. ISSN 03784754. doi: 10.1016/j.matcom.2010.07.026.
- [162] Michael A. Roscher and Dirk Uwe Sauer. Dynamic electric behavior and open-circuit-voltage modeling of LiFePO₄-based lithium ion secondary batteries. *Journal of Power Sources*, 196(1):331–336, 2011. ISSN 03787753. doi: 10.1016/j.jpowsour.2010.06.098.
- [163] K. M. Tsang, L. Sun, and W. L. Chan. Identification and modelling of Lithium ion battery. *Energy Conversion and Management*, 51(12):2857–2862, 2010. ISSN 01968904. doi: 10.1016/j.enconman.2010.06.024.
- [164] Jia-Ni Shen, Yi-Jun He, Zi-Feng Ma, Hong-Bin Luo, and Zi-Feng Zhang. Online state of charge estimation of lithium-ion batteries: A moving horizon estimation approach. *Chemical Engineering Science*, 154:42–53, 2016. ISSN 00092509. doi: 10.1016/j.ces.2016.06.061.
- [165] Christian Fleischer, Wladislaw Waag, Hans Martin Heyn, and Dirk Uwe Sauer. On-line adaptive battery impedance parameter and state estimation considering physical principles in reduced order equivalent circuit battery models part 2. Parameter and state estimation. *Journal of Power Sources*, 262:457–482, 2014. ISSN 03787753. doi: 10.1016/j.jpowsour.2014.03.046.
- [166] Htet Aung, Kay Soon Low, and Shu Ting Goh. State-of-charge estimation of lithium-ion battery using square root spherical unscented Kalman filter (Sqrt-UKFST) in nanosatellite. *IEEE Transactions on Power Electronics*, 30(9):4774–4783, 2015. ISSN 08858993. doi: 10.1109/TPEL.2014.2361755.
- [167] Zhongwei Deng, Lin Yang, Yishan Cai, and Hao Deng. Online Identification with Reliability Criterion and State of Charge Estimation Based on a Fuzzy Adaptive Extended Kalman Filter for Lithium-Ion Batteries. *Energies*, 9(6):472, 2016. ISSN 1996-1073. doi: 10.3390/en9060472.

- [168] Jianwei Li, Bin Jia, Michael Mazzola, and Ming Xin. On-line battery state of charge estimation using Gauss-Hermite quadrature filter. In *Conference Proceedings - IEEE Applied Power Electronics Conference and Exposition - APEC*, pages 434–438. IEEE, 2012. ISBN 9781457712159. doi: 10.1109/APEC.2012.6165856.
- [169] Jian Lin, Xidong Tang, Brian J Koch, Damon R Frisch, and Michael J Gielniak. Dynamically adaptive method for determining the state of charge of a battery, 2010.
- [170] C Bo, B Zhifeng, and C Binggang. State of charge estimation based on evolutionary neural network. *Energy Conversion and Management*, 49(10):2788–2794, 2008. ISSN 01968904. doi: 10.1016/j.enconman.2008.03.013.
- [171] Ondrej Linda, Edward James, William Ii, Student Member, Matthew Huff, Milos Manic, Senior Member, Ieee Vishu Gupta, Jasper Nance, Herbert Hess, Freeman Rufus Member, Ash Thakker, and Justin Govar. Intelligent Neural Network Implementation for SOCI Development of Li / CFx Batteries. In *Proc*, pages 57–62. IEEE IRCS, 2009.
- [172] Pu Shi Pu Shi, Chunguang Bu Chunguang Bu, and Yiwen Zhao Yiwen Zhao. The ANN models for SOC/BRC estimation of Li-ion battery. In *2005 IEEE International Conference on Information Acquisition*, number 1, pages 560–564. IEEE ICIA, 2005. ISBN 0-7803-9303-1. doi: 10.1109/ICIA.2005.1635151.
- [173] J A LEONARD, M A KRAMER, and L H UNGAR. Using Radial Basis Functions To Approximate a Function and Its Error-Bounds. *{IEEE} T. Neural Networ.*, 3(4): 624–626, 1992.
- [174] Yuang Shung Lee, Wei Yen Wang, and Tsung Yuan Kuo. Soft computing for battery state-of-charge (BSOC) estimation in battery string systems. *IEEE Transactions on Industrial Electronics*, 55(1):229–239, 2008. ISSN 02780046. doi: 10.1109/TIE.2007.896496.
