



COMILLAS

UNIVERSIDAD PONTIFICIA

ICAI

Tesis doctoral

Desarrollo de la metodología “DSRM-MML”, de seguimiento continuo de la degradación de un *BESS* operando en regulación

Autor: Ing. José Ignacio Alvarez-Monteserin García

Director: Dr. Miguel Ángel Sanz Bobi

Feb-2024

A mis padres, esposa e hijas.

“Sin la investigación, el futuro se para en el presente”

Resumen

En el contexto mundial actual de transición energética en el que vivimos, los sistemas de almacenamiento de energía han adquirido una gran “popularidad”, debido al cambio de paradigma acaecido en los vehículos de transporte, (políticas de *cero emisiones*) y a la necesidad de almacenamiento de energía, renovable principalmente.

Así, los sistemas de almacenamiento de energía mediante baterías de iones de litio (LIB), han tomado, por el momento, una posición preferente en el mercado por su alta densidad energética. Siendo este tipo de tecnología la más utilizada para los grandes sistemas de almacenamiento, empleados en vehículos y centrades eléctricas principalmente.

Estos grandes sistemas de almacenamiento son generalmente costosos, debido a la necesidad de litio para su fabricación, por lo que emplear los recursos adecuados en su mantenimiento es sumamente importante para garantizar su seguridad y durabilidad. En esta línea, se han desarrollado los trabajos e investigaciones de esta tesis, ya que una característica muy importante de estos sistemas es su degradación.

Los BESS (Battery Energy Storage System) sufren degradación por su operación y con el paso del tiempo, por lo que conocer el nivel de degradación es primordial para su seguridad, para operar correctamente el BESS (optimización del uso) y para poder cuantificar su capacidad en todo momento, ya que como se ha mencionado, esta está en constante detrimento.

Los mecanismos y factores que afectan a la degradación de las LIB son muchos, p. ej., la intensidad de carga-descarga o el número de ciclos, como factores más determinantes. En cualquier caso, el objetivo de esta tesis no es estudiar los mecanismos que le suceden a las LIB que hacen que se degrade, ni tampoco se entrará en valorar los factores que afectan a su vida. En lo que a esta tesis se refiere, la degradación de una LIB se “podría definir” como la pérdida de capacidad que sufre dicha LIB, y el objetivo de la tesis será estimar o cuantificar esa pérdida, a lo largo de su vida útil, en función de esos factores de operación que hacen que se degrade.

Son muchos los métodos actuales para estimar la degradación de las LIB existentes en la literatura, pero no así los métodos empleables a nivel práctico para las LIB operadas en la vida real. Así se muestra en la revisión del estado del arte, donde además se pone el foco en el mantenimiento y sus amplias

posibilidades de mejora, demostrando que el conocimiento de la degradación del BESS posibilita su utilización para un mantenimiento predictivo eficiente.

Por tanto, esta tesis tiene su principal motivación en el desarrollo de un indicador que, de manera eficiente, establece la degradación de las LIB y una metodología que permite aplicar este indicador en condiciones de operación muy volátiles.

Así, en el transcurso de esta tesis, se ha elaborado un nuevo indicador que da a conocer la degradación existente en las LIB y posibilita su uso práctico en los dispositivos que emplean este tipo de baterías, como p.ej. vehículos eléctricos, BESS, etc. Motivación que ha llevado a dar solución a otro de los grandes problemas planteados en el estado del arte, ya que en ningún momento hay que interrumpir la operación ni la disponibilidad del BESS para poder estimar su degradación.

En esta tesis también se ha llevado a cabo la aplicación del nuevo indicador, con modelos de “Machine Learning” (ML), para estimar la degradación de un BESS operando en regulación de frecuencia en una red eléctrica real, con datos de un año y medio. Esta estimación de la degradación, obtenida con la metodología DSRM-MML desarrollada en la tesis, se ha contrastado con la medida en la prueba de capacidad anual (*Capacity Test*) llevada a cabo en el BESS, permitiendo comparar cuantitativamente la degradación de la capacidad sufrida en las diferentes partes (*racks*) que forman del BESS.

Como ultimo objetivo y motivación de esta tesis, se han encontrado oportunidades de mejora (por medio del estado del arte) en el mantenimiento de los BESS. Así, se han estudiado cuatro *planes de mantenimiento* elaborados por “actores” del sector, a los que se han aplicado, en esta tesis, las mejoras surgidas por la aplicación del nuevo indicador de salud y la metodología desarrollada. Esto ha hecho posible mejorar la eficiencia en su mantenimiento, aplicando los recursos sólo donde son necesarios, y por tanto posibilitando el ahorro de costes operativos y de mantenimiento.

Abstract

In the current global context of energy transition, energy storage systems have become very "popular" due to the paradigm shift in transport vehicles, (zero-emission policies) and the need for energy storage, mainly renewable energy.

Thus, energy storage systems using lithium-ion batteries (LIB) have taken, at the moment, a preferential position in the market due to their high energy density. This type of technology is the most widely used for large storage systems, mainly used in vehicles and power plants.

These large batteries are usually expensive, due to the fact that they use lithium for their manufacture, so using adequate resources in their maintenance is extremely important to ensure their safety and durability. The work and research of this thesis have been developed along these guidelines, since the main characteristic of these systems is their degradation.

The BESS (Battery Energy Storage System) suffer degradation by use and by the passage of time, so knowing the level of degradation is essential for its safety, to operate the BESS correctly (optimisation of usage) and to be able to quantify their capacity at all times, since, as we have mentioned, this is in constant detriment.

The mechanisms and factors that affect the degradation of LIBs are many, e.g., the charge-discharge current or the number of cycles, as the most determining factors. In any case, the aim of this thesis is not to investigate the mechanisms that occur in the LIBs which causes them to degrade, neither will it evaluate the factors that affect their lifetime. As far as this thesis is concerned, the degradation of a LIB could be "defined" as the reduction in capacity that the LIB suffers, and the aim of the thesis will be to estimate or quantify this *face capacity* over its lifetime, depending on the operating factors that degrade it.

There are many current methods for estimating the degradation of lithium-ion batteries in the literature, but not the methods that can be used in practice for LIBs operated in real life. This is shown in the *literature review*, where in addition, the focus is placed on maintenance and its great opportunities for improvement, thus demonstrating that, by knowing the degradation of the BESS it can be used for efficient predictive maintenance.

Therefore, the motivation for this thesis aims to develop a health indicator that, in an efficient way, establishes the degradation of LIBs and a methodology that allows the application of this indicator in very volatile operating conditions.

Thus, during this thesis, a new indicator has been developed that shows the existing degradation of LIBs, and enables its practical use in devices that employ this kind of batteries, e.g., electric vehicles, BESS, etc. This motivation has led to a new solution to the other main problem identified in the state-of-the-art, since at no time does the operation or availability of the BESS have to be interrupted in order to estimate its degradation.

This thesis has also implemented the application of the new indicator, with Machine Learning models, to estimate the degradation of a BESS operating in frequency regulation in a real power grid, with data from a year and a half. This degradation estimation, obtained with the methodology DSRM-MML developed in this thesis, has been contrasted with that measured in the annual *Capacity Test* carried out in the BESS, allowing to know quantitatively the degradation of the capacity suffered in the different parts (racks) that form the BESS.

Finally, as the last objective and motivation of this thesis, improvement opportunities have been found (by means of the *literature review*) in the BESS maintenance. Thus, four *maintenance plans* elaborated by "*players*" of the sector have been studied, to which the improvements obtained by applying the new health indicator and the developed methodology have been applied in this thesis. This has facilitated the maintenance efficiency improvement, focusing resources only where they are needed, and therefore making it possible to save operational and maintenance costs.

Capítulo de agradecimientos

Quisiera expresar en este importante capítulo, mi más sincero agradecimiento a todas esas personas que, de una u otra forma, han contribuido a la realización de esta tesis, fruto de largas, pero motivadoras horas de trabajo durante los últimos cinco años. Agradecimientos que expongo en orden cronológico.

En primer lugar, a mis padres para expresarles mi más profundo agradecimiento por la educación que me han dado y su incondicional apoyo durante estos años, así como a mi esposa e hijas, por el tiempo que *“les he robado”* y privado de mi compañía y atención.

Agradecer a la Universidad Pontificia Comillas en general, y a su dirección y director de ICAI, Dr. Antonio Muñoz San Roque, en particular, por *“abrirme en su día la puerta”* hacia esta oportunidad de colaboración e investigación.

A mi director de tesis, Miguel Angel Sanz Bobi, agradecerle la ayuda, la paciencia y enseñanza que me *ha prestado* en este viaje de cinco largos años inolvidables.

A mi empresa Endesa S.A y su matriz Enel SpA,. En primer lugar, a Cruz Arrese, Martin Madrid y Francisco Mariscal, por ayudarme a *abrir esa puerta*. En especial, a mi antiguo director Antonio Crisol, del que obtuve su apoyo desde el inicio y puso a mi disposición recursos sin los cuales, esta tesis se hubiera visto *mermada*. Y a Cesar Hernandez, del que tuve su apoyo incondicional también en todo momento, al igual que mis compañeros de equipo, por su apoyo moral.

A todos mis profesores que me han guiado y enseñado en los primeros años, y en especial a Aurelio Garcia C. y Eugenio Sanchez U., por su especial dedicación. Al personal de administración, y en especial a Ajida Lavtar, a Isabel Morata y a Jesús Merino, por su amabilidad extrema. Sin olvidarme de Juan C. del Real, Rafael Palacios y Mario Castro, por sus consejos y ayuda final prestada.

Agradecimientos también a mi familia y amigos que se han preocupado durante estos años y me han dado su cariño y apoyo.

A mis compañeros de viaje, Roberto Barrella, Geovany Maryland y especialmente a Carlos Vallez F., por sus ánimos, consejos y confianza.

Agradecimientos al *Centro de Excelencia de Pronósticos Ames de la NASA*, al *Centro de Ingeniería Avanzada del Ciclo de Vida (CALCE)* y al *Oxford University Research Archive (ORA)* de la Universidad de Oxford, por las publicaciones de sus datos, que a tantos investigadores han ayudado y motivado en sus tesis y artículos.

Índice de Contenido

Capítulo 1.....	23
Introducción y Estado del Arte.....	23
1.1. Introducción	24
1.1.1 Motivación.....	25
1.1.2 Objetivos de la tesis.....	27
1.1.3 Esquema de la tesis doctoral	28
1.2. Estado del arte.....	29
1.2.1 Motivación.....	29
1.2.2 Introducción	29
1.2.3 Estado del arte referido a métodos de estimación del SOH aplicado a LIB de laboratorio.	34
1.2.4 Estado del arte. Métodos existentes sobre la degradación de los sistemas de almacenamiento de energía por baterías en entorno real.	38
1.2.5 Estado del arte relativo al mantenimiento de los BESS	46
1.3. Puntos destacados del estado del arte.....	48
1.3.1 Referente a LIB y BESS	48
1.3.2 Referente al mantenimiento aplicado a BESS	50
Capítulo 2.....	51
Identificación de un nuevo indicador de salud (DSR)	51
2.1. Introducción y motivación.	52
2.2. Conjuntos de datos utilizados en este Capítulo	53
2.3. Propuesta de un nuevo indicador de degradación de las baterías 	55
2.3.1 Introducción del HI	56
2.3.2 Definición del indicador de salud	57
2.3.3 Ratio de velocidad de degradación (DSR). Correlación con el SOH	59
2.3.4 Ventajas del uso de (DSR)	62
2.3.5 DSR como indicador de salud.	63
2.4. Validación del HI como estimador del SOH	67

2.4.1	Modelo Gaussiano. GPR	67
2.4.2	Modelo MLPNN.	73
2.5.	Uso del DSR con corrientes no constantes.....	76
2.4.3	Análisis de los del conjunto de datos	76
2.4.4	Indicador DSRv subyacente al DSR.	80
2.6.	Puntos destacados del capítulo	85
Capítulo 3.....		87
Arquitectura y características del BESS en estudio..		87
3.1. Motivación		88
3.2. Introducción.....		88
3.3. Arquitectura de los BESS		89
3.4. Balanceo de celdas en un BESS.....		94
3.4.1	Causas del desequilibrio de celdas	95
3.4.2	Repercusión del desequilibrio celular.	96
3.4.3	Tipos de equilibrio celular	98
3.4.4	Beneficios del equilibrado de celdas	102
3.5. Especificaciones eléctricas y variables del BESS de la tesis. ...		102
3.6. Medida de la capacidad de los BMS del BESS de la tesis.....		106
3.7. Puntos destacados del capítulo		107
Capítulo 4.....		110
Aplicación del nuevo DSR a un BESS operando en regulación de frecuencia		110
4.1. Motivación.....		111
4.2. Introducción.....		111
4.3. Aplicando el indicador DSR a un BESS.		112
4.3.1	Envejecimiento del BESS	112
4.3.2	Evaluación de la degradación de un BESS basándose en la sensibilidad del indicador DSR.....	118
4.4. Necesidad de adaptación del DSR al modo de operación del BESS.		120
4.4.1	Situación de partida.....	120
4.4.2	Características del modo de operación del BESS.....	122

4.5. Entorno propuesto para la evaluación de la condición de un BESS	127
4.5.1 Necesidades de medición de las curvas de datos.....	128
4.6. Nuevo indicador DSRa adaptado a las necesidades de la operación del BESS.....	130
4.6.1 Desarrollo del indicador DSRa	132
4.6.2 Primer análisis de sensibilidad del DSRa.....	133
4.7. Metodología DSR Multi-Model Machine Learning para la estimación de la degradación del BESS.....	136
4.7.1 Procedimiento	136
4.7.2 Resultados y comparativa con la medida real de la capacidad del BESS	158
4.8. Puntos destacados del capítulo.....	159
Capítulo 5.....	163
Mantenimiento aplicado a un BESS por medio de la metodología desarrollada	163
5.1. Motivación.....	164
5.2. Introducción	164
5.3. Programas de mantenimiento actuales empleados en los BESS	166
5.4. Manuales de mantenimiento preventivo	167
5.4.1 Proveedor primero.	167
5.4.2 Proveedor segundo.....	171
5.4.3 Proveedor tercero.	173
5.4.4 Proveedor cuarto.....	174
5.5. Desarrollo de una especificación técnica para la operación y el mantenimiento.	175
5.6. Mejora de la operación mediante el mantenimiento predictivo basado en DSRM-MML.....	177
5.7. Mejoras concretas planteadas y debidas al uso de la metodología DSRM-MML.	180
5.8. Puntos destacados del capítulo.....	181

Capítulo 6.....	184
Conclusiones, contribuciones y futuros desarrollos	184
6.1. Conclusiones de la tesis.....	185
6.2. Contribuciones de la tesis y publicaciones	189
6.3. Futuribles desarrollos.....	191
Bibliografía.....	192
Anexo I:	201
Anexo II:	210

Índice de Figuras

Fig. 1.1. Arquitectura de un BESS formado por 2 contenedores que tienen varios SBMS, formados a su vez por varios módulos integrados en racks.	25
Fig. 1.2. Clasificación de los métodos del estado del arte dentro de los tres grupos establecidos. Los trabajos marcados en verde centran su estudio en la aplicación de estos métodos en la vida real.	33
Fig. 2.1. Evolución de las capacidades a lo largo de los ciclos para el conjunto de las baterías de la NASA (a) y CALCE (b).	55
Fig. 2.2. Perfiles de tensión de carga desde el ciclo 1 hasta el final de la vida útil del ciclo (EOL) para la batería B0005 de la Nasa.	57
Fig. 2.3. Cálculo de la variación de la pendiente desde el ciclo 1 (puntos P1 y P2) hasta los puntos de fin de ciclo (P'1 y P'2).	58
Fig. 2.4. Pendientes para el rango de tensión medido entre [3,8 -3,9 V] para la batería B0005 de la NASA a lo largo de sus ciclos de carga.	58
Fig. 2.5. Ratio de velocidad de degradación para la batería B0005 de la NASA. (a) Rango DSR [3,8-3,9V]. (b) Rango DSR [3,9-4,0V]. (c) Rango DSR [4,0-4,1V]. (d) Rango DSR [4,1-4,2V].	59
Fig. 2.6. DSR [3,850-3,9V] y DSR [3,875-3,9V] vs. 1-SOH y 1/Capacidad, para la batería CS2_37 de CALCE.	60
Fig. 2.7. Relación observada que existe entre el SOH y el DSR. (a) 1/Capacidad vs. DSR [3,8-3,9V]. (b) 1-SOH vs. DSR [3,8-3,9V] para B0005.	60
Fig. 2.8. Ratio de Velocidad de Degradación para la batería CS2_37 de CALCE. (a) DSR [3,8-3,9V]. (b) DSR [3,9-4,0V].	63
Fig. 2.9. Tendencias de los modelos GPR. (a) Modelo1 probado con el conjunto de datos de la batería B0005. (b) Modelo2 probado con el conjunto de datos de la batería CS2_35.	70
Fig. 2.10. Salida real vs. estimada (Modelo3 GRP) con los datos de la batería CS2_36 de CALCE.	72
Fig. 2.11. Gráfica de tendencias del modelo MLPNN. (a) Probado con el conjunto de datos de la batería B0007. (b) Probado con el conjunto de datos de la batería CS2_36.	75
Fig. 2.12. Gráfica de tendencia del modelo MLPNN probado con el conjunto de datos de la batería B0007 y CS2_36.	75
Fig. 2.13. Evoluciones de las capacidades de las diferentes celdas (1 y 2) y modos de operación (SPM, BMP y BMR) de las baterías presentadas de la Universidad de Oxford.	77
Fig. 2.14. Intensidades de carga y descarga de los tres tipos de operación (BMR, BMP y SPM) de las celdas presentadas por la Universidad de Oxford.	77
Fig. 2.15. Detalle de las intensidades de los 3 modos de operación (BMR, BMP y SPM).	78
Fig. 2.16. Detalle de los perfiles de tensión e intensidad para el modo de operación BMR1.	78
Fig. 2.17. Detalle de los perfiles de tensión e intensidad para el modo de operación BMR2.	78
Fig. 2.18. Distribución de tensiones de carga para BMR1.	79
Fig. 2.19. Distribución de tensiones de carga para BMR2.	79
Fig. 2.20. Distribución de intensidades de carga para los DSR[3,7-3,8] de la celda BMR1.	80
Fig. 2.21. Distribución de intensidades de carga para los DSR[3,7-3,8] de la celda BMR2.	80
Fig. 2.22. Evolución del 1-SOH y DSR[3,7-3,8V] para BMR1 para intensidades entre 15,5 y 17,5 A.	81
Fig. 2.23. Evolución del 1-SOH y DSR[3,7-3,8V] para BMR2 para intensidades entre 15,5 y 17,5 A.	81
Fig. 2.24. DSR [3,7-3,8V] con todas las intensidades de carga BMR1.	83
Fig. 2.25. DSR [3,7-3,8V] con intensidades de carga entre 15,5 y 17,5 A para BMR1.	84
Fig. 2.26. DSRv [3,7-3,8V] con todas las intensidades de carga para BMR1.	84

Fig. 2.27. DSRv [3,7-3,8V] con intensidades de carga entre 15,5 y 17,5 A para BMR1.....	85
Fig. 3.1. Arquitectura del BESS utilizado en la tesis, formado por dos contenedores A y B.	89
Fig. 3.2. Características de una celda unitaria del BESS utilizado en la tesis	90
Fig. 3.3. Características de un módulo del BESS utilizado en la tesis	90
Fig. 3.4. Características de un rack unitario del BESS utilizado en la tesis.....	91
Fig. 3.5. Diagrama de los 19 racks conectados al BMS1 Maestro.	92
Fig. 3.6. Diagrama de los 12 SBMS que forman el BESS en estudio para la tesis.	92
Fig. 3.7. Diagrama de conexión de los PCS.....	93
Fig. 3.8. Diagrama de conexión de un ESS.	93
Fig. 3.9. Diagrama del EMS.	93
Fig. 3.10. Diagrama de celdas cargadas con y sin degradación celular.	97
Fig. 3.11. Diagrama de celdas descargadas con y sin degradación celular.....	98
Fig. 3.12. Circuito de equilibrado de celdas mediante resistencia de derivación conmutada por medio de semiconductores Q.....	99
Fig. 3.13. Circuito de equilibrado de celdas mediante inductor único.	100
Fig. 3.14. Circuito de equilibrado de celdas mediante condensadores.	100
Fig. 3.15. Circuito de equilibrado de celdas mediante transformador único.	101
Fig. 3.16. Fotográfica del BESS de la tesis. (EASE, 2018)	103
Fig. 3.17. Tensión real (medida) de rack vs. tensión media de las celdas del rack.	105
Fig. 3.18. Tensión real (medida) de rack vs. tensión media de las celdas del rack normalizadas.	105
Fig. 4.1. Tensiones de carga de tres ciclos realizados a intensidades pseudo- constantes, para el Rack1 del SBMS1.	113
Fig. 4.2. Intensidades de los ciclos C142, C863 y C1308 para el Rack1 del SBMS1.....	113
Fig. 4.3. Tensiones de carga de tres ciclos realizados a intensidades pseudo-constantes, para el Rack1 del SBMS2.	114
Fig. 4.4. Intensidades de los ciclos C138, C871 y C1305 para el Rack1 del SBMS2.....	114
Fig. 4.5. Tensiones de carga de tres ciclos realizados a intensidades pseudo-constantes, para el Rack1 del SBMS3.	115
Fig. 4.6. Intensidades de los ciclos C145, C859 y C1307 para el Rack1 del SBMS3.....	115
Fig. 4.7. Tensiones de carga de tres ciclos realizados a intensidades pseudo-constantes, para el Rack1 del SBMS4.	115
Fig. 4.8. Intensidades de los ciclos C156, C873 y C1296 para el Rack1 del BMS4.....	116
Fig. 4.9. Temperaturas de los ciclos C142, C863 y C1308 para el Rack1 del SBMS 1.....	116
Fig. 4.10. Temperaturas de los ciclos C142, C863 y C1308 para el Rack1 del SBMS 1 y temperaturas de los ciclos C145, C859 y C1307 para el Rack1 del SBMS 3.....	117
Fig. 4.11. Temperaturas vs. Tensiones de los ciclos C142, C862 y C1308 para el Rack1 del SBMS1.	117
Fig. 4.12. Evolución de los 4 DSR [mV/s] vs. SOH para SBMS4 (Rack1).	119
Fig. 4.13. DSR[3,700-3,725] [mV/s] para el Rack 1 de los SBMS 1, 2, 3 y 4.	119
Fig. 4.14. DSR[3,775-3,800] [mV/s] para el Rack 1 de los SBMS 1, 2, 3 y 4.	120
Fig. 4.16 a). Perfil de intensidad de carga de la batería B0005. b) Perfil de intensidad de carga de la batería BMR1.	122
Fig. 4.15. Marcos de trabajo de los DSR presentados.	121
Fig. 4.17. Tensión e Intensidad para el Rack 2 del SBMS1.	123
Fig. 4.18. Tensión e intensidad del rack 2 del SBMS1 para intensidades positivas.	123
Fig. 4.19. Tensión e intensidad del rack 2 del SBMS1 para intensidades negativas.	124
Fig. 4.20. Segmentos de tensión del Rack5 del SBMS9 para un periodo de 9 horas.	124
Fig. 4.21. Segmentos de tensión del Rack5 del SBMS9 para un periodo de 8 meses.....	125
Fig. 4.22. Distribución de la duración de los segmentos de carga.....	125
Fig. 4.23. Intensidad de los segmentos de tensión de carga del Rack5 del SBMS9.....	126
Fig. 4.24. Segmentos de tensión de carga del Rack5 del SBMS9.....	127

Fig. 4.25. Marcos de funcionamiento del BESS de la tesis.	128
Fig. 4.26. Segmentos de tensión de carga extraídos.	128
Fig. 4.27. Segmentos de Tensión e Intensidad medidos e interpolados.	129
Fig. 4.28. DSR secundales del segmento de carga.	129
Fig. 4.29. Evolución de las medias de los DSR para los 19 Racks del SBMS1.	131
Fig. 4.30. Evolución de las medias de los DSR para los 19 Racks del SBMS2.	131
Fig. 4.31. Distribución de las tensiones de los 19 racks de los periodos correspondientes a los meses de: dic-18, jul-19 y jun-20.	132
Fig. 4.32. Distribución de las intensidades de los 19 racks de los periodos correspondientes a los meses de: dic-18, jul-19 y jun-20.	133
Fig. 4.33. Evolución de los DSRa en los intervalos temporales (dic-18, jul-19 y jun-20) para los 19 Racks del SBMS3.	133
Fig. 4.34. Evolución de los DSRa en los intervalos temporales (dic-18, jul-19 y jun-20) para los 19 Racks del SBMS1.	134
Fig. 4.35. Evolución de los DSRa en los intervalos temporales (dic-18, jul-19 y jun-20) para los 19 Racks del SBMS4.	134
Fig. 4.36. Evolución de los DSRa en los intervalos temporales (dic-18, jul-19 y jun-20) para los 19 Racks del SBMS2.	135
Fig. 4.37. Marcos de funcionamiento de los 3 DSR desarrollados en la tesis.	135
Fig. 4.38. Distribución de tensiones de los 19 racks del SBMS8.	137
Fig. 4.39. Distribución de intensidades de los 19 racks del SBMS8.	138
Fig. 4.40. Distribución de los DSRa calculados de los 19 racks del SBMS8.	138
Fig. 4.41. Esquema e Hiperparámetros del modelo SVM.	139
Fig. 4.42. Salida DSRa para el modelo SVM, para el Rack1 del SBMS8 con el conjunto datos de prueba del periodo jul-19.	141
Fig. 4.43. Error del modelo SVM para la salida DSRa del Rack1 del SBMS8 con datos del periodo jul-19.	142
Fig. 4.44. Error del modelo SVM para la salida DSRa del rack1 del SBMS8 con datos del periodo nov-19.	143
Fig. 4.45. Evolución de los errores ELowV (%) a lo largo de los periodos elegidos para los 19 racks del SBMS8 para el modelo SVM.	144
Fig. 4.46. Evolución de los errores ELowV (%) normalizados a lo largo de los periodos elegidos, para los 19 racks del SBMS8 para el modelo SVM.	144
Fig. 4.47. Evolución del MAE por debajo de la banda de confianza a lo largo de los periodos elegidos para los 19 racks del SBMS8 para el modelo SVM.	145
Fig. 4.48. Evolución, a lo largo de los periodos ene-20 y jul-20, de los errores ELowV (%) normalizados del modelo SVM para los SBMS 1, 2, 3, 6, 8 y 12.	146
Fig. 4.49. Esquema e Hiperparámetros del modelo Ensemble.	147
Fig. 4.50. Error del modelo ensemble para la salida DSRa del Rck1 del SBMS8 con datos del periodo jul-19.	148
Fig. 4.51. Error del modelo ensemble para la salida DSRa del rack1 del SBMS8 con datos del periodo nov-19.	149
Fig. 4.52. Evolución de los errores ELowV (%) a lo largo de los periodos elegidos para los 19 racks del SBMS8 para el modelo ensemble.	149
Fig. 4.54. Evolución del MAE por debajo de la banda de confianza a lo largo de los periodos elegidos, para los 19 racks del SBMS8 de los modelos ensemble.	150
Fig. 4.55. Evolución de los indicadores ELow (%) normalizados para los 6 SBMS (1, 2, 3, 6, 8 y 12) elaborados con un modelo ensemble, para los periodos ene-20 y jul-20.	151
Fig. 4.56. Esquema e Hiperparámetros del modelo LR.	152
Fig. 4.56. Esquema e Hiperparametros del modelo LR. (Continuación).....	153
Fig. 4.57. Error del modelo ensemble para la salida DSRa del Rck1 del SBMS8, con datos del periodo jul-19.	154
Fig. 4.58. Error del modelo LR para la salida DSRa del rack1 del SBMS8, con datos del periodo nov-19.	155

Fig. 4.61. Evolución del MAE por debajo de la banda de confianza, a lo largo de los periodos elegidos, para los 19 racks del SBMS8 de los modelos LR.....	156
Fig. 4.62. Evolución a lo largo de los periodos ene-20 y jul-20, de los errores ELowV (%) normalizados del modelo LR para los SBMS 1, 2, 3, 6, 8 y 12.	157
Fig. 5.1. Sección de la Tabla 5.1.	180

FIGURAS ANEXOS

Fig. I.1. Distribuciones de las tensiones de los 19 rack para el SBMS1.....	201
Fig. I.2. Distribuciones de las intensidades de los 19 rack para el SBMS1.....	201
Fig. I.3. Distribuciones de los DSRa de los 19 rack para el SBMS1.....	202
Fig. I.4. Distribuciones de las tensiones de los 19 rack para el SBMS2.....	202
Fig. I.5. Distribuciones de las intensidades de los 19 rack para el SBMS2.....	203
Fig. I.6. Distribuciones de los DSRa de los 19 rack para el SBMS2.....	203
Fig. I.7. Distribuciones de las tensiones de los 19 rack para el SBMS3.....	204
Fig. I.8. Distribuciones de las intensidades de los 19 rack para el SBMS3.....	204
Fig. I.9. Distribuciones de los DSRa de los 19 rack para el SBMS3.....	205
Fig. I.10. Distribuciones de las tensiones de los 19 rack para el SBMS6.....	205
Fig. I.11. Distribuciones de las intensidades de los 19 rack para el SBMS6.....	206
Fig. I.12. Distribuciones de los DSRa de los 19 rack para el SBMS6.....	206
Fig. I.13. Distribuciones de las tensiones de los 19 rack para el SBMS8.....	207
Fig. I.14. Distribuciones de las intensidades de los 19 rack para el SBMS8.....	207
Fig. I.15. Distribuciones de los DSRa de los 19 rack para el SBMS8.....	208
Fig. I.16. Distribuciones de las tensiones de los 19 rack para el SBMS12.....	208
Fig. I.17. Distribuciones de las intensidades de los 19 rack para el SBMS12.....	209
Fig. I.18. Distribuciones de los DSRa de los 19 rack para el SBMS12.....	209
Fig. II.1. Esquema e Hiperparámetros del modelo ensemble SBMS1.	210
Fig. II.2. Esquema e Hiperparámetros del modelo ensemble SBMS2.	211
Fig. II.3. Esquema e Hiperparámetros del modelo ensemble SBMS3.	211
Fig. II.4. Esquema e Hiperparámetros del modelo ensemble SBMS6	212
Fig. II.5. Esquema e Hiperparámetros del modelo ensemble SBMS12	212
Fig. II.6. Esquema e Hiperparametros del modelo SVM SBMS1.....	213
Fig. II.7. Esquema e Hiperparametros del modelo SVM SBMS2.....	214
Fig. II.8. Esquema e Hiperparametros del modelo SVM SBMS3.....	215
Fig. II.9. Esquema e Hiperparametros del modelo SVM SBMS6.....	216
Fig. II.10. Esquema e Hiperparámetros del modelo SVM SBMS12.....	217
Fig. II.11. Esquema e Hiperparámetros del modelo LR SBMS1.	218
Fig. II.12. Esquema e Hiperparámetros del modelo LR SBMS2.	219
Fig. II.13. Esquema e Hiperparámetros del modelo LR SBMS3.	220
Fig. II.14. Esquema e Hiperparametros del modelo LR SBMS6.	221
Fig. II.15. Esquema e Hiperparametros del modelo LR SBMS12.	222

Índice de Tablas

Tabla 1.1a. Parámetros necesarios para la elaboración de los métodos seleccionados en el estado del arte.	44
Tabla 1.1b. Posibles aplicaciones y características de los métodos seleccionados en el estado del arte.	45
Fig. 2.7. Relación observada que existe entre el SOH y el DSR. (a) 1/Capacidad vs. DSR [3,8-3,9V]. (b) 1-SOH vs. DSR [3,8-3,9V] para B0005.....	60
Tabla 2.1. Parámetros de ajuste con su banda de confianza al 95% y errores del polinomio lineal de grado uno usado para las baterías de NASA y CALCE.	61
Tabla 2.2. Correlación entre el DSR [3,8-3,9V], [3,9-4,0V], [4,0-4,1V] y [4,1-4,2V] vs. 1 / Cap (%) y la FC (%) respectivamente.	61
Tabla 2.3. Características e hiperparámetros utilizados para los modelos GPR de las baterías de la NASA.....	64
Tabla 2.4. Características e hiperparámetros utilizados para los modelos GPR de las baterías de la CALCE CS2_35, CS2_36 y CS2_37.	64
Tabla 2.5. Errores del modelo GRP utilizando el indicador DSR [3,875-3,9V] como entrada vs. 1/Cap para los paquetes de datos de las baterías de la NASA y CALCE.	65
Tabla 2.6. Características e hiperparámetros del modelo lineal para las baterías de la Nasa B0005, B0006 y B0007 y CALCE CS2_35, CS2_36 y CS2_37.	66
Tabla 2.7. Errores del modelo LR utilizando DSR [3,825-3,850V] y DSR [3,850-3,75V] como entrada vs. DSR [3,875-3,9V] con el conjunto de datos de baterías de la NASA y CALCE	66
Tabla 2.8. Características e hiperparámetros utilizados para el modelo GPR de las baterías de la NASA B0005, B0006 y B0007.	68
Tabla 2.9. Características e hiperparámetros utilizados para el modelo GPR de las baterías de la CALCE CS2_35, CS2_36 y CS2_37.....	68
Tabla 2.10. Errores del modelo GPR utilizando DSR[3,825-3,850V], DSR[3,850-3,875V] y DSR[3,875-3,9V] como entradas vs. 1-SoH con el conjunto de datos de baterías de la NASA y CALCE.	69
Tabla 2.11. Comparativa entre los resultados de esta tesis y los del estado del arte.	71
Tabla 2.12. Características e hiperparámetros utilizados para el Modelo3 GPR entrenado con las baterías de la NASA B0005, B0006, B0007, y las baterías de CALCE CS2_35 y CS2_37.	71
Tabla 2.12. Características e hiperparámetros utilizados para el Modelo3 GPR entrenado con las baterías de la NASA B0005, B0006, B0007, y las baterías de CALCE CS2_35 y CS2_37. (Continuación)	72
Tabla 2.13. Errores del Modelo3 (GRP) probado con los datos de la batería CS2_36 de CALCE.	72
Tabla 2.14. Entradas y salida del modelo MLPNN entrenado con datos de las baterías B0005, B0006, CS2_35 y CS2_37.	74
Tabla 2.15. Errores del modelo MLPNN probado con los datos de las baterías B0007 y CS2_36.	74
Tabla 2.16. Parámetros de ajuste con su banda de confianza al 95% y errores del polinomio lineal de grado uno usado para las baterías BMR1 y BMR2 de Oxford.	81
Tabla 2.17. Correlaciones entre los diferentes indicadores DSR y el SOH de las dos celdas BMR1 y BMR2.	83
Tabla 3.1 Dimensiones del BESS a nivel de dispositivos: Contenedor, BMS, Rack, Modulo y celda.	103
Tabla 3.2 Dimensiones del BESS a nivel de potencia y capacidades.	103

Tabla 3.3 Medidas de la capacidad de cada uno de los SBMS del BESS para el CT realizado en jul-2020.	107
Tabla 3.4 Parámetros del polinomio de ajuste para la curva de degradación del BESS FC (%).	107
Tabla 4.1. Cálculo de 4 DSR en los niveles de tensión [3,7-3,725], [3,725-3,75], [3,75-3,775] y [3,775-3,8] para 3 ciclos de carga y el rack 1 de los SBMS 1, 2, 3 y 4.	118
Tabla 4.2. Medias y desviaciones estándar de los DSRa del SBMS8.	138
Tabla 4.3. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de entrenamiento.	140
Tabla 4.4. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba.	142
Tabla 4.5. Errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de entrenamiento.	147
Tabla 4.6. Tabla con los errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba.	148
Tabla 4.7. Errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de entrenamiento.	153
Tabla 4.8. Tabla con los errores R2 de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba.	154
Tabla 4.9. Indicadores normalizados ELowV (%) para los 3 tipos de modelos (Ensemble, LR, SVM)	158
Tabla 4.10. Medias del indicador ELowV (%) normalizado vs. las capacidades medidas de los SBMS.	159
Tabla 5.1. Plan de mantenimiento preventivo para los SBMS.	167
Tabla 5.3. Eventos de desconexión.	169
Tabla 5.4. Plan de mantenimiento con código de tarea y responsable.	171
Tabla 5.5. Plan de mantenimiento con tipo de operación y responsable.	173
Tabla 5.6. Plan de mantenimiento con la descripción de la tarea.	174
Tabla II.1. Errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS1.	210
Tabla II.2. Errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS2.	211
Tabla II.3. Errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS3.	211
Tabla II.4. Errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS6.	212
Tabla II.5. Errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS12.	212
Tabla II.6. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS1.	213
Tabla II.7. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS2.	214
Tabla II.8. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS3.	215
Tabla II.9. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS6.	216
Tabla II.10. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS12.	217
Tabla II.11. Errores R2 de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS1.	218