- [175] Wei Xiang Shen, K. T. Chau, C. C. Chan, and Edward W C Lo. Neural network-based residual capacity indicator for nickel-metal hydride batteries in electric vehicles. *IEEE Transactions on Vehicular Technology*, 54(5):1705–1712, 2005. ISSN 00189545. doi: 10.1109/TVT.2005.853448.
- [176] J. Abonyi, R. Babuska, Hb Verbruggen, and F Szeifert. Incorporating prior knowledge in fuzzy model identification. *International Journal of Systems Science*, 31(5):657–667, 2000. ISSN 0020-7721. doi: 10.1080/002077200290966.
- [177] Hanmin Sheng and Jian Xiao. Electric vehicle state of charge estimation: Nonlinear correlation and fuzzy support vector machine. *Journal of Power Sources*, 281:131–137, 2015. ISSN 03787753. doi: 10.1016/j.jpowsour.2015.01.145.

- [178] Seyed Mohammad Rezvanizani, Zongchang Liu, Yan Chen, and Jay Lee. Review and recent advances in battery health monitoring and prognostics technologies for electric vehicle (EV) safety and mobility. *Journal of Power Sources*, 256:110–124, 2014. ISSN 03787753. doi: 10.1016/j.jpowsour.2014.01.085.
- [179] Luciano Sánchez, Inés Couso, and Manuela González. A design methodology for semi-physical fuzzy models applied to the dynamic characterization of LiFePO₄ batteries. *Applied Soft Computing Journal*, 14(PART B):269–288, 2014. ISSN 15684946. doi: 10.1016/j.asoc.2013.03.020.
- [180] M Berecibar, I Gandiaga, I Villarreal, N Omar, J Van Mierlo, and P Van den Bossche. Critical review of state of health estimation methods of Li-ion batteries for real applications. *Renewable & Sustainable Energy Reviews*, 56:572–587, 2016. doi: 10.1016/j.rser.2015.11.042.
- [181] Caihao Weng, Xuning Feng, Jing Sun, and Huei Peng. State-of-health monitoring of lithium-ion battery modules and packs via incremental capacity peak tracking. *Applied Energy*, 180:360–368, 2016. ISSN 03062619. doi: 10.1016/j.apenergy.2016.07.126.
- [182] Jürgen Remmlinger, Michael Buchholz, Markus Meiler, Peter Bernreuter, and Klaus Dietmayer. State-of-health monitoring of lithium-ion batteries in electric vehicles by on-board internal resistance estimation. *Journal of Power Sources*, 196(12):5357–5363, 2011. ISSN 03787753. doi: 10.1016/j.jpowsour.2010.08.035.
- [183] James D. Kozlowski. Electrochemical cell prognostics using online impedance measurements and model-based data fusion techniques. In *IEEE Aerospace Conference Proceedings*, volume 7, pages 3257–3270. IEEE, 2003. ISBN 078037651X. doi: 10.1109/AERO.2003.1234169.
- [184] Jonathan Højberg, Bryan D McCloskey, Johan Hjelm, Tejs Vegge, Keld Johansen, Poul Norby, and Alan C Luntz. An Electrochemical Impedance Spectroscopy Investigation of the Overpotentials in Li–O₂ Batteries. *ACS Applied Materials & Interfaces*, 7(7):4039–4047, 2015. ISSN 1944-8244. doi: 10.1021/am5083254.
- [185] Z. Deng, Z. Zhang, Y. Lai, J. Liu, J. Li, and Y. Liu. Electrochemical Impedance Spectroscopy Study of a Lithium/Sulfur Battery: Modeling and Analysis of Capacity Fading. *Journal of the Electrochemical Society*, 160(4):A553–A558, 2013. ISSN 0013-4651. doi: 10.1149/2.026304jes.
- [186] L H J Raijmakers, D L Danilov, J P M van Lammeren, M J G Lammers, and P H L Notten. Sensorless battery temperature measurements based on electrochemical impedance spectroscopy. *J. Power Sources*, 247:539–544, 2014. ISSN 03787753. doi: 10.1016/j.jpowsour.2013.09.005.

- [187] Scott J. Moura, Nalin A. Chaturvedi, and Miroslav Krstić. Adaptive Partial Differential Equation Observer for Battery State-of-Charge/State-of-Health Estimation Via an Electrochemical Model. *Journal of Dynamic Systems, Measurement, and Control*, 136(1):011015, 2013. ISSN 0022-0434. doi: 10.1115/1.4024801.
- [188] Yi-Hsien Chiang, Wu-Yang Sean, and Jia-Cheng Ke. Online estimation of internal resistance and open-circuit voltage of lithium-ion batteries in electric vehicles. *J. Power Sources*, 196(8):3921–3932, 2011. ISSN 03787753. doi: 10.1016/j.jpowsour.2011.01.005.
- [189] Pérez G., Garmendia M., Reynaud J.F., Crego J., and Viscarret U. Enhanced closed loop State of Charge estimator for lithium-ion batteries based on Extended Kalman Filter. *Applied Energy*, 155:834–845, 2015. ISSN 03062619 (ISSN). doi: 10.1016/j.apenergy.2015.06.063.
- [190] Seongjun Lee, Jonghoon Kim, Jaemoon Lee, and B. H. Cho. State-of-charge and capacity estimation of lithium-ion battery using a new open-circuit voltage versus state-of-charge. *Journal of Power Sources*, 185(2):1367–1373, 2008. ISSN 03787753. doi: 10.1016/j.jpowsour.2008.08.103.
- [191] Geobal. A technique for estimating the state of health of lithium batteries through a RVM observer. *EEE Trans. Power Electron*, 25(25):1013–1022, 2010.
- [192] Hans-Georg Schweiger, Ossama Obeidi, Oliver Komesker, André Raschke, Michael Schiemann, Christian Zehner, Markus Gehnen, Michael Keller, and Peter Birke. Comparison of Several Methods for Determining the Internal Resistance of Lithium Ion Cells. *Sensors*, 10(6):5604–5625, 2010. ISSN 1424-8220. doi: 10.3390/s100605604.
- [193] Marco Landi and George Gross. Measurement techniques for online battery state of health estimation in vehicle-to-grid applications. *IEEE Transactions on Instrumentation and Measurement*, 63(5):1224–1234, 2014. ISSN 00189456. doi: 10.1109/TIM.2013.2292318.
- [194] Caihao Weng, Yujia Cui, Jing Sun, and Huei Peng. On-board state of health monitoring of lithium-ion batteries using incremental capacity analysis with support vector regression q. *Journal of Power Sources*, 235:36–44, 2013.
- [195] Limei Wang, Chaofeng Pan, Liang Liu, Yong Cheng, and Xiuliang Zhao. On-board state of health estimation of LiFePO₄ battery pack through differential voltage analysis. *Applied Energy*, 168:465–472, 2016. ISSN 03062619. doi: 10.1016/j.apenergy.2016.01.125.
- [196] Caihao Weng, Jing Sun, and Huei Peng. A unified open-circuit-voltage model of lithium-ion batteries for state-of-charge estimation and state-of-health monitoring.

- Journal of Power Sources*, 258:228–237, 2014. ISSN 03787753. doi: 10.1016/j.jpowsour.2014.02.026.
- [197] Xuning Feng, Jianjun Jianqiu Li, Minggao Ouyang, Languang Lu, and Xiangming He. Using probability density function to evaluate the state of health of lithium-ion batteries. *Journal of Power Sources*, 232:209–218, 2013. ISSN 03787753. doi: 10.1016/j.jpowsour.2013.01.018.
- [198] Matthieu Dubarry, Vojtech Svoboda, Ruey Hwu, and Bor Yann Liaw. Incremental Capacity Analysis and Close-to-Equilibrium OCV Measurements to Quantify Capacity Fade in Commercial Rechargeable Lithium Batteries. *Electrochemical and Solid-State Letters*, 9(10):A454, 2006. ISSN 10990062. doi: 10.1149/1.2221767.
- [199] Matthieu Dubarry, Cyril Truchot, and Bor Yann Liaw. Synthesize battery degradation modes via a diagnostic and prognostic model. *Journal of Power Sources*, 219:204–216, 2012. ISSN 03787753. doi: 10.1016/j.jpowsour.2012.07.016.