Tabla II.12. Tabla con los errores R2 de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS2.....	219
Tabla II.13. Tabla con los errores R2 de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS3.....	220
Tabla II.14. Tabla con los errores R2 de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS6.....	221
Tabla II.15. Tabla con los errores R2 de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS12.....	222

Índice de Abreviaturas

AC	Corriente Alterna, Alternating Current
BESS	Sistema de Almacenamiento de Energía por Baterías, Battery Energy Storage Systems
BMS	Sistema de Gestión de la Batería, Battery Management System
BOL	Inicio de Vida, Begin of Life
BVE	Baterías de Vehículos Eléctricos
CC	Corriente Constante, Constant Current,
CI	Circuitos Integrados
CNN	Red Neuronal Convolucional, Convolutional Neural Network
CT	Prueba de Capacidad, Capacity Test
CV	Tensión Constante, Constant Voltaje.
DC	Corriente Continua, Direct Current
DDM	Data-Driven Methods, Metodos Basados en Datos
DL	Aprendizaje Profundo, Deep Learning
DSR	Degradation Speed Ratio, Ratio de Velocidad de la Degradacion
DSTA-GRU	Unit Dynamic Spatial and Temporal Attention-Based Gated Recurrent Unit
ECM	Modelo de Circuito Equivalente, Equivalent Circuit Model
EIM	Modelo de Impedancia Electroquímica, Electrochemical Impedance Model
EL	Ensemble Learning, Aprendizaje de Conjunto
ELM	Extreme Learning Machine, Aprendizaje Automatico Extremo
EMS	Energy Management System, Sistema de Gestion de Energía
EOL	End-of-Life, Fin de Vida
ESS	Sistema de Almacenamiento de Energía, Energy Storage Systems
ESSU	Unidad de Sistema de Almacenamiento de Energía, Energy Storage System Unit
FC	Capacidad Perdida, Fade Capacity
FNN	Red Neuronal de Avance, Redes Neuronales Feedforward
FOI	Características de Interés, Features of Interest
GPR	Proceso de Regresión Gaussiano, Gaussian Process Regression
HF_s	Características de Salud, Healthy Features
HI	Indicador de Salud, Health Indicator
HMI	Interfaz Hombre- Máquina, Human-Machine Interface
IC	Capacidad Incremental, Incremental Capacity
ICA	Análisis de la Capacidad Incremental, Incremental Capacity Analysis
IR	Resistencia Interna , Internal Resistance

LIB	Baterías de Ion de Litio, Lithium-ion Batteries
LR	Regresión Lineal, Regresion Lineal
LS-SVM	Soporte Vector Maquina por Mínimos Cuadrados, Least Squares-Vector Support Machine
LSTM	Red Neuronal de Memoria a Corto Plazo, Long Short-Term Memory
MBM	Metodos Basados en Modelos, Model Based Methods
MELM	Máquina de aprendizaje metabólico extremo, Metabolic Extreme Learning Machine
MES	Análisis del Error del Modelo, Model Error Spectrum
ML	Aprendizaje Automático, Machine Learning
MLP	Perceptrón Multicapa, Multilayer Perceptron
MLPNN	Red Neuronal Multicapa y con Retropropagación, Multilayer Neural Networks and Backpropagation
MP	Mantenimiento Preventivo
NN	Redes Neuronales, Neural Networks
OCV	Tensión de Circuito Abierto, Open Circuit Voltage
OEL	Aprendizaje Conjunto Optimizado, Optimized Ensemble Learning
OVP	Protección por Sobre-Tensión, Over-Voltage Protection
PCA	Análisis de Componentes Principales, Principal Component Analysis
PCS	Sistema de Conversión de Energía. Power Conversion System
PDF	Función de Densidad de Probabilidad, Probability Density Function
RNN	Red Neuronal Recurrente, Recurrent Neural Network
RUL	Vida Util Remanente, Remaining Useful Life
SBMS	Almacén del BMS, Store of BMS
SG	Savitzky – Golay
SOC	Estado de Carga, State of Charge
SOH	Estado de Salud, State of Health
SVM	Maquina de vectores de Soporte, Support Vector Machine
UVP	Protección por Baja-Tensión, Under-Voltage Protection
VE	Vehículos Eléctricos

Capítulo 1

Introducción y Estado del Arte

Estructura de la tesis: **Capítulo 1**

• Introducción y Estado del Arte •

Identificación de un nuevo indicador de salud (DSR)

Arquitectura y características del BESS en estudio

Aplicación del nuevo DSR a un BESS

operando en regulación de frecuencia

Mantenimiento aplicado a un BESS

por medio de la metodología desarrollada

Conclusiones, contribuciones y futuros desarrollos

- Este capítulo introduce el **concepto de qué es un sistema de almacenamiento de energía mediante baterías (BESS)**, qué motivaciones se presentan para la realización de esta tesis y cuáles son sus objetivos principales.
- Posteriormente se detalla el estado del arte referente a:
 - Mecanismos de estimación del estado de **salud de las baterías de ion de litio de laboratorio**.
 - Mecanismos de estimación del estado de **salud de BESS**.
 - Estado del arte relativo al **mantenimiento de los BESS**.
- Para finalizar se detallan los **puntos destacados** con las dificultades y los retos planteados en el estado del arte.

1.1. Introducción

En el contexto actual de transición energética mundial en el que vivimos, los sistemas de almacenamiento de energía han adquirido un gran protagonismo debido, p.ej., al cambio de paradigma acaecido en los vehículos de transporte (políticas de *cero emisiones*, (Borbujo *et al.*, 2021)) y la necesidad de almacenamiento de energía, renovable principalmente.

Dada esta necesidad, los sistemas de almacenamiento de energía mediante baterías de iones de litio (“Lithium-Ion Batteries”, LIB) han tomado, por el momento, una posición preferente en el mercado, debido a su alta densidad energética. Por ello, este tipo de tecnología actualmente es la más utilizada para los grandes sistemas de almacenamiento, empleados principalmente en vehículos y centrades eléctricas.

Los llamados BESS corresponden a las siglas anglosajonas *Battery Energy Storage Systems*, que a su vez son una parte perteneciente a los *Energy Storage Systems* (ESS). Estos últimos se han utilizado en la industria durante décadas para el almacenamiento de energía de diversas formas (volantes de inercia, sistemas de almacenamiento de calor mediante sales fundidas, sistemas de bombeo en centrales hidráulicas...). Pero es ahora, con el auge de las LIB utilizadas en la mayoría de los dispositivos eléctricos de uso diario (telefonía, relojes *inteligentes*, cámaras de fotos, drones, etc.), cuando se están implantando en el mundo también muchos sistemas de almacenamiento de energía eléctrica que integran estas LIB, para formar un BESS.

Estos sistemas están formados por elementos básicos de almacenamiento llamados celdas, que se agrupan formando módulos y estos a su vez en racks. Estos racks, de igual manera, son escalables para aumentar la capacidad de almacenamiento o la tensión del sistema hasta formar un “*Store of Battery Management System*”, por sus siglas del inglés *SBMS*. En la Fig. 1.1 se muestra la arquitectura y conexión a la red eléctrica de un BESS formado por varios SBMS (del núm. 1 al *n*), donde se aprecian estas agrupaciones de varios módulos ubicados en racks, que a su vez se conectan entre sí para formar un SBMS que es controlado por un BMS. De igual forma los SBMS son escalables, y con varios de ellos si se necesitara, formar un BESS de mayor potencia o capacidad. Todo BESS tiene un PCS (Power Conversion System) que es el encargado de transformar la corriente continua (DC) en alterna (AC) y viceversa, para poder interconectarlo con el sistema de red eléctrica por medio de un transformador de alta tensión.

Por tanto, de una celda que tiene una tensión nominal de 3,8 V y unos pocos amperios hora (Ah) de capacidad, podemos obtener un sistema con varios

MW/h de energía para dar servicio en alta tensión (~ 1.000 V). En el Capítulo 3 de la tesis se explicará en detalle la arquitectura del BESS empleado para los desarrollos de la tesis, sus componentes principales, el funcionamiento y su mantenimiento.




Fig. 1.1. Arquitectura de un BESS formado por 2 contenedores que tienen varios SBMS, formados a su vez por varios módulos integrados en racks.

En esta línea, como todas las instalaciones industriales, los BESS sufren degradación por el uso (operación) y por el paso del tiempo. Conocer el nivel de degradación es primordial para poder operarlo correctamente, para su optimización de uso y para su seguridad. Estos 3 puntos: degradación, optimización y seguridad serán el foco de esta tesis.

1.1.1 Motivación

Como se ha mencionado anteriormente, la degradación de los BESS es una de las motivaciones de esta tesis, y como se verá en la sección 1.2.4 de este capítulo, existen muchas oportunidades de mejora en este sentido en la actualidad.

A continuación, enumeramos los métodos actuales para estimar la degradación de las LIB, tendiéndose por norma general a clasificar en tres métodos:

1. Métodos de medición directa, basados en la medición de características de la batería, p.ej., de la resistencia interna o de la impedancia.

2. Métodos basados en modelos, que simulan la batería como un modelo: p. ej., modelo de circuito equivalente (ECM) o modelo de impedancia electroquímica (EIM).
3. Métodos basados en datos, que se basan en enfoques de extracción de características de la batería a partir de valores observados de variables que pueden medirse.

Normalmente, en los DDM la extracción de esas características se realiza por medio de mediciones físicas necesarias para la gestión de la batería, y obtenidas a través de sus ciclos de funcionamiento.

Las señales de medida para su gestión y utilizadas en los métodos DDM son:

- ✓ Tensión carga.
- ✓ Tensión descarga.
- ✓ Intensidad carga.
- ✓ Intensidad descarga.
- ✓ Temperatura de la batería.

Los métodos actuales para estimar la degradación de los BESS no han tenido mucho desarrollo en la literatura y en lo que convergen la mayoría de los artículos existentes, es en que los métodos empleados para las LIB no obtienen los resultados esperados al aplicarlos a los BESS. Por ello, la motivación general de esta tesis se ha visto influenciada por la “poca literatura” existente, en lo que se refiere a métodos prácticos del conocimiento de la degradación de un BESS. Esto ha motivado el estudio y finalmente desarrollo de un medio para estimar la degradación de un BESS con los datos de operación disponibles de este.

En esta línea, para la obtención de dichos datos ha sido necesario realizar labores de:

- ✓ Análisis de las variables del BESS.
- ✓ Conexión con el sistema PI remoto (sistema SCADA).
- ✓ Descarga de los datos por un periodo de un año y medio de duración.
- ✓ Almacenamiento, siendo necesaria la creación de cuatro *datastores* en MATLAB con un tamaño total de 80 Gb de capacidad de almacenamiento.

El primer paso dado en esta tesis para estimar la degradación del BESS, ha sido el desarrollado de un nuevo indicador de salud (“Health Indicator”, HI) capaz de medir el estado de la degradación de una celda de una LIB. Dicho

indicador de salud usa solamente fragmentos de tensión de los diferentes ciclos en el momento de la carga de la batería, lo que permite disminuir el número de datos utilizados para ello. Además, se puede utilizar para realizar el diagnóstico de la degradación de una instalación BESS al completo, utilizando este como entradas de modelos de predicción. Esto posibilita conocer el estado de salud de los diferentes racks del BESS, prácticamente en tiempo real.

1.1.2 Objetivos de la tesis

En esta sección se explican en detalle los tres objetivos de la tesis, que se exponen a continuación:

1. Establecer un indicador de salud (HI) que permita conocer el estado de la degradación de las LIB, de una forma rápida en su medición y su estimación.

Del mismo modo, como objetivo complementario a este, se establece una metodología utilizando este nuevo indicador, para calcular el estado de salud ("State of Health", SOH) de las LIB. La consecución de estos dos objetivos ha dado como resultado un artículo y la publicación de sus resultados (Alvarez-Monteserin and Sanz-Bobi, 2022).

2. Una vez cumplido el objetivo primero de la tesis (desarrollo de este nuevo indicador), el segundo objetivo planteado es conocer el nivel de degradación de un BESS en operación mediante el uso de este indicador. Para ello se plantearon dos objetivos complementarios:
 - ✓ Aplicar el nuevo indicador a un BESS operando en regulación de frecuencia en la vida real, teniendo en cuenta las complicaciones que esto conlleva (conjunto de datos de operación de la batería y comportamiento fuera del entorno de laboratorio).
 - ✓ Desarrollo de una metodología basada en aprendizaje automático, que permita mediante el uso del HI conocer la degradación del BESS.

Se ha realizado y enviado también un artículo para la publicación de los resultados.

3. Por último, como objetivo principal tercero, se mejorará el mantenimiento realizado en la vida real a los BESS. Para ello se plantean dos objetivos secundarios:

- ✓ Evaluar cuatro modelos de mantenimiento “Planes de mantenimiento” que se realizan a las celdas, módulos, que forman parte de cuatro BESS operando en la vida real.
- ✓ Elaborar mejoras significativas en estos cuatro planes de mantenimiento mediante el uso de la metodología desarrollada como objetivo 2, que permite estimar la evolución de la degradación de las celdas del BESS.

1.1.3 Esquema de la tesis doctoral

La tesis se estructura en 6 capítulos:

El Capítulo 1 incluye una introducción, resaltando los objetivos de la tesis, el estado del arte relativo a la estimación de la degradación de las LIB, posteriormente de los BESS y finalmente al mantenimiento de estos. Dando respuesta a los objetivos planteados, subsiguientes:

1. Métodos existentes para el estudio de la degradación de las celdas de las LIB, relativos al Capítulo 2 de la tesis.
2. Métodos para el estudio de la degradación empleados en los sistemas de baterías utilizados en la vida real, para vehículos eléctricos (VE), y BESS principalmente, para tenerlos en cuenta en el Capítulo 4.
3. Estrategias del mantenimiento de los BESS, para tenerlas en cuenta en el Capítulo 5 de la presente tesis.

El Capítulo 2 presenta un nuevo HI empleado en la estimación de la degradación de las LIB. Además, se compara con el indicador universal SOH mediante el uso de modelos de predicción. También se muestra la utilización de este nuevo indicador con baterías que se cargan a corrientes no constantes, ampliando así la utilidad presentada en este Capítulo 2.

En el Capítulo 3 se presentan en detalle las partes que forman un BESS, poniendo el foco en el sistema de almacenamiento, clave en el desarrollo de esta tesis y en el del equilibrado de sus celdas, clave en el mantenimiento y la seguridad del BESS.

En el Capítulo 4 se desarrolla una variante subyacente del indicador creado en el Capítulo 2, y junto a una metodología que emplea tres tipos de modelos de aprendizaje automático (“Machine Learning”, ML), es capaz de establecer los niveles de degradación de los SBMS que forman el BESS.

El Capítulo 5 establece puntos de mejora, sobre cuatro procedimientos de mantenimiento empleados en BESS operativos, mediante utilización de la metodología propuesta en el Capítulo 4.

Por último, en el Capítulo 6 se presentan las conclusiones, aportaciones y los futuros trabajos con posibilidad de desarrollo.

1.2. Estado del arte

1.2.1 Motivación

Por norma general el análisis del estado de arte tiene como motivación, conocer el estado de la técnica existente en el ámbito de estudio de la tesis para poder ampliarlo durante el desarrollo de dicha tesis. Esta circunstancia ha llevado a dividir el estado del arte en 3 apartados diferentes:

- (1) Estado del arte referido a métodos de estimación del SOH aplicado a las LIB de laboratorio.
- (2) Estado del arte referido a métodos de estimación del SOH de LIB utilizadas en la vida real con datos reales, poniendo el foco en vehículo eléctrico (VE) o BESS.
- (3) Estado del arte actual sobre el mantenimiento aplicado a los BESS.

De la misma forma, el estado del arte se focaliza en los métodos actuales existentes, al ser estos más pragmáticos a la hora de implantar como solución en un sistema en la vida real, y poniendo el foco de manera crítica en su posible aplicación real. Este es el foco establecido, ya que estas son las metodologías con las que esta tesis se debe comparar, y que lo ha guiado durante su desarrollo.

1.2.2 Introducción

Debido al auge que está teniendo el uso de las LIB para almacenar energía en muchos dispositivos: *laptop*, teléfonos, VE, drones, grandes sistemas de almacenamiento de energía (BESS), son muchas también las investigaciones y los artículos publicados sobre su proceso de envejecimiento, degradación o estado de salud, para intentar saber qué capacidad real tienen en cada momento.

La vida útil de una batería se puede definir como, el tiempo estimado durante el cual esta realizará la función o cometido para la que fue diseñada y

para un uso concreto. Del mismo modo, el envejecimiento es un término asociado a los procesos químicos y mecánicos presentes en dispositivos electroquímicos (como las baterías) que pueden causar una degradación gradual de sus prestaciones y por tanto provocar una reducción de su vida útil. De esto se deduce que son dos conceptos que van ligados y están inversamente correlacionados, el aumento de la degradación produce una disminución de la vida útil.

Los mecanismos y factores que afectan a la degradación de las LIB son muchos, p. ej., la profundidad de descarga, la intensidad de carga-descarga, la temperatura o el número de ciclos, como factores más determinantes. En lo relativo a los mecanismos, son muchos también los que afectan al envejecimiento cíclico de la batería, pero el mecanismo de degradación más destacado, al menos en cuanto a la literatura científica se refiere (Urquiza and Singh, 2023), es el engrosamiento o crecimiento de la capa de interfaz del electrolito sólido (“Solid Electrolyte Interface”) (Edge et al., 2021).

La LIB es un sistema complejo de entender, y el mecanismo de envejecimiento es aún más complicado. Hay varios factores que provocan la degradación de la capacidad y la potencia de una batería, (Attia *et al.*, 2022) y estos vienen determinados por diferentes mecanismos y procesos que dependen de los componentes y de la química utilizada en su fabricación. Según (Attia *et al.*, 2022), las tendencias de la degradación de las LIB se clasifican en lineales, sublineales y superlineales, y se muestran como *la capacidad frente al número de ciclos*.

En cualquier caso, en esta tesis no se estudian los mecanismos ni procesos que hacen que las LIB se degraden. En lo que a esta tesis se refiere, la degradación de una LIB se “podría definir” como la pérdida de capacidad que sufre dicha LIB, y el objetivo de la tesis será estimar o cuantificar esa pérdida a lo largo de su vida útil, independientemente de esos factores de operación o funcionamiento que hacen que se degrade.

Está demostrado que el tiempo de vida útil de una LIB está relacionado con el “número de ciclos” (cargas y descargas), la tasa de corriente (C-rate) empleado durante esos ciclos y el rango de tensión en la operación, entre otros aspectos (Yi Li *et al.*, 2019). Está muy extendido además, que cuando el SOH de una LIB decrece más del 80-70%, ha llegado al final de su vida útil, y se considera defectuosa (Lee and Lee, 2021), (Qu *et al.*, 2019).

Dos parámetros muy utilizados para evaluar el nivel de degradación de las LIB son la pérdida de capacidad y la pérdida de potencia.

- ✓ La pérdida de capacidad está referida a la reducción que sufre la LIB para almacenar energía, causada por su degradación. P.ej., en el caso de VE es crucial, porque representa la disminución de la autonomía.
- ✓ La pérdida de potencia se define como, la disminución de la energía entregada por la LIB en el momento de ser demandada, por unidad de tiempo. Esta pérdida es debida a un aumento de la resistencia de la celda debido al envejecimiento o a una temperatura de trabajo muy baja, y es importante también en los VE o en los BESS por motivos obvios.

Algunos de los beneficios de conocer y evaluar el SOH de las LIB son:

- (1) Poder evaluar el estado de carga real ("State of Charge", SOC) de la batería y por tanto las horas de funcionamiento restantes que le quedan.
- (2) Poder gestionar el mantenimiento de forma correcta y eficiente, ya que sólo se aplicará a las partes (celdas, módulos, racks, SBMS) que lo necesiten.
- (3) El conocimiento del SOH disminuye el riesgo de fallo crítico en las LIB, por lo que aumenta la seguridad en el uso del dispositivo, VE o BESS.

En la literatura científica se encuentran varios métodos basados en diferentes estrategias y algoritmos para la estimación del SOH. Estrategias, por ejemplo, llevadas a cabo a través de procesos fuera del *tiempo real* (offline) (Schweiger *et al.*, 2010) y (Chen *et al.*, 2018), y otras desarrolladas como métodos de estimación en tiempo real (online), (Wang *et al.*, 2016), (Feng *et al.*, 2019) y (Weng *et al.*, 2013). Pero en la literatura la forma más extendida de agrupar los muchos métodos de estimación del SOH que existen es hacerlo en estas tres categorías:

- I. **Métodos de medición directa.** Este método se basa en la medición de alguna de las características interna de la batería, como p. ej., la resistencia interna (Schweiger *et al.*, 2010), la medición de la impedancia (Guha and Patra, 2017) o el método de recuento de culombios (Soon Ng *et al.*, 2009). Estos son los métodos aplicados con mayor frecuencia en este grupo.

Enlazando con el siguiente grupo de métodos, (Tian, Xiong and Yu, 2019), estiman los parámetros del ("Open Circuit Voltage", OCV) para desarrollar un circuito eléctrico equivalente de la batería ("Equivalent Circuit Model", ECM). Posteriormente, por medio de un análisis de la capacidad incremental ("Incremental Capacity Analysis", ICA) estiman el SOH.

- II. **Métodos basados en modelos.** Por las siglas en ingles “Model Based Methods” (MBM). Consideran la batería como un modelo electroquímico, eléctrico o empírico, p. ej., el ECM o el EIM (Electrochemical Impedance Model). Dos ejemplos de este grupo son los planteados por (Braun *et al.*, 2022) que desarrollaron un modelo para el SOH basado en los datos de tensión e intensidad y un ECM, o (Chen *et al.*, 2022) que desarrollaron un método basado en el análisis del error del modelo (“Model Error Spectrum”, MES) creado para la batería mediante un ECM, alegando que durante el envejecimiento de esta, la precisión del modelo disminuye, y hay una correlación entre el envejecimiento y la distribución del error.
- III. **Métodos basados en datos.** Por las siglas en ingles “Data Driven Methods” (DDM). Se basan en enfoques de extracción de características a partir de valores observados de variables que pueden medirse (tensión, intensidad, temperatura, etc.). Son flexibles y utilizan enfoques de aprendizaje automático. Actualmente es el grupo de mayor desarrollo en la metodología de estimación del SOH, también debido a la *popularidad* de los modelos de ML, muy empleados en este grupo.

En la Fig. 1.2 se muestra la clasificación, según los tres grupos mencionados anteriormente, de todos los métodos presentados en el estado del arte de esta tesis para estimar el SOH.

Al realizar un análisis cronológico de los trabajos, se aprecia que los métodos de medición directa están en desuso al ser estos costosos, menos precisos y como consecuencia, poco competitivos y difíciles de implantar en la vida real.

Los MBM están presentes nuevamente en los estudios para su aplicación en la vida real, después de verse *desplazados* durante un tiempo por los DDM. Siendo estos últimos (DDM) los que han tenido una mayor acogida con el auge del ML y “Deep Learning” (DL), unido a que son los métodos de mayor precisión. Por norma general necesitan las temperaturas de celda, corrientes, tensiones, etc., obtenidos a través de varios ciclos de carga y descarga para posteriormente, desarrollar modelos que estimen el SOH. Y es aquí donde se encuentra la primera dificultad, al aplicarlos a las LIB de los dispositivos utilizados en la vida real, estas mediciones no están acotadas, tal como sí sucede con los conjuntos de datos de laboratorio.

El sistema BESS además es un conjunto de celdas interconectadas, por lo que su degradación no se puede estimar con pruebas o modelos que tienen en cuenta sólo los mecanismos de envejecimiento para cada célula, ha de ser realizado conjuntamente.




Fig. 1.2. Clasificación de los métodos del estado del arte dentro de los tres grupos establecidos. Los trabajos marcados en verde centran su estudio en la aplicación de estos métodos en la vida real.

Es ahora cuando se están empezando a desarrollar estudios empleando datos reales, o al menos con parámetros de operación reales (Von Bülow, Mentz and Meisen, 2021), y de nuevo estos estudios, más focalizados en aplicaciones reales (VE y BESS principalmente), vuelven a emplear MBM y DDM.

La metodología utilizada en esta tesis se engloba en la categoría de DDM, al emplearse un nuevo HI desarrollado en el Capítulo 2 y utilizar ML para estimar la degradación del BESS dentro del Capítulo 4.

1.2.3 Estado del arte referido a métodos de estimación del SOH aplicados a baterías en laboratorios.

Los estudios agrupados en este apartado han sido desarrollados con datos de baterías de laboratorio, teniendo dificultades para su aplicación en la vida real, ya que como se ha mencionado, muchos de estos métodos no pueden extraer los datos necesarios cuando la batería está en su operación real. Así, p.ej., (Liu, Xu and Feng, 2020) propusieron un HI utilizando datos de los rangos de tensión durante los procesos de carga y descarga, operación que no siempre se produce al completo en las LIB en la vida real.

Son muchos los artículos encontrados en la literatura que utilizan los **perfiles de carga y descarga** de las LIB para extraer HI y estimar el SOH. **Algunos ejemplos son:**

(Cui and Joe, 2021) comparan seis modelos de redes neuronales (“Neural Networks”, NN) y, seleccionando el que obtiene menor error RMSE, estiman el SOH. El modelo elegido, que mejora el comportamiento de los modelos LSTM y GRU, ya que selecciona mejor las características de entrada más relevantes, es el (DSTA-GRU) “Unit Dynamic Spatial and Temporal Attention-Based Gated Recurrent Unit”. Como características de entrada utilizan seis, extraídas de los tiempos y tensiones de los perfiles de carga y descarga.

Del mismo modo (Wu *et al.*, 2020) realizaron un estudio donde se propone un método de estimación del SOH basado en el aprendizaje automático (“Long Short-Term Memory”, LSTM), utilizando los perfiles de tensión de carga y descarga y la variación en las curvas IC (Incremental Capacity).

(Meng *et al.*, 2020) proponen, para la estimación del SOH de las LIB, un método basado en el aprendizaje conjunto optimizado (“Optimized Ensemble Learning”, OEL), que mejora la precisión de la estimación del SOH mediante la integración de un modelo SVM (Support Vector Machine) con HI extraídos de la intensidad y tensión de las curvas de carga y descarga de las LIB.

En este estudio (Cai *et al.*, 2019) propone un nuevo marco de trabajo para la selección de las características de interés (“Features of Interest”, FOI), y poder estimar así el SOH de las LIB. Para ello, se monitoriza la degradación de una batería de laboratorio y se miden las variables mediante un grupo de pulsos

de corriente de 18 segundos de duración para varios C-rate (Intensidad/Capacidad). Posteriormente se utiliza un estimador de SVM para obtener el SOH. Este método mejora los existentes hasta el momento, ya que reduce significativamente los tiempos empleados en la toma de medidas para los modelos.

Por último, (Han *et al.*, 2022) extraen varios indicadores de salud con datos de perfiles de tensión e intensidad de carga y descarga, para aplicarlos a un modelo de red neuronal LSTM.

Hay muchos artículos que proponen HI que tienen altas correlaciones con el SOH (Liu *et al.*, 2018), y se llevan a cabo a través de características extraídas en **el proceso de descarga** de las baterías, (Li *et al.*, 2015) y (Deng *et al.*, 2020). Estos métodos tienen más difícil su aplicación de la vida real porque están desarrollados para condiciones óptimas de laboratorio y estas características sólo se dan en descargas a corriente constante. Lo mismo sucede con (Chen *et al.*, 2019) que analizaron la curva de tensiones de descarga a corriente constante con el fin de describir la degradación de la batería y utilizan un modelo SVM por mínimos cuadrados (LS-SVM) para estimar el SOH. Es difícil encontrar un dispositivo que opere siempre con un régimen de descarga constante desde su SOC máximo al mínimo ininterrumpidamente, por lo que, como se ha mencionado, hace más difícil su aplicación.

La misma limitación tienen (Liu and Yan, 2020), que desarrollaron un modelo de estimación del SOH por medio un algoritmo de “Extreme Learning Machine” (ELM) que utiliza, a través de un filtro “Savitzky – Golay”, dos HI extraídos de los perfiles de descarga de las baterías.

Sin embargo, **el proceso de carga** se lleva a cabo de manera más estable y controlada, p.ej. en telefonía, drones, ordenadores, VE, algunos tipos de BESS, etc., ya que es el diseñador del dispositivo el que suele poner sus condiciones óptimas de carga. Este control hace que los métodos que utilizan estos perfiles de carga sean más fáciles de implementar, y así **lo realizan los siguientes artículos**:

(Wang *et al.*, 2019) propusieron un nuevo HI con una alta correlación con la capacidad. Este HI se estima con un ECM. El autor utilizó las curvas de carga a tensión constante para estimar este HI, para lo que la batería debe alcanzar primero el voltaje máximo (4.2V). Otra restricción operativa que limita su implantación en la vida real, ya que esto no siempre ocurre en todas las cargas.

(Zhang and Tian, 2019) extrajeron los tiempos de carga entre dos tensiones específicas con el fin de estimar el SOH por un método Gaussiano, el modelo

“Gaussian Process Regression” (GPR). Así, se realiza una comparación de algún intervalo de tiempo de carga entre tensiones, e incluso de todo el ciclo de carga a corriente constante (CC), desde la tensión mínima hasta la máxima, por lo que el método también requiere alcanzar la tensión máxima de la batería para estimar su SOH.

(Tan and Zhao, 2020) propusieron nueve FOI diferentes basados en curvas de carga. Su mejor coeficiente de correlación vs. el SOH es de 0.98, pero requiere una carga completa para alcanzar este objetivo. Posteriormente, el método necesita una red neuronal LSTM para predecir el SOH. La limitación de este método en la vida real viene dada por la necesidad de medir toda la curva de carga para todos los ciclos, por lo que será difícil su implantación fuera de un entorno de laboratorio.

(Ruan *et al.*, 2021) realizan una previsión del SOH con un HI extraído de los perfiles de carga a tensión constante (CV), incluso siendo este tiempo de carga pequeño, pueden realizar una reconstrucción de esta curva y obtener el HI necesario. El SOH se estima con el método de recuento de amperios, donde la $Q_{\max}$ se obtiene con un ajuste lineal (LR) utilizando la carga Q durante el intervalo CV. La posible limitación de este método reside en que el intervalo de CV se realiza con SOC altos, por lo que fuera de ese rango no disponemos de la medida necesaria.

(Wei *et al.*, 2022) proponen un método de estimación del SOH por etapas extrayendo diferentes conjuntos de indicadores de salud con los datos de CC de la curva parcial. Los indicadores HI se extraen con datos de los picos de la curva dQ/dV y posteriormente, para estimar el SOH, se utilizan dos configuraciones de NN.

Y para finalizar este grupo, (Feng *et al.*, 2019) utilizaron un intervalo de 15 minutos del perfil de tensiones de carga y un modelo SVM. Este modelo se entrenó utilizando datos basados en el modelo ICA y OCV.

Métodos más complejos son los propuestos por (He *et al.*, 2020) y (Bian *et al.*, 2020) que obtienen nuevas FOI a través del método ICA, curvas dQ/dV y sus picos de tensión. Finalmente, el SOH se estima con un modelo LR, o el planteado por (Kaur *et al.*, 2021), que proponen modelos de tres familias diferentes de arquitecturas de redes: red neuronal de avance (FNN), red neuronal convolucional (CNN) y la red neuronal LSTM, para la estimación de la capacidad de la batería. Como entradas del modelo se utilizan las tensiones, intensidades y temperaturas de dos baterías diferentes, abarcando todas las necesidades existentes en lo que a toma de medidas se refiere.

Otros modelos fundamentan sus desarrollos en las **resistencias internas** de las LIB, como p.ej. (Pan *et al.*, 2018), que desarrollan un método basado en ELM para extraer los HI de LIB en un entorno de laboratorio y mediante un ECM (Thevenin y un algoritmo RLS, (Zou *et al.*, 2015)), obtener las resistencias internas, en ohmios, y la polarizada. Con el modelo ajustado en el entorno de laboratorio realizan un modelo on-line, que con los HI obtenidos de las LIB del VE y un estimador de la capacidad, hecho con NN, obtienen el SOH.

De igual forma, (Khaleghi Rahimian and Tang, 2023) desarrollan un modelo de estimación del SOH con datos de celdas del mismo tipo que las utilizadas para VE, bajo diferentes condiciones de operación y temperatura. Para ello toman como datos de entrada la temperatura, tensión, intensidad, resistencia medida en la descarga y el rendimiento energético acumulado. Posteriormente con NN “*feed-forward*” se estima el SOH aplicando dichas variables de entrada.

Por último, (L. Chen *et al.*, 2021) proponen un nuevo entorno con el uso de “Metabolic Extreme Learning Machine” (MELM) para la estimación del SOH. Utilizando un ECM de Thévenin para la extracción de las características de degradación, desarrollan un modelo ELM para describir el complejo mecanismo de degradación de la batería y aplicar sus parámetros al modelo MELM para estimar el SOH.

Otros artículos en cuyos desarrollos son necesarias **las temperaturas** son:

(Yao *et al.*, 2020) mediante un modelo de programación genética y utilizando tres medidas características, estiman el SOH de algunos conjuntos de datos de baterías de la NASA. En este desarrollo son necesarias la temperatura, la intensidad y la tensión de la LIB, utilizando la curva de carga y la de descarga, por lo que el método está muy limitado en su implantación en algún dispositivo.

(Wang *et al.*, 2022) presentan un método de estimación del SOH basado en datos, con un novedoso modelo integrado de GPR. Se analizan las características de envejecimiento y se extraen tres HI de las tensiones y temperaturas de las curvas de carga y descarga. Posteriormente, se propone una nueva función *kernel* utilizando cuatro funciones medias para un modelo GPR para la estimación del SOH.

(Wu *et al.*, 2022) utilizan en primer lugar, dos codificadores automáticos para extraer de las curvas de tensión y temperatura los HI, que posteriormente añaden a un modelo “Ensemble Learning” (EL) que utiliza redes “Gate Recurrent Unit” para la estimación del SOH.

(Tian, Xiong and Shen, 2020) propusieron la medición de incrementos de temperatura (ΔT) en un intervalo de tensión específico durante la carga constante, y con un modelo de regresión SVM estiman el SOH. Los resultados se comparan con el método ICA.

Como último ejemplo de métodos empleados para LIB en entornos de laboratorio, uno que necesita las tres variables principales (tensión, intensidad y temperatura) y en ambos procesos (carga y descarga). (Lee *et al.*, 2022) hacen referencia a una de las dificultades que presenta un BESS con respecto a las celdas unitarias, y es que se deben tener en cuenta los desequilibrios entre celdas, módulos, racks, etc., ya que dicho desequilibrio indica desviaciones en la tensión, en el SOC y por tanto en la temperatura de las celdas. Por ello, un desequilibrio grave en estos contenedores (módulos, racks, etc.) puede mermar su capacidad, potencia y eficiencia. Los autores de este estudio utilizan el método de extracción de características “Principal Component Analysis” (PCA) para extraer las características de degradación, y junto con un modelo LSTM, mejoran el rendimiento de la predicción del SOH. La extracción de estas características se hace en condiciones controladas, no de operación real, y las baterías utilizadas para el estudio no son operadas en la vida real, sino que han sido degradadas mediante un “*ciclador*” de baterías.

Una vez revisado el estado del arte para métodos desarrollados a partir de LIB en entornos de laboratorio, en el siguiente apartado se verán estudios focalizados a usos más prácticos.

1.2.4 Estado del arte. Métodos existentes sobre la degradación de los sistemas de almacenamiento de energía mediante baterías, en entorno real.

En este apartado se presenta el estado del arte sobre métodos que sí tienen cabida en los sistemas de almacenamiento de energía por medio de LIB empleados en la vida real. Este estará centrado además en las dificultades de los métodos del apartado anterior y las recomendaciones dadas por los autores en el estado del arte.

Como norma principal, los autores marcan como líneas generales, que los métodos expuestos en el estado del arte anterior, métodos empleados para celdas de litio probados en laboratorio, no dan los resultados esperados al aplicarse en la vida real sobre sistemas de almacenamiento para VE y BESS. Como ejemplo, podemos mencionar que los HI empleados por (Cui and Joe,

2021), que toma las tensiones máximas de los perfiles de carga o de descarga, no se dan en la operación del BESS empleado en esta tesis.