- [200] Caihao Weng, Xuning Feng, Jing Sun, and Huei Peng. State-of-health monitoring of lithium-ion battery modules and packs via incremental capacity peak tracking. *Applied Energy*, 180:360–368, 2016. ISSN 03062619. doi: 10.1016/j.apenergy.2016.07.126.
- [201] A. J. Smith, J. C. Burns, and J. R. Dahn. High-Precision Differential Capacity Analysis of LiMn₂O₄/graphite Cells. *Electrochemical and Solid-State Letters*, 14(4):A39, 2011. ISSN 10990062. doi: 10.1149/1.3543569.
- [202] Jun Xu, Binggang Cao, Zheng Chen, and Zhongyue Zou. An online state of charge estimation method with reduced prior battery testing information. *International Journal of Electrical Power and Energy Systems*, 63:178–184, 2014. ISSN 01420615. doi: 10.1016/j.ijepes.2014.06.017.
- [203] Hui Li and Qingfu Zhang. Multiobjective Optimization Problems With Complicated Pareto Sets, MOEA/D and NSGA-II. *IEEE Transactions on Evolutionary Computation*, 13(2):284–302, 2009. ISSN 1941-0026. doi: 10.1109/TEVC.2008.925798.
- [204] Indraneel Das and J. E. Dennis. Normal-Boundary Intersection: A New Method for Generating the Pareto Surface in Nonlinear Multicriteria Optimization Problems. *SIAM Journal on Optimization*, 8(3):631–657, 1998. ISSN 1052-6234. doi: 10.1137/S1052623496307510.
- [205] William La Cava, Kourosh Danai, Lee Spector, Paul Fleming, Alan Wright, and Matthew Lackner. Automatic identification of wind turbine models using evolutionary multiobjective optimization. *Renewable Energy*, 87:892–902, 2016. ISSN 18790682. doi: 10.1016/j.renene.2015.09.068.

- [206] Nuno Lourenço, Francisco B. Pereira, and Ernesto Costa. Unveiling the properties of structured grammatical evolution. *Genetic Programming and Evolvable Machines*, 17(3):251–289, 2016. ISSN 13892576. doi: 10.1007/s10710-015-9262-4.
- [207] Michael O’Neill and Conor Ryan. Grammatical evolution. *IEEE Transactions on Evolutionary Computation*, 5(4):349–358, 2001. ISSN 1089778X. doi: 10.1109/4235.942529.
- [208] Ian Dempsey, Anthony Brabazon, and Michael O’Neill. Constant creation and adaptation in grammatical evolution. *Studies in Computational Intelligence*, 194(1): 69–104, 2009. ISSN 1860949X. doi: 10.1007/978-3-642-00314-1_5.
- [209] Anthony Brabazon, Michael O’Neill, and Ian Dempsey. An introduction to evolutionary computation in finance. *IEEE Computational Intelligence Magazine*, 3(4):42–55, 2008. ISSN 1556603X. doi: 10.1109/MCI.2008.929841.
- [210] Robert I. McKay, Nguyen Xuan Hoai, Peter Alexander Whigham, Yin Shan, and Michael O’Neill. Grammar-based Genetic programming: A survey. *Genetic Programming and Evolvable Machines*, 11(3-4):365–396, 2010. ISSN 13892576. doi: 10.1007/s10710-010-9109-y.
- [211] Leonardo Vanneschi, Mauro Castelli, and Sara Silva. A survey of semantic methods in genetic programming. *Genetic Programming and Evolvable Machines*, 15(2):195–214, 2014. ISSN 13892576. doi: 10.1007/s10710-013-9210-0.
- [212] Michael Fenton, Ciaran McNally, Jonathan Byrne, Erik Hemberg, James McDermott, and Michael O’Neill. Automatic innovative truss design using grammatical evolution. *Automation in Construction*, 39:59–69, 2014. ISSN 09265805. doi: 10.1016/j.autcon.2013.11.009.
- [213] L. Sánchez, I. Couso, and J. A. Corrales. Combining GP operators with SA search to evolve fuzzy rule based classifiers. *Information Sciences*, 136(1-4):175–191, 2001. ISSN 00200255. doi: 10.1016/S0020-0255(01)00146-3.
- [214] Luciano Sánchez and José R. Villar. Obtaining transparent models of chaotic systems with multi-objective simulated annealing algorithms. *Information Sciences*, 178(4): 952–970, 2008. ISSN 00200255. doi: 10.1016/j.ins.2007.09.029.