(Schimpe *et al.*, 2018) exponen que, aunque se pretenda estimar con exactitud el SOH, este normalmente debe compararse con datos de un ensayo en el laboratorio ("*Capacity Test*", *CT*), y dicho *CT* se debe hacer siempre con las mismas condiciones de C-rate y de temperatura, tanto en la carga como en la descarga. Esto hace que, aun tomando como 100% correcto el medido en el *CT*, al compararlo con el estimado por el modelo que usa datos de la operación, (de los BESS o del VE, p.ej.) medidos en unas condiciones diferentes (temperatura o C-rate), la comparación entre el modelo y el SOH medido en laboratorio siempre va a tener un error. Esto es necesario tenerlo en cuenta a la hora de trabajar con datos de baterías que funcionan en la vida real, VE, BESS, o cualquier dispositivo.

(You, Park and Oh, 2017) ponen de manifiesto que la mayoría de los estudios realizados estiman el SOH bajo supuestos bastante restrictivos, como la realización de ciclos dentro de un rango fijo, o una temperatura fija, con intensidades de carga-descargas constantes, etc. Pero estos supuestos no pueden aplicarse a las baterías de los VE y BESS reales, que en su mayoría se someten a ciclos arbitrarios. Los autores de este estudio estiman el SOH en entornos más prácticos, en los que las baterías deben soportar patrones de comportamientos de carga y descarga reales. Así, utilizan datos de la corriente y la tensión de baterías "envejecidas" con patrones de operación de VE de la vida real, como entradas de una red neuronal recurrente (RNN) para el desarrollo del modelo que predice el SOH.

(Zhao *et al.*, 2021) analizan los DDM enfocados a sistemas con LIB que dan servicio a la red eléctrica, y exponen que, según sus investigaciones, la mayoría de esos modelos de SOH se construyen y verifican con datos de pruebas de baterías de laboratorio, pero no se han implementado en aplicaciones reales. Por este motivo estos modelos sólo representan la evolución de la degradación para la configuración de la prueba, pero no se han implementado en aplicaciones de red reales. Argumentan que la complejidad del perfil de operación de la batería aumenta considerablemente entre las pruebas y las aplicaciones reales, pudiendo estos modelos no ser capaces de estimar con precisión el SOH en su aplicación real.

(Huo *et al.*, 2021) apuntan a que los MBM y los DDM son deterministas, por lo que no pueden "capturar" la propiedad estocástica del envejecimiento de las LIB. Ellos utilizan una red *Bayesiana* de modelado gráfico probabilístico para procesos indeterministas, para solventar este problema. Dicho modelo se entrena y prueba con datos reales de un periodo de 2 años con datos de 16 VE.

(Zhang *et al.*, 2022) ponen de manifiesto la importancia de establecer con precisión la degradación del BESS ya que es su principal coste de operación. Basándose en un modelo semi-empírico y la ley de *Arrhenius*, realizan un modelo de degradación cíclico con relación a la potencia de descarga. Finalmente, con un modelo lineal establecen los costes de envejecimiento de la batería, que tiene en cuenta la potencia de descarga y la profundidad del ciclo. Estos modelos se aplican al despacho de optimización, en el mercado diario de energía, para tener en cuenta el coste de la operación a la hora de realizar las ofertas.

Algo muy parecido realizan (Li *et al.*, 2022), que proponen una cuantificación del coste del envejecimiento del BESS, realizado mediante un modelo multifactorial, que valora la pérdida de vida útil de la batería establecido por medio de características de envejecimiento como la profundidad de descarga y el C-rate. Así, este artículo presenta una solución práctica en la cuantificación y mitigación de los costes de envejecimiento de las baterías mediante la optimización de las estrategias de gestión de la energía.

(She *et al.*, 2021) afirman que la medición del SOH de las baterías de los VE en el mundo real es un reto, y las pruebas necesarias, a realizar en el laboratorio y a gran escala, suelen requerir mucho tiempo y trabajo. Para paliar este problema aplican el método de ICA para la estimación del SOH de baterías de VE reales. Para ello combinan el cálculo del valor del ECM para paquetes de baterías de laboratorio, con las pruebas a nivel de celda. Verifican el método utilizando datos de celdas de laboratorio con datos de baterías de 12 VE. Los resultados muestran que el método propuesto puede realizar una estimación precisa del SOH, tanto para baterías de laboratorio como para VE reales.

(Vichard *et al.*, 2021) proponen un modelo ECM capaz de reproducir el comportamiento dinámico de la batería: tensión con respecto a la temperatura y el SOC. Los parámetros de este modelo pueden utilizarse para estimar la resistencia interna (estrechamente relacionada con el SOH). Basándose en un filtro de *Kalman*, el modelo se puede utilizar para estimar el SOC y la capacidad, indicador también del SOH. El método propuesto puede integrarse y aplicarse para el uso del VE.

(Zhang *et al.*, 2021) estiman el SOH por medio de dos modelos basados en el ICA, de un BESS de 20 kW/100 kWh formado por baterías “second-life” de autobuses, y con los datos de tensión de carga y descarga de la operación de dichas baterías. Los dos métodos utilizados en la comparativa son el ICA y la “*Probability Density Function*” (PDF). Además, establecen que la altura H del pico mayor en las curvas ICA o PDF tiene una correlación lineal con el SOH de la

batería. Esto implica que, si no se conoce el SOH de la batería, se puede obtener el grado de envejecimiento relativo a partir de los datos reales de tensión de carga, proporcionando una orientación de la degradación, clave para el funcionamiento y el mantenimiento del BESS.

(Hamar *et al.*, 2021) disponen de un conjunto de datos (8 años de histórico de 704 VE) que aportan más de 110.000 mediciones de siete variables predictoras del envejecimiento: temperatura, kilometraje, edad, SoC, C-rate de carga, C-rate de descarga y throughput, así como 704 mediciones de sus capacidades. Dicho conjunto lo utilizan para entrenar y validar dos modelos, uno semi-empírico basado en la ley de *Arrhenius* y otro basado en una NN que comparan para estimar el SOH. Los resultados son similares, en cuanto al error se refiere, en ambos casos.

(Von Bülow, Mentz and Meisen, 2021) ya expresan las limitaciones de los modelos existentes realizados con datos de laboratorio para la aplicación en el contexto de las Baterías de Vehículos Eléctricos (BVE). Por ejemplo, las variaciones en la corriente de carga y descarga, que dichos modelos no tienen en cuenta. Así, los autores proponen un modelo “*Multilayer Perceptron*” (MLP) para la previsión del SOH para su uso en el mundo real. Las entradas del modelo se seleccionan dentro de ciertos rangos operativos, combinando señales (corriente, SOC y temperatura) de dos baterías durante un número de ciclos determinado. Así, las características de entrada elegidas no se limitan a la aplicación de datos de laboratorio, sino que son aplicables al funcionamiento en el mundo real de las BVE.

(Calcuttawala and Alhaider, 2021) desarrollan una metodología para determinar el SoH de un sistema BESS operado por Vattenfall sin realizar pruebas de capacidad y resistencia fuera de la operación. Establecen, al igual que otros autores, que el diagnóstico en línea del sistema, utilizando variables medidas, como la corriente, la tensión y la temperatura, es crucial para mantener el funcionamiento ininterrumpido del sistema. Con un ECM de 2º orden y un filtro de Kalman estiman el SOC, y mediante una regresión lineal, el SOH. Todo el marco de estimación se valida utilizando datos de pruebas de ciclos de celdas en laboratorio. Las curvas de intensidad, tensión y el SOC son las proporcionadas por el BMS. Para estimar la capacidad del pack de baterías, el funcionamiento se divide en sus fases individuales de carga y descarga. Para cada uno de esos pasos, la corriente acumulada puede calcularse fácilmente a partir de los valores de corriente, mientras que la diferencia de SOC puede calcularse a partir de las estimaciones proporcionadas por el BMS en los mismos intervalos de tiempo. Según sus autores, el método requiere una gran cantidad de datos para la regresión, por lo que no es adecuado para aplicaciones BMS.

(Oji *et al.*, 2021) realizan una comparativa de modelos para estimar el SOH usando MBM (KF, PF y ARIMA) y DDM (ANN, ELM, CNN, SVM, RVM, etc.) con datos de seis baterías ubicadas en autobuses urbanos. Como conclusiones exponen que, en función de las necesidades buscadas, se ha de escoger el método mejor, y concluyen que ningún método de los estudiados por ellos en esta revisión puede considerarse absolutamente superior. Aconsejan que para cada situación particular, debe evaluarse la precisión deseada, el intervalo de confianza de salida, la capacidad de tratar la “no linealidad”, la robustez, los costes de cálculo, la capacidad de tratar la “escasez de datos” o la generalización.

Además, plantean los siguientes inconvenientes:

- (1) Los métodos que emplean un modelo realizado en condiciones de laboratorio y que posteriormente se aplican, con las condiciones de operación reales, no consideran que la evolución de la degradación es diferente a la establecida en el laboratorio a lo largo del uso de la batería del VE.
- (2) En los BESS, miles de celdas de LIB individuales están conectadas en serie para formar módulos o rack, por lo que construir modelos de estimación para cada celda individual es ineficaz. Por tanto, es esencial contar con un modelo de estimación generalizado.
- (3) Los MBM se basan en un modelo, p.ej., un modelo electroquímico, para estimar el SOH de la batería. Sin embargo, las variaciones en las condiciones de funcionamiento hacen que baterías del mismo tipo puedan presentar modelos electroquímicos con variables completamente diferentes. En este sentido, los DDM son más flexibles porque no están sujetos a estas limitaciones.

Para finalizar y en la *misma línea*, (Urquiza and Singh, 2023) exponen que:

- (1) Habiendo numerosas investigaciones sobre el SOH de las LIB, en comparación, se ha investigado poco sobre la estimación del SOH para aplicaciones BESS.
- (2) El estado del arte en aplicaciones BESS basa sus métodos, generalmente, en datos recogidos en las aplicaciones de los VE, y aunque estas técnicas de estimación del SOH utilizadas para estos, pueden extenderse a las aplicaciones BESS, aún faltan pruebas y datos para aplicaciones BESS concretas. Esto es debido a que existen diferencias muy significativas entre los perfiles de ciclo de las baterías que funcionan en los VE y en los sistemas BESS.

- (3) Para finalizar concluyen que los modelos de baterías, contruidos a partir de datos experimentales de LIB para aplicaciones de VE, pueden llevar a conclusiones poco fiables sobre el funcionamiento, el rendimiento y la fiabilidad de las baterías en aplicaciones de BESS.

Una vez revisado el estado del arte de los diferentes métodos empleados, se ha realizado la Tabla 1.1 resumen, donde se han introducido los parámetros más relevantes a analizar desde el punto de vista de los problemas encontrados en la literatura científica, y desde un punto de vista práctico a la hora de la posible aplicación del método en la vida real. En ella aparecen los artículos del estado del arte del apartado 1.2.3 (id. 1 hasta id. 34) y del apartado 1.2.4 (id. 35 hasta id. 45). Los métodos con id. 45 y 46 (marcados en color verde) son los derivados de esta tesis, que se desarrollarán en el Capítulo 2 y 4.

Así se han establecido las siguientes secciones en la tabla:

1. Requisitos/Necesidades del método. Donde se establecen qué parámetros es necesario tener para la posible aplicación del método. Esta sección se ha dividido en tres:
 - ✓ Mediciones a realizar, y duración de las mismas en los segmentos dados.
 - ✓ Operación necesaria para su medición: la carga o la descarga.
 - ✓ Medidas a tomar en la operación. ¿Qué medidas utilizan los diferentes métodos? Por norma general suelen ser la temperatura, la tensión e intensidad de la batería, aunque existen métodos, sobre todo los MBM, que necesitan conocer la resistencia o impedancias de la batería.
2. Aplicación del método. Donde se establece a qué tipo de aplicación es susceptible de dar servicio: baterías de laboratorio (LAB), LIB, VE, BESSc y BESSa. Y si es posible que ese servicio sea en “*tiempo real*”. Las siglas BESSc aplican a BESS que realizan su carga en CC, y BESSa hacen referencia a BESS que realizan la carga a corriente variable, como la que presenta el BESS de esta tesis.
3. Características del método. Aquí se presentan los resultados del método en lo relativo a los datos de precisión, qué tipo de modelo emplean para estimar el SOH, a qué grupo pertenece y si el estudio ha sido realizado o probado con datos de operación reales.

Tabla 1.1a. Parámetros necesarios para la elaboración de los métodos seleccionados en el estado del arte.

id.	Artículo	REQUISITOS/NECESIDADES DEL MÉTODO						
		Duración del segmento		Operación necesaria para su aplicación		Medidas necesarias		
		Mediciones a lo largo de todo el segmento de curva (✓ Si; *NO; N/A = No informado)	Duración del intervalo de medida (✓ Todo; *Nada; N/A = No Informado)	Carga	Descarga	Temperatura	Intensidad	Tension
1	(Tian, Xiong and Yu, 2019)	✓	✓	✓			✓	✓
2	(Chen et al., 2022)	✓	✓	✓			✓	✓
3	(Braun et al., 2022)	✓	✓	✓			✓	✓
4	(Liu, Xu and Feng, 2020)	✓	N/A	✓	✓			✓
5	(Cai et al., 2019)	✓	Un pulso (18 s)	✓	✓		✓	✓
6	(Chen et al., 2019)	✓	✓		✓			✓
7	(Wang et al., 2016)	✓	✓	✓				✓
8	(Feng et al., 2019)	*	15 min	✓				✓
9	(Weng et al., 2013a)	✓	✓	✓				✓
10	(He et al., 2020)	✓	✓	✓				✓
11	(Bian et al., 2020)	✓	✓	✓	✓			✓
12	(Liu et al., 2018)	✓	N/A		✓			✓
13	(Li et al., 2015)	✓	✓	✓	✓			✓
14	(Deng et al., 2020)	✓	✓		✓		✓	✓
15	(Wang et al., 2019)	*	Durante la carga a Tensión=cte.	✓				✓
16	(Zhang and Tian, 2019)	✓	Durante la carga a Intensidad=cte.	✓				✓
17	(Tan and Zhao, 2020)	✓	✓	✓				✓
18	(Tian, Xiong and Shen, 2020)	✓	✓	✓		✓		
19	(Yao et al., 2020)	✓	✓		✓	✓	✓	✓
20	(Wei et al., 2022)	*	Por encima de 3,7 V	✓				✓
21	(Wu et al., 2022)	✓	N/A	✓		✓		✓
22	(Wang et al., 2022)	✓	✓	✓	✓	✓	✓	✓
23	(Ruan et al., 2021)	*	Durante la carga a Tensión=cte.	✓				✓
24	(Liu and Yan, 2020)	✓	✓		✓			✓
25	(Han et al., 2022)	✓	✓	✓			✓	✓
26	(Wu et al., 2020)	N/A	N/A	✓	✓			✓
27	(L. Chen et al., 2021)	N/A	N/A		✓		✓	✓
29	(Kaur et al., 2021)	✓	✓	✓	✓	✓	✓	✓
30	(Khaleghi Rahimian and Tang, 2023)	*	15 % SOC	✓	✓	✓	✓	✓
31	(Cui and Joe, 2021)	✓	✓	✓	✓			✓
32	(Pan et al., 2018)	✓	✓	✓	✓		✓	✓
33	(Meng et al., 2020)	*	*	✓	✓		✓	✓
34	(Lee et al., 2022)	✓	*	✓	✓	✓	✓	✓
35	(Huo et al., 2021)	N/A	N/A	✓	✓	✓	✓	✓
36	(You, Park and Oh, 2017)	N/A	✓	✓	✓		✓	✓
37	(Zhang et al., 2022)	✓	*	✓	✓	✓		
38	(Li et al., 2022)	✓	DOD	✓	✓		✓	✓
39	(She et al., 2021)	✓	*	*				✓
41	(Vichard et al., 2021)	✓	✓			✓	✓	✓
42	(Zhang et al., 2021)	✓	✓	✓	✓		✓	✓
43	(Hamar et al., 2021)	✓	✓	✓	✓	✓		Throughput; edad; km
44	(Von Bülow, Mentz and Meisen, 2022)	*		✓	✓	✓	✓	✓
45	(Calcuttawala and Alhaider, 2021)	✓	✓	✓	✓		✓	✓
46	(Alvarez-Monteserin and Sanz-Bobi, 2022); Capítulo 2 de esta tesis	*	$\Delta T = 0,025V$	✓				✓
47	Metodología del c. 5 de esta tesis	*	10 min	✓			✓	✓

Tabla 1.1b. Posibles aplicaciones y características de los métodos seleccionados en el estado del arte.

APLICACIÓN DEL MÉTODO				CARACTERÍSTICAS DEL MÉTODO			
Artículo	Aplicación:(L AB;LIB; VE;BESSc;BE SSa)	On-line (Realizable en tiempo real)	Sobre datos reales	Precision	Método/Algoritmo	Grupo (MBM; DDM)	
1 (Tian, Xiong and Yu, 2019)	VE; LIB	✓	✗	Error relativo= 0,031	OCV, ICA	MBM	
2 (Chen et al., 2022)	VE; LIB	✓	✗	MAE = 0,0068	ECM y MES	MBM	
3 (Braun et al., 2022)	LAB	✗	✗	MAE=0,0123	ECM	MBM	
4 (Liu, Xu and Feng, 2020)	LAB	✓	✗	RMSE = 0,0124	A "hierarchical Ensemble Model" of Extreme Learning Machine (ELM)	DDM	
5 (Cai et al., 2019)	LAB	✗	✗		SVM	DDM	
6 (Chen et al., 2019)	LIB	✓	✗	RMSE = 0,0032	Least square – supported vector machine (LS-SVM)	DDM	
7 (Wang et al., 2016)	LAB	✓	✗	Error bound of ±2.5%.	DVA= (dv/dQ)-Q;	MBM	
8 (Feng et al., 2019)	LIB	✓	✗	El 99.7% del error de estimación del SOH es menor del 3%	ICA y SVM	DDM	
9 (Weng et al., 2013a)	LIB	✓	✗	MAE = 0,01	ICA y SVM	DDM	
10 (He et al., 2020)	LAB	✗	✗	MAE = 0.00159	ICA	MBM	
11 (Bian et al., 2020)	LAB	✗	✗	RMSE= 0,0012 a 0.0041	ICA	MBM	
12 (Liu et al., 2018)	LAB	✓	✗	RMSE = 0,00065	Unscented particle filter (UPF)	MBM	
13 (Li et al., 2015)	VE; LIB	✓	✗	ARE (Average relative error) = 0,007 y Error máximo =0,058	PF y ANN	DDM	
14 (Deng et al., 2020)	LAB	✗	✗	RMSE = 0,013. MAE =0,01 y RMSE=0,013	LR, SVM y GPR	DDM	
15 (Wang et al., 2019)	LAB	✗	✗	RMSE = 0,0111 a 0,0180	ECM	MBM	
16 (Zhang and Tian, 2019)	LIB	SI	✗	RMSE = 0,0077 y RMSE = 0,0163	GPR	DDM	
17 (Tan and Zhao, 2020)	LIB	✓	✗	RMSE = 0,0054 y 0,0143	LSTM convinado con "fully connected" (FC)	DDM	
18 (Tian, Xiong and Shen, 2020)	LAB	✓	✗	RMSE= 0,0249; 0,0196 y 0,0158	Support Vector Regression (SVR)	DDM	
19 (Yao et al., 2020)	LAB	✗	✗	RMSE = 0,0038; 0,0066; 0,0042	Modelo Genetic Programming (GP). Basado en arboles.	MBM	
20 (Wei et al., 2022)	LIB	✓	✗	MAE entre 0,003 y 0,02	ANN	DDM	
21 (Wu et al., 2022)	VE; LIB	✗	✗	RMSE = 0,0104	Ensemble learning (EL) y Gate Recurrent Unit (GRU) networks.	DDM	
22 (Wang et al., 2022)	LAB	✗	✗	RMSE menor que 0,025 para todas las baterías	GPR	DDM	
23 (Ruan et al., 2021)	LAB	n	✗	MAE aprox 0,02	LR y OCV	MBM	
24 (Liu and Yan, 2020)	LAB	✓	✗	Media de RMSE = 0,0123	Extreme learning machine (ELM)	DDM	
25 (Han et al., 2022)	VE; LIB	✓	✗	RMSE (mejor) = 0,027	LSTM.	DDM	
26 (Wu et al., 2020)	VE; LIB	✗	✗	RMSE (mínimo) = 0,0072	LSTM	DDM	
27 (L. Chen et al., 2021)	LAB	✗	✗	RMSE entre 0,0874 y 0,109	Model-based (thevenin) y metabolic extreme learning machine (MELM)	MBM	
29 (Kaur et al., 2021)	VE; LIB	✗	✗	RMSE = 0,0447 (FNN);0,0527(CNN);0,0426(LSTM)	Deep Learning: (FNN), (CNN) y (LSTM)	DDM	
30 (Khaleghi Rahimian and Tang, 2023)	VE; LIB	✗	✗	RMSE = 0,009	Deep feed-forward NN	DDM	
31 (Cui and Joe, 2021)	LAB	✗	✗	RMSE = 0,0045;0,0045 y 0,004	Dynamic spatial-temporal attention- based gated recurrent unit (DSTA- GRU), pero prueban 5 tipos de modelos (GRU, DSA-GRU, TA-GRU, DSTA-RNN, DSTA-LSTM, DSTA-GRU)	DDM	
32 (Pan et al., 2018)	VE; LIB	✓	✗	RMSE 0,011	ELM, NN y un modelo de Thevenin con un algoritmo RLS.	DDM	
33 (Meng et al., 2020)	VE; LIB	✗	✗	MSE = 0,0017 para Cell1 y 0,0028 para Cell2	Basado en un marco de aprendizaje conjunto optimizado. Self-adaptive Differential Evolution (SaDe) algorithm y un SVM.	DDM	
34 (Lee et al., 2022)	LIB	✓	✗	RMSE=0,39	NN(LSTM)	DDM	
35 (Huo et al., 2021)	VE; LIB	✓	✓	MAE= 0,04	Bayesian Network (BN)	DDM	
36 (You, Park and Oh, 2017)	VE; LIB	✓	✗	RMSE = 0,0404 y 0,0765	LSTM layer	DDM	
37 (Zhang et al., 2022)	VE;BESSc	✓	✗	$\epsilon = (Q_{loss} - Q_{loss})/Q_{loss}$ (Error relativo) =5%	Modelo semi-empírico basado en la ley de ARRHENIUS	MBM	
38 (Li et al., 2022),	VE;BESSc	✓	✓	N/A	IBLEM (semi-empírico)	MBM	
39 (She et al., 2021)	VE; LIB	✓	✓	RMSE=0,02457	ICA (SOH = Ax IC +B)	MBM	
41 (Vichard et al., 2021)	VE; LIB	✓	✓	NRMSE=0,016	ECM-Electrical circuit model	MBM	
42 (Zhang et al., 2021)	BESSc	✓	✓	Error Abs: IC = 0,0062 a 0,0237; PF = 0,0009 a 0,0358	ICA y PDF	MBM	
43 (Hamar et al., 2021)	VE; LIB	✓	✓	RMSE = 0,034 y 0,0305	Modelos: semi-empírico basado en la ley de ARRHENIUS(temperatura y carga); NN (con edad, Km y Temp)	DDM	
44 (Von Bülow, Mentz and Meisen, 2021)	VE; LIB	✓	✗	RMSE=0,1574	MLP	DDM	
45 (Calcuttawala and Alhaider, 2021)	BESSc	✓	✗	RMSE = 0,155	ECM y UKF	MBM	
46 (Alvarez-Monteserin and Sanz-Bobi, 2022); Capítulo 2 de esta tesis	VE; LIB	✓	✗	RMSE = 0,0095 a 0,0186	GPR	DDM	
47 Metodología del c. 5 de esta tesis	BESSa	✓	✓	Error = 0,16	LR; SVM y GPR	DDM	

Analizando los datos de la Tabla 1.1 y haciendo una valoración *coste/beneficio*, de los diferentes métodos y sus necesidades para su extracción (medidas y HI), se puede ver que, en la mayoría de los métodos propuestos, no es eficiente la realización de tantos HI, puesto que, en la mayoría de los casos, estos no incrementan sustancialmente la precisión del resultado. Sin embargo, sí hacen que los recursos empleados para la estimación del SOH sean más costosos. Esto último imposibilita en muchos casos que la estimación del SOH se realice de forma rápida (on-line) o se imposibilite su aplicación en las LIB de la vida real.

1.2.5 Estado del arte relativo al mantenimiento de los BESS

Ya ha sido revisado el estado del arte para ver los métodos existentes que estiman el estado de la degradación de las celdas de las LIB, y de los sistemas de baterías empleados en VE o BESS conectados a redes eléctricas.

En el Capítulo 5 se pondrá el foco en la posible mejora en los trabajos de mantenimiento de los sistemas BESS, utilizando la metodología propuesta en esta tesis en el Capítulo 4.

Por ello, en el actual apartado 1.2.5 se revisará el estado del arte sobre el mantenimiento de los BESS. Así, existiendo muchos artículos en la literatura que utilizan MBM y DDM para estimar el SOH de las LIB, tal como se vio en el apartado 1.2.3, no existen demasiados que propongan métodos usados en BESS, tal como se vio en el apartado 1.2.4, y existen muy pocos relativos a su aplicación en el mantenimiento (preventivo o predictivo), tal como se verá en esta sección.

Como primer ejemplo, en 2009 se publicó una guía realizada por el “*Comité 21 Coordinador de Normas del IEEE*” en la que participaron múltiples científicos, (*IEEE Standards Coordinating Committee 21 IEEE, 2009*) donde se proporcionan enfoques para el diseño, operación, mantenimiento, integración e interoperabilidad de sistemas BESS con sistemas eléctricos de diferentes tipologías.

(Abdeltawab and Mohamed, 2021) proponen un método para la optimización del *plan de mantenimiento* del BESS y lograr así un mayor beneficio, al tener una interrupción mínima en la operación de este.

(Wu *et al.*, 2021) desarrollan un método de mantenimiento, basado en el aprendizaje por refuerzo, para llevar a cabo una gestión óptima del mantenimiento preventivo (MP) en los BESS equipados con sistemas de

medición o estimación de la degradación de la capacidad. Para ello establecen un marco de MP multinivel para obtener una estrategia de acción que tiene en cuenta los costes, la capacidad y la fiabilidad. En este artículo se pone de manifiesto también, que las actividades de MP en los BESS tienen como objetivo lograr una mejor operación a largo plazo, y la necesidad de conocer en todo momento el SOH de la batería para ello.

(J. C. Chen *et al.*, 2021) ponen de manifiesto que la vida útil remanente (“Remaining Useful Life”, RUL) es crucial para la aplicación de estrategias de mantenimiento predictivo, y desarrollan un modelo híbrido basado en datos para la predicción del SOH y la RUL, utilizando el conjunto de datos de la NASA, el mismo utilizado en el primer capítulo de esta tesis.

Por último, (Fioravanti *et al.*, 2020) abogan por el uso del mantenimiento predictivo de los BESS, ya que señalan que este enfoque no se ha utilizado plenamente en los sistemas de baterías, y pueden potencialmente, evitar que se produzcan fallos catastróficos. Entienden que las prácticas predictivas en los sistemas complejos y electrónicos, son más difíciles de aplicar que en otros tipos (mecánicos, p. ej.). En los sistemas electroquímicos y electrónicos complejos, un sistema BESS p.ej., un problema en un componente hoy puede manifestarse más adelante y repercutir en un fallo de otro componente, lo que implica una recopilación de datos en muchos niveles para la posible predicción de fallos.

Enumeran algunos de los obstáculos a superar que tienen actualmente los BESS para la monitorización y el mantenimiento predictivo:

- (1) El hardware convencional de los BESS está limitado en comunicaciones y computación.
- (2) Los BMS actuales no están diseñados para este tipo de tareas por norma general, lo que hace difícil implantar una metodología de predicción del SOH una vez el BESS está conectado a la red.
- (3) Los EMS actuales están diseñados para controlar el BESS como recurso de la red a la que está conectado, pero no incluyen funciones de monitorización ni seguridad, lo que limita las actuaciones preventivas de los operadores del sistema.

Focalizan además el objetivo para un mantenimiento predictivo correcto: *“...identificar los indicadores de fallos potenciales e intervenir de manera preventiva en el BESS en operación, sin que la intervención suponga un problema en sí misma.”*. Exponiendo así, que un planteamiento de supervisión correcto debe pasar por la creación de indicadores que proporcionen los fallos en un periodo previo adecuado, señalando el componente determinado y con un impacto mínimo en la operación del BESS.

Señalan que se debe establecer en la metodología, una lista que identifique las relaciones indicador-fallo que puedan ser rastreados y monitorizados en el sistema.

1.3. Puntos destacados del estado del arte

Después de los métodos vistos en el estado del arte, para estimar o medir la degradación de las baterías de iones de litio, podemos establecer que los parámetros internos de las celdas de la batería (p. ej., impedancia, resistencia interna, etc.) son difíciles de monitorear por cualquier BMS, debido a su difícil acceso mientras están en operación. Por esta razón, los parámetros internos de las LIB no se utilizan en los procesos de estimación del SOH en tiempo real.

Sin embargo, la temperatura, **la corriente y la tensión son variables externas de la batería que se pueden medir directamente** y sus características se pueden analizar para utilizarlas en la estimación del proceso de envejecimiento de la batería, mediante modelos DDM.

También se puede concluir, que la mayoría de los DDM planteados en el estado del arte para celdas de las LIB en entornos de laboratorio, no son susceptibles de empleo en los sistemas BESS, por su complejidad, su coste, su imposibilidad de implantación en un sistema computacional pequeño, o simplemente porque el método a aplicar “no encaja” con el diseño de los órganos de control establecidos en el BESS.

1.3.1 Referente a LIB y BESS

Como **resumen del estado del arte** de métodos para estimar el SOH de LIB y BESS, se enumeran las **principales dificultades y retos** presentados por los autores:

Dificultades encontradas:

- (1) El entorno de trabajo y condiciones sobre los que se han realizado la mayoría de los **estudios que estiman el SOH para LIB** de laboratorio **no pueden aplicarse a las baterías de los VE y BESS** reales.
- (2) Las **mediciones de capacidad** (CT) que se realizan en laboratorio y se comparan con el SOH estimado con datos reales, **siempre diferirán de la capacidad real**, ya que el CT **no se realiza en las condiciones reales** de temperatura y C-rate.

- (3) **No existe el método de estimación del SOH “paradigma”**. Son las necesidades buscadas, las que harán escoger el método más adecuado en función de: la precisión deseada, el intervalo de confianza de salida, la “no linealidad”, la robustez, los costes de cálculo, la “escasez de datos” o la generalización. Haciendo que cada necesidad lleve su solución *ad hoc*.
- (4) La **evolución de la degradación** estimada por un modelo desarrollado con unas condiciones de laboratorio **difiere al aplicar las condiciones reales**, ya que estas condiciones evolucionan de manera diferente a lo largo del uso de la LIB.
- (5) Los **estudios realizados con datos de VE**, donde se intenta generalizar su uso a los BESS, **no han sido probados con datos de BESS** operando en la vida real.
- (6) Poca investigación sobre la estimación del SOH de las LIB para aplicaciones BESS, y pocos estudios con datos de BESS reales.
- (7) **En los BESS**, generalmente **los métodos requieren una gran cantidad de datos** para la estimación del SOH, por lo que no es adecuado su implantación en los BMS.
- (8) **Los modelos contruidos** a partir de datos experimentales de LIB para aplicaciones de VE pueden llevar a conclusiones **poco fiables en aplicaciones de BESS**.

Retos planteados:

- (1) La importancia de determinar con precisión **la degradación del BESS** ya que **es su principal coste** de operación.
- (2) **La medición de la capacidad** de las baterías de los VE para el cálculo del SOH es costoso, ya que las pruebas necesarias a realizar en el laboratorio y a gran escala **necesitan muchos recursos**.
- (3) **Un diagnóstico en línea** del SOH, utilizando variables medidas (corriente, tensión y la temperatura), **es esencial para mantener el funcionamiento** ininterrumpido del sistema.

- (4) En los BESS, emplear un MBM para cada celda individual es ineficaz, siendo esencial contar con un modelo de estimación generalizado.

En línea con lo anterior, a efectos del mantenimiento del BESS, tal como se verá en el Capítulo 5, conocer el SOH global del BESS no es operativo si no se conoce **el SOH de las unidades que lo componen**, ya que no **nos permite diferenciar el nivel de degradación de cada SBMS** o cada rack que lo forman. Siendo en este sentido los DDM la mejor elección para solucionar esto.

1.3.2 Referente al mantenimiento aplicado a BESS

Como resumen del estado del arte en el **mantenimiento aplicado a los BESS**, se enumeran las **principales aportaciones**:

- (1) **Conocer el SOH** y la RUL de un BESS es **crucial para** la aplicación de **estrategias de mantenimiento** predictivo.
- (2) Se aboga por el uso del **mantenimiento predictivo de los BESS**, ya que este enfoque no se ha desarrollado plenamente aún.
- (3) El mantenimiento predictivo ayuda a **evitar que se produzcan fallos catastróficos** y por tanto de seguridad.
- (4) Un **mantenimiento predictivo** correcto en un BESS implica una **recopilación de datos en muchos niveles** para la predicción de potenciales fallos.

Retos para la monitorización predictiva:

- (1) **Limitación del hardware** de los BESS en cuanto a comunicaciones y computación.
- (2) **Limitación de los BMS** en diseño para la realización de monitorización.
- (3) **Limitación del EMS** en diseño para actuaciones preventivas.
- (4) **Identificación de HI y modelos de fallos preventivos** en el BESS en operación, sin intervenir el funcionamiento normal de este, señalando el componente y el periodo previo determinado.

Capítulo 2

Identificación de un nuevo indicador de salud (DSR)

Estructura de la tesis: **Capítulo 2**

Introducción y Estado del Arte

• Identificación de un nuevo indicador de salud (DSR) •

Arquitectura y características del BESS en estudio

Aplicación del nuevo DSR a un BESS

operando en regulación de frecuencia

Mantenimiento aplicado a un BESS

por medio de la metodología desarrollada

Conclusiones, contribuciones y futuros desarrollos

- En este capítulo se desarrolla un **nuevo HI** que debido a su alta correlación con el SOH tradicional, puede en todo momento **establecer el nivel de degradación de una LIB** cargada a CC.
- Además, se muestran los tres conjuntos de datos de LIB que se han utilizado en el capítulo para el estudio.
- Posteriormente se presentan las múltiples **ventajas del uso de este nuevo HI**.
- Para finalizar, mediante varios modelos de ML, **se prueba la viabilidad del uso del HI** como entradas de modelos para estimar el SOH.

2.1. Introducción y motivación.

En la introducción del Capítulo 1 se esbozó qué era un BESS y qué componentes básicos tenía. Siendo este el principal protagonista de la tesis y *en el camino* al desarrollo de una metodología para lograr estimar su degradación, ha sido necesario establecer un nuevo HI que diera respuesta a las carencias vistas en el estado del arte de las LIB de laboratorio, y que pudiera aplicarse en un BESS operando en la vida real.

Como ya se ha mencionado anteriormente, el HI más popular utilizado para evaluar la degradación de las LIB es el SOH. Este indicador es necesario para garantizar la seguridad, buen funcionamiento y gestión de la batería, por ejemplo, para la estimación correcta del SOC.

En este segundo capítulo de la tesis se propone un nuevo HI basado en perfiles de tensión de carga para resolver algunos de los problemas antes mencionados y cubrir algunos de los vacíos detectados en el estado del arte.

Este nuevo HI, por su alta correlación y similitud con el SOH, puede reemplazarlo en la labor de indicador de salud cuantitativo, y además tiene la ventaja de que se puede calcular o estimar con mucha facilidad, ya que está basado en perfiles de tensión de carga, exclusivamente. Como se mostrará, se calcula con variables medidas directamente (tensión y tiempo), no siendo necesario esperar todo el ciclo de carga para su cálculo, por lo que se reducen los tiempos de espera. Debido a su alta correlación con la capacidad, funciona como un gran marcador del “*fin de vida de la batería*” (“End-of-Life”, EOL), resolviendo algunos de los problemas y vacíos mencionados y detectados en el estado del arte.

Además, como se ha podido ver en el Capítulo 1, son muchos los HI, o características de salud (“Healthy of Features” HF) existentes y utilizados principalmente como entradas de modelos para estimar el SOH. Estos indicadores o características se extraen siempre de los perfiles de tensión, intensidad, temperatura, resistencia, impedancia, etc., durante el proceso de carga o descarga de las baterías.

Como ejemplo, (Wu *et al.*, 2020) extraen cinco características: la duración de la carga de CC (F1), la relación de carga de CC (F2), la duración de la descarga (F3), el valor pico de IC (F4) y la tensión correspondiente F5, para predecir el SOH, (Khaleghi Rahimian and Tang, 2023) utilizan la temperatura, la tensión, la intensidad, la resistencia (medida en la descarga) y el rendimiento energético

acumulado y (Tan and Zhao, 2020) necesitan nueve características extraídas de la curva de tensión de carga.

En la mayoría de los casos revisados en la literatura, para obtener estos HI o HF es necesario que se haya realizado toda la carga o descarga de la batería durante los diferentes ciclos de su vida y así poder estimar el SOH.

Esto ponía de manifiesto la necesidad de obtener un HI que no fuera tan costoso en términos de tiempo de extracción de datos, recursos operativos y complicación de cálculos. Por ello, en este Capítulo 2 se propone un nuevo HI, basado en segmentos de tensión solamente de carga (periodos cortos durante la tensión de carga), para así resolver la mayor parte de los problemas mencionados anteriormente y cubrir algunos de los vacíos detectados en el estado del arte, como se ha mencionado.

Se buscó un HI que se ajustara a aplicaciones de la vida real, donde la carga de la batería se realiza a corriente constante en la mayoría de los dispositivos (VE, laptop, móviles, drones, etc.) y en condiciones controladas. Se buscó también que pudiera medirse con los menores recursos posibles, sin necesidad de más sensores de los necesarios para la operación del dispositivo (tensiones e intensidades) y que no precisara de cálculos costosos en tiempo y recursos. Por lo que, para este nuevo HI no se necesita, por ejemplo, conocer el perfil de descarga de la batería, ni que se realice una carga completa de la misma. Ya que, en aplicaciones de la vida real generalmente, la carga de la batería se lleva a cabo a corriente constante y en condiciones controladas y, por lo tanto, se cumplirán las condiciones convenientes para medir y estimar el nuevo HI descrito en este Capítulo 2.

También se probará este nuevo HI con un modelo de regresión (GPR) para estimar la capacidad perdida y poder realizar comparaciones con modelos existentes en la literatura. De manera similar, se desarrolla un modelo de NN multicapa utilizando como entradas valores del nuevo indicador, para estimar la degradación. La sensibilidad y precisión de estos dos modelos con datos desconocidos son difícilmente superables, con $R^2 = 1$ y $R^2 = 0,98$ respectivamente.

2.2. Conjuntos de datos utilizados en este Capítulo

Para la propuesta, el desarrollo y las pruebas de este indicador se han seleccionado tres conjuntos de datos de LIB utilizados en mucha de la literatura

científica existente. La elección de estos tres grupos de baterías ha surgido por la necesidad de:

- (1) Elegir baterías que hayan sido ampliamente utilizadas en estudios científicos similares, para poder comparar los resultados obtenidos.
- (2) Analizar el comportamiento de las tensiones de carga de las baterías y poder probar así el nuevo HI desarrollado.
- (3) Disponer de una variedad de químicas de baterías diferentes operadas de forma (con perfiles de carga y descarga) diferente y además también con intensidades variables.
- (4) Poder generalizar el uso del nuevo indicador HI probándolo con diferentes baterías.

El primer grupo es del *Centro de Excelencia de Pronósticos Ames de la NASA* con las baterías B0005, B0006 y B0007 de iones de litio y 2 Ah de capacidad nominal. En esta, las cargas se realizaron en modo CC a 1,5 A hasta que las tensiones de las baterías alcanzaron los 4,2 V. Las descargas se llevaron a cabo a un nivel de CC de 2 A hasta que el voltaje de las baterías cayó a 2,7 V, 2,5 V y 2,2 V para las baterías B0005, B0006 y B0007 respectivamente. Los experimentos se detuvieron cuando las baterías alcanzaron una degradación del 30% en su capacidad nominal.

La segunda fuente de datos utilizada es del *Centro de Ingeniería Avanzada del Ciclo de Vida (CALCE) de la Universidad de Maryland*, con la numeración CS2-35, CS2-36 y CS2-37. Estas celdas son de iones de litio con ánodo de grafito y cátodo de LiCoO₂, con 1,1 Ah de capacidad nominal. En este caso, las cargas se realizan en modo CC a 0,5 A hasta que la tensión de la batería alcanza los 4,2 V, y la descarga a 1A en CC y el voltaje de corte para estas baterías fue de 2.7V. El proceso de envejecimiento acelerado se realizó a una temperatura ambiente de 24°C.

El último conjunto de datos de baterías (BMP-cell1 y BMP-cell2) son de Kokam Co. LTD, modelo SLPB78205130H de polímero de litio, con 16 Ah de capacidad, pertenecientes a *Oxford University Research Archive (ORA) de la Universidad de Oxford*. Así, para el modelo "Profit-Maximizing Bucket" (BMP), los límites de tensión se fijaron en 3,42 V y 4,08 V, correspondientes al 10 % y al 90 % del estado de carga, y el perfil de corriente de carga tiene variaciones de 2 A hasta 17 A.

De todas las celdas de baterías pertenecientes a los tres grupos se dispone de las mediciones de capacidad (Ah) a lo largo de los ciclos de carga y descarga, tal como se muestra en la Fig. 2.1 y Fig. 2.13, por lo que el SOH se puede calcular fácilmente por medio de la ecuación (1) de la próxima Sección 2.3.




Fig. 2.1. Evolución de las capacidades a lo largo de los ciclos para el conjunto de las baterías de la NASA (a) y CALCE (b).

El conjunto de datos de la NASA y CALCE se emplearán en el apartado 2.3 de este capítulo, y el conjunto de ORA se empleará en el 2.5, ya que este tiene un perfil de carga de intensidad variable.

2.3. Propuesta de un nuevo indicador de degradación de las baterías

Como se ha mencionado, en este apartado del Capítulo 2 se desarrollará un nuevo HI que permitirá realizar una valoración de la degradación de las LIB de forma continua.

2.3.1 Introducción del HI

El SOH es el indicador más popular para reflejar la degradación de las LIB. La fórmula más extendida para este indicador de salud se muestra como:

$$\text{SOH (\%)} = \frac{C_{\text{ACTUAL}} [\text{Ah}]}{C_{\text{BOL}} [\text{Ah}]} \quad (1)$$

Donde C_{ACTUAL} y C_{BOL} son la capacidad actual y de inicio de vida (“Begin of Life”, BOL), respectivamente.

El valor del SOH de la batería en el primer ciclo de uso BOL, es 100%, es decir, su capacidad nominal. De la misma forma, el valor en el fin de vida (EOL) se establece globalmente en un 70-80%, es decir, la capacidad degradada es el 20-30% (Locorotondo *et al.*, 2020), (Guha and Patra, 2017). Por lo tanto, la relación entre SOH y la capacidad degradada (“Fade Capacity”, FC) es:

$$\text{FC (\%)} = 1 - \text{SOH (\%)} \quad (2)$$

Otra variante del SOH extendida en la literatura actual (Lee *et al.*, 2022), es referirlo a la resistencia interna de la batería, ya que esta va en aumento con la operación y el paso del tiempo como norma general, aunque depende del tipo de degradación.

El valor de C_{BOL} viene dado por el fabricante y como se ha mencionado, es la capacidad nominal de la celda expresado en Ah y determinada por el fabricante.

Para conocer la capacidad real, C_{ACTUAL} de una batería (celda, modulo, rack (string) o escalados de estos, SBMS y BESS), se ha de realizar una prueba de capacidad, mediante un procedimiento que debe realizarse siempre en las mismas condiciones de temperatura y C-rate de carga y de descarga, tal como exponen (Schimpe *et al.*, 2018). Esto hace que, llevar a cabo esta prueba sea costoso en tiempo y recursos, además de la necesidad de interrumpir la operación de la batería e incluso la necesidad de conexión a un sistema (circuito) de pruebas, para ello.

A la vista de lo anterior, se propone un nuevo HI basado en la observación de nuevas características de interés (FOI) de las curvas de tensión a corriente constante. Estas curvas de tensión, a lo largo de los diferentes ciclos de carga de la batería B0005 de la Nasa, se muestran en la Fig. 2.2.

Se puede apreciar cómo, con el transcurso de los ciclos de carga, los tiempos de carga hasta alcanzar la tensión objetivo (4,2 V generalmente) se reducen, es decir, decrecen a lo largo de su vida. Mientras esto ocurre, la batería se va degradando y su capacidad real va disminuyendo.




Fig. 2.2. Perfiles de tensión de carga desde el ciclo 1 hasta el final de la vida útil del ciclo (EOL) para la batería B0005 de la Nasa.

Esta FOI mostrada para la batería B0005 se puede observar en todas las LIB de las seleccionadas en la Sección 2.2, ya que sus perfiles de intensidad de carga son iguales a lo largo de sus ciclos.

2.3.2 Definición del indicador de salud

De acuerdo con el análisis realizado en el punto anterior, se expone el desarrollo de un nuevo indicador de degradación construido a partir de datos de tensiones y tiempos obtenidos de las curvas de carga a corriente constante. Así, se extraen las características de envejecimiento basadas únicamente en las curvas de tensión durante la fase de carga a corriente constante.

Como se puede apreciar en la Fig. 2.2, como resultado del decrecimiento de los tiempos de carga hasta alcanzar la tensión *objetivo* (4,2V), para la batería B0005 de la Nasa, las pendientes (calculadas entre dos puntos cualesquiera) de las curvas de tensión a lo largo de los ciclos de carga, también varían, aunque en este caso esta variación es creciente.

Así, (p.ej., Fig. 2.3) la pendiente para el ciclo 1 entre los puntos P_1 y P_2 , viene dada por la formula (3):

$$m = \frac{V_{4,1} - V_{4,0}}{t_2 - t_1}, \quad (3)$$

$$\text{y para el ciclo EOL, } m' = \frac{V_{4,1} - V_{4,0}}{t'_{2} - t'_{1}}, \quad (4)$$




Fig. 2.3. Cálculo de la variación de la pendiente desde el ciclo 1 (puntos P1 y P2) hasta los puntos de fin de ciclo (P'1 y P'2).

Si calculamos las pendientes de todos los ciclos de carga (desde el ciclo 1 hasta el ciclo EOL) de la batería B0005 entre dos puntos de tensión (p.ej.: desde 3,8 V hasta 3,9 V), llegaríamos a una curva como la de la Fig. 2.4:




Fig. 2.4. Pendientes para el rango de tensión medido entre [3,8 -3,9 V] para la batería B0005 de la NASA a lo largo de sus ciclos de carga.

EL *eje x* indica el número de ciclos de carga de la batería, y el *eje y* muestra el cálculo de las pendientes mencionadas anteriormente. Así, con estas pendientes podemos definir el nuevo indicador propuesto, que se ha denominado “*Degradation Speed Ratio*” (DSR), y expresa la velocidad de degradación de la batería¹, medida en este rango de tensión [3,8-3,9V] y a lo

¹Una medida del DSR aporta el valor de la degradación en un punto, pero las siguientes ofrecen una *tendencia o ratio comparativo*.

largo de todos sus ciclos de carga realizados (del ciclo 1 al ciclo EOL). Este indicador DSR se mide en V/s y para el ejemplo de la Fig. 2.4, esta velocidad aumenta de 0,2 mV/s a 1,4 mV/s a lo largo de los 168 ciclos de carga. Como se verá a lo largo del capítulo, este indicador se puede calcular para cualquier batería a lo largo de cualquier intervalo de tensión, y el resultado será similar para todas las baterías elegidas en la Sección 2.2, ya que sus perfiles de intensidad de carga son iguales a lo largo de sus ciclos, tal como se mencionó en la sección anterior.

Este indicador nos dice por cada intervalo de tensión, por ejemplo [3,8-3,9V], [3,9-4,0V]..., qué incremento de velocidad de degradación en mV/s tiene una batería, y cuanto mayor sea dicha velocidad, mayor será la capacidad perdida (FC).

2.3.3 Ratio de velocidad de degradación (DSR). Correlación con el SOH

Una vez definido el indicador de salud DSR y calculada la primera velocidad para dos niveles de tensión dados (en el ejemplo anterior [3.8-3.9V]), se pueden calcular para los intervalos sucesivos de esa misma curva de tensiones de carga. Así, por ejemplo, las velocidades para la batería B0005 de la fuente de datos de la NASA, calculadas en los intervalos [3,8-3.9V]; [3,9-4,0V]; [4,0-4,1V] y [4,1-4,2V] respectivamente, se muestran en la Fig. 2.5.




Fig. 2.5. Ratio de velocidad de degradación para la batería B0005 de la NASA. (a) Rango DSR [3,8-3,9V]. (b) Rango DSR [3,9-4,0V]. (c) Rango DSR [4,0-4,1V]. (d) Rango DSR [4,1-4,2V].

Después de obtener las velocidades en los diferentes rangos de tensión, procedemos a analizar la similitud que tiene cada DSR con el indicador de capacidad, 1-SOH(%) y 1/Cap(%) respectivamente.

Se ha usado la inversa de la capacidad (%) y la FC, 1-SOH(%), porque mejora la visualización de la correlación que tiene con las velocidades, como se aprecia en la Fig. 2.6. En esta se muestran dos velocidades de degradación [3,850-3,9V] y [3,875-3,9V] con la FC (%) y 1/Cap (%).




Fig. 2.6. DSR [3,850-3,9V] y DSR [3,875-3,9V] vs. 1-SOH y 1/Capacidad, para la batería CS2_37 de CALCE.

La Fig. 2.7 muestra una relación lineal observada entre la velocidad de degradación medida en el rango [3,8-3,9V] vs. 1/Capacidad (%) y vs. 1-SOH (%) respectivamente con unas bandas de confianza del 95%.




Fig. 2.7. Relación observada que existe entre el SOH y el DSR. (a) 1/Capacidad vs. DSR [3,8-3,9V]. (b) 1-SOH vs. DSR [3,8-3,9V] para B0005.

En la Tabla 2.1 se reflejan los parámetros de las curvas de ajuste lineal del polinomio de grado uno representados en la Fig. 2.7, con su banda de confianza del 95 %, tanto para la relación con su FC (%) como para la relación con la inversa de la capacidad normalizada (1/Capacidad (%)). También se encuentran los parámetros para el resto de las baterías de la Nasa (B0006 y B0007) y CALCE (CS2_35, CS2_36 y CS2_37), al igual que los errores de ajuste R^2 , R^2 ajustado y el RMSE.

Tabla 2.1. Parámetros de ajuste con su banda de confianza al 95% y errores del polinomio lineal de grado uno usado para las baterías de NASA y CALCE.

DSR[3,8-3,9V]/s	$f(x) = p1 \cdot x + p2$	B0005 (vs. 1-SOH(%))	B0005 (vs. 1/CAP(%))	B0006 (vs. 1-SOH(%))	B0006 (vs. 1/CAP(%))	B0007 (vs. 1-SOH(%))	B0007 (vs. 1/CAP(%))
p1 (p1b;p1a)	253.8 (239.4, 268.2)	370.5 (354.3, 386.7)	100 (92.23, 107.9)	183.4 (173.5, 193.4)	419.9 (393.1, 446.6)	566.1 (536.5, 595.7)	
p2 (p2b;p2a)	0.0006674 (-0.009576, 0.01091)	0.9755 (0.964, 0.987)	0.1061 (0.09246, 0.1197)	1.104 (1.087, 1.121)	0.04808 (-0.06032, -0.03584)	0.9202 (0.9066, 0.9337)	
R^2	0.8813	0.9259	0.7967	0.8909	0.8543	0.8969	
R^2 (Ajustado)	0.8806	0.9255	0.7955	0.8903	0.8534	0.8963	
RMSE	0.03518	0.03959	0.0554	0.07036	0.03249	0.03597	

DSR[3,8-3,9V]/s	$f(x) = p1 \cdot x + p2$	CS2_35 (vs. 1-SOH(%))	CS2_35 (vs. 1/CAP(%))	CS2_36 (vs. 1-SOH(%))	CS2_36 (vs. 1/CAP(%))	CS2_37 (vs. 1-SOH(%))	CS2_37 (vs. 1/CAP(%))
p1 (p1b;p1a)	1164 (1133, 1195)	452.3 (446.7, 458)	1146 (1110, 1183)	352.3 (347.3, 357.2)	984 (956.4, 1012)	415.5 (411.2, 419.8)	
p2 (p2b;p2a)	0.04413 (0.03887, 0.04939)	0.1611 (0.1602, 0.1621)	0.05051 (0.04393, 0.05709)	0.1156 (0.1147, 0.1165)	0.07276 (0.06725, 0.07827)	0.1497 (0.1489, 0.1506)	
R^2	0.8663	0.9677	0.8184	0.9589	0.8384	0.9746	
R^2 (Ajustado)	0.8661	0.9677	0.8181	0.9589	0.8383	0.9746	
RMSE	0.04823	0.008717	0.06428	0.008675	0.05902	0.009165	

Del mismo modo se pueden calcular los índices de correlación para los rangos de los DSR que queramos analizar. En la Tabla 2.2 se muestra, en las cuatro primeras filas, los índices de correlación existente entre los rangos DSR [3,8-3,9V], [3,9-4,0V], [4,0-4,1V] y [4,1-4,2V] vs. 1/Cap(%) y la FC (%) respectivamente.

Tabla 2.2. Correlación entre el DSR [3,8-3,9V], [3,9-4,0V], [4,0-4,1V] y [4,1-4,2V] vs. 1 / Cap (%) y la FC (%) respectivamente.

	DSR vs. 1/Cap (%)						DSR vs. 1-SOH(%)					
	Batería de la NASA			Batería de CALCE			Batería de la NASA			Batería de CALCE		
	B0005	B0006	B0007	CS2_35	CS2_36	CS2_37	B0005	B0006	B0007	CS2_35	CS2_36	CS2_37
DSR R1 (3.8-3.9)	0.97	0.94	0.95	0.98	0.96	0.99	0.95	0.91	0.93	0.93	0.9	0.92
DSR R2 (3.9-4.0)	0.96	0.94	0.96	0.95	0.94	0.95	0.94	0.89	0.94	0.87	0.83	0.84
DSR R3 (4.0-4.1)	0.98	0.94	0.96	0.83	0.88	0.89	0.96	0.89	0.95	0.72	0.75	0.75
DSR R4 (4.1-4.2)	0.96	0.85	0.87	0.66	0.92	0.91	0.94	0.77	0.85	0.6	0.86	0.81
DSR R5 (3.8-3.825)	0.98	0.89	0.94	0.92	0.89	0.90	0.97	0.86	0.90	0.85	0.80	0.83
DSR R6 (3.825-3.85)	0.96	0.91	0.94	0.93	0.89	0.92	0.93	0.88	0.92	0.86	0.80	0.84
DSR R7 (3.85-3.875)	0.95	0.93	0.93	0.96	0.94	0.96	0.92	0.90	0.90	0.93	0.88	0.93
DSR R8 (3.875-3.9)	0.96	0.91	0.95	0.98	0.98	0.98	0.93	0.88	0.92	0.97	0.94	0.96
DSR R9 (ini-3.825)	0.97	0.91	0.90	0.92	0.73	0.90	0.95	0.88	0.85	0.89	0.62	0.84
DSR R10 (3.8-3.85)	0.97	0.93	0.94	0.92	0.89	0.92	0.95	0.90	0.92	0.86	0.80	0.85
DSR R11 (3.85-3.9)	0.96	0.92	0.94	0.98	0.97	0.98	0.93	0.89	0.91	0.96	0.93	0.96

Las DSR se pueden medir en el intervalo de tensión de carga que estimemos oportuno. Para este estudio hemos tomado el DSR R1 [3,8-3,9V], ya que como se puede observar en la Tabla 2.2, tiene los mejores índices de correlación.

En este sentido, al objeto de reducir los posibles tiempos de medición de las variables y tener más intervalos de velocidad a disposición del método, se ha particionado el intervalo de mejor correlación [3,8-3,9V] en 4 subintervalos y

calculadas posteriormente sus respectivas correlaciones. De este modo, si una celda no empieza a cargarse en ese intervalo de tensión o la medida no está disponible, lo hará en otro intervalo elegido. Por ejemplo, el R8 como primera opción y el R7 como segunda, [3,850-3,875] y [3,875-3,9] ya que son los de mayor correlación.

Para el desarrollo del estudio se ha profundizado hasta los 4 subintervalos, es decir, un incremento de tensión de 0,25V, pero se puede continuar reduciendo el intervalo de tensión según necesidades, y realizar el análisis de correlación con la variable de capacidad para su corroboración.

2.3.4 Ventajas del uso de (DSR)

Las ventajas del uso de este nuevo indicador son múltiples, pero quizás la principal sea su eficiencia, si tenemos en cuenta su simpleza de cálculo frente a su relevancia (sensibilidad con la capacidad). Otras ventajas se enumeran a continuación:

- (1) Las velocidades de degradación (DSR) son un indicador con un alto índice de correlación con la capacidad degradada de las baterías, ya que relaciona y tiene en cuenta, no sólo los tiempos de carga ((Wang *et al.*, 2019) (Zhang and Tian, 2019)) sino también las tensiones.
- (2) La ya mencionada reducción de tiempos de medida, p.ej. un ciclo de carga y descarga completa de la batería B0005 de la NASA transcurre en unos 7000 s (4000+3000), y sin embargo el ciclo de carga en el intervalo [3,8-3,9V] es de unos 500 s en el BOL de la LIB. Por tanto, obtenemos una reducción de los tiempos de medida del 93% para el ciclo carga y descarga y un 84% respecto al ciclo de carga.
- (3) Este nuevo indicador de salud (DSR) nos permite en todo momento ver la tendencia de la degradación de la batería, sin necesidad de tener que estimar el cálculo del SOH. Si realizamos la comparativa entre dos velocidades del mismo rango de tensión, se puede ver si esta degradación se mantiene constante en el tiempo (entre unos márgenes de confianza) o si, por el contrario, se va acelerando y en qué cuantía. Pudiendo tomar así alguna medida de operación o mantenimiento al respecto.
- (4) El DSR puede ser calculado para diferentes intervalos de tensión, dando como resultado diferentes ratios de velocidad, que pueden adelantar un “fallo total”. Por ejemplo, en qué momento la batería superará su EOL, ya que como se aprecia en la Fig. 2.8, a partir del ciclo 800, la FC pasa de ser el 25% al 100% en sólo 200 ciclos. Al igual que el

DSR[3,9-4,0V], que pasa de valer 0,07 mV/s a 0,81 mV/s en esos 200 ciclos (del ciclo 800 al ciclo 1.000). En ese intervalo la FC pasa del 30% al 80%, tal como se muestra en la Fig. 2.6.

- (5) El indicador DSR se puede utilizar como indicador independiente y sustitutivo del SOH tradicional, tal como explicaremos más adelante, ya que en la vida real la medición del SOH sólo se puede realizar en condiciones de laboratorio muy determinadas (CT), y esto no ocurre con el nuevo DSR, que se puede medir en cualquier momento.
- (6) Facilidad de su implementación en el BMS, ya que una vez elegido el rango de tensión a medir sólo es necesario calcular la pendiente de ese trozo de "segmento de tensión".
- (7) Debido a esto, se puede realizar el cálculo de la degradación en todo el espectro de tensiones de carga, pudiendo realizar el cálculo en cualquiera de las franjas de la tensión que esté disponible durante los ciclos de carga.





Fig. 2.8. Ratio de Velocidad de Degradación para la batería CS2_37 de CALCE. (a) DSR [3,8-3,9V]. (b) DSR [3,9-4,0V].

2.3.5 DSR como indicador de salud.

Como se ha mencionado ya, en la vida real, la medición de la capacidad de las LIB sólo se puede realizar en condiciones precisas de laboratorio (Schimpe *et al.*, 2018), por lo que es costoso realizar esta operación. Teniendo en cuenta una de las ventajas mencionadas anteriormente, para la validación del DSR [3,875-3,9V] como HI, se ha realizado la estimación de la capacidad para cada una de las baterías, con un único rango de DSR [3,875-3,9V] como entrada del modelo GPR (Rasmussen, 2006) y para las 6 celdas. En primer lugar, los hiperparámetros de los modelos para los tres tipos de celdas de las baterías de la NASA se muestran en la Tabla 2.3.

Tabla 2.3. Características e hiperparámetros utilizados para los modelos GPR de las baterías de la NASA.



A continuación, en la Tabla 2.4 se muestran también los correspondientes a las tres baterías de CALCE.

Tabla 2.4. Características e hiperparámetros utilizados para los modelos GPR de las baterías de la CALCE CS2_35, CS2_36 y CS2_37.




Tabla 2.4. Características e hiperparámetros utilizados para los modelos GPR de las baterías de la CALCE CS2_35, CS2_36 y CS2_37. (Continuación)

Hiperparametro	CS2_35	CS2_36	CS2_37
LogLikelihood	3.196	3216	3677
KernelInformation(SL;SF;AQR)	[2,2237;0,1626;0,2245]	[1,2068;0,1034]	[1,280;0,1303;0,0911]
Sigma	0,0051	0,0051	0,0046
Beta	0,2951	0,2633	0,2973

Para finalizar, la Tabla 2.5 muestra los errores del modelo GRP usando el DSR [3,875-3,9V] como única entrada y con las 6 baterías.

Tabla 2.5. Errores del modelo GRP utilizando el indicador DSR [3,875-3,9V] como entrada vs. 1/Cap para los paquetes de datos de las baterías de la NASA y CALCE.

DSR [3.875-3.9V] vs. 1/Cap. (%)						
	Baterías de la NASA			Baterías de CALCE		
	B0005	B0006	B0007	CS2_35	CS2_36	CS2_37
RMSE	0.0063	0.0157	0.0097	0.0052	0.0050	0.0046
MAE	0.0041	0.0111	0.0072	0.0037	0.0034	0.0034
MSE	4.0297 e-5	24.0 e-5	9.4209 e-5	2.7198 e-5	2.582 e-5	2.184 e-5
R ²	1	0.98	0.99	0.99	0.99	1

Como se aprecia en los datos de la Tabla 2.5, los modelos creados con una única entrada para estimar la capacidad de las celdas, tienen una alta precisión en su estimación, lo que hace pensar que puede ser, en sí mismo, un indicador de la degradación.

Una vez comprobado que el indicador DSR [3,875-3,9V] es un instrumento válido para evaluar la degradación de las baterías, se puede utilizar una regresión lineal simple (Grünwald, 2007) con los dos rangos DSR predecesores al anterior en estudio: [3,825-3,850V] y [3,850- 3,875V] como entradas del modelo LR y así estimar el mencionado DSR [3,875-3,9V]. De esta manera se valida también que estimar un DSR para un rango de tensión (que se puede utilizar como indicador de degradación) es muy simple y preciso. Esto puede ser muy útil en caso de no disponer de la medida del DSR en ese rango, p.ej. por la pérdida de la señal de tensión.

En la Tabla 2.6 se muestran las características y los parámetros del modelo lineal utilizado en cada caso, para dicho ejercicio de estimación.

Tabla 2.6. Características e hiperparámetros del modelo lineal para las baterías de la Nasa B0005, B0006 y B0007 y CALCE CS2_35, CS2_36 y CS2_37.

Modelo LR Baterías NASA&CALCE

Entradas

DSR [3,825-3,850V]

DSR [3,850-3,75V]

→

→

Salida

DSR [3,875-3,9V]

Hiperparametros del Modelo

$f(x1,x2) = p1*x1 + p2*x2 + p3*x1*x2 + cte$	B0005	B0006	B0007	CS2_35	CS2_36	CS2_37
p1	0,1971	0,1212	0,032	0,0696	0,3141	0,1488
p2	0,2127	0,2695	0,6363	1,1116	0,9257	1,0863
p3	0	0	-62,17	-584,25	-927,57	-743,69
(cte.) Intercept	8,93E-05	6,5E-05	5,04E-05	-4,89E-05	-5,68E-05	-5,46E-05
R2	0,9977	0,9778	0,9974	0,9832	0,9828	0,9787
R2(ajustado)	0,9977	0,9775	0,9973	0,9832	0,9827	0,9787
RMSE	1,08E-05	7,8E-05	4,59E-06	8,4395E-06	7,905E-06	8,02E-06
LogLikelihood	1.664	1174	1806	8.384	8286	9172
Num. muestras	166	168	168	885	975	1042

En Tabla 2.7 se muestran los errores obtenidos con el uso del modelo LR.

Tabla 2.7. Errores del modelo LR utilizando DSR [3,825-3,850V] y DSR [3,850-3,75V] como entrada vs. DSR [3,875-3,9V] con el conjunto de datos de baterías de la NASA y CALCE

Entradas: DSR[3,825-3,850V] & DSR[3,850-3,875V] Salida: DSR[3,875-3,9V]

	Baterías de la NASA			Baterías de CALCE		
	B0005	B0006	B0007	CS2_35	CS2_36	CS2_37
RMSE	1,147 e-5	8,471 e-5	4,957 e-6	8,4766 e-6	7,968 e-6	7,351 e-6
MAE	7,537 e-6	4,595 e-5	3,774 e-6	6,731 e-6	6,355 e-6	5,109 e-6
MSE	1,316 e-10	7,176 e-9	2,458 e-11	7,185 e-11	6,348 e-11	5,404 e-11
R ²	1	0,98	1	0,98	0,98	0,99

Como así demuestran los resultados de la Tabla 2.7, con el modelo lineal es posible estimar un DSR por medio de los dos DSR anteriores, p.ej., con el objetivo explicado anteriormente, poder estimar en un momento determinado un DSR “perdido”. La sensibilidad del indicador DSR a la degradación de la capacidad, hace que realizar este tipo de ejercicio, sea simple, sin necesidad de métodos más complejos (Yang *et al.*, 2021).

Otra de las ventajas de utilizar el indicador DSR (p.ej. el DSR[3,875-3,9V]) es que la medida real de la variable de salida se puede obtener (midiéndolo o

estimándolo) con mucha más frecuencia y facilidad que la capacidad, y así poder corregir nuestro modelo de estimación en tiempo real.

Al tener la variable de salida DSR [3,875-3,9V] una correlación muy alta con el SOH ($R^2_{(AVR)}=0,96$) para las 6 baterías, Tabla 2.2, el novedoso HI (DSR) funciona como estimador muy fidedigno de la capacidad degradada y se puede medir de una manera más directa y simple.

Por lo tanto, el DSR se puede obtener en todo momento utilizando un pequeño intervalo de la curva de tensión de carga, p. ej., en los ordenadores portátiles o teléfonos inteligentes, al cargarse durante un instante. Además, este nuevo HI usa sólo una característica de interés (ΔV en un rango), por lo que es más fácil de implementar y su esfuerzo computacional es menor.

2.4. Validación del HI como estimador del SOH

Para la **validación del nuevo HI (DSR) como indicador de degradación**, se proponen en el estudio dos maneras diferentes. Una primera, como se viene realizando en estudios similares, utilizando este indicador como variable de entrada de un *modelo Gaussiano* (GRP) para estimar la capacidad degradada y comparar resultados. Y una segunda manera, realizando este mismo proceso con un *modelo de NN* de (2+8+4) capas para ver el comportamiento de este modelo en baterías con datos no usados en el entrenamiento. Esto permitirá modelar las posibles características no lineales subyacentes a las relaciones lineales analizadas, ya que, como es sabido, un MLPNN es un aproximador funcional universal capaz de modelar relaciones no lineales con un buen rendimiento.


Posteriormente, se prueba el comportamiento de este modelo utilizando un conjunto de datos desconocido. Ambos enfoques se describen en las siguientes secciones.

2.4.1 Modelo Gaussiano. GPR

Para probar el nuevo HI, se ha utilizado el DSR como entrada de dos modelos GPR independientes (uno entrenado con un conjunto de datos de las baterías de la NASA, y otro entrenado con datos de las baterías de CALCE) para predecir el SOH y poder comparar así este método con los desarrollados en otros estudios. De esta manera, se utiliza el conjunto de datos de baterías de la NASA (celdas B0005, B0006 y B0007) para entrenar un primer modelo GPR, con el fin de comparar los resultados con estudios que usan el mismo conjunto de datos.

Las características e hiperparámetros del modelo GPR empleado para las baterías de la NASA se muestran en la Tabla 2.8.

Tabla 2.8. Características e hiperparámetros utilizados para el modelo GPR de las baterías de la NASA B0005, B0006 y B0007.



Hiperparámetros del Modelo	
Num. muestras	313
KernelFunction	Exponential
PredictMethod	Exac
FitMethod	Exac
ActiveSetMethod	Random
BasisFunction	Constant
LogLikelihood	809
KernelInformation(SL,SF)	[21,6967;0,1729]
Sigma	0,0135
Beta	0,221

De igual manera, se desarrolló otro segundo modelo GPR entrenado con el conjunto de datos compartidos por CALCE (celdas CS2_35, CS2_36 y CS2_37) con el mismo propósito, comparar los resultados con modelos existentes en la literatura.

Las características e hiperparámetros del modelo GPR se muestran en la Tabla 2.9.

Tabla 2.9. Características e hiperparámetros utilizados para el modelo GPR de las baterías de la CALCE CS2_35, CS2_36 y CS2_37.




Tabla 2.9. Características e hiperparámetros utilizados para el modelo GPR de las baterías de la CALCE CS2_35, CS2_36 y CS2_37. (Continuación)

Hiperparámetros del Modelo	
Num. muestras	1683
KernelFunction	Exponential
PredictMethod	Exac
FitMethod	Exac
ActiveSetMethod	Random
BasisFunction	Constant
LogLikelihood	5.087
KernelInformation(SL;SF)	[34,0978;0,2667]
Sigma	0,0076
Beta	0,263

Una vez entrenados ambos modelos, se probaron con valores reservados (no utilizados en el proceso de entrenamiento) para este propósito. La Tabla 2.10 muestra los indicadores de error en cada caso.

Tabla 2.10. Errores del modelo GPR utilizando DSR[3,825-3,850V], DSR[3,850-3,875V] y DSR[3,875-3,9V] como entradas vs. 1-SoH con el conjunto de datos de baterías de la NASA y CALCE.

Entradas: DSR [3,825-3,850V], DSR [3,850-3,875V] & DSR [3,875-3,9V]; Salida: 1-SOH (%)

	Modelo1 GPR (Baterías de la NASA)			Modelo2 GPR (Baterías de CALCE)		
	B0005	B0006	B0007	CS2_35	CS2_36	CS2_37
RMSE	0,0106	0,0186	0,0117	0,0095	0,0140	0,0107
MAE	0,0071	0,0132	0,0095	0,0065	0,0079	0,0074
MSE	1,1332 e-4	3,4537 e-4	1,3644 e-4	9,0595742 e-5	1,9589 e-4	1,1469 e-4
R ²	0,99	0,98	0,98	0,99	0,99	0,99

Como se aprecia en la Tabla 2.10, el R² de ambos modelos es muy elevado, del 98% para el Modelo1 y del 99% para el Modelo2. Esto implica que, con el uso de sólo tres intervalos de DSR, realizados mediante la medición de la tensión en la curva de carga desde el nivel 3,825 V hasta el 3,9 V, es posible estimar la capacidad perdida por cada batería hasta ese momento de su vida.

En las Figuras 2.9a y 2.9b igualmente, se muestran las tendencias de los valores estimados y reales de las baterías B0005 y CS2_35, probadas con esos datos apartados y con cada uno de sus modelos.




Fig. 2.9. Tendencias de los modelos GPR. (a) Modelo1 probado con el conjunto de datos de la batería B0005. (b) Modelo2 probado con el conjunto de datos de la batería CS2_35.

La Tabla 2.11 se ha realizado a partir de los resultados de los modelos mencionados en la revisión de la literatura realizada en Capítulo 1.2.3, al objeto de poder comparar estos con los de esta tesis.

Tabla 2.11. Comparativa entre los resultados de esta tesis y los del estado del arte.