- [215] Santiago Garcia, Fermin Gonzalez, and Luciano Sanchez. Evolving Fuzzy Rule Based Classifiers with GA-P: A Grammatical Approach. In *Genetic Programming, Proceedings of EuroGP’99*, volume 1598, pages 203–210. Springer, 1999. ISBN 3-540-65899-8. doi: doi:10.1007/3-540-48885-5_17.

- [216] Ekaterina J. Vladislavleva, Guido F. Smits, and Dick den Hertog. Order of nonlinearity as a complexity measure for models generated by symbolic regression via pareto genetic programming. *IEEE Transactions on Evolutionary Computation*, 13(2):333–349, 2009. ISSN 1089778X. doi: 10.1109/TEVC.2008.926486.
- [217] Ji Ni, Russ H. Driberg, and Peter I. Rockett. The use of an analytic quotient operator in genetic programming. *IEEE Transactions on Evolutionary Computation*, 17(1): 146–152, 2013. ISSN 1089778X. doi: 10.1109/TEVC.2012.2195319.
- [218] Ji Ni and Peter Rockett. Tikhonov Regularization as a Complexity Measure in Multiobjective Genetic Programming. *IEEE Transactions on Evolutionary Computation*, 19(2):157–166, 2015. ISSN 1089778X. doi: 10.1109/TEVC.2014.2306994.
- [219] Les M. Howard and Donna J. D’Dangelo. The GA-P: A Genetic Algorithm and Genetic Programming Hybrid. *IEEE Expert-Intelligent Systems and their Applications*, 10(3): 11–15, 1995. ISSN 08859000. doi: 10.1109/64.393137.
- [220] Oscar Cordón, Enrique Herrera-Viedma, María Luque, Félix De Moya, and Carmen Zarco. Analyzing the performance of a multiobjective GA-P algorithm for learning fuzzy queries in a machine learning environment. In *Lecture Notes in Artificial Intelligence (Subseries of Lecture Notes in Computer Science)*, volume 2715, pages 611–619, 2003. ISBN 3-540-40383-3. doi: 10.1007/3-540-44967-1_73.
- [221] Gisele L. Pappa and Alex A. Freitas. Evolving rule induction algorithms with multi-objective grammar-based genetic programming. *Knowledge and Information Systems*, 19(3):283–309, 2009. ISSN 02191377. doi: 10.1007/s10115-008-0171-1.
- [222] Mohamed Bader-El-Den, Riccardo Poli, and Shaheen Fatima. Evolving timetabling heuristics using a grammar-based genetic programming hyper-heuristic framework. *Memetic Computing*, 1(3):205–219, 2009. ISSN 18659284. doi: 10.1007/s12293-009-0022-y.
- [223] Giovanni Guizzo, Silvia R. Vergilio, and Aurora T R Pozo. Evaluating a Multi-objective Hyper-Heuristic for the Integration and Test Order Problem. In *Proceedings - 2015 Brazilian Conference on Intelligent Systems, BRACIS 2015*, pages 1–6, New York, New York, USA, 2016. ACM Press. ISBN 9781509000166. doi: 10.1109/BRACIS.2015.11.
- [224] Urvesh Bhowan, Mark Johnston, Mengjie Zhang, and Xin Yao. Evolving diverse ensembles using genetic programming for classification with unbalanced data. *IEEE Transactions on Evolutionary Computation*, 17(3):368–386, 2013. ISSN 1089778X. doi: 10.1109/TEVC.2012.2199119.

- [225] Laura Dioşan and Anca Andreica. Multi-objective breast cancer classification by using multi-expression programming. *Applied Intelligence*, 43(3):499–511, 2015. ISSN 0924669X. doi: 10.1007/s10489-015-0668-8.
- [226] Jakub Mid, Martin Pilat, Klara Pekova, and Roman Neruda. Multi-objective genetic programming for dataset similarity induction. In *Proceedings - 2015 IEEE Symposium Series on Computational Intelligence, SSCI 2015*, pages 1576–1582. IEEE, 2016. ISBN 9781479975600. doi: 10.1109/SSCI.2015.222.