						Esta tesis (Alvarez-Monteserin and Sanz-Bobi, 2022)					
		(Tian, Xiong and Shen, 2020)	(Zhang and Tian, 2019)	(Wang <i>et al.</i> , 2019)	(Yuanyuan Li <i>et al.</i> , 2019)			(Liu, Xu and Feng, 2020)	(Bak and Lee, 2019)		
B0005	RMSE	0,0249	0,0077	0,0111	0,0084	0,0106	0,0095	0,015		RMSE	CS2_35
	MAE	0,049	0,0064	0,0088	0,0053	0,0071	0,0065			MAE	
	R ²	0,94		0,98	0,98	0,99	0,99			R ²	
B0006	RMSE	0,0196	0,0163	0,0180	0,0180	0,0186	0,0140	0,017	0,0067	RMSE	CS2_36
	MAE	0,0597	0,0143	0,146	0,146	0,0132	0,0079			MAE	
	R ²	0,97		0,96	0,96	0,98	0,99			R ²	
B0007	RMSE	0,0158		0,014		0,0117	0,0107	0,0124		RMSE	CS2_37
	MAE	0,0629		0,0098		0,0095	0,0074			MAE	
	R ²	0,96		0,97		0,98	0,99			R ²	

Los datos de esta tabla comparativa demuestran que el R² es el más elevado hasta el momento para todas las baterías y comparándolo con todos los modelos. En el caso de las baterías de CALCE, de las que no se dispone de R², los otros dos indicadores (RMSE y MAE) también tienen un mejor resultado, excluyendo al modelo empleado por (Bak and Lee, 2019) para la batería CS2_36.

Para analizar el comportamiento generalista del indicador DSR se ha entrenado otro Modelo3 (GPR) con los conjuntos de datos de las baterías B0005, B0006, B0007, CS2_35 y CS2_37, para probarlo posteriormente con el conjunto de datos de la batería CS2_36 y estimar el 1-SOH. De esta forma, se probará el comportamiento del modelo con datos de un tipo de batería para la que, dicho Modelo3, no ha sido entrenado.

Las características e hiperparámetros del este Modelo3 (GPR) se pueden ver en la Tabla 2.12.


Tabla 2.12. Características e hiperparámetros utilizados para el Modelo3 GPR entrenado con las baterías de la NASA B0005, B0006, B0007, y las baterías de CALCE CS2_35 y CS2_37.

Tabla 2.12. Características e hiperparámetros utilizados para el Modelo3 GPR entrenado con las baterías de la NASA B0005, B0006, B0007, y las baterías de CALCE CS2_35 y CS2_37. (Continuación)

Hiperparametros del Modelo	
Num. muestras	1.395
KernelFunction	RationalQuadratic
PredictMethod	Exac
FitMethod	Exac
ActiveSetMethod	Random
BasisFunction	Constant
LogLikelihood	4.173
KernelInformation(SL;SF;AQR)	[0,4584;0,3441;0,0058]
Sigma	0,0068
Beta	0,2314

Del mismo modo, en la Tabla 2.13 se muestran los errores y en la Fig. 2.10 las tendencias, de los valores reales y estimados por dicho Modelo3.

Tabla 2.13. Errores del Modelo3 (GRP) probado con los datos de la batería CS2_36 de CALCE.

Entradas: DSR[3,8-3,825V], DSR[3,825-3,850V], DSR[3,850-3,875V] & DSR[3,875-3,9V]; Salida: 1-SOH (%)	
Modelo GPR; datos de entrenamiento: NASA (B0005, B0006, B0007) & CALCE (CS2_35, CS2_37)	
Batería para prueba:	CS2_36
RMSE	0,0151
MAE	0,0098
MSE	2,2851 e-4
R ²	0,98




Fig. 2.10. Salida real vs. estimada (Modelo3 GRP) con los datos de la batería CS2_36 de CALCE.

Como se demuestra en la Tabla 2.13, los errores presentados por el Modelo3 (GPR) son similares a los presentados en la Tabla 2.11, donde se compraban los métodos del estado del arte, pero en el caso del Modelo3, su entrenamiento no procesó ningún dato de la batería CS2_36. Por ello, podemos decir que con el uso de indicadores DSR es posible crear modelos cuyo comportamiento será excelente ($R^2= 0,98$) frente a baterías de operación desconocidas para dicho modelo.

Los datos utilizados en la comparativa de la Tabla 2.11 proceden de un entorno controlado de laboratorio (NASA y CALCE). En la vida real, los sistemas BMS implementan circuitos integrados (CI) en el proceso de monitorización de la batería (Dimitrov, Collier and Cruden, 2019) con el fin de lograr errores inferiores al 0,25% en la medición de la tensión, por lo que el cálculo de los DSR y su precisión estarían a la altura de las necesidades del sistema. En cualquier caso, como el cálculo de del DSR se realiza con un incremento de tensión (ΔV) en el numerador, un posible error de medida (o desviación de la tensión real) del sensor, haría que ese incremento no se viera afectado por la desviación. Además, si fuera necesario, se pueden aplicar modelos de diagnóstico de fallos de sensores como los propuestos por (Yu *et al.*, 2021), haciendo que las medidas utilizadas en el modelo en la vida real no se vean comprometidas.


Así, en este punto podemos afirmar que el uso de este nuevo HI tiene una ventaja más añadida, al depender solamente de la medida de la tensión para su uso, es más robusto frente a fallos y tiene mayor facilidad de detección de estos, no necesitando sensores de temperatura, corrientes, resistencias u otras medidas o cálculos utilizados como entrada en los modelos de predicción.

2.4.2 Modelo MLPNN.

En este apartado de la tesis se ha desarrollado un modelo “Multilayer neural networks and backpropagation” (MLPNN) (Keller, Liu and Fogel, 2016), que es el núcleo básico de los principales diseños de NN utilizados en DL. Así, utilizando el nuevo indicador de degradación DSR (DSR[3,825-3,850V], DSR[3,850-3,875V], y DSR[3,875-3,9V]) como entradas del núcleo básico (MLPNN, 4+8+2 capas) del modelo de RN, se estima la degradación de la batería y se analiza cómo responde a otros conjuntos de datos de baterías no utilizados en el entrenamiento de la RN. El conjunto de datos utilizados en el entrenamiento se ha formado con las baterías B0005, B0006, CS2_35 y CS2_37 y posteriormente se probó con el conjunto de datos de las baterías B0007 y CS2_36.

Las características del modelo MLPNN se muestran en la Tabla 2.14.

Tabla 2.14. Entradas y salida del modelo MLPNN entrenado con datos de las baterías B0005, B0006, CS2_35 y CS2_37.



Los resultados se muestran en la Tabla 2.15 y en la Fig. 2-11 (prueba con datos de las baterías B0007 y CS2_36) y en la Fig. 2-12 (prueba realizada con los datos de B0007+CS2_36) respectivamente. Se aprecia un buen comportamiento con los dos conjuntos de datos de baterías desconocidos, así como una precisión del mismo orden de magnitud que los modelos utilizados en otros estudios, pero con un conjunto de datos de baterías "reales". Esto hace pensar nuevamente que el empleo de estos DSR como entradas a modelos de NN hacen posible la estimación de la degradación de LIB que no han sido utilizadas para el entrenamiento del modelo, por lo que se puede asumir que es generalizable su uso en LIB dentro del entorno de trabajo determinado.

Tabla 2.15. Errores del modelo MLPNN probado con los datos de las baterías B0007 y CS2_36.

Entradas: DSR[3,825-3,850V], DSR[3,850-3,875V] y DSR[3,875-3,9V];

Salida: 1-SOH (%)

Modelo MLPNN; datos de entrenamiento: (NASA (B0005 y B0006) & CALCE (CS2_35 y CS2_37))		Baterías		
Baterías para prueba:		B0007	CS2_36	B0007+CS2_36
RMSE		0,011	0,0155	0,0149
MAE		0,0083	0,012	0,0114
MSE		1,21E-4	2,41E-4	2,23E-4
R²		0,98	0,98	0,98




Fig. 2.11. Gráfica de tendencias del modelo MLPNN. (a) Probado con el conjunto de datos de la batería B0007. (b) Probado con el conjunto de datos de la batería CS2_36.




Fig. 2.12. Gráfica de tendencia del modelo MLPNN probado con el conjunto de datos de la batería B0007 y CS2_36.

Como ha quedado probado, por medio de ambos modelos (GPR y MLPNN), los resultados son muy buenos incluso con datos desconocidos y con datos de otras baterías (no utilizados en ningún caso en el entrenamiento de los modelos). Validando el indicador propuesto dentro del "*marco de investigación*" definido en esta tesis.

Así, el método y el indicador proporcionan rapidez en la estimación de la "*capacidad perdida*" y simplicidad. Es de esperar que, si se utilizaran NN más complejas (DL) con este nuevo indicador, los resultados serían aún mejores.

2.5. Uso del DSR con corrientes no constantes.

Después de probar el uso del indicador DSR con los datos de las baterías cargadas a corriente constante, se procede a analizar su uso con baterías cargadas a corriente no constante. Esto permitirá aumentar el entorno de trabajo del indicador DSR, ya no sólo para perfiles de tensión de carga con CC, sino también para perfiles de corriente variable.

En este apartado se lleva a cabo un análisis para este tipo de corrientes de carga, previo al uso de los datos del BESS de la tesis operado en regulación de frecuencia. Siendo la corriente de carga y de descarga de este BESS, variable y completamente aleatoria, en función de la operación necesaria para la regulación de frecuencia establecida por la red a la que está conectado.

Los datos estudiados en este caso corresponden a baterías del repositorio "*Oxford energy trading battery degradation dataset*" de la Universidad de Oxford, (Reniers, J M, G Mulder, 2020). Con los datos correspondientes al paquete catalogado como BMR (celda 1 y 2).

2.4.3 Análisis del conjunto de datos

Existen 6 celdas de LIB en el paquete de datos ofrecido por la Universidad de Oxford mencionado anteriormente, marcadas con tres siglas diferentes en función de la operación realizada sobre ellas (SPM, BMP y BMR). En la Fig. 2.13 se aprecian las diferentes degradaciones que provocan estas diferencias en la operación de estas. Para el estudio del presente apartado de esta tesis, se han utilizado las dos celdas BMR1 y BMR2, ya que como se puede ver en la Fig. 2.14, son las que tienen una mayor pérdida de capacidad o mayor degradación a lo largo de sus ciclos de vida.




Fig. 2.13. Evoluciones de las capacidades de las diferentes celdas (1 y 2) y modos de operación (SPM, BMP y BMR) de las baterías presentadas de la Universidad de Oxford.

Esta mayor degradación de las celdas BMR1 y BMR2, es debido en gran medida a que las intensidades de carga y descarga son mayores a lo largo de sus ciclos de uso, tal como se muestra en la Fig. 2.14.




Fig. 2.14. Intensidades de carga y descarga de los tres tipos de operación (BMR, BMP y SPM) de las celdas presentadas por la Universidad de Oxford.

En la Fig. 2.15 se puede ver que el rango de intensidades para el paquete BMR está en el intervalo $[-20A, 20 A]$.




Fig. 2.15. Detalle de las intensidades de los 3 modos de operación (BMR, BMP y SPM).

Del mismo modo, en las Figuras 2.16 y 2.17, se aprecia el perfil de la curva de carga (con intensidades negativas) y descarga (con intensidades positivas), siendo, como se sabe, sobre el perfil de carga sobre el que se calcula el DSR.




Fig. 2.16. Detalle de los perfiles de tensión e intensidad para el modo de operación BMR1.




Fig. 2.17. Detalle de los perfiles de tensión e intensidad para el modo de operación BMR2.

Para la obtención de los DSR se ha procedido, en primer lugar, a analizar las distribuciones de las tensiones de carga de las respectivas celdas BMR1 y BMR2 mostradas en las Figuras 2.18 y 2.19 respectivamente.




Fig. 2.18. Distribución de tensiones de carga para BMR1.




Fig. 2.19. Distribución de tensiones de carga para BMR2.

En estas dos distribuciones se puede apreciar que la frecuencia mayor observada está en el intervalo [3.7-3.8] V. Así, se tomará este como intervalo de cálculo de los DSR para cada una de las celdas BMR1 y BMR2.

Una vez calculados los DSR[3,7-3,8V] para cada ciclo de carga, se analizan las distribuciones de intensidad de carga para cada celda BMR1 y BMR2 (Fig. 2.20 y Fig. 2.21). Esta intensidad elegida para la selección es la media aritmética entre el inicio y final del periodo de carga.




Fig. 2.20. Distribución de intensidades de carga para los DSR[3,7-3,8] de la celda BMR1.




Fig. 2.21. Distribución de intensidades de carga para los DSR[3,7-3,8] de la celda BMR2.

De ellas se deduce que la mayor parte de los valores de las intensidades observadas están en el intervalo [15,5-17,5] A.

2.4.4 Indicador DSR_v subyacente al DSR.

Al filtrar los datos por estas intensidades, quedan las dos tendencias DSR mostradas a continuación en las Figuras 2.22 y 2.23, donde se ha introducido también la curva de degradación de la celda durante esos ciclos. Esta curva de degradación se ha calculado a partir de los datos de capacidad medidas cada ciclo y perteneciente al conjunto de datos BMR1 y BMR2.

Los parámetros de los modelos lineales de ajuste se presentan en la Tabla 2.16.

Tabla 2.16. Parámetros de ajuste con su banda de confianza al 95% y errores del polinomio lineal de grado uno usado para las baterías BMR1 y BMR2 de Oxford.

DSR[3,7-3,8]V/s	$f(x) = p1 \cdot x + p2$	BMR1 (vs. 1-SOH(%))	BMR2 (vs. 1-SOH(%))
p1 (p1b;p1a)		4,604e-8 (4,417e-8; 4,79e-8)	4,725e-8 (4,533e-8; 4,917e-8)
p2 (p2b;p2a)		8,666e-5 (8,539e-5;8,792e-5)	8,549e-5 (8,413e-5; 8,685e-5)
R ²		0,8147	0,7886
R ² (Ajustado)		0,8145	0,7884
RMSE		9,31E-06	9,19E-06




Fig. 2.22. Evolución del 1-SOH y DSR[3,7-3,8V] para BMR1 para intensidades entre 15,5 y 17,5 A.




Fig. 2.23. Evolución del 1-SOH y DSR[3,7-3,8V] para BMR2 para intensidades entre 15,5 y 17,5 A.

La Tabla 2.17 muestra la correlación lineal existente entre el indicador DSR, calculado bajo diferentes condiciones, y la degradación de la celda en cuestión. Siendo:

1.- **DSR sin limitación de intensidad de carga:** se tienen en cuenta, para el cálculo de la correlación lineal, todos los DSR[3,7-3,8V], independientemente de qué intensidad media de carga tengan, es decir, en toda la distribución de intensidades mostrada en las Figuras 2.20 y 2.21.

2.- **DSR con limitación de intensidad:** sólo se tienen en cuenta, para el cálculo de la correlación lineal, los DSR[3,7-3,8V] calculados cuya intensidad de carga se encuentra entre 15,5 y 17,5 A.

3.- **DSR con un coeficiente de ajuste determinado.** Este coeficiente de ajuste se ha introducido por el efecto que la intensidad de carga tiene sobre la pendiente de tensión en el proceso de carga. Así, p. ej., cuanto mayor sea la intensidad de carga (mayor C-rate), menor será el tiempo de carga. Cuando se carga una celda con corriente constante durante todos sus ciclos de carga y se calculan los DSR en un mismo intervalo de la curva de tensión (como se explicó en el Capítulo 2) el indicador DSR sólo se ve influenciado por la degradación de la batería, pero no por la variación de la corriente.

En el caso de las LIB de esta sección, con corrientes de carga no constantes y diferentes en los ciclos de carga de las baterías BMR1 y BMR2, esta intensidad interfiere en la curva de tensión de carga, en su pendiente y como consecuencia, en los valores del indicador DSR de cada ciclo. Por ello, se ha definido un indicador DSR nuevo (DSR_v) que tiene un coeficiente de ajuste, $1/((\rho_c^2 + \rho_v^2))$, tal como se muestra en la ecuación 5, para intentar paliar este efecto de la intensidad variable sobre el DSR. De este modo se logra aumentar la correlación lineal con la degradación, como se puede apreciar en los valores de la Tabla 2.17. Este coeficiente, además de la intensidad en el inicio del intervalo (I_{p1}) y en el final del intervalo (I_{p2}), también tiene en cuenta la capacidad (Ah) de la celda. t_1 y t_2 son los tiempos en el inicio y final del intervalo del DSR.

$$DSR_v = \frac{DSR}{(\rho_c^2 + \rho_v^2)} \quad (5)$$

$$\text{Donde: } \rho_c = \frac{I_p \cdot (t_2 - t_1)}{\text{Capacidad} \cdot 3600} \quad (6)$$

$$I_p = \begin{cases} I_{p1} & \text{si } I_{p1} \leq I_{p2} \\ I_{p2} & \text{si } I_{p2} < I_{p1} \end{cases};$$

$$\text{Donde: } \rho_v = \frac{1}{2} \cdot \frac{(I_{p2} - I_{p1}) \cdot (t_2 - t_1)}{\text{Capacidad} \cdot 3600} \quad \text{si } I_{p1} \leq I_{p2} \quad (7)$$

$$\text{Y donde: } \rho_v = \frac{1}{2} \cdot \frac{(I_{p1} - I_{p2}) \cdot (t_2 - t_1)}{\text{Capacidad} \cdot 3600} \quad \text{si } I_{p2} < I_{p1} \quad (8)$$

Tabla 2.17. Correlaciones entre los diferentes indicadores DSR y el SOH de las dos celdas BMR1 y BMR2.

DSR[3,7-3,8]	Numero de celda	Coefficiente de correlación
1.-Sin limitación de intensidad	BMR1	0,71
2.-Limitado por intensidad (15-17 A)	BMR1	0,87
3.-Con coeficiente de ajuste (DSRv)	BMR1	0,76
1.-Sin limitación de intensidad	BMR2	0,71
2.-Limitado por intensidad (15-17 A)	BMR2	0,88
3.-Con coeficiente de ajuste (DSRv)	BMR2	0,79

Como se observa en las Figuras 2.22 y 2.23, la tendencia del indicador DSR para el caso de cargas con corrientes entre 15,5 y 17, 5 A, es muy similar a la de la degradación. De hecho, viendo el coeficiente de correlación para ambos casos (2 y 4), entre el DSR y la degradación de cada celda, nos proporciona en ambos casos una alta correlación lineal, 0,87 y 0,88 respectivamente.

En las Figuras 2.24 y 2.25, se muestran las tendencias de los dos DSR[3,7-3,8] de la Tabla 2.17 para la celda BMR1, con su distribución. Precisamente esta distribución muestra la reducción de dispersión del indicador DSR[3,7-3,8] al comparar ambas figuras: los DSR[3,7-3,8V] con todas las intensidades de carga y los DSR[3,7-3,8] con la intensidad filtrada (15,5 a 17,5 A), Fig. 2.24 y Fig. 2.25 respectivamente. Así, la desviación estándar se reduce de 2.3788e-05 a 2.0365e-05, es decir, un 14%, al igual que la varianza, que pasa de 5.6586e-10 a 4.1473e-10, un 26% para el caso de limitar la intensidad.




Fig. 2.24. DSR [3,7-3,8V] con todas las intensidades de carga BMR1.




Fig. 2.25. DSR [3,7-3,8V] con intensidades de carga entre 15,5 y 17,5 A para BMR1.

Sin embargo, el indicador DSR[3,7-3,8V] con coeficiente de ajuste (DSRv), no se ve casi afectado por la filtración de la intensidad en función de su distribución de carga (Figuras 2.26 y 2.27). Tal como se demuestra comparando sus desviaciones estándar (0.0018 vs. 0.0018) y sus varianzas (3.3128e-06 vs. 3.1905e-06). Esto indica que el indicador DSRv tiene una mayor correlación con la degradación cuando es “medido” (calculado) con celdas de batería que son cargadas a corriente no constante.




Fig. 2.26. DSRv [3,7-3,8V] con todas las intensidades de carga para BMR1.




Fig. 2.27. DSRv [3,7-3,8V] con intensidades de carga entre 15,5 y 17,5 A para BMR1.

El estudio también se ha realizado con los datos de la celda BMR2 de la Tabla 2.17, obteniendo el mismo resultado:

En las desviaciones estándar calculadas para la celda BMR2, se aprecia una reducción desde $2.0699\text{e-}05$ a $1.8453\text{e-}05$ (reducción del 11%), limitando los datos a intensidades entre 15,5 y 17,5 A. Al igual que la varianza, que pasa de $4.2845\text{e-}10$ a $3.4051\text{e-}10$ (reducción del 21%).

El mismo comportamiento se produce en la celda BMR2 que para la BMR1 en lo referente al indicador DSRv. En este caso las desviaciones estándar son 0.0014 vs. 0.0014 y las varianzas $2.0031\text{e-}06$ vs. $1.9923\text{e-}06$, lo que nos vuelve a indicar que el indicador DSRv no es tan sensible a las intensidades de carga variables como el DSR original. Esto permite su uso en este entorno de operación (carga con intensidades variables).

2.6. Puntos destacados del capítulo

En este capítulo de la tesis se ha presentado un **nuevo indicador del estado de la degradación** de las LIB llamado **DSR**, que es sensible al envejecimiento de las LIB y puede adelantar incluso su pérdida total de capacidad.

Se han enumerado sus características principales, siendo estas:

- (1) **Alta sensibilidad** ante el proceso de degradación.
- (2) **Precisión** en la cuantificación de la capacidad perdida.
- (3) Medición directa y rápida.
- (4) **Obtención** de forma **sencilla**, en lo que a calculo se refiere.

Debido a estas características, como **principales ventajas del DSR** frente a otros indicadores, se han establecido:

- (1) Su **eficiencia**, teniendo en cuenta la simpleza de cálculo frente a su relevancia (sensibilidad con la capacidad).
- (2) **Alto índice de correlación** con la capacidad degradada de las LIB.
- (3) **Reducción de tiempos de medida**, por lo que es mucho más rápido de medir y de estimar que el tradicional SOH.
- (4) **Seguimiento en tiempo real** de la tendencia de la degradación de la batería, pudiendo llevar a cabo alguna medida de operación o mantenimiento al respecto.
- (5) Puede adelantar la pérdida total de capacidad.
- (6) **Indicador independiente** y sustitutivo del SOH tradicional.
- (7) **Facilidad de implementación en el BMS**, por su rapidez y sencillez de cálculo.
- (8) Se puede realizar el **cálculo** de la degradación **en todo el espectro tensiones de carga**.
- (9) **Sólo** es necesaria **la tensión** para su cálculo, por lo que es más robusto frente a fallos.
- (10) **Ahorro en sensores, siendo solo necesaria la tensión**.

Después de ver las características y beneficios del uso de **este DSR**, se ha demostrado también que, dicho indicador **tiene resultados muy precisos cuando se utiliza como entrada de modelos**, debido a su alta sensibilidad y similitud en la evolución de la degradación de la batería.

Además, se han presentado resultados de tres modelos: LR, GPR y MLPNN entrenados y probados con seis conjuntos de baterías diferentes. Los **resultados se han comparado con modelos del estado del arte**, obteniendo una alta precisión ($R^2 > 0,98$) para datos desconocidos en todos los modelos.

Se ha probado, de igual forma, la **generalización del uso de este indicador con cualquier LIB** de las tecnologías presentadas, que cumpla con el entorno de operación establecido (**intensidad de carga en CC**).

Finalmente, se ha **elaborado también un indicador DSRv**, para su uso con **intensidades de carga no constantes**, que aumenta la correlación con el SOH en este tipo de operación, lo que presupone un mejor resultado como indicador, para su uso en estas condiciones de funcionamiento.

Capítulo 3

Arquitectura y características del BESS en estudio

Estructura de la tesis: **Capítulo 3**

Introducción y Estado del Arte
Identificación de un nuevo indicador de salud (DSR)

• Arquitectura y características del BESS en estudio •

Aplicación del nuevo DSR a un BESS

operando en regulación de frecuencia

Mantenimiento aplicado a un BESS

por medio de la metodología desarrollada

Conclusiones, contribuciones y futuros desarrollos

- En este capítulo se presenta la **arquitectura de los BESS**, con sus componentes principales, como p. ej.: el EMS, el PCS, el BMS, el SBMS, los racks, los módulos y celdas que lo forman.
- Además, se expone la necesidad del **balanceo de las celdas** para mantener la seguridad de las celdas del BESS y **disminuir su degradación**. Se presentan los métodos más utilizados para llevar a cabo dicho balanceo y sus beneficios.
- Finalmente se detallan los parámetros o **variables más relevantes del sistema BESS** empleado para esta tesis, como son la capacidad nominal, intensidad máxima, potencia máxima, etc.

3.1. Motivación

Los sistemas de almacenamiento de energía mediante baterías de iones de litio son sistemas eficaces para el desempeño de este cometido, ya que disponen de una alta densidad energética, pero a la vez, estas LIB requieren una tecnología de seguridad avanzada debido a su *inestabilidad* química. Para garantizar la seguridad y fiabilidad de los BESS, es fundamental que dispongan de sistemas que controlen los componentes que lo forman, entre los que se encuentra el sistema de equilibrado de celdas.

Este sistema es esencial para salvaguardar la seguridad de las celdas, su operación, su mantenimiento y su estado de salud.

Del mismo modo, conocer las características del BESS y los componentes que lo forman es importante para la realización de una operación y mantenimiento eficiente. Puntos que ha promovido el desarrollo de este Capítulo 3.

3.2. Introducción

Una vez desarrollado y probado el indicador DSR para su utilización en las LIB, se procederá, en el Capítulo 4, a implantar una metodología para su uso en los BESS. Para ello, es necesario el estudio y conocimiento de estos sistemas de almacenamiento de energía que utilizan LIB.

A lo largo de este capítulo, se introducen los siguientes conceptos:

- (1) La arquitectura y las partes de un BESS, poniendo el foco en las que tienen un papel clave en su degradación.
- (2) Se especifican las causas del desequilibrio de las celdas de los racks que forman los SBMS de un BESS y su repercusión en el funcionamiento, degradación e integridad física.
- (3) Posteriormente, se expone en qué consisten la ecualización de celdas y por qué es necesaria su realización, haciendo mención expresa de los sistemas de equilibrado y los beneficios de su uso.

- (4) Para finalizar, se presentarán las características y variables significativas del BESS empleado en esta tesis para el desarrollo y prueba de la metodología a implantar del Capítulo 4.

3.3. Arquitectura de los BESS

La arquitectura del sistema BESS estudiado para la tesis está basado en el estándar MESA, (MESA, 2018) “*Modular Energy Storage Architecture*” (Arquitectura Modular de Almacenamiento de Energía). Este estándar es un conjunto de especificaciones y se desarrolló por un consorcio industrial de empresas eléctricas y proveedores de tecnología.

El sistema BESS utilizado para la tesis está constituido por dos contenedores, nombrados como A y B, tal como muestra la Fig. 3.1.





Fig. 3.1. Arquitectura del BESS utilizado en la tesis, formado por dos contenedores A y B.

La unidad mínima de almacenamiento de los BESS es la celda, que en el sistema estudiado tiene una capacidad nominal de 78 Ah, una tensión nominal de 3,7 V, y por tanto, una energía nominal de 288,6 Wh. Su rango de tensión de operación es de 2,7 a 4,1 V, tal como se muestra en la Fig. 3.2.



Parámetro	Cantidad
Peso	1.910 kg
Química de la batería	NCM/LMO mezcla
Capacidad Nominal	78 Ah
Tensión nominal	3,7 V
Energía Nominal	288,6 Wh
Tensión de Operación (V)	2,7 a 4,1
Método de carga CC-CV	CC-CV

* NCM/LMO: LiNiCoMnO₂/LiMn₂O₄

Fig. 3.2. Características de una celda unitaria del BESS utilizado en la tesis.

Para construir los sistemas de almacenamiento de energía se emplea un diseño modular jerárquico que permite realizar configuraciones *ad hoc*, facilita el mantenimiento y la posibilidad de expansión-ampliación a futuro.

El siguiente nivel jerárquico por encima de la celda es el módulo (Fig. 3.3), y es el componente básico de los “Energy Storage Systems”. Este se integra utilizando celdas en serie, tantas como acepte el BMS que las gestiona.



Parámetro	Cantidad
Componentes	22 celdas, 1 BMS
Dimensiones	37x58,8x16 cm
Peso	50 kg
Tensión nominal	81,4 V
Energía nominal	6,26 kWh (1/3C)
Capacidad nominal	78 Ah
Tensión de Operación (V)	68,2 a 90,2 V
Método de carga CC-CV	4,1V/Cel., 26A, 3A

Fig. 3.3. Características de un módulo del BESS utilizado en la tesis.

En el caso de este sistema BESS los módulos están formados por 22 celdas en serie, por lo que su capacidad nominal será igual a la de la celda, su tensión nominal será de $22 \times 3,7 \text{ V} = 81,4 \text{ V}$ y tendrá una tensión de operación entre: 68,2~90,2 V. El BMS de cada módulo gestiona la temperatura de las celdas y la tensión de las mismas.

Estos módulos a su vez se interconectan con otro BMS (sistema de gestión de baterías), para así poderlos integrar en bastidores o racks.



Parámetro	Cantidad
Componentes	12 módulos, 1 SW, 1 BMS
Dimensiones	42x70,2x223 cm
Peso	700 kg
Tensión nominal	976,8 V
Energía nominal	76,2 kWh (1/3C)
Capacidad nominal	78 Ah
Tensión de Operación (V)	818,2 a 1.082,4V
Método de carga CC-CV	4,1V/Cel.,26A,3A

Fig. 3.4. Características de un rack unitario del BESS utilizado en la tesis.

Por tanto, cada rack contiene a su vez su propio sistema de gestión (BMS), que gestiona dichos módulos y tiene, entre otras, la función de medir tensiones y corrientes para todas las celdas del rack, por medio de los BMS de los módulos. También disponen de un conmutador (switch) que gestiona la desconexión del rack en todo momento. El BMS del rack dispone de su propio algoritmo de SOC que se calcula y actualiza automáticamente, protegiendo así las baterías de posibles fallos.

Así, cada “string” (nombre lógico que se da a la conexión de cada rack-bastidor físico) tiene su sistema de seguridad para su desconexión en caso necesario, con un conmutador y un fusible de protección. Con esto, el sistema BESS tiene la flexibilidad de aislar cualquier rack de la operación.

El BESS utilizado para esta investigación dispone de bastidores (racks) que albergan 12 módulos interconectados con un BMS y un conmutador (switch). Estos racks trabajan a una tensión nominal de 976,8 V y un rango de operación de 818,4 a 1.082,4 V (IEEE Standards Coordinating Committee 21 IEEE, 2009), tal como muestra la Fig. 3.4.

El siguiente nivel jerárquico se obtiene con la conexión en paralelo de estos racks, y así agruparlos por medio de otro sistema BMS (Maestro), para satisfacer los requisitos de potencia y energía de la aplicación para la que hayan sido diseñados. Cuantos más racks haya interconectados, mayor será la capacidad de almacenamiento de energía del sistema BESS.

Este BMS maestro, que está en un nivel superior y gestiona las unidades BMS de cada uno de los racks, es el que se comunica con el PCS. La Fig. 3.5 muestra los niveles de BMS utilizados para la jerarquía de almacenamiento, donde se pueden ver los BMS de los módulos, los de los racks o “strings” y finalmente el BMS maestro que gestiona la agrupación de los 19 racks, y además le da

nombre, BMS1, p.ej. A todo este sistema de almacenamiento gestionado por el BMS1, se le ha denominado SBMS1 (Store BMS1).




Fig. 3.5. Diagrama de los 19 racks conectados al BMS1 Maestro.

En el caso que nos ocupa disponemos de 12 SBMS tal como se muestra en la Fig. 3.6.




Fig. 3.6. Diagrama de los 12 SBMS que forman el BESS en estudio para la tesis.

Todos estos elementos: celdas, módulos y racks, son sistemas que trabajan en corriente continua (DC), ya que no dejan de ser un grupo, en mayor o menor medida, de celdas conectadas en serie y paralelo. Para dar servicio en corriente alterna (AC), se utilizan los PCS. Estos son sistemas que se ocupan de transformar la AC en DC para cargar las baterías (aguas abajo) y también transformar la DC en AC para dar energía y potencia al servicio que se precise.

La Fig. 3.7 ilustra la configuración necesaria para la implementación de un PCS. En el caso del BESS de la tesis, a cada PCS como el de la figura 3.7, va conectado un SBMS, *aguas abajo*, que a su vez alberga 19 racks.



Fig. 3.7. Diagrama de conexión de los PCS.

Estructuras de mayor capacidad y potencia se forman añadiendo estas configuraciones en paralelo, para formar así los ESS. En el BESS en estudio, los ESS lo forman 2 PCS con 2 SBMS, tal como se aprecia en la Fig. 3.8., habiendo un total de 6 ESS formando el BESS.




Fig. 3.8. Diagrama de conexión de un ESS.

Finalmente, hay un sistema que controla a todos los ESS (controlador maestro), la aparatura de conexión del BESS a la red de distribución y gestiona el funcionamiento o modos de control del BESS. Este sistema se denomina EMS (Energy Management System). Para el BESS en estudio el EMS gestiona 6 ESS tal como se muestra en la Fig. 3.9.




Fig. 3.9. Diagrama del EMS.

Resumiendo, existen varios niveles jerárquicos del BESS utilizado para esta tesis. Este dispone de una configuración de 6 ESS con 2 PCS cada uno de ellos, Fig. 3.9, que hacen un total de 12 PCS con 12 SBMS. Cada sistema SBMS tiene aguas abajo 19 Racks o “string” con 12 módulos cada uno, los cuales albergan 22 celdas tipo. Esto hacen un total de 60.192 ($12 \times 19 \times 12 \times 22$) celdas de 78 Ah de capacidad.

En lo referente al control del sistema, por cada unidad de energía, se emplea un sistema de gestión de batería llamado “*sistema de gestión de batería*” BMS multinivel, para la supervisión y el control de esa unidad de energía. El módulo lleva integrado uno (Fig. 3.3) y el rack lleva otro (Fig. 3.4). El BMS de módulo, diseñado para medir la tensión, la temperatura y ejecutar funciones de equilibrado de las 22 celdas, se encuentra en el nivel más bajo. El BMS de rack gestiona 12 unidades BMS de módulo y mide la tensión, la corriente de rack y realiza funciones de protección conmutando su propio contactor de DC.

Cerrando la unidad básica de energía ESS, un BMS maestro que gestiona las 19 unidades BMS de rack y se comunica con el PCS. Finalmente, un controlador maestro que gestiona los 6 ESS y se conecta con el EMS.

Como es de suponer también, los sistemas BESS necesitan generalmente transformadores de tensión con su aparamenta adecuada para la conexión de la batería a la red de distribución de electricidad.

Para garantizar una temperatura de funcionamiento estable, dentro de los contenedores del BESS donde se encuentran los racks, se dispone de un equipo HVAC (Heating Ventilation Air Conditioning), cuyo rango de temperaturas de operación está entre 10 °C y 30 °C. Así este sistema HVAC está diseñado para mantener la temperatura del contenedor entre 20 y 23 °C, de forma que se palien los efectos que las bajas y altas temperaturas tienen en las celdas (disminución de eficiencia y aumento de la degradación, respectivamente) y además debería garantizar que estas temperaturas de las celdas no afectan significativamente a las tensiones de operación medidas.

Otro de los sistemas necesarios para el correcto funcionamiento de un BESS, y que además es muy importante para la durabilidad de las baterías que lo componen, es el sistema de balanceo de celdas, encargado del proceso de equilibrado, mencionado anteriormente.

3.4. Ecualización de celdas en un BESS

Como se ha mencionado anteriormente, con la necesidad de conexión de celdas en serie, los valores de la tensión de dichas celdas deben ser iguales para

obtener así un rack con la máxima eficiencia. En la configuración del BESS de la tesis son 22 celdas por módulo y 12 módulos por rack, hasta obtener una tensión nominal de 976,8 V.

El proceso para mantener todas las tensiones de celda iguales, cuando se operan en serie y están completamente cargadas, se llama equilibrado o equalización de celdas.

3.4.1 Causas del desequilibrio de celdas

Cuando se combinan diferentes celdas para formar un paquete de baterías, se debe asegurar que estas tengan la misma composición química y tensión nominal en su instalación. Una vez que los módulos y racks comienzan a operarse y se someten a cargas y descargas, las celdas se pueden desequilibrar debido a las siguientes razones (Phung, Collet and Crebier, 2014):

(1) Desequilibrio del SOC.

En la fabricación de módulos ideal, las baterías deberían componerse de celdas de la misma capacidad, en lugar de celdas con los mismos niveles de tensión, pero la obtención de la capacidad es más costosa (en términos de medición de la variable) que la obtención de la tensión de celda. Por ello las celdas se combinan en términos de voltaje, al hacer un paquete (Xu *et al.*, 2013). Con el tiempo la variación del SOC implicará una divergencia en el nivel de tensión.

(2) Variación de la Resistencia Interna.

Encontrar celdas con la misma resistencia interna (IR) es seguramente imposible, (no hay dos celdas idénticas, ya que siempre hay ligeras diferencias en el estado de carga, tasa de autodescarga, capacidad, características de temperatura, etc.), y además a medida que la batería envejece, esta IR de la celda también varía. Por tanto, en un paquete de baterías, todas las celdas tienen diferente IR, por pequeña que sea esa diferencia, y esta diferencia a su vez contribuye a una diferencia de la impedancia interna de la celda, que determina la corriente que fluye a través de ella y en consecuencia a su tensión para un nivel de SOC (Xu *et al.*, 2013).

Por ello, aunque en inicio todas las celdas que forman una batería tuvieran una idéntica IR, es decir, la variación de esta IR de una con otras fuera cero, con la operación de dicha batería esta variación se vería incrementada y con ello las variaciones de tensión de unas con respecto a otras.

(3) Temperatura.

La temperatura influye en la degradación de las celdas durante la carga y descarga (Qu *et al.*, 2022). Además, en un paquete de baterías (módulos, racks, BESS) las celdas se distribuyen de diferentes formas sobre estos módulos/racks, y por tanto puede haber diferencias de temperatura en el paquete si el sistema de refrigeración no es adecuado. Así, la temperatura no estaría homogéneamente distribuida, afectando a su IR, y con ello a variaciones de tensión de unas con respecto a otras, causando un desequilibrio entre las celdas del módulo y rack.

3.4.2 Repercusión del desequilibrio celular

Como se ha mencionado, las celdas de las baterías son dispositivos que se degradan con la operación de carga y descarga y pueden llegar a dañarse sin las limitaciones adecuadas. Si las celdas tienen diferente SOC, p.ej., con el uso, la tensión empieza a disminuir hasta que la celda de menor energía almacenada alcanza la tensión de corte de descarga. En ese momento, si la energía sigue fluyendo a través de la célula, ésta se dañará irreparablemente. Si por el contrario, el sistema BMS desconecta el paquete del sistema, paliaremos el posible daño, pero estaremos utilizando de manera ineficiente la energía de las baterías, ya que por una celda con caída de tensión estamos apartando de la operación al resto.

Del mismo modo, cuando se realiza la carga de este grupo de células a la tensión combinada correcta, las células sanas se sobrecargan, ya que tomarán la energía que la célula ya dañada no es capaz de almacenar, y por tanto, se dañará el resto. Por lo que es absolutamente necesario realizar un proceso de equilibrado. Otras repercusiones (Duraismy and Kaliyaperumal, 2021) al no realizar el equilibrado de celdas son:

(1) Embalamiento térmico.

Las celdas de ion de litio son muy sensibles a la sobrecarga y la sobre descarga, por lo que estos excesos pueden provocar un desbordamiento térmico (Tran *et al.*, 2022) cuando el incremento de generación de calor interno supera la velocidad a la que se puede disipar dicho calor.

Con un procedimiento de equilibrado de celdas, cada celda no defectuosa en el paquete de baterías se equilibra a la misma capacidad relativa que las otras celdas no defectuosas. Esto ayuda a mantener el

pack de celdas mejor refrigerado ya que el calor es uno de los principales factores que conducen al desbordamiento térmico.

(2) Degradación de la celda.

Cuando una celda de litio se sobrecarga, aunque sea ligeramente por encima de su valor recomendado, la capacidad energética, la eficiencia y el ciclo de vida de la celda se reducen (Timilsina *et al.*, 2023). Esta degradación de la celda se debe principalmente a:

- La degradación de los electrodos.
- Al crecimiento del electrolito sólido en el ánodo.
- A la formación de óxido en el cátodo, que puede provocar una pérdida inminente de capacidad.
- Al recubrimiento con litio en la superficie del ánodo por elevados C-rates en la carga.

(3) Carga incompleta de un paquete de celdas.

Las baterías se cargan generalmente a una corriente constante, que hace que la tensión de la batería aumente conforme avanza la carga, hasta alcanzar su valor máximo (etapa CC). La carga continua entonces en su etapa CV hasta alcanzar el 100%. Si las celdas no están equilibradas en el proceso de carga, este se interrumpirá cuando la celda con la tensión mayor alcance el voltaje de corte, y por tanto no todas las celdas estarán completamente cargadas.

Como se aprecia en la Fig. 3.10, las celdas de menor capacidad (debido a la degradación precipitada, p.ej.) se cargan completamente estando el resto con capacidad libre de energía.




Fig. 3.10. Diagrama de celdas cargadas con y sin degradación celular.

(4) Uso incompleto de la energía del paquete de celdas.

Del mismo modo, en el proceso de descarga de la batería, las celdas más deterioradas, que tendrán una capacidad menor, se descargan más rápidamente que las otras, alcanzando el voltaje menor más rápidamente. Como se muestra en la batería de la Fig. 3.11, las celdas 1 y 2 se han descargado completamente, lo que impide que el resto puedan aportar su energía a la operación, por lo que la eficiencia disminuye.




Fig. 3.11. Diagrama de celdas descargadas con y sin degradación celular.

3.4.3 Tipos de equilibrado de celdas

Son muchos los artículos de investigación y desarrollo de circuitos para el equilibrado de celdas que forman los paquetes de baterías. Por ejemplo, (Paidi and Gudey, 2022) muestran los dos métodos por excelencia que hay para solucionar dicho problema. En el siguiente apartado se analiza más en detalle dichos mecanismos.

(1) Equilibrio celular pasivo.

El método de equilibrado pasivo consiste en igualar las tensiones de todas las celdas del paquete (módulo), tomando como referencia la de menor tensión, hasta igualarlas (equilibrarlas) con esta. La forma de igualar dichas tensiones es mediante la descarga de las celdas de mayor tensión a través de un elemento resistivo.

- El circuito empleado es mediante una **resistencia de derivación conmutada**, mostrado en la Fig. 3.12, y tiene dos

tipologías: en modo continuo o en modo de detección. En modo continuo todos los interruptores conmutan a la vez, es decir, se encienden y apagan al mismo tiempo. Al contrario que en el modo de detección, que actúan en función de un sensor de tensión que detecta el desequilibrio en tiempo real para cada celda y actúa en consecuencia. Este método puede utilizarse para las baterías de iones de litio que se emplean en los vehículos eléctricos.




Fig. 3.12 Circuito de equilibrado de celdas mediante resistencia de derivación conmutada por medio de semiconductores Q.

Una desventaja de este método es que, debido a la gran disipación de energía necesaria, el equilibrado pasivo se utiliza para aplicaciones de baja potencia, y en la que los tiempos de equilibrado pueden ser largos. Además, por las altas cantidades de pérdidas energéticas es un método poco eficiente.

(2) Equilibrio celular activo.

En el equilibrado de celdas activo, en lugar de disipar la energía en forma de calor hasta equilibrar los SOC de todas las celdas, dicha energía se transfiere a las celdas con las que hay conexión, según el circuito de la solución elegida. Así, las celdas de mayor SOC utilizarán su excedente para cargar las celdas de menor SOC. Por este motivo son mecanismos eficientes y con diversas metodologías, los utilizados en el balance activo (Hemavathi Sugumar, 2021), (Ahmad *et al.*, 2019). Es el método más recomendado, aunque también más costoso. Se pueden clasificar atendiendo al componente utilizado para realizar el equilibrado. Así, pueden utilizarse diferentes metodologías:

- **Un método inductor:** por medio de bobinas, como muestra la Fig. 3.13 (Phung, Collet and Crebier, 2014), (Mestrallet *et al.*, 2014) o transformadores, Fig 3.15 (Shang *et al.*, 2017), (Chen *et al.*, 2016).
- **Un método capacitivo** (ver Fig. 3.16), por medio de un condensador o varios condensadores, (Kim *et al.*, 2014).
- **Un método conversor**, con convertidores electrónicos, (Shang *et al.*, 2015), (Azad *et al.*, 2020).
- También existen métodos de equilibrado de celdas que **utilizan circuitos formados por varios de ellos**, por ejemplo (Azad *et al.*, 2020) propone un circuito LC que transfiere la energía entre la celdas con mayor SOC a la de menor SOC.




Fig. 3.13 Circuito de equilibrado de celdas mediante inductor único.




Fig. 3.14 Circuito de equilibrado de celdas mediante condensadores.

Los tres métodos tienen grandes oportunidades de mejora, por ejemplo, el circuito condensador tiene un proceso de carga que repercute en un equilibrado lento, y además genera una gran cantidad de pérdidas de energía durante la carga de estos condensadores.

Los circuitos con inductor o transformador pueden transferir la energía de un módulo a otro o de celda a celda, por lo que realizan un equilibrado muy rápido. Su principal línea de mejora es su elevado coste y la necesidad de incluir un condensador de filtro en el circuito.




Fig. 3.15 Circuito de equilibrado de celdas mediante transformador único.

El equilibrado de celdas basado en convertidores ha aumentado su desarrollo en los últimos años debido a sus atractivas características, que permiten un control completo del proceso de equilibrado, sin embargo, su complejidad y el elevado coste siguen siendo los principales retos.

(Wei *et al.*, 2019) proponen un sistema de ecualización de CC con una matriz de conmutación y un modelo Gauss-Seidel. Este método presenta varias ventajas principalmente:

- El convertidor Buck-Boost tiene una estructura simple con una independencia de cada subcircuito de ecualización, que permite reducir el tiempo de ecualización.
- Su sistema de procesamiento matricial para la conmutación evita el problema de la carga y descarga reiterada, mitigando los daños causados por la intervención del circuito de ecualización, y alargando así la vida del módulo o rack de celdas.

Las ventajas del equilibrado de celdas activo con respecto al pasivo son varias, entre ellas la posibilidad del funcionamiento de las celdas con diferencias en su capacidad dentro de un módulo o pack. Otra ventaja es el aumento de la eficiencia energética, ya que no desecha la sobrante, sino que se transfiere. Como en el método pasivo, prolongación de la vida útil mejorando la esperanza de vida de las celdas, pero en este caso el equilibrado es más rápido.

Como líneas de mejora encontramos la limitación de transferencia de energía solamente del SOC mayor al menor, y los algoritmos de control son más complejos y de mayor coste de producción que en el pasivo.

Como norma general, cuanto más complejo es el circuito de equilibrado, más elementos tiene el circuito, y por tanto mayor es su complejidad de uso (control más complejo). Esto implica también mayor versatilidad en su uso, posibilitando la transferencia de energía no sólo con las celdas adyacentes, sino con otras incluso de otro modulo. Implica también un menor tiempo de equilibrado, aunque un mayor coste de fabricación.

3.4.4 Beneficios del equilibrado de celdas

Como se ha visto en este capítulo, el equilibrado de celdas es un proceso importante a tener en cuenta en los BESS, por la repercusión que tiene en la degradación de las celdas. Por este motivo, disponer de un sistema de equilibrado adecuado, es necesario si se quiere mantener las celdas en buenas condiciones de operación y mantenimiento.

La inclusión de estos sistemas de equilibrado de celdas dentro del BESS repercute aún más, como se mencionará en el Capítulo 5, en que estos se definan como *sistemas complejos*. *“Definimos un sistema complejo como un sistema con muchos componentes que interactúan y en el que es difícil modelar exhaustivamente todos los comportamientos debido a las dependencias, relaciones y demás interacciones entre estos componentes”*, (Fioravanti et al., 2020).

3.5. Especificaciones eléctricas y variables del BESS de la tesis.

Una vez vista la arquitectura y los componentes principales que integran el BESS de la tesis, dentro del apartado 3.3 de este capítulo, en esta sección se muestran las dimensiones globales del mismo, para tener una visión global de la magnitud del BESS como sistema eléctrico y electrónico.

El BESS de la tesis se encuentra localizado en el Reino Unido, y conectado al operador energético *“National Grid”*, para dar una *Respuesta en Frecuencia Firme* inferior a un segundo, lo que supone un ahorro de costes para el sistema eléctrico.



Fig. 3.16 Fotográfica del BESS de la tesis. (EASE, 2018)

Para dar este servicio, se desarrolló un BESS que está formado por dos contenedores A y B, los cuales albergan cada uno 6 SBMS con 19 racks o “strings lógicos”. Cada Rack contiene a su vez 12 módulos y cada módulo 22 celdas. Las Tablas 3.1 y 3.2 muestran las dimensiones del BESS a nivel de ítems.

Tabla 3.1 Dimensiones del BESS a nivel de dispositivos: Contenedor, BMS, Rack, Módulo y celda.

	Contenedor	SBMSxContenedor	RackxBMS	MóduloxRack	CeldaxMódulo
Contenedor	A	6	19	12	22
Contenedor	B	6	19	12	22
T. nominal			976,8 V	81,4 V	3,7 V
I. máx.			156 A		2C
P. máx.	34.743 kW				

Tabla 3.2 Dimensiones del BESS a nivel de potencia y capacidades.

	Contenedores	SBMS	Racks	Módulos	Celdas
N.º Total	2	12	228	2.736	60.192
Cap./Uni.	8.685 kWh	1.447,5 kWh	936 Ah	78 Ah	78 Ah
Cap. Total	17.370 kWh				

Como se ha mencionado anteriormente, los sistemas BMS del BESS son los encargados de medir y almacenar los valores de las tensiones de las celdas, módulos y racks del sistema, entre otras medidas a tener en cuenta. Una vez diseñadas las dimensiones del sistema, llevar a cabo la gestión de todo el proceso de medidas del BESS, para su correcta operación y mantenimiento, es un reto en sí para la ingeniería de datos. Así, por ejemplo, sólo teniendo en cuenta la variable tensión, esta se ve implicada en 60.192 celdas, unidas a 2.736 módulos y 228 racks. Si a esta le asignamos un muestreo de 6 datos por minuto

(p.ej) , harían un total de 378.000 datos por minuto, aprox., sólo para una variable a medir y almacenar. Las variables a medir se van incrementando “*aguas arriba*”, debido al aumento de los sistemas del BESS conforme vamos integrando o escalando los dispositivos que lo forman.

Como ejemplo, a nivel de celda las variables a medir son: la tensión, la intensidad y la temperatura de celda, pero para la gestión de estas, los BMS deben emplear controles, p. ej., para el equilibrado de las celdas. Por ello, escalando el número de variables a medir (sin tener en cuenta el control del sistema) y sólo para los sistemas de almacenamiento de energía (celdas, módulos y rack) serían del orden de 180.000 medidas entre tensiones, intensidades y temperaturas, de celdas, módulos y racks del sistema.

Esto, como se ha dicho, hace la *gestión del dato* imposible según se escala el proceso “*aguas arriba*”, por lo que los sistemas de gestión que lo forman, más allá del de control interno, tienden a agrupar mediciones globales, por ejemplo, a nivel de rack. Las mediciones a nivel de celda, de las variables necesarias para el control, se quedan en los BMS del módulo o del rack, para el uso de los sistemas que controlan estos, para su correcto mantenimiento y operación.

Así, los datos de tensión, intensidad y temperaturas utilizados para esta tesis, extraídos del sistema SCADA de datos del BESS, son a nivel de rack. Esto es debido a que el sistema PI (OSIsoft, 2020) diseñado para el almacenamiento de las señales del BESS, debe estar dimensionado de forma eficiente, y muestrear más de 180.000 señales cada segundo, sólo para las celdas del BESS, se hace muy difícil. Es en este contexto donde se hace referencia a las dificultades encontradas en el estado del arte, cuando se explicaba la imposibilidad de utilizar un modelo de circuito equivalente (ECM) para cada una de las celdas.

El caso similar, aunque de menor envergadura, lo tenemos para el almacenamiento de las medidas (tensión, intensidad y temperatura) de los módulos del BESS. Se tendrían 2.736x3 medias (8.208 variables a almacenar por segundo). Por ello, en el diseño del sistema PI para el almacenamiento de las señales del BESS de esta envergadura, se suelen considerar para su almacenamiento, sólo las variables de los racks. Siendo, aun así, un montante considerable de 684 (228 x 3) variables.

Además, en lo referente a las tensiones del rack almacenadas por el sistema, se almacena en todo momento la tensión real del rack, de 818,4 a 1.082,4 V y *la media* de las tensiones de las celdas del rack, entre 3,4 y 4,2 V. Esta última variable hace que se pueda considerar un rack como *una gran batería* formada por 264 celdas cuya tensión de trabajo está en el rango de 3,4 a 4,2 V. Esto se

demuestra en la Fig. 3.16, que visualiza las curvas de tendencia de la tensión real del rack (818,4 ~1.082,4 V) y la media de las tensiones de las celdas del mismo. Como se puede apreciar, las dos curvas siguen la misma tendencia a lo largo del tiempo.




Fig. 3.17. Tensión real (medida) de rack vs. tensión media de las celdas del rack.

Del mismo modo, normalizando las dos señales de tensión, se aprecia que son completamente equivalentes, por lo que es indiferente tomar una u otra a nivel de tendencias. Ver Fig. 3.18.




Fig. 3.18. Tensión real (medida) de rack vs. tensión media de las celdas del rack normalizadas.

Para el análisis y desarrollo de los modelos y metodología de esta tesis, se ha preferido utilizar la media de las tensiones del rack porque su rango de tensiones está en el orden de los utilizados en la literatura científica de las LIB, para la realización de las comparaciones.

3.6. Medida de la capacidad de los SBMS del BESS de la tesis.

Una de las medidas relevantes, que se ha podido tomar durante el periodo en que se analizan los datos del BESS, y necesaria para la demostración desarrollada en la metodología planteada del Capítulo 4 de la tesis, es la medición de las capacidades de los 12 SBMS que constituyen el BESS.

Este procedimiento se puede encontrar en la literatura científica (Smith *et al.*, 2018), (Schimpe *et al.*, 2018), aunque cada fabricante y operador puede especificar las condiciones en las que realizar el CT o “performance test” para medir la capacidad en un momento determinado.

Así, el procedimiento de CT establecido para el BESS de esta tesis es:

1. Una vez retirado el BESS del servicio de respuesta en frecuencia, se procede a su descarga, a la máxima potencia (intensidades de rack de unos 100 A), hasta que el sistema de control detiene la descarga, cuando ya no se puede mantener el nivel de potencia (SoC del Contenedor A ~ 1% y del Contenedor B ~ 1%).
2. A continuación, se procede a cargar de nuevo el BESS a su máxima potencia (intensidades de carga del rack de unos 100 A), hasta que el sistema de control reduce el nivel de potencia de carga (SoC del Contenedor A ~ 84 % y del Contenedor B ~ 88%).
3. Tras un periodo de descanso de 10 minutos, el BESS se descarga nuevamente a la máxima potencia hasta que el sistema de control reduce el nivel de potencia de descarga. Es en este proceso donde se toman las medidas de capacidad de los SBMS del BESS, y que aplican como *nueva capacidad* del BESS.
4. Posteriormente el BESS se carga hasta alcanzar un SoC operativo adecuado y se reanuda el servicio.

Las medidas de capacidad tomadas para cada SBMS se pueden ver en la Tabla 3.3.

Tabla 3.3 Medidas de la capacidad de cada uno de los SBMS del BESS para el CT realizado en jul-2020.

SBMS	1	2	3	4	5	6	7	8	9	10	11	12	Total
Energía Exportada (kWh)	1.170	1.150	1.165	1.150	1.175	1.140	1.075	1.090	1.110	1.090	1.100	1.095	13.510

La obtención de estas medidas de capacidad es esencial a la hora de poder validar la metodología desarrollada en el Capítulo 4. Así, la medida del SOH calculada para la fecha de realización de la prueba (jul-2020) es del 92.9%

De igual forma se dispone de la medida del SOH anterior establecida en jun-2019 y es del 96%. El BOL del BESS se realizó en jun-2018 considerando el SOH el 100%. Con estas medidas es posible el ajuste con una línea de tendencia.

Los valores de los parámetros del polinomio de grado uno de ajuste, se muestra en la Tabla 3.4.

Tabla 3.4 Parámetros del polinomio de ajuste para la curva de degradación del BESS FC (%).

$f(x) = p1 \cdot x + p2$	FC (%) (BC 95%)
p1 (p1b;p1a)	0,002834 (-0,0006388;0,006306)
p2 (p2b;p2a)	0,002051 (-0,05354;0,05765)
R²	0,99
R² (Ajustado)	0,98
RMSE	4,83E-03

3.7. Puntos destacados del capítulo

En este Capítulo 3 se ha presentado la **arquitectura y funcionamiento de un BESS** con datos de operación reales de un año y medio utilizados para este estudio, donde:

En primer lugar, se han desglosado las partes del BESS en lo que a arquitectura de almacenamiento se refiere, siendo las partes más relevantes:

- Las celdas
- Los módulos
- Los racks
- Los SBMS.

En lo referente a su conectividad a la corriente alterna, **destacar el PCS**, que es básicamente un converso AC/DC, y que **junto con un transformador forman el ESS**, la unidad básica de almacenamiento en AC.

Posteriormente se han tratado las **causas del desequilibrio** de las celdas de los racks que forman el BESS, y la repercusión que tiene en su funcionamiento si no se corrige. Como causas principales se han enumerado:

- **El desequilibrio del SOC.**
- Las diferencias entre las **resistencias internas** de las celdas.
- Las **temperaturas no homogéneas**.

También se han enumerado las **repercusiones en caso de no realizar el equilibrado** para el conjunto del BESS, estas son principalmente:

- **Embalamiento término.**
- **Degradación** celular.
- **Carga incompleta** del paquete de celdas.
- **Uso incompleto** de la energía de los módulos y racks.

De la misma forma se exponen los tipos y circuitos más utilizados para la realización del equilibrado:

- Equilibrio celular pasivo:
Mediante **resistencia fija** o por el uso de **resistencia conmutada**.
- Equilibrio celular activo:
Método **inductor, capacitivo, conversor y mixtos**.

Así, se han expuesto las **ventajas del equilibrado de celdas activo** vs. el pasivo, estas son:

1. **Mayor versatilidad**, posibilitando la transferencia de energía, no sólo con las celdas adyacentes, sino con otras incluso de otro modulo del rack.
2. **Mayor eficiencia energética**, ya que no desecha la sobrante, sino que se transfiere.
3. **Menor tiempo de equilibrado**, aunque un mayor coste de fabricación.

Además, se han presentado las características y **variables más significativas del BESS** empleado en esta tesis, para el desarrollo y futura prueba de la metodología a implantar. Como dimensiones más significativas para tener en cuenta:

- 2 contenedores.
- 12 SBMS.
- 229 racks.
- 2.736 módulos.
- **60.192 celdas.**
- **17.370 kWh de capacidad.**

Para finalizar se han mostrado los resultados de la prueba de capacidad CT realizada en julio del 2020, donde se ha medido que la **capacidad real** en esa fecha era de **13.510 kWh**.

Capítulo 4

Aplicación del nuevo DSR a un BESS operando en regulación de frecuencia

Estructura de la tesis: **Capítulo 4**

Introducción y Estado del Arte

Identificación de un nuevo indicador de salud (DSR)

Arquitectura y características del BESS en estudio

• Aplicación del nuevo DSR a un BESS operando en regulación de frecuencia •

Mantenimiento aplicado a un BESS

por medio de la metodología desarrollada

Conclusiones, contribuciones y futuros desarrollos

- En este capítulo se **aplica el nuevo HI DSR** al entorno del BESS presentado en el Capítulo 3, en primer lugar, con los pocos datos que cumplen dicho entorno de trabajo marcado (curvas de carga a corriente pseudo-constante), para **mostrar la sensibilidad del indicador DSR para con la degradación del BESS**.
- A continuación, se **desarrolla un nuevo indicador DSRa** subyacente del DSR, que es **más sensible a la operación con corrientes variables**, y se adapta mejor a las necesidades de la operación del BESS, mostrando también los resultados obtenidos con corrientes pseudo-constantes.
- Para terminar, **se presenta una metodología** que, mediante el nuevo DSRa, **es capaz de medir la degradación sufrida por los racks** de un SBMS y por los SBMS **del BESS** estudiado en la tesis, con los datos de un año de operación.

4.1. Motivación

Como ya se ha mencionado, los BESS son sistemas que disponen de una alta densidad energética, que requieren de una tecnología de seguridad avanzada debido a su inestabilidad química. Para garantizar la seguridad y fiabilidad de los BESS, es fundamental determinar la evolución de la degradación de las baterías que lo forman.

Los cambios en las características eléctricas, el aumento de la resistencia interna (Wang *et al.*, 2016) que tienen como consecuencia la reducción de la potencia (Shen *et al.*, 2018), y la reducción de la capacidad (Chen *et al.*, 2018) provocan el deterioro del rendimiento de las baterías, lo que dificulta su gestión operativa. Por lo tanto, es necesario conocer estos parámetros de la batería para controlar con precisión su estado, su desempeño, y garantizar su seguridad. Los diagnósticos que muestran cómo se está degradando el rendimiento de la batería, pueden ayudar a prevenir el abuso de esta degradación, el embalamiento térmico, así como determinar cuándo es necesario sustituir partes o la unidad entera. El SOH es el principal indicador para determinar la degradación de la batería (Weng *et al.*, 2013).

Una vez establecida la necesidad, la motivación del trabajo de este capítulo se establece por, la casi total ausencia de datos de operación real de sistemas ESS basados en LIB, que se encuentran dentro del entorno establecido para la aplicación del DSR. Esto ha llevado al desarrollo de un “*nuevo camino*” para determinar la degradación del BESS con este tipo de operación tan volátil.

4.2. Introducción

Después de establecer los componentes que integran un BESS, poniendo el foco en sus sistemas de almacenamiento de energía y de control, en este capítulo se aborda principalmente el desarrollo de una metodología capaz de establecer la degradación de un BESS operado en regulación de frecuencia. Para ello:

- (1) Se muestra la aplicación del nuevo indicador DSR, al BESS, mediante la selección de los datos que cumplen los requisitos establecidos de carga a CC para su aplicación. Se mostrará la sensibilidad del DSR ante la degradación del BESS, cuando este opera con intensidades de carga constantes. Esto permite poder evaluar su degradación.
- (2) Se exponen las necesidades de ampliación del entorno de operación del indicador DSR para cubrir las necesidades operativas del BESS de la

tesis. Se propone ampliar el entorno mediante el desarrollo de un nuevo HI adaptado a la volatilidad de operación de dicho BESS.

- (3) Se desarrolla un nuevo indicador DSRa, que se adapta mejor a la operación de este BESS, y que permitirá su uso en el entorno de operación volátil que tiene el BESS. Se elabora, finalmente, una metodología conjunta que cubre las necesidades planteadas, mediante el uso del indicador DSRa y la técnica de predicción “One-to-All”, mediante la creación de 3 tipos de modelos de ML.
- (4) Además, se mostrarán los resultados obtenidos mediante el uso de esta nueva metodología, comparando estos resultados con los medidos en las pruebas de capacidad mostradas en el Capítulo 3.6.

4.3. Aplicando el indicador DSR a un BESS.

En el Capítulo 2 se mostraba, por medio de la Fig. 2.1, la variación de los segmentos de tensión de carga a través de los diferentes ciclos de carga en la vida de una batería. Esta se obtenía mostrando los perfiles de tensión de carga a lo largo de toda la vida de la batería.




Fig. 2-1. Perfiles de tensión de carga desde el ciclo 1 hasta el final de la vida útil del ciclo (EoL).

4.3.1 Envejecimiento del BESS

Al igual que se aprecia en el comportamiento de dichas baterías de laboratorio, se ha apreciado, durante el desarrollo de la tesis, que los sistemas BESS también sufren esa variación en la tensión de carga con el paso de los ciclos de vida.

Así, durante el año y medio de toma de medidas del BESS, se ha comprobado que existen algunos periodos en los que la corriente fue pseudo-constantes (en torno a 100 A) durante algunos ciclos de carga de los diferentes SBMS. Así, se ha podido comparar, en esta investigación, algunos segmentos de tensión en los ciclos iniciales, medios y finales del estudio, para diferentes racks y SBMS del sistema BESS.

La Fig. 4.1 muestra tres segmentos de tensión, para tres ciclos de carga, para el Rack1 del SBMS1, realizados a intensidades prácticamente constantes (alrededor de 100 A, (Fig. 4.2)), en la que se aprecia el desfase de la tensión a lo largo de esos 3 ciclos, ocurridos entre los meses de diciembre de 2018 (ciclo 142), marzo de 2019 (ciclo 863) y junio de 2019 (ciclo 1308).




Fig. 4.1. Tensiones de carga de tres ciclos realizados a intensidades pseudo-constantes, para el Rack1 del SBMS1.




Fig. 4.2. Intensidades de los ciclos C142, C863 y C1308 para el Rack1 del SBMS1.

Lo mismo se aprecia para los ciclos del Rack1 del SBMS2. Como se puede ver en la Fig. 4.3, hay una disminución del tiempo de carga para un mismo nivel de tensión a lo largo de la vida de la batería, tal como se vio en el Capítulo 2.




Fig. 4.3. Tensiones de carga de tres ciclos realizados a intensidades pseudo-constantes, para el Rack1 del SBMS2.




Fig. 4.4. Intensidades de los ciclos C138, C871 y C1305 para el Rack1 del SBMS2.

En la Fig. 4.4 se muestran las intensidades de carga para dichos ciclos. En la Fig. 4.3 se muestra que la tensión respecto al tiempo empleado para el ciclo 1305 es mayor que para el ciclo 871, siendo incluso la intensidad de carga del ciclo 1305 algo menor que la del ciclo 871. Este decremento del tiempo de carga es debido al efecto comentado de la Fig. 2.1.

El mismo fenómeno ocurre en los Racks1 de los SBMS3 y SBMS4 verificados también en las Figuras 4.5, 4.6, 4.7 y 4.8. En estas figuras se aprecia el mismo fenómeno de decremento del tiempo de carga para alcanzar su nivel de tensión máxima, tal como se apreciaba en la Fig. 2.1. Fenómeno que va ligado a la

degradación de la LIB, en este caso a la degradación del rack, como sistema de almacenamiento de energía mediante LIB.




Fig. 4.5. Tensiones de carga de tres ciclos realizados a intensidades pseudo-constantes, para el Rack1 del SBMS3.




Fig. 4.6. Intensidades de los ciclos C145, C859 y C1307 para el Rack1 del SBMS3.




Fig. 4.7. Tensiones de carga de tres ciclos realizados a intensidades pseudo-constantes, para el Rack1 del SBMS4.




Fig. 4.8. Intensidades de los ciclos C156, C873 y C1296 para el Rack1 del BMS4.

En este proceso de estudio de los tres ciclos de carga del BESS que se ha podido analizar a corrientes pseudo-constante, también se ha estudiado el comportamiento de las temperaturas marcadas para estos ciclos de carga.

Así, por ejemplo, en la Fig. 4.9 se muestran las temperaturas del Rack1 del SBMS1 para los ciclos 142, 863 y 1308, donde se aprecia un incremento de temperatura del rack durante la carga para esos 3 ciclos, de unos 3 °C.




Fig. 4.9. Temperaturas de los ciclos C142, C863 y C1308 para el Rack1 del SBMS 1.

Como se aprecia en la Fig. 4.1, el incremento de tensión para ese intervalo de tiempo (16 min) aumenta de 3,68 a 3,85 V, con unas intensidades del orden de 100 A (Fig. 4.2). Lógicamente, las temperaturas iniciales son diferentes para cada ciclo, en función de cómo estuvieran estas cuando comenzó el proceso de carga a dichas intensidades, por lo que debemos tener en cuenta los incrementos de temperaturas en los tres ciclos, no la absoluta, para ver cómo evolucionan a lo largo del tiempo estudiado, de diciembre de 2018 (ciclo 142) a junio del 2019, (ciclo 1308).

Así, del mismo modo que sucede con la evolución de las temperaturas con el paso de los ciclos en las baterías estudiadas en el capítulo 2, y conforme a los artículos de la literatura actual (Jia *et al.*, 2021), en los racks del BESS estudiados, las temperaturas también tienen el mismo comportamiento. Como se muestra en estas curvas, los incrementos de temperatura con el paso de los ciclos de vida operativos aumentan, como se aprecia en la Fig. 4.10




Fig. 4.10. Temperaturas de los ciclos C142, C863 y C1308 para el Rack1 del SBMS 1 y temperaturas de los ciclos C145, C859 y C1307 para el Rack1 del SBMS 3.

El mismo fenómeno se observa cuando se comparan las temperaturas en función de los niveles de tensión a lo largo de los ciclos de carga, de estos racks de los SBMS del BESS. Fenómenos similares a los publicados por artículos de investigación con datos de baterías de la NASA, (Tian, Xiong and Shen, 2020). Como se aprecia en la Fig. 4.11, la temperatura que adquieren los racks en el proceso de carga se incrementa respecto al nivel de tensión adquirido, conforme pasan los ciclos de uso.




Fig. 4.11. Temperaturas vs. Tensiones de los ciclos C142, C862 y C1308 para el Rack1 del SBMS1.

4.3.2 Evaluación de la degradación de un BESS basándose en la sensibilidad del indicador DSR

Tal como se vio en el Capítulo 3.5, el comportamiento de cualquiera de los 19 racks que forma cualquiera de los 12 SBMS que integran el BESS, puede “*ser tratado*” como una macro-celda de iones de litio en cuanto a la consideración de tensión e intensidad, tomando como tensión del rack la media de las tensiones de todas sus celdas.

De igual forma se ha visto que dicha tensión experimenta cambios en su pendiente de carga con el transcurso de los ciclos, como se mostraba en las Figuras 4.1, 4.3, 4.5 y 4.7, para los racks 1 de los SBMS 1, 2, 3 y 4 respectivamente, que se han tomado como ejemplo. Es de suponer, que el comportamiento de los otros 8 SBMS es similar, ya que la operación sufrida por estos es la misma.

Esta variación se puede medir calculando los DSR para cada SBMS y racks en diferentes niveles de tensión (DSR[3,700-3,725], (DSR[3,725-3,750], (DSR[3,750-3,775] y por último el DSR[3,775-3,800]). Esto permite ver la tendencia creciente a lo largo de los 3 ciclos de carga con intensidades pseudo-constantes de los 4 racks analizados, tal como se muestra en la Tabla 4.1, y de la misma forma que se hizo en el Capítulo 2 con las baterías de laboratorio.

En esta tabla se aprecian los valores de varios DSR tomados en diferentes niveles de tensión, para 3 ciclos de carga realizados a lo largo de un año de tiempo y para el Rack1 de los SBMS 1, 2, 3 y 4. Estos valores de DSR muestran su incremento con el paso de los ciclos, sea cual fuere el nivel de tensión y SBMS donde se realice la medición.

Tabla 4.1. Cálculo de 4 DSR en los niveles de tensión [3,7-3,725], [3,725-3,75], [3,75-3,775] y [3,775-3,8] para 3 ciclos de carga y el rack 1 de los SBMS 1, 2, 3 y 4.

Nº SBMS	Nº Ciclo	DSR[3,700-3,725V] [mV/s]	DSR[3,725-3,750V] [mV/s]	DSR[3,750-3,775V] [mV/s]	DSR[3,775-3,800V] [mV/s]
1	C142	0,118366968	0,135736033	0,157078178	0,198217699
1	C863	0,119568226	0,138064968	0,172343167	0,201530316
1	C1308	0,125565899	0,143606976	0,174738558	0,211759439
2	C138	0,116732014	0,132875803	0,159112427	0,199845208
2	C871	0,12071212	0,138024941	0,163316397	0,203149665
2	C1305	0,126814793	0,140378701	0,174702896	0,211716223
3	C145	0,118332289	0,134962774	0,166454086	0,206348042
3	C859	0,124314701	0,143604913	0,172325895	0,209976931
3	C1307	0,127497337	0,147866735	0,17598224	0,209995615
4	C156	0,123668816	0,131479478	0,167658395	0,20146049
4	C873	0,123726129	0,138848213	0,168869447	0,210022506
4	C1296	0,132208763	0,139594727	0,172327285	0,219188211

Así, realizando las gráficas de tendencia de los 4 DSR para un SBMS (el BSM4 p.ej.), se aprecian las evoluciones crecientes de los cuatro, a lo largo de los ciclos (periodo que transcurre de diciembre del 2018 a junio de 2019). En la Fig. 4.12 se aprecian esas evoluciones frente a la tendencia de la degradación global del BESS, cuyo ajuste se realizó en el Capítulo 3.6 con los datos de los CT.




Fig. 4.12. Evolución de los 4 DSR [mV/s] vs. SOH para SBMS4 (Rack1).