- [227] Christopher Lazarus. Pareto-dominance based MOGP for evolving soccer agents. In *Proceedings - 2015 IEEE Symposium Series on Computational Intelligence, SSCI 2015*, pages 280–287. IEEE, 2016. ISBN 9781479975600. doi: 10.1109/SSCI.2015.49.
- [228] Tomoyuki Hiroyasu, Toshihide Shiraishi, and Tomoya Yoshida. A feature transformation method using multiobjective genetic programming for two-class classification. In *2015 IEEE Congress on Evolutionary Computation (CEC)*, pages 2989–2995. IEEE, 2015. ISBN 978-1-4799-7492-4. doi: 10.1109/CEC.2015.7257261.
- [229] Pu Wang, Ke Tang, Thomas Weise, E. P K Tsang, and Xin Yao. Multiobjective genetic programming for maximizing ROC performance. *Neurocomputing*, 125:102–118, 2014. ISSN 09252312. doi: 10.1016/j.neucom.2012.06.054.
- [230] Edmund K. Burke, Michel Gendreau, Matthew Hyde, Graham Kendall, Gabriela Ochoa, Ender Oezcan, and Rong Qu. Hyper-heuristics : A Survey of the State of the Art. Technical Report 12, University of Nottingham, School of Computer Science, Nottingham, UK, 2010.
- [231] Su Nguyen, Mengjie Zhang, Mark Johnston, and Kay Chen Tan. Automatic design of scheduling policies for dynamic multi-objective job shop scheduling via cooperative coevolution genetic programming. *IEEE Transactions on Evolutionary Computation*, 18(2):193–208, 2014. ISSN 1089778X. doi: 10.1109/TEVC.2013.2248159.
- [232] Oscar Cordon, Enrique Herrera-Viedma, María Luque, Félix De Moya, and Carmen Zarco. Analyzing the performance of a multiobjective GA-P algorithm for learning fuzzy queries in a machine learning environment. *Lecture Notes in Artificial Intelligence (Subseries of Lecture Notes in Computer Science)*, 2715:611–619, 2003. ISSN 03029743. doi: doi:10.1007/3-540-44967-1_73.
- [233] Yuviny Echevarría Cartaya, Luciano Sánchez Ramos, and Cecilio Blanco Viejo. Li-Ion Battery charge/discharge benchmark, 2017.
- [234] Eckart Zitzler, Kalyanmoy Deb, and Lothar Thiele. Comparison of Multiobjective Evolutionary Algorithms: Empirical Results. *Evolutionary Computation*, 8(2):173–195, 2000. ISSN 1063-6560. doi: 10.1162/106365600568202.

- [235] Kalyanmoy Deb, Lothar Thiele, Marco Laumanns, and Eckart Zitzler. Scalable multi-objective optimization test problems. In *Proceedings of the 2002 Congress on Evolutionary Computation, CEC 2002*, volume 1, pages 825–830. IEEE, 2002. ISBN 0-7803-7282-4. doi: 10.1109/CEC.2002.1007032.
- [236] Eckart Zitzler, Marco Laumanns, Lothar Thiele, Carlos M Fonseca, Viviane Grunert Da Fonseca, M C Fonseca, and G V Fonseca. Why quality assessment of multiobjective optimizers is difficult. In *Gecco*, pages 666–674. Morgan Kaufmann Publishers Inc., 2002. ISBN 1-55860-878-8.
- [237] Eckart Zitzler, Lothar Thiele, Marco Laumanns, Carlos M. Fonseca, and Viviane Grunert Da Fonseca. Performance assessment of multiobjective optimizers: An analysis and review. *IEEE Transactions on Evolutionary Computation*, 7(2):117–132, 2003. ISSN 1089778X. doi: 10.1109/TEVC.2003.810758.
- [238] Yuviny Echevarría, Luciano Sánchez, and Cecilio Blanco. Assessment of Multi-Objective Optimization Algorithms for parametric identification of a Li-Ion battery model. In Francisco Martínez-Álvarez, Alicia Troncoso, Héctor Quintián, and Emilio Corchado, editors, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, volume 9648, chapter Assessment, pages 250–260. Springer International Publishing, Cham, 2016. ISBN 9783319320335. doi: 10.1007/978-3-319-32034-2_21.
- [239] Thomas Harvey Rowan. *Functional Stability Analysis of Numerical Algorithms*. PhD thesis, University of Texas at Austin, 1990.