Tal como sucedía en las baterías estudiadas de laboratorio, los DSRs calculados en este entorno de funcionamiento (intensidad de carga constante), marcan la tendencia de la degradación del BESS. También se puede apreciar que, conforme aumentamos el intervalo de tensión sobre el que calculamos el DSR, aumenta también el valor de este, como sucedía en las baterías de laboratorio.

Si se toma un DSR en un intervalo de tensión (p. ej. el de la Fig. 4.13) para cada uno de los racks número uno de los 4 SBMS, se puede comparar el envejecimiento producido en cada uno de ellos utilizando el DSR, tal como se muestra en las figuras 4.13 y 4.14. En estas se aprecia claramente el mayor deterioro del rack1 del SBMS4, ya que en ambas figuras es el de mayor valor.




Fig. 4.13. DSR[3,700-3,725] [mV/s] para el Rack 1 de los SBMS 1, 2, 3 y 4.




Fig. 4.14. DSR[3,775-3,800] [mV/s] para el Rack 1 de los SBMS 1, 2, 3 y 4.

Con esto se puede asegurar que, el comportamiento del indicador DSR en los racks del BESS cuando estos son cargados a corriente casi constante, es similar al obtenido con las baterías del Capítulo 2 de laboratorio. Esto constata la posibilidad de utilizar del indicador DSR en un BESS, tal como se explicó en el mencionado capítulo.

Así pues, en caso de disponer de sistemas BESS que operen en su mayoría del tiempo con intensidades de carga constantes, (en vehículos eléctricos, en parques solares, etc.), con el cálculo del indicador DSR en el intervalo de tensión seleccionado, tendremos un conocimiento relativo de cómo se deteriora este BESS, tal como se explicaba en el Capítulo 2.

En los apartados posteriores del presente capítulo se explicará la metodología a emplear cuando el BESS no opera con intensidades constantes a lo largo de sus ciclos de uso, para poder conocer el estado de su degradación.

4.4. Necesidad de adaptación del DSR al modo de operación del BESS.

4.4.1 Situación de partida.

Como se demostró en el Capítulo 2, para que el DSR tenga la sensibilidad adecuada para su uso en la estimación de la degradación de una LIB, es necesario acotar las condiciones de operación de la batería para intentar cumplir con el marco de trabajo exigido hasta ahora por el indicador. Este marco, como se demostró, implica el cumplimiento de alguna de estas situaciones:

- (1) Que la carga se realice a intensidad constante durante todo el intervalo CC y a lo largo de todos sus ciclos, o al menos de los ciclos de carga donde se necesita tomar las medidas de tensión necesarias para el cálculo del DSR.

- (2) Que la carga se realice a intensidad no constante, pero que haya intervalos de tensión, siempre los mismos, en los que la carga se realice con la misma intensidad. Es el caso estudiado en el Capítulo 2.5, donde la LIB se cargaba con intensidades no constantes, pero el indicador DSR era sensible cuando se filtraban los datos y se utilizaban sólo los de intensidades entre 15 y 17 A. Esto a lo largo de todos sus ciclos o al menos en los ciclos de carga donde se necesita tomar las medidas de tensión.
- (3) Cuando se tienen unas condiciones similares a las del punto anterior, y en lugar de filtrar los datos por las intensidades “adecuadas”, se utiliza el indicador DSRv. En este caso también ha de cumplirse la recurrencia de carga con el mismo perfil de intensidad (aunque esta pueda ser no cte.) en cada ciclo y para cada nivel de tensión. Este nuevo indicador DSRv amplió, su posible uso a más LIB de aplicación en la vida real, ya que flexibiliza su proceso de carga.

Llegados a este punto, el indicador DSRv, mejora su correlación con intensidades no constantes, pero su marco de trabajo está limitado también a una recurrencia de perfiles de intensidad de carga, donde se pretenda tomar las medidas del DSRv (en esos ciclos recurrentes), y en el mismo nivel de tensión. Esto hace que la variación de la intensidad de carga, a lo largo de los ciclos, no desvirtúe la sensibilidad de DSRv para con la degradación de la LIB.

Como se muestra en la Fig. 4.15, se pueden catalogar así, las cuatro formas de funcionamiento o marcos de trabajo del DSR, en función de si los ciclos de carga se realizan a intensidad cte. o no, y en función de la recurrencia de los ciclos de carga. Entendiendo por recurrencia en este caso, que los ciclos de carga se realicen siempre de la misma forma, es decir, con el mismo perfil de intensidad. En a Fig. 4.16 a) se muestra el perfil de intensidad de carga que se utilizó para el cálculo del DSR en el Capítulo 2, y en la b) el perfil de intensidad de la LIB BMR1 que se utilizó para el cálculo del DSRv.




Fig. 4.15. Marcos de trabajo de los DSR presentados.




Fig. 4.16 a). Perfil de intensidad de carga de la batería B0005. b) Perfil de intensidad de carga de la batería BMR1.

Como se aprecia para el caso b, la intensidad de carga no es constante, pero si el perfil de intensidad de los ciclos de carga.

4.4.2 Características del modo de operación del BESS

Como se expuso en el Capítulo 3, la finalidad del sistema BESS es participar en la regulación primaria de la red eléctrica donde se encuentra ubicada, necesaria para el buen funcionamiento de esta. Así pues, el objetivo es la corrección automática y casi instantánea (respuesta en menos de 1 segundo) de los desequilibrios de frecuencia marcados por el sistema.

Debido al tipo de operación, tal como se aprecia en la Fig. 4.17, las variaciones en la intensidad de carga y descarga son muy volátiles, impredecibles y no recurrentes en sus ciclos. Por ello, no es posible incluir la operación del BESS de la tesis en ninguna de las dos *áreas conocidas*, I o II, de la Fig. 4.15. Por lo que, pretender tomar medidas para los DSR en los ciclos de carga de los racks, es poco conveniente, dada la poca representatividad en el comportamiento que supondría.

Tampoco existen periodos de tiempo suficientemente largos, a priori, como para que se puedan tomar referencias de los DSR de un ciclo a otro, como se aprecia en la tendencia de la curva de intensidad y tensión frente al tiempo de la Fig. 4.17.




Fig. 4.17. Tensión e Intensidad para el Rack 2 del SBMS1.

De las tendencias de tensión e intensidad, se pueden aislar los datos para las intensidades positivas, con las que se realiza la operación de carga de las celdas, y ver la curva que quedaría, tal como se muestra en la Fig. 4.18.




Fig. 4.18. Tensión e intensidad del rack 2 del SBMS1 para intensidades positivas.

De este modo se trabajará con los procesos de carga, que son los que se utilizan para el cálculo del DSR y DSRv, según el procedimiento del Capítulo 2.

En la Fig. 4.19 se pueden apreciar, de igual forma, los procesos de descarga, al aislar la curva inicial con intensidades negativas. Así, se ha desglosado la curva inicial en dos independientes, una con los datos de carga y otra con los de descarga.




Fig. 4.19. Tensión e intensidad del rack 2 del SBMS1 para intensidades negativas.

Pero, debido a esa incertidumbre en la necesidad de la operación del BESS, mencionada anteriormente, y a esa necesidad en la capacidad de respuesta de 1 segundo, es necesario que haya que seleccionar, para el posible cálculo de los DSR, unos periodos de carga determinados, de manera que aseguremos que no se ha producido un micro periodo de descarga entre las cargas. Por ejemplo, de los datos mostrados en la Fig. 4.18, es necesario seleccionar aquellos que no tengan micro-descargas en los segmentos de curva seleccionados, asegurando así que su intensidad sea positiva durante una longitud determinada en dicho segmento.

En la Fig. 4.20 se puede ver un fragmento de como quedan los segmentos de carga elegidos, una vez filtrados los datos con los criterios anteriormente comentados. Así, por ejemplo, se puede apreciar que para un día (26-dic-19), existen varios segmentos de carga sobre los que se podrían calcular los DSR.




Fig. 4.20. Segmentos de tensión del Rack5 del SBMS9 para un periodo de 9 horas.

De igual forma, la Fig. 4.21 muestra los segmentos de tensión de carga que se pueden utilizar para el cálculo de los DSR para el Rack5 del SBMS9, a lo largo de ocho meses de tiempo.




Fig. 4.21. Segmentos de tensión del Rack5 del SBMS9 para un periodo de 8 meses.

Como se aprecia en la distribución de dichos segmentos de la Fig. 4.22, la mayor parte de ellos no tienen una duración mayor de 10 min, lo que impide tener un numero de muestras suficientes, a lo largo del segmento de tensión de carga en la mayoría de los casos, por lo que en estas condiciones es difícil aplicar el DSR y DSRv para que muestre la sensibilidad de la degradación.




Fig. 4.22. Distribución de la duración de los segmentos de carga.

Además, como se muestra en la Fig. 4.23, también las intensidades de carga para esos segmentos de tensión tienen una volatilidad muy grande, lo que hace que se distorsione mucho la sensibilidad del DSR y DSRv para mostrar la degradación de la batería.




Fig. 4.23. Intensidad de los segmentos de tensión de carga del Rack5 del SBMS9.

En resumen, podemos decir que la operación de este tipo de baterías hace muy difícil el uso del DSR y DSRv, tal como se emplearon para las baterías de carga constante y no constante, propuestos hasta ahora como indicadores de degradación de las LIB. Esto es debido a los tres motivos indicados, a continuación, que desvirtúan la sensibilidad de los dos indicadores:

1. Intensidad muy volátil, variable durante el segmento de tensión elegido.
2. Intensidad variable de unos ciclos a otros, dentro del mismo nivel de tensión. La intensidad de un nivel de tensión (DSR) de un ciclo dado, generalmente no es la del ciclo siguiente, ya que está promovida por la volatilidad de la operación. Así, p. ej., en el ciclo 3 se puede tener una intensidad fija de 2 A para el cálculo del DSR [3,7-3,8V], y para el ciclo 4 esta intensidad haber sido de 10 A.
3. Poca disponibilidad de segmentos de carga adecuados. Dificultad en la disposición de ciclos completos de carga, que vayan desde la tensión mínima hasta la máxima, disponiendo sólo de segmentos en intervalos aleatorios (en función de la operación del BESS), que imposibilitan, p.ej., medir el DSR[4,05-4,1V] en el siguiente periodo de carga, porque ese intervalo no sucederá hasta después de varios ciclos de descarga-carga, tal como se muestra en el ejemplo de la Fig. 4.24.




Fig. 4.24. Segmentos de tensión de carga del Rack5 del SBMS9.

En la Fig. 4.24 se aprecia como para un DSR en el entorno de 4,09 V sólo se dispone de 4 segmentos en el intervalo de un año de datos de operación, señalados con los puntos rojos discontinuos.

Estos tres problemas no se manifestaban en las baterías BMR1 y BMR2 del paquete de datos de la Universidad de Oxford, probadas con el indicador DSRv en el capítulo 2. Allí la mayor distribución de intensidad para el DSR[3,7-3,8V] estaba en torno a 16~18 A, como se muestra en la Figuras 2.20 y 2.21 respectivamente, y se disponían de ciclos completos de carga y descarga para el cálculo de todos los DSR necesarios.

Esto provoca la falta de datos para el cálculo de una tendencia de los indicadores DSR o DSRv, y también poca sensibilidad de los indicadores con la degradación, de los DSR que se puedan calcular.

4.5. Entorno propuesto para la evaluación de la condición de un BESS

Una vez planteados los problemas existentes para la obtención de los indicadores DSR o DSRv debido a la operación del BESS de la tesis, el reto a superar es la ampliación del entorno operativo expuesto en la Fig. 4.15, para así cubrir el área III, incluida entre la “intensidad NO cte.” y “Ciclos NO recurrentes”, tal como se muestra en la Fig. 4.25




Fig. 4.25. Marcos de funcionamiento del BESS de la tesis.

4.5.1 Necesidades de medición de las curvas de datos

Para realizar la ampliación de ese entorno de trabajo, se ha planteado el desarrollo de un nuevo indicador subyacente al DSR original, que sea *sensible* a la degradación de las LIB en este entorno y que sea medible en cualquier segmento de tensión, independientemente de con que intensidad se realice la carga del rack del BESS.

Para ello en primer lugar, es necesario “disminuir” o “eliminar” el impacto que tiene la intensidad en el DSR, cuando esta es variable de principio a fin del segmento de carga en el que se pretende medir el DSR.

Así, en la Fig. 4.26 se muestran los datos de 4 segmentos de tensión de carga almacenados en el sistema y el detalle de uno de ellos.




Fig. 4.26. Segmentos de tensión de carga extraídos.

Como se señaló, el DSR tiene una dependencia del tiempo ($t_2 - t_1$) que representa el incremento de tensión ($V_{4.1} - V_{4.0}$) que sufre una batería en el proceso de carga, durante el intervalo de tiempo que transcurre desde t_1 hasta t_2 , tal como se mostró en la ecuación 3 del Capítulo 2.

$$m = \frac{V_{4.1} - V_{4.0}}{t_2 - t_1}, \quad (3)$$

Así, si se toma la tensión cada segundo y calculamos el DSR durante ese intervalo temporal, se obtiene una curva con los DSR calculados cada segundo del proceso de carga.

En la Fig. 4.27 se muestran las curvas con los datos de tensión y la correspondiente intensidad, utilizada en dicho proceso de carga del rack. Estos datos son los almacenados (ptos. azules) e interpolados (línea roja discontinua) cada segundo, para el Rack1 del SBMS 1 correspondientes al segmento de tensión de carga, marcado en azul, de la Fig. 4.26.




Fig. 4.27. Segmentos de Tensión e Intensidad medidos e interpolados.

De esta forma se pueden calcular los DSR para dicho segmento de tensión, obtenidos en cada segundo de la carga, tal como muestra la Fig. 4.28.




Fig. 4.28. DSR secundales del segmento de carga.

En esta figura 4.28 se aprecia como, los cambios de intensidad influyen en la evolución de la curva de tensión de carga y, por ende, en los DSR. Esto hace muy difícil (por medio de métodos directos) obtener la sensibilidad que tiene el indicador DSR para estimar la degradación de la batería, demostrada en el Capítulo 2, por lo que esta sensibilidad del indicador calculado está por cuantificar.

4.6. Nuevo indicador DSRa adaptado a las necesidades de la operación del BESS

En la sección 4.5.1 anterior se ha explicado como calcular el indicador DSR para tener un valor en cada segundo, eliminando así la componente temporal, al ser esta en todo momento, un segundo. Por tanto, el indicador DSR sólo dependería del incremento de tensión medido en cada segundo de tiempo.

En las expresiones siguientes se comparan la nueva forma (7) de calcular el indicador con la manera inicial (8):

$$\text{DSR [3,7 V]} = \frac{\Delta V(1s)}{1s} \text{ [V/s]} \quad (7)$$

$$\text{DSR [3,7-3,8 V]} = \frac{3,8-3,7}{t_{(3,8v)} - t_{(3,7v)}} \text{ [V/s]} \quad (8)$$

Así, en la ecuación (7), el denominador pasa a ser constante (1s) y es el numerador el que marca el valor del indicador, siendo este el incremento de tensión ganado en el proceso de carga en ese segundo de tiempo, para cualquier intensidad de carga.

Al realizar el cálculo de los DSR siempre en este intervalo de tiempo (1 s), reducimos los efectos que pueda tener la diferencia de intensidad (ya comentada) entre el inicio y el fin del intervalo de tensión del DSR. De esta forma, por cada segmento de tensión de carga seleccionado (tal como se explicó en la sección anterior), tendremos tantos valores de DSR como tiempo en segundos dure dicho segmento de carga. El indicador ya no vendrá expresado con un intervalo de tensión, (3,7-3,8 V) p.ej., sino con la tensión medida en ese instante (ese segundo de tiempo) de la curva de carga.

En esencia, el indicador DSR no ha cambiado, simplemente se calcula haciendo coincidir su Δt , ($t_2 - t_1$) con 1 segundo. Es decir, si se dispusiera de las medias de tensión de carga con un muestreo igual a 1 segundo, el DSR tendría el valor del incremento de esa tensión de una muestra a otra.

En la *búsqueda de esa sensibilidad* de este DSR en el BESS de la tesis, por ejemplo, para los datos de las curvas de carga con las intensidades casi constantes (~100 A) de un segmento de carga para los cuatro periodos disponibles (17-dic-18, 8-mar-19, 15-mar.19 y 20-jun-19), se han calculado las *medias* de todos los DSR de cada segundo de tiempo a lo largo de esos cuatro segmentos de carga entre el DSR(3.68V) y el DSR(3.83V), para los 19 racks de los SBMS1 y SBMS2. Se ha tomado este intervalo porque se dispone de medidas para los 19 racks y los 2 SBMS.

Los resultados se muestran en las Figuras 4.29 y 4.30, donde se ve la evolución a lo largo de las cuatro muestras de estas medias de los DSR calculados. Al igual que en los DSR calculados entre intervalos de tensión para cada periodo, en este caso también evolucionan de forma creciente, y se puede comparar el comportamiento entre los diferentes racks de los SBMS.




Fig. 4.29. Evolución de las medias de los DSR para los 19 Racks del SBMS1.




Fig. 4.30. Evolución de las medias de los DSR para los 19 Racks del SBMS2.

Pero como se ha dicho, en este tipo de BESS es muy difícil que se opere con este tipo de intensidades casi constantes, por lo que se ha de buscar que el indicador sea sensible con la operación con todas las intensidades.

4.6.1 Desarrollo del indicador DSRa

Para ello se ha elaborado, de forma similar al del Capítulo 2, otro indicador subyacente que tiene en cuenta la intensidad de corriente de carga, para así reducir el efecto de distorsión que tiene dicha intensidad variable en la correlación entre el DSR y la degradación de las celdas. Este se ha denominado DSRa y se define como: el incremento de tensión obtenido cada segundo del proceso de carga, por unidad de corriente empleada en dicha carga en ese instante de tiempo (1 s).

$$\text{DSRa [3,7 V]} = \frac{\Delta V}{1(s) * I} [V/(s \cdot A)] \quad (9)$$

Las dos Figuras 4.31 y 4.32 muestran las distribuciones de tensión e intensidad respectivamente, de los 19 de racks del SBMS3, tomando como datos sólo los periodos de tiempo correspondientes a los meses: dic-18, jul-19 y jun-20.




Fig. 4.31. Distribución de las tensiones de los 19 racks de los periodos correspondientes a los meses de: dic-18, jul-19 y jun-20.




Fig. 4.32. Distribución de las intensidades de los 19 racks de los periodos correspondientes a los meses de: dic-18, jul-19 y jun-20.

Como se muestra en los histogramas, las distribuciones de tensión e intensidad de los 19 racks del SBMS3 (tomado de muestra como ejemplo) son homogéneas, siendo esto coherente con su igual uso (operación) que se da a los 19 racks, sometidos a la misma intensidad operativa y por tanto con niveles de tensión similares también. Si esto no fuera así, podría ser síntoma inequívoco de algún desequilibrio entre ellos.

4.6.2 Primer análisis de sensibilidad del DSRa

Una vez vista la homogénea distribución de las intensidades y tensiones entre los racks, en la Fig. 4.33, se muestra la evolución del indicador DSRa a lo largo de los tres periodos temporales mencionados, para los 19 racks. Dicho indicador ha sido elaborado calculando la media de todos los DSRa, obtenidos cada segundo, de los segmentos de carga elaborados para todos los ciclos de carga, de cada intervalo temporal (dic-18, jul-19 y jun-20), para los 19 Racks del SBMS3.




Fig. 4.33. Evolución de los DSRa en los intervalos temporales (dic-18, jul-19 y jun-20) para los 19 Racks del SBMS3.

El mismo resultado se ha obtenido (previa verificación de la homogeneidad de sus tensiones e intensidades en esos ciclos) para los 19 racks del SBMS1, tal como se aprecia en la Fig. 4.34.

Como se puede ver, de modo similar a lo que sucedía en la Fig. 4.29 con los DSR calculados con intensidades casi constantes (~ 100 A), el DSRa también incrementa su valor a lo largo de los 3 periodos de uso, siendo sensible a la degradación. En este caso la diferencia es que, el indicador ya no trabaja con intensidades constantes, sino variables y muy volátiles.




Fig. 4.34. Evolución de los DSRa en los intervalos temporales (dic-18, jul-19 y jun-20) para los 19 Racks del SBMS1.

Los 19 racks del SBMS4 tienen un comportamiento similar al de los otros SBMS mostrados anteriormente, tal como se presenta en la Fig. 4.35.




Fig. 4.35. Evolución de los DSRa en los intervalos temporales (dic-18, jul-19 y jun-20) para los 19 Racks del SBMS4.

No así el rack 17 del SBMS 2, que tal como se aprecia en la Fig. 4.36, el DSRa lo marca como un comportamiento claramente diferenciado del resto de los racks del SBMS2 y de igual manera, al compararlo con los racks número 17 de los otros SBMS en estudio. Este comportamiento diferenciado puede ser debido a un desequilibrio en este rack con respecto a los demás del mismo SBMS.




Fig. 4.36. Evolución de los DSRa en los intervalos temporales (dic-18, jul-19 y jun-20) para los 19 Racks del SBMS2.

Por ello, se observa que este nuevo indicador DSRa, que tiene en consideración la intensidad de carga, es sensible a la degradación, y además a un posible comportamiento anómalo que suceda como consecuencia de la operación del BESS.

Así, en la Fig. 4.37 se completa el marco operativo definido del DSR para su aplicación en un BESS.




Fig. 4.37. Marcos de funcionamiento de los 3 DSR desarrollados en la tesis.

4.7. Metodología DSR Multi-Model Machine Learning para la estimación de la degradación del BESS

Una vez definido el nuevo indicador DSRa, que se adapta mejor a las prestaciones requeridas para su utilización en la vida real de una batería, se ha procedido a utilizarlo para el seguimiento de la degradación, mediante el desarrollo de modelos basados en este indicador.

La metodología DSR Multi-Model Machine Learning (DSR-MMML), tiene como objetivo la estimación de la degradación de los BESS, operados con intensidad no constante y con ciclos no recurrentes. Para ello se utiliza el indicador DSRa y un procedimiento que, por medio de modelos ML, es capaz de cuantificar la degradación del BESS con tan solo dos datos operativos, y necesarios para su correcto funcionamiento, la tensión y la intensidad. Finalmente **se comparan los resultados obtenidos con los de un “Capacity Test” CT.**

4.7.1 Procedimiento

El procedimiento desarrollado en el DSR-MMML establece el uso de tres tipos de modelos diferentes: SVM, Ensemble y LR, utilizando los datos de operación del BESS del periodo jul-19. Se ha utilizado este periodo, como el inicial de base, ya que ese mes de julio se realizó un CT al BESS, y por tanto se toma como referencia.

En cuanto a los modelos elegidos, se ha pretendido utilizar ML, pero sin llegar a grandes y complejos modelos como los que se desarrollan con el uso de NN. Con ello se pretende dar más relevancia a la sensibilidad que tienen las entradas para con la degradación, que al propio modelo “*caja negra*” con el que se podría obtener buenos resultados simplemente utilizando los parámetros adecuados: entradas referidas a tiempos de funcionamiento, número de ciclos, etc., unido a un gran desarrollo empleado en estos modelos NN.

Así, se han realizado tres tipos de modelo, para dar mayor fiabilidad al proceso. Para ello se ha utilizado un modelo LR, para ver los resultados obtenidos mediante el uso de un modelo simple, y poder ver las relaciones lineales existentes entre las variables, DSRa.

En lo referente a los modelos SVM y ensemble, se han seleccionado estos dos modelos para cubrir las relaciones no lineales que puedan existir, y que el

LR no pueda. Así, realizando pruebas con diferentes modelos no lineales, se vio que los que obtenían mejores resultados, con los datos de entrenamiento, fueron el SVM y el ensemble. Las características e hiperparámetros se verán en los próximos apartados.

4.7.1.1 Conjunto de datos del BESS.

Los datos utilizados como ejemplo para mostrar el desarrollo de esta metodología son, en primer lugar, los del SBMS8, pero se presentarán también los datos del resto de SBMS utilizados en el apartado de resultados.

Sobre los datos completos del periodo jul-19 de los 19 racks del SBMS8, se han apartado algunos al azar (random) para su uso posterior al entrenamiento de los modelos, teniendo este grupo la consideración de *conjunto de datos de prueba, con 28 muestras*. El conjunto de datos original, excluyendo el *conjunto de datos de prueba*, es el llamado *conjunto de datos de entrenamiento*, que es el utilizado para el entrenamiento de los modelos expuestos, con 139 muestras.

En lo referente a los datos completos utilizados, en las figuras 4.38 y 4.39 se muestran las distribuciones de tensión e intensidad, respectivamente, de los 19 racks del SBMS8 utilizados para el cálculo de los 19 indicadores DSRa.

Los rangos de tensiones en todos los racks de este SBMS8 van de 3,3V a 3,9V, estando distribuidos homogéneamente. Al igual que se aprecia en las intensidades, que abarcan un rango entre 0 y 30 A y se distribuyen homogéneamente también los 19 racks.




Fig. 4.38. Distribución de tensiones de los 19 racks del SBMS8.




Fig. 4.39. Distribución de intensidades de los 19 racks del SBMS8.

En la Fig. 4.40 se muestran las distribuciones de los 19 indicadores, correspondientes a cada rack del SBMS8 utilizados para el desarrollo de los modelos mencionados anteriormente. Y en la Tabla 4.2 se visualizan sus medias y desviaciones estándar, donde se vuelve a apreciar la homogeneidad de las medias de los DSRa de todos los racks, estando en un rango entre 0,0166 y 0,0197 [mV/s*A]




Fig. 4.40. Distribución de los DSRa calculados de los 19 racks del SBMS8.

Tabla 4.2. Medias y desviaciones estándar de los DSRa del SBMS8

	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
Mean	0,0186	0,0180	0,0194	0,0196	0,0166	0,0186	0,0187	0,0177	0,0193	0,0190
SD	0,0089	0,0085	0,0078	0,0077	0,0071	0,0107	0,0108	0,0080	0,0140	0,0075
	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19	
Mean	0,0167	0,0187	0,0197	0,0197	0,0190	0,0193	0,0192	0,0197	0,0189	
SD	0,0076	0,0101	0,0092	0,0100	0,0093	0,0096	0,0104	0,0111	0,0083	

4.7.1.2 Modelos empleados.

Como se ha mencionado, se utilizan los modelos SVM, Ensemble y una regresión lineal simple (LR) como modelos empleados en el desarrollo de la metodología.

SVM (Aprendizaje con Soporte Vector).

Para cada tipo de modelo, p.ej. en este caso el SVM, se ha elaborado un conjunto de 19 modelos, uno para cada rack del SBMS seleccionado, utilizando los datos de un DSRa como salida, y como entradas del modelo los datos del resto de DSRa, tal como se aprecia en la Fig. 4.41. En esta se pueden observar las entradas del modelo, la salida (en función de las entradas elegidas), y los hiperparámetros relevantes del modelo SVM.




Fig. 4.41. Esquema e Hiperparámetros del modelo SVM.

Épsilon representa al parámetro que define el ancho de la banda alrededor de la línea de regresión ajustada, dentro de la cual, no se asigna ninguna penalización a los errores de predicción, es decir, se consideran aceptables y no contribuyen a la función de pérdida durante el entrenamiento del modelo. El valor de épsilon se elige normalmente a través de la validación cruzada o algún otro método de ajuste de hiperparámetros.

Los indicadores de error R^2 , del *conjunto de datos de entrenamiento*, se muestran en la Tabla 4.3. Como se puede comprobar, por norma general, con las variables de entrada de los modelos (indicadores DSRa con la distribución de la Fig. 4.40), se logra predecir con un alto nivel de ajuste, la salida de los racks determinados.

Tabla 4.3. Errores R^2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de entrenamiento.

SVM SBMS8	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R^2 [%]	0,92	0,94	0,84	0,92	0,89	0,93	0,65	0,92	0,82	0,89

SVM SBMS8	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R^2 [%]	0,88	0,93	0,90	0,97	0,93	0,90	0,91	0,93	0,83

El objetivo de los modelos planteados, variando las salidas y entradas con los datos de los DSRa, es vigilar el comportamiento de un rack frente a los otros, y de ahí deducir si hay uno, cuyo comportamiento evoluciona de forma diferente a los demás.

Para ello, se han elaborado los 19 modelos mencionados, que tienen como objetivo ver, qué racks mantienen un comportamiento esperado similar en el tiempo y cuáles no. Esto proporcionaría una idea de la evolución interna del SBMS.

Para el ejemplo, en primer lugar, se ha realizado el modelo Rack1 (variable a estimar el DSRa del rack1) con el conjunto de datos de entrenamiento. Como entradas, las variables DSRa, del rack 2 al rack 19, y como salida la variable DSRa del rack 1 a predecir. El modelo SVM Rack1 tiene un *Kernel de función Gausiana* de escala 4,2 con 31 vectores de soporte de las 139 muestras.

Los parámetros *Épsilon* y los vectores, se muestran en la Fig. 4.41 para cada uno de los modelos entrenados, desde el modelo Rack1 (teniendo como salida el DSRa del rack 1) al modelo Rack19 (teniendo como salida el DSRa del rack 19).

Con el modelo Rack1 realizado con los datos de entrenamiento, se ha calculado el error MAE y la desviación estándar (SD) del error (SD_MAE).

Una vez entrenado, se ha procedido a probar este modelo Rack1 con el *conjunto de datos de prueba* del mismo periodo citado, y se ha valorado su comportamiento.

Así, en la Fig. 4.42 se muestra:

- ✓ Una banda superior de color azul discontinuo, que marca la salida REAL más el termino $MAE + 2 \cdot SD_MAE$.

- ✓ Una banda inferior de color naranja discontinuo, que marca la salida REAL menos el termino $MAE + 2 \cdot SD_MAE$.
- ✓ La salida del valor estimado por el modelo, DSRa del Rck1. Producida al introducir en el modelo las 18 entradas restantes, de los DSRa del rack 2 al rack 19. Esta está marcada como línea roja continua.
- ✓ Por último, la señal real en negro continuo, DSRa del rack 1.




Fig. 4.42. Salida DSRa para el modelo SVM, para el Rack1 del SBMS8 con el conjunto de datos de prueba del periodo jul-19.

Las dos bandas discontinuas mencionadas de la Fig. 4.42 son dos bandas que representan los límites de confianza superior e inferior de la salida del modelo. Así, desde este punto de vista, los puntos estimados por el modelo que queden fuera de ellas, se tomarán como estimaciones erróneas.

Como medidas del posible desvío del modelo, se ha calculado el número de datos que caen por encima de la banda superior (azul) y por debajo de la inferior (naranja), como se muestra en la Fig. 4.43. Se puede apreciar el punto azul que marca el único valor correspondiente a, que la curva estimada del DSRa del modelo Rack1 está por debajo de la banda inferior de confianza marcada con línea naranja.

También se han elaborado los dos indicadores de error porcentuales, que medirán qué porcentaje de puntos de los valores estimados de la muestra, están por encima de la banda de confianza superior (línea azul) y cuantos están por debajo de la banda de confianza inferior (línea naranja), sobre el número total de valores (28 muestras).




Fig. 4.43. Error del modelo SVM para la salida DSRa del Rack1 del SBMS8 con datos del periodo jul-19.

Así, en el caso del ejemplo actual, correspondería a un valor (punto azul) sobre un total de 28 muestras estimadas por el modelo. Por tanto, el indicador de error inferior porcentual ELowV (%) será del 3,57 %, y el superior EUpV (%) del 0%.

Los indicadores de error R^2 , obtenidos con el *conjunto de datos de prueba*, se muestran en la Tabla 4.4. Como se puede comprobar también, los modelos estiman las salidas con datos nunca vistos, con un alto porcentaje de precisión, por lo que se logra predecir con un alto nivel de ajuste la salida de los racks determinados.

Tabla 4.4. Errores R^2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba.

SVM SBMS8	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R^2 [%]	0,85	0,98	0,86	0,85	0,9	0,78	0,71	0,89	0,83	0,89

SVM SBMS8	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R^2 [%]	0,68	0,91	0,85	0,9	0,78	0,69	0,78	0,66	0,86

Posteriormente se ha probado el comportamiento del modelo con los datos disponibles de los siguientes periodos del SBMS8: nov-19, dic-19, ene-20 y jul-20.

En la Fig. 4.44 se aprecia que, para el periodo siguiente (nov-19), el nivel de puntos de error aumenta con respecto al periodo con el que se entrenó el modelo (jul-19). Siendo el indicador de error inferior ELowV (%) = 9,4 % y el superior EUpV (%) = 8,4%.




Fig. 4.44. Error del modelo SVM para la salida DSRa del rack1 del SBMS8 con datos del periodo nov-19.

Para el periodo siguiente (dic-19) el indicador de error inferior es ELowV (%) = 8 % y el superior EUpV (%) = 7,2%.

Así, para el periodo jul-20, tenemos que el porcentaje de errores por debajo llega al 31,7 %, para este rack 1 del SBMS8. Este incremento del número de errores por debajo de la banda de confianza (línea naranja) se debe a que, con el tiempo, como se ha demostrado en esta tesis, el indicador DSR aumenta conforme aumenta la degradación.

Las bandas de confianza están formadas por los valores reales de los DSRa y los términos $\pm (MAE+2SD)$ dados por el modelo. Este ha sido entrenado con datos donde el indicador DSRa no sufre variación significativa, permaneciendo casi constante porque durante dicho periodo la degradación puede considerarse despreciable. Con el paso del tiempo, el DSRa real tiende a aumentar y el DSRa ajustado del modelo empieza a desviarse por la banda de abajo, por lo que el número de puntos por debajo de la muestra tiende a aumentar, al igual que el indicador de error ELowV (%), como muestran los valores de la Fig. 4.45 para los 19 racks del SBMS8.

En esta Fig. 4.45 se observa que, para todos los modelos, el nivel de error ELowV (%) ha aumentado considerablemente desde el periodo jul-19 al jul-20, por lo que es de prever que, las entradas DSRa estén marcando una degradación que los modelos no recogen con las entradas DSRa del periodo jul-19 con las que fueron entrenados.




Fig. 4.45. Evolución de los errores ELowV (%) a lo largo de los periodos elegidos para los 19 racks del SBMS8 para el modelo SVM.

Una variación de esta Fig. 4.45, más descriptiva, puede realizarse mostrando los valores normalizados de los porcentajes de error de cada periodo respecto al inicial, Fig.4.46. Esta normalización muestra los incrementos de ELowV (%) descontando los errores del periodo inicial, es decir, sólo tienen en cuenta los incrementos de ELowV (%).




Fig. 4.46. Evolución de los errores ELowV (%) normalizados a lo largo de los periodos elegidos, para los 19 racks del SBMS8 para el modelo SVM.

Estos errores ELowV(%) normalizados muestran valores más representativos, ya que parten del valor 0 como error de base para todos los racks, lo que permite la comparativa entre los racks del SBMS8.

Del mismo modo, el cálculo del MAE de las diferencias entre el valor REAL- $(MAE+2SD)$ y el estimado, tiende a aumentar también con el aumento de la degradación. Así, la Fig. 4.47 muestra los errores absolutos mencionados de los 19 modelos SVM (uno por rack) testeados con los datos de los periodos consecutivos, hasta jul-20.




Fig. 4.47. Evolución del MAE por debajo de la banda de confianza a lo largo de los periodos elegidos para los 19 racks del SBMS8 para el modelo SVM.

Los valores NaN (expresados en blanco) se producen cuando no hay ningún valor ajustado por debajo de la banda de confianza (naranja), lo que significa que no hay errores en el ajuste del modelo.

Además, si se realizan las acciones siguientes para los SBMS que forman el BESS:

- ✓ Extracción de datos de tensión e intensidad para los periodos jul-19, ene-20 y jul-20.
- ✓ Cálculo de los DSRa con las tensiones e intensidades de los segmentos de carga disponibles para los tres intervalos temporales citados.
- ✓ Creación de los modelos SVM con los hiperparámetros seleccionables (función del núcleo *Gaussiano* y escala 4,2).
- ✓ Cálculo de los indicadores ELowV (%) para las salidas de los 19 modelos SVM.
- ✓ Generar el grafico de calor con los valores de este indicador ELowV (%) normalizado.

Y se igualan las escalas del gráfico, podemos comparar comportamientos entre SBMS diferentes, tal como se muestra en la Fig. 4.48. En esta, se han

comparado los indicadores de errores ELowV (%) normalizados de 6 SBMS diferentes para ver su evolución temporal, realizados con los modelos SVM.

Los datos empleados para la realización de los modelos SVM para los SBMS 1, 3, 6 y 12, se encuentran en el Anexo I, y los parámetros y errores de los modelos, en el Anexo II.

Los gráficos comparativos sólo se han podido realizar para los SBMS 1, 2, 3 del Contenedor A y los SBMS 6, 8 y 12 del Contenedor B, ya que del resto de SBMS no se dispone de datos operativos que lo permitan.




Fig. 4.48. Evolución, a lo largo de los periodos ene-20 y jul-20, de los errores ELowV (%) normalizados del modelo SVM para los SBMS 1, 2, 3, 6, 8 y 12.

Estas graficas de calor, que muestran los errores porcentuales (ELowV(%)) normalizados de los puntos que se salen por debajo de la banda de confianza (naranja), pueden ser un indicador de la evolución final de cada SBMS del BESS. Así, cuanto más oscuras sean las celdas del periodo final en análisis (jul-20), mayor serán los porcentajes de errores del modelo y en principio mayor el grado de degradación del SBMS medido en ese intervalo temporal.

Estas graficas de calor, además, pueden poner el foco en los SBMS más degradados y guiar los planes de mantenimiento, para que las decisiones no se realicen por meras planificaciones, sino sustentadas en datos, tal como se determina en el Capítulo 5.

En este caso p.ej., según marcan los indicadores ELowV (%) normalizados del modelo SVM de la Fig. 4.48, es de prever que los SBMS menos degradados sean el SBMS1 y el SBMS3.

Ensemble (Modelo de conjunto).

Este tipo de modelo de aprendizaje automático combina las predicciones de múltiples modelos más pequeños, para mejorar la precisión y robustez de las predicciones. Para este tipo de modelo, también se ha elaborado un conjunto de 19 modelos, uno para cada rack del SBMS seleccionado, utilizando los datos de un DSRa como salida, y como entradas del modelo los datos del resto de DSRa, tal como se aprecia en la Fig. 4.49.

Al igual que en modelo SVM, en esta Fig. 4.49 también se observan las entradas del modelo, la salida (en función de las entradas elegidas) y los hiperparámetros relevantes.




Fig. 4.49. Esquema e Hiperparámetros del modelo Ensemble.

El método del modelo *ensemble* es el LSBoot (Least Squares Boosting), lo que significa que minimiza una función de pérdida cuadrática, lo que lo hace particularmente adecuado para problemas de regresión.

Los indicadores de error R^2 , obtenidos con el conjunto de *datos de entrenamiento*, se muestran en la Tabla 4.5. En este caso también, con las variables de entrada de los modelos, se logra predecir con un alto nivel de ajuste, la salida de los racks determinados.

Tabla 4.5. Errores R^2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de entrenamiento.

Ensemble SBMS8	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,95	0,97	0,97	0,96	0,97	0,97	0,93	0,97	0,97	0,97

Ensemble SBMS8	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,95	0,98	0,98	0,96	0,97	0,98	0,97	0,93	0,96

De forma similar a como se procedió con el modelo SVM, una vez entrenado el modelo ensemble, se ha procedido a probarlo con el *conjunto de datos de prueba* del mismo periodo (jul-19), y se ha valorado su comportamiento con los mismos argumentos e indicadores de error propuestos para el modelo SVM.

Así, en la Fig. 4.50 se puede apreciar el punto azul, que marca el único valor que sale de las bandas de confianza, correspondiente a que, la curva estimada del DSRa del Rack1, está por debajo de la banda inferior de confianza marcada con línea naranja.




Fig. 4.50. Error del modelo ensemble para la salida DSRa del Rack1 del SBMS8 con datos del periodo jul-19.

También se han elaborado los indicadores de error porcentuales ELowV (%) y EUpV (%), que en el caso del ejemplo de la Fig. 4.50, correspondería a un valor (punto azul) sobre un total de 28 muestras estimadas por el modelo. Por tanto, el indicador de error inferior ELowV (%) será del 3,57 %, y el superior EUpV (%) del 0%.

Los indicadores de error R^2 , obtenidos con el *conjunto de datos de prueba*, se muestran igualmente en la Tabla 4.6. También se comprueba que los modelos estiman las salidas, con datos nunca vistos, con un alto porcentaje de precisión.

Tabla 4.6. Tabla con los errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba.

Ensemble SBMS8	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R^2 [%]	0,94	0,96	0,97	0,96	0,96	0,97	0,92	0,97	0,96	0,96

Ensemble SBMS8	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R^2 [%]	0,94	0,98	0,97	0,95	0,97	0,97	0,97	0,93	0,96

Tal como requiere la metodología, se prueba el comportamiento del modelo con los datos de los siguientes periodos del SBMS8: nov-19, dic-19, ene-20 y jul-20.




Fig. 4.51. Error del modelo ensemble para la salida DSRa del rack1 del SBMS8 con datos del periodo nov-19.

En la Fig. 4.51 se aprecia que, para el periodo siguiente (nov-19), el nivel de puntos de error aumenta con respecto al periodo con el que se entrenó el modelo (jul-19). Siendo el indicador de error inferior ELowV (%) = 13,3 % y el superior EUpV (%) = 4,6%. Para el periodo siguiente (dic-19), el indicador de error inferior es ELowV (%) = 12,8 % y el superior EUpV (%) = 5%. Y para jul-20, ELowV (%) = 34,4 %, para este rack 1 del SBMS8.

Los valores con los 4 periodos del *conjunto de datos de prueba* para los 19 racks del SBMS8 se muestran en la Fig. 4.52.




Fig. 4.52. Evolución de los errores ELowV (%) a lo largo de los periodos elegidos para los 19 racks del SBMS8 para el modelo ensemble.

También se observa que para todos los modelos (del Rack1 al Rack19), el nivel de error ELowV (%) ha aumentado considerablemente desde el periodo jul-19 a jul-20, por lo que su degradación, es de prever, que siga un camino similar.

La misma conclusión se obtiene con los errores ELowV (%) normalizados, mostrados en la Fig. 4.53.




Fig. 4.53. Evolución de los errores ELowV (%) normalizados a lo largo de los periodos elegidos para los 19 racks del SBMS8 del modelo ensemble.

Del mismo modo, en la Fig. 4.54 se muestran los errores absolutos MAE de los 19 modelos ensemble (uno por rack), testeados con los datos de los periodos consecutivos, hasta jul-20.




Fig. 4.54. Evolución del MAE por debajo de la banda de confianza a lo largo de los periodos elegidos, para los 19 racks del SBMS8 de los modelos ensemble.

El ejercicio realizado para la generalización al resto de SBMS del modelo SVM, es necesario realizarlo con el modelo ensemble, para cumplir así con la

metodología establecida. Los datos empleados para la realización de los modelos para los SBMS 1, 3, 6 y 12 se encuentran en el Anexo I, y los parámetros y errores de los modelos, en el Anexo II.

Al igual que se mostró en la Fig. 4.53 para el SBMS8, se puede visualizar la evolución de los errores porcentuales normalizados (ELowV (%)) del modelo tipo *Ensemble*, para todos los SBMS de los que se dispone de datos en los periodos sucesivos (ene-20 y jul-20).




Fig. 4.55. Evolución de los indicadores ELow (%) normalizados para los 6 SBMS (1, 2, 3, 6, 8 y 12) elaborados con un modelo ensemble, para los periodos ene-20 y jul-20.

En este caso, también, los indicadores ELow (%) normalizados de los 6 SBMS de la Fig. 4.55, nos marcan que los SBMS 1 y 3 son los que menos degradación han sufrido, lo que ya va haciendo previsible, que esto es realmente así.

Regresión lineal múltiple (Modelo LR).

El modelo de regresión lineal es un método estadístico que permite estudiar la relación entre dos o más variables. En este caso es un modelo de regresión lineal multivariable, o regresión lineal múltiple, ya que calcula la relación entre 18 variables independientes (entradas) y una variable dependiente (salida), ajustando una ecuación de regresión lineal entre ellas.

Se ha empleado este tipo de modelo dentro de la metodología, ya que, como se mencionó, no se necesita el uso de modelos complejos para estimar la degradación de un BESS, tan solo con el uso de las DSRa y su sensibilidad, se obtienen resultados precisos.

Así, consta en esta sección, que con el uso de un simple modelo lineal se obtienen resultados similares a los obtenidos con los modelos anteriores, que pueden modelar relaciones no lineales.

Para el tipo LR, también se ha elaborado un conjunto de 19 modelos (uno por cada rack del SBMS seleccionado), en el que se ha tomado como salida, los datos de un DSRa y como entradas, los datos del resto de DSRa. Así se muestra en la Fig. 4.56.

Al igual que en los modelos SVM y ensemble, en esta Fig. también se observan las entradas del modelo, la salida (en función de las entradas elegidas) tal como se ha dicho, y los hiperparámetros relevantes, como los 19 coeficientes de las ecuaciones de regresión.




Fig. 4.56. Esquema e Hiperparametros del modelo LR.

Entradas	Coefficientes	Salida Rack1	Salida Rack12	Salida Rack13	Salida Rack14	Salida Rack15	Salida Rack16	Salida Rack17	Salida Rack18	Salida Rack19
DSRa de Rack11	p11	0	-0,039597397	-0,047525543	-0,073898575	0,113114506	0,171068619	0,415078218	0,067584057	-0,271084319
DSRa de Rack12	p12	0,107908185	0	0,193113902	0,089313807	0,088923586	0,043998521	0,038441155	-0,283635197	0,403960199
DSRa de Rack13	p13	-0,080309432	0,345912097	0	0,196659602	0,289877508	0,132719512	0,670330121	-0,415452499	-0,220085631
DSRa de Rack14	p14	-0,046261626	0,410738784	0,351486009	0	-0,163484683	-0,19312594	-0,6263555	0,54729525	0,149447765
DSRa de Rack15	p15	0,625890353	0,155995869	-0,023677749	0,091959664	0	0,421144425	-0,294596363	0,626810208	-0,16458787
DSRa de Rack16	p16	-0,090594779	0,01000533	0,184351182	-0,035439388	0,198596606	0	0,031191364	0,053953261	0,415223414
DSRa de Rack17	p17	0,800175068	-0,031697865	-0,076631515	-0,064322695	-0,12798288	0,0825213	0	0,2346244	-0,035498942
DSRa de Rack18	p18	0,195234019	-0,046235744	-0,075667535	0,149880134	0,727387001	0,10743446	0,414586885	0	0,394527065
DSRa de Rack19	p19	0,001833826	0,001949187	-0,223137269	-0,111847051	-0,03130266	0,333130587	0,1284913	0,091472581	0

Fig. 4.56. Esquema e Hiperparámetros del modelo LR. (Continuación)

La ecuación de regresión del modelo atiende a la expresión:

$$Y1 = \beta_0 + \beta_1 X1 + \beta_2 X2 + \beta_3 X3 + \dots + \beta_{n-1} X(n-1) + \beta_n Xn + \epsilon \quad (10)$$

Donde:

Y1, es la salida estimada en función de las entradas (X1 Xn).

β_0 , corresponde al termino cte. (Intercept)

$\beta_1 \dots \beta_n$, son los coeficientes del modelo (p1 a p19 de la Tabla 4.56)

X1 ... Xn, corresponden a las entradas del modelo.

ϵ , es el error del modelo.

Así, para el modelo con salida Rack1 sería, p.ej.:

$$\text{DSRa_Rack1(est.)} = \text{cte. (Intercept)} + p2 * \text{DSRa_Rack2} + p3 * \text{DSRa_Rack3} + \dots + p19 * \text{DSRa_Rack19} \quad (11)$$

Donde:

DSRa_Rack1(est.) es la salida estimada por la LR, siendo las entradas del modelo el DSRa2 hasta el DSRa19.

Los indicadores de error R^2 , obtenidos con el conjunto de *datos de entrenamiento* se muestran en la Tabla 4.7. En este caso también, con las variables de entrada de los modelos, se logra predecir con un alto nivel de ajuste la salida de los racks de cada caso.

Tabla 4.7. Errores R^2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de entrenamiento.

LR SBMS8	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R^2 [%]	0,96	0,94	0,82	0,90	0,91	0,87	0,82	0,94	0,96	0,92

LR SBMS8	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R^2 [%]	0,85	0,93	0,95	0,96	0,92	0,88	0,94	0,96	0,81

Al igual que con los modelos anteriores, con el modelo LR una vez entrenado, se ha procedido a probarlo con el *conjunto de datos de prueba* del mismo periodo citado, y se ha evaluado su comportamiento con los mismos argumentos e indicadores de error propuestos: ELowV (%), en su modo absoluto y normalizado, y MAE.

En la Fig. 4.57 se puede apreciar el punto azul, que marca el único valor también, que sale de las bandas de confianza, correspondiente a que la curva estimada del DSRa del modelo Rack1, está por debajo de la banda inferior de confianza marcada con línea naranja.

Por tanto, el indicador de error inferior ELowV (%) será del 3,57 %, y el superior EUpVa (%) del 0%, de la misma forma que con los modelos anteriores.




Fig. 4.57. Error del modelo ensemble para la salida DSRa del Rck1 del SBMS8, con datos del periodo jul-19.

Los indicadores de error R^2 , obtenidos con el *conjunto de datos de prueba* se muestran en la Tabla 4.8. También se comprueba que los modelos estiman las salidas, con datos nunca vistos, con un alto porcentaje de precisión en general.

Tabla 4.8. Tabla con los errores R2 de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba.

LR SBMS8	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R^2 [%]	0,93	0,81	0,80	0,84	0,70	0,80	0,54	0,89	0,94	0,56

LR SBMS8	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R^2 [%]	0,70	0,75	0,73	0,93	0,88	0,87	0,88	0,93	0,74

Del mismo modo, se prueba el comportamiento del modelo LR con los datos de los siguientes periodos del SBMS8: nov-19, dic-19, ene-20 y jul-20.




Fig. 4.58. Error del modelo LR para la salida DSRa del rack1 del SBMS8, con datos del periodo nov-19.

En la Fig. 4.58 se aprecia el mismo comportamiento dado, que para los dos modelos anteriores en el periodo nov-19, siendo el indicador de error inferior ELowV (%) = 13,3 % y el superior EUpV (%) = 4,6%.

Para el periodo siguiente (dic-19), el indicador de error inferior es ELowV (%) = 12,8 % y el superior EUpV (%) = 5%. Y para jul-20, ELowV (%) = 34,4 %, para este rack 1 del SBMS8.

Los valores con los 4 periodos del *conjunto de datos de prueba*, para los 19 racks del SBMS8 se muestran en la Fig. 4.59.




Fig. 4.59. Evolución de los errores ELowV (%) a lo largo de los periodos elegidos, para los 19 racks del SBMS8 para el modelo LR.

Para el tipo LR, se observa que para todos los modelos (del Rack1 al Rack19), a excepción del modelo Rack2, modelo Rack7 y modelo Rack9, el nivel de error ELowV (%) aumenta también considerablemente desde el periodo jul-19 al jul-20, por lo que su degradación es de prever que siga un camino similar.

A la misma conclusión se llega con los errores ELowV (%) normalizados, mostrados en la Fig. 4.60.




Fig. 4.60. Evolución de los errores ELowV (%) normalizados, para los periodos elegidos, para los 19 racks del SBMS8 del modelo LR.

En la Fig. 4.61 se muestran los errores absolutos MAE, de los 19 modelos LR, testeados con los datos de los periodos consecutivos, hasta jul-20. En el caso de este indicador, los modelos Rack2 y Rack7, sí van en consonancia con el resto.




Fig. 4.61. Evolución del MAE por debajo de la banda de confianza, a lo largo de los periodos elegidos, para los 19 racks del SBMS8 de los modelos LR.

Los valores NaN (expresados en blanco) se producen cuando no hay ningún valor ajustado por debajo de la banda de confianza (naranja) lo que significa que no hay errores en el ajuste del modelo.

Al igual que con los modelos SVM y ensemble, la Fig. 4.62 muestra los resultados obtenidos para los SBMS, que tienen los datos operativos necesarios para la realización de los modelos LR, y su posterior obtención de los indicadores ELowV (%) normalizados.




Fig. 4.62. Evolución a lo largo de los periodos ene-20 y jul-20, de los errores ELowV (%) normalizados del modelo LR para los SBMS 1, 2, 3, 6, 8 y 12.

Los datos empleados para la realización de los modelos para los SBMS 1, 3, 6 y 12 se encuentran en el Anexo I, y los parámetros y errores de los modelos, en el Anexo II.

Para finalizar, la previsión de los modelos LR también nos indican (al menos visualmente), que el SBMS1 y SBMS3 han sufrido una menor degradación que el resto.

Una vez explicados los 3 modelos que forman parte de la metodología a aplicar, para la estimación de la degradación de un BESS, se puede asegurar que esta metodología (a priori), permite comparar el comportamiento de la evolución temporal real, con respecto al comportamiento esperado que tienen los racks de un SBMS entre sí. Además, si esta metodología se aplica a los diferentes SBMS del BESS, nos puede dar también una comparativa del estado de cada uno de los SBMS.

4.7.2 Resultados y comparativa con la medida real de la capacidad del BESS

A partir de los resultados de los tres modelos, es posible observar que los dos SBMS menos degradados son el 1 y 3. Tomando las medidas del CT realizado durante el mes de julio de 2020, se verifica que los SBMS con menor degradación son el SBMS1 y el SBMS3 con 1.170 kWh y 1.165 kWh respectivamente.

De igual forma, los tres modelos marcan que los tres SBMS con mayor deterioro serían el SBMS2, el SBMS6 y el SBMS8, conforme a los gráficos de calor.

Además, se ha realizado *un ejercicio* para establecer una medida *cuantitativa* de la degradación comparativa entre los SBMS estudiados. Para ello, se han tomado los valores de los indicadores ELowV (%) normalizados de cada SBMS en el periodo jul-20, y para cada uno de los tres modelos utilizados (SVM, ensemble y LR). Con estos valores se han calculado sus medias aritméticas (TOTALES), previa normalización, de 0 a 100, de los errores para cada tipo de modelo: SVM, LR y Ensemble. Los resultados se muestran en la Tabla 4.9.

Con este ejercicio de medida *cuantitativa*, se puede corroborar lo que ya se percibía con los resultados de los tres modelos: SVM, ensemble y LR, cuando los gráficos de calor daban como SBMS con menor degradación el SBMS1 y SBMS3. Ahora, tal como se ve numéricamente en la Tabla 4.9, los datos numéricos de cada modelo y los de la columna "Totales", verifican lo percibido anteriormente.

Tabla 4.9. Indicadores normalizados ELowV (%) para los 3 tipos de modelos (Ensemble, LR, SVM)

N.º SBMS	M. Ensemble	M. LR	M. SVM	TOTALES
1	47,6	22,2	3,5	24
2	100	85,9	45,3	77
3	37,1	27,3	10,4	25
6	80,1	100	80,4	87
8	77,3	87,3	100	88
12	46,2	58,3	44,4	50

De la misma forma se puede comprobar que, los tres SBMS más degradados, que marcaban también los *gráficos de calor visualmente*, son el SBMS2, el SBMS6 y el SBMS8.

Como los gráficos de calor no llegan a poder diferenciar los niveles exactos, si permite hacerlo el uso de los indicadores ELowV (%) numéricos, que obtienen una *medida cuantitativa* que se puede comparar. Hay que excluir el SBMS12, cuyos resultados no convergen con los de su capacidad medida.

Comparando los valores de la columna “Totales”, obtenidos de las medias de los indicadores ELowV (%) de cada modelo, con los valores reales medidos en el CT del Capítulo 3.6, se ha realizado la Tabla 4.10.

Esta tabla comparativa, ratifica los resultados obtenidos en la metodología DSRM-MML, marcando el orden de los SBMS en cuanto a su nivel de degradación. Siendo los SBMS más degradados el octavo y el sexto con 1.090 y 1.140 kWh respectivamente, lo que coincide con los datos cuantificados por la metodología.

Tabla 4.10. Medias del indicador ELowV (%) normalizado vs. las capacidades medidas de los SBMS.

N.º SBMS	TOTALES	Capacidad Medida (kWh)
1	24	1.170
3	25	1.165
2	77	1.150
6	87	1.140
8	88	1.090

4.8. Puntos destacados del capítulo

En este Capítulo 4 se ha avanzado en la consecución de los objetivos de la tesis, en este caso en **determinar la degradación de un sistema BESS conectado a la red** eléctrica para la regulación de frecuencia. Para ello, **se han realizado los siguientes trabajos**:

- ✓ En primer lugar, se ha aplicado el indicador DSR elaborado en el Capítulo 2 al BESS, mediante la selección de los datos disponibles de operación que cumplen los requisitos establecidos en el entorno de trabajo del DSR para su uso. Se ha **demostrado** así, que el **indicador DSR tiene utilidad** cuando el **BESS opera con**

intensidades de carga semi-constantes, permitiendo **evaluar** de una manera rápida, **la tendencia de la degradación de los SBMS** del BESS.

- ✓ Se han **establecido las restricciones del DSR, para su uso en el BESS** de la tesis, debido a las características de operación establecidas en su proceso de carga. Estas son las tres restricciones principales:
 1. Intensidad de **operación del BESS muy volátil** e impredecible.
 2. Intensidad **variable** de unos ciclos de carga a otros, **dentro del mismo nivel de tensión**.
 3. **Poca disponibilidad de los segmentos de carga adecuados**, que dificulta la disposición de ciclos completos de carga que vayan desde la tensión mínima hasta la máxima.
- ✓ Se ha **realizado una propuesta** para mitigar las restricciones planteadas anteriormente:
 1. **Ampliar el entorno de operación del indicador DSR** para cubrir las necesidades operativas, intensidad de carga variable y ciclos no recurrentes, del BESS de la tesis.
 2. **Desarrollo de un nuevo HI** adaptado a la volatilidad de operación.
- ✓ Se ha desarrollado un nuevo indicador DSRa, que trabaja en entornos de intensidad variable y ciclos no recurrentes. Esto permite su uso en un entorno de operación volátil.
- ✓ Finalmente, se ha elaborado una **metodología conjunta, llamada DSRM-MML**, que cubre las necesidades planteadas, mediante el **uso del indicador DSRa** y una **técnica de predicción**. Para llevar a cabo **la metodología de identificación del estado de degradación de un BESS** ha sido necesaria la realización de los siguientes puntos:
 1. Se ha elaborado un **nuevo indicador DSRa** que trabaja en el entorno de operación demandado por el BESS, **con intensidades NO constantes y ciclos no recurrentes**.
 2. Se ha utilizado la **técnica de predicción “One-to-All”**, creando modelos ML capaces de identificar, si un rack se comporta de manera distinta a otro, dado que este comportamiento

debería ser similar, **permitiendo así detectar anomalías de degradación.**

3. Como entradas de los 19 modelos creados (uno por cada rack) se han utilizado 18 de los 19 DSRa y como salida, el DSRa que no forma parte de las entradas de dicho modelo.
4. Esta técnica además permite el **uso de 3 tipos diferentes de modelos ML**. En este caso se han utilizado modelos **SVM, ensemble y LR**. Por ello ha sido necesario crear 57 modelos diferentes, por cada uno de los 6 SBMS del BESS. Los resultados de esos modelos han mostrado su utilidad para detectar anomalías de degradación, mediante el **desarrollo de unos indicadores de error** de salida de bandas (**ELowV (%)**), pudiendo identificar de manera fácil, y en la operación de los racks, si unos se comportan de forma distinta a otros.
5. **La utilización de los indicadores** de error ELowV (%), generados por cada uno de los tres tipos de modelos, **posibilita la cuantificación de la degradación** de los racks de los SBMS que forman el BESS.
6. Por último, se han **comparado los resultados** obtenidos mediante la aplicación de esta metodología, **con los obtenidos del CT del Capítulo 3.6**. Los resultados nos llevan a pensar que, de manera cuantitativa, la metodología empleada es capaz de catalogar, de forma adecuada, los niveles de degradación de los SBMS que forman el BESS y poner el foco en los que tienen mayor necesidad de un proceso de mantenimiento correctivo.

Como **conclusión**, la aplicación de **esta metodología permite** detectar comportamientos de rack con problemas dentro de cada uno de los SBMS, y mediante el uso de los indicadores ELowV (%), **estimar de forma cuantitativa la degradación** de los racks y SBMS que forman el BESS, **con tan sólo las señales de tensión e intensidad** de operación del BESS.

Esto hace posible cumplir con los retos planteados por (Fioravanti *et al.*, 2020), quienes consideran que los sistemas de mantenimiento predictivo son complejos de implementar en un BESS y generalmente es necesario realizarlos en la fase de diseño. Así, **en este capítulo se ha planteado una metodología capaz de implantarse en cualquier BESS una vez puesto en operación**, sin necesidad de planificarlo en la fase de diseño.

El otro de los grandes problemas planteado en el estado del arte, también se soluciona con esta metodología, ya que **en ningún momento hay que**

interrumpir (ni total ni parcialmente) **la operación, ni la disponibilidad del BESS, para poder estimar su degradación**, ya que esta se elabora a partir de sólo dos señales, la tensión y la intensidad de funcionamiento en el proceso de carga del rack, medidas estas por su BMS.

El uso de **esta metodología posibilita una mayor eficiencia en el mantenimiento** de los BESS, al conocer en todo momento el estado de salud de los SBMS que lo forman sin alterar la operación, focalizando los recursos sólo donde son necesarios, y por tanto, el ahorro de costes, tal como plantean (Fioravanti *et al.*, 2020) y como se verá en el Capítulo 5.

Capítulo 5

Mantenimiento aplicado a un BESS por medio de la metodología desarrollada

Estructura de la tesis: **Capítulo 5**

Introducción y Estado del Arte

Identificación de un nuevo indicador de salud (DSR)

Arquitectura y características del BESS en estudio

Aplicación del nuevo DSR en un BESS

operando en regulación de frecuencia

• **Mantenimiento aplicado a un BESS por medio de la metodología desarrollada** •

Conclusiones, contribuciones y futuros desarrollos

- En este capítulo se presentan cuatro ejemplos de planes de mantenimiento preventivo elaborados por cuatro empresas del sector de los BESS y la elaboración de una “Especificación técnica para la operación y mantenimiento del BESS”.
- Posteriormente se exponen las dificultades para el uso de la supervisión predictiva en un BESS: alto volumen de datos, dificultad en la identificación de indicadores, hardware limitado y BMS no diseñados para reconocimiento de fallos.
- Para terminar, se enumeran los beneficios obtenidos por el uso de la metodología DSRM-MML:
 1. Mejorará la disponibilidad y el conocimiento del estado del BESS.

2. Reducción de: indicadores para los modelos predictivos, de los costes de monitorización, de sensores, de las comunicaciones y de los sistemas de procesamiento.
3. Esta metodología puede instalarse en cualquier BESS ya en operación.

5.1. Motivación

En este capítulo, a través del estado del arte, se plantean los problemas actuales que existen en el mantenimiento de un BESS, debidos principalmente, a la complejidad eléctrica y dimensiones de estos sistemas. También se exponen las recomendaciones vigentes (en el estado del arte) en lo referente a la manera de plantear y llevar a cabo dicho mantenimiento.

Así, se muestran cuatro ejemplos de planes de mantenimiento preventivo, realizados en la vida real en lo referente a sus *dispositivos* de almacenamiento de energía (celdas, módulos, racks), que forman parte del BESS y sobre los que se han planteado posibles mejoras, por la utilización de la metodología desarrollada en el Capítulo 4.

5.2. Introducción

El mantenimiento industrial se puede definir como, el conjunto de actividades técnicas que se realizan para conservar o restaurar las condiciones operativas, de los equipos y maquinarias en la industria. Su finalidad es prevenir y solucionar problemas, averías o fallos que puedan afectar la producción, la seguridad y la vida útil de los elementos industriales.

La necesidad del mantenimiento se produce para minimizar el proceso de fallo real o inminente en los equipos, haciendo que estos continúen funcionando eficazmente durante su vida útil, establecida en el diseño.

Existen diferentes tipos de mantenimiento: correctivo, preventivo y predictivo:

- El mantenimiento correctivo se realiza cuando el elemento en cuestión ha dejado de funcionar en las condiciones para las que fue diseñado, y por tanto ha de repararse o sustituirse.
- Para paliar o evitar que este fallo se produzca recurrentemente en los equipos, ha de complementarse con un mantenimiento preventivo. (Medrano Márquez, González Ajuech and de León Santiago, 2017)

- El mantenimiento preventivo consiste en realizar las acciones para evitar o mitigar la degradación del componente, equipo o sistema, con el objeto de prolongar su vida útil, según un programa basado en el tiempo o el funcionamiento del equipo. (Mora, 2009)
- Este se realiza según un *plan de mantenimiento* recurrente (semanal, mensual, anual, etc.) basado generalmente en los recursos disponibles y necesarios a destinar para ello. La necesidad se determina por las estadísticas de vida media o prevista de cada equipo, perteneciente al sistema a mantener.
- Los mantenimientos correctivo y preventivo son dos conceptos muy asentados ya en la industria.
- El mantenimiento predictivo es aquel que se realiza en el momento de ser necesario, en función del estado “de salud” real del equipo. Es un mantenimiento basado en la condición. Para que esto pueda llevarse a cabo, se deben realizar mediciones que detecten el inicio de la degradación o deterioro. Para ello, se debe realizar un seguimiento de los equipos, con la intención de detectar cambios en los patrones de funcionamiento que puedan ser indicativos de un fallo inminente, estimando la predicción de este con la antelación suficiente para realizar el mantenimiento oportuno, y evitar así el fallo total.
- El mantenimiento predictivo basa sus actividades de conservación de los elementos en función de su estado real, y no de un programa preestablecido (mantenimiento preventivo) o de un fallo total que se haya ocasionado (mantenimiento correctivo). (Palencia, 2011)

Con ello obtenemos dos beneficios principalmente con respecto al mantenimiento preventivo y correctivo:

- (1) El aumento de la disponibilidad del sistema y tiempos de operación, ya que sólo se realizan trabajos de mantenimiento cuando son necesarios. Esto repercute en mayores ingresos por dicha operación.
- (2) La disminución de los costes de equipos y mano de obra. Al sustituir sólo los componentes deteriorados, se produce un ahorro en los costes de reparación, con una *garantía de deterioro* que será tan probable como lo es el *proceso predictivo empleado*.

5.3. Programas de mantenimiento actuales empleados en los BESS

Una de las dificultades a la hora de mantener un sistema BESS es la diversidad empresarial de los sistemas que lo forman, es decir, la multitud de procedencias en cuanto a fabricantes de los componentes que lo forman. Esto hace que la gestión en la reparación o sustitución de los elementos dañados sea más compleja, al entrar muchos implicados en el proceso, y ante algún problema detectado en el sistema, sea difícil a veces encontrar la responsabilidad, más que el elemento dañado.

Por ello la realización de un plan de mantenimiento preventivo, donde se establezcan las tareas específicas para la correcta conservación de los componentes, toma mucha importancia y a la par complejidad, al tener que integrar los manuales de mantenimiento realizados por todos los proveedores de equipos de los diferentes fabricantes. Así, en función de los requisitos que cada uno de estos fabricantes haya manifestado en sus *manuales de mantenimiento*, se desarrolla un manual global o *plan de mantenimiento preventivo y correctivo* para el sistema BESS. El mantenimiento predictivo generalmente está en un *nivel superior*, y no sólo conlleva la realización de un plan, sino que va asociado a procesos y sistemas más complejos.

El *plan de mantenimiento preventivo y correctivo* debe englobar a todos los componentes o subsistemas, (celdas, módulos, racks, BMS, PCS, etc.) y detallar la frecuencia y trabajos a realizar para cada componente que esté dentro del marco del *plan de mantenimiento preventivo*. En este capítulo se detallan cuatro *planes de mantenimiento preventivo* para cuatro sistemas en producción de almacenamiento de energía con baterías (BESS), elaborados por fabricantes de baterías y por proveedores de ESS basados en LIB.

El objetivo de este mantenimiento preventivo (opcional para el fabricante del sistema de baterías) es mejorar la fiabilidad y prolongar la vida útil de las celdas, módulos y racks, con la finalidad de mantener las mejores condiciones de rendimiento con un funcionamiento adecuado.

En estos fragmentos de *manual de mantenimiento preventivo*, expuestos en la sección 5.4, se muestran sólo las labores de mantenimiento realizadas sobre los dispositivos de almacenamiento de energía, poniendo el foco así en las mejoras que se plantearán sobre el mantenimiento del BESS de la tesis.

5.4. Manuales de mantenimiento preventivo

Dentro de esta sección se presentarán cuatro *manuales de mantenimiento* elaborados por diferentes empresas del sector para LIB, en lo relativo al mantenimiento preventivo de las celdas de iones de litio y aparataje eléctrica.

5.4.1 Proveedor primero.

En la Tabla 5.1, se detallan las especificaciones relativas al mantenimiento preventivo de los módulos:

➤ Programa de mantenimiento preventivo

La frecuencia del plan puede modificarse en función de la capacidad instalada.

Tabla 5.1. Plan de mantenimiento preventivo para los SBMS

Día	Ítem
1	- Personarse para comprobaciones "in situ".
	- Comprobación del funcionamiento del contactor de DC.
	- Calibración del SOH (*).
	- Comprobación del estado de la batería en funcionamiento.
	- Inspección visual.
	- Comprobación del entorno.
2	- Calibración SOH (*).
	- Comprobación del estado de la batería en operación.
	- Equilibrado de celdas.
	- Comprobación del estado de la batería sin operación.
3	- Prueba de carga de la respuesta en frecuencia.
	- Calibración SOH (*).
	- Comprobación del estado de la batería en operación.
	- Reunión de revisión.

* La calibración SOH se realizará para cada línea de batería (modulo/rack), debido al emplazamiento del PCS.

➤ Descripción y realización del mantenimiento.

De igual forma, en la Tabla 5.2 se detallan las descripciones de cómo realizar las actividades de mantenimiento, p. ej.: funcionamiento del contactor de DC, calibración del SOH, etc.

Tabla 5.2. Descripciones sobre la realización de las tareas

Día	Ítem	Descripción
1	Control del funcionamiento del contactor DC	1. Ejecutar el comando de apagado total del contactor de DC y comprobar que la tensión de DC llega a 0 mediante el programa de monitorización del PCS, y verificar si el estado del sensor del contactor es correcto o no.
		2. Ejecutar el comando de encendido del contactor DC para cada rack individual, y comprobar si el estado del sensor del contactor es correcto.
	Calibración SOH	1. Cargue el sistema de baterías al 100% del SOC utilizando el método estándar de carga CC-CV.
		2. Esperar 30 minutos.
		3. Descargue el sistema de baterías hasta el 5% del SOC utilizando el método estándar de descarga CC.
		4. Esperar 30 minutos y volver a cargar el sistema de baterías para prepararlo de nuevo para la operación.
	Comprobación del estado de la batería	1. Compruebe si la batería se dispara o se activa la alarma durante la calibración del SOH.
		2. Compruebe si todos los datos de tensión y temperatura de la célula se ajustan a las especificaciones.
	Inspección visual	1. Comprobar si hay condensación en la sala y en el sistema de baterías.
		2. Comprobar si hay humo u olor a producto químico en la sala de baterías.
		3. Comprobar si hay alguna distorsión o cambio de color en el cable de alimentación y comunicación de la batería.
		4. Comprobar si hay deformaciones en la estructura mecánica.

	Verificación del entorno	1. Comprobar si la temperatura ambiente de la sala de la batería se encuentra dentro de las especificaciones de funcionamiento.
		2. Comprobar si la uniformidad de la temperatura en la sala de baterías es inferior a 3 °C o no.
		3. Se comprobará al menos en 6 puntos la temperatura ambiente.
		4. Comprobar si la humedad está dentro de las especificaciones de funcionamiento y si hay condensación en la sala y en el sistema de baterías.
2	Estado de la batería	1. Comprobar si la batería se dispara o se activa la alarma durante la calibración del SOH.
	Equilibrado de celdas	1. Mantener el sistema de baterías en reposo para el equilibrado de celdas.
3	Prueba de carga FR	1. Operar el sistema de baterías de acuerdo con el procedimiento de prueba proporcionado por el cliente.

Del mismo modo, en el manual se especifica cómo realizar la desconexión del sistema para realizar el mantenimiento.

Cuando se produce una desconexión o una alarma durante el funcionamiento del sistema, se debe solucionar y tomar las medidas oportunas. Para ello, se utiliza el botón *Reset*. Antes de tomar medidas, los datos y la información sobre alarmas y desconexiones deben ser verificados por el propio EMS cliente y deben tomarse las precauciones de seguridad adecuadas de acuerdo con la normativa vigente y con las instrucciones de seguridad de este documento.

La Tabla 5.3 muestra las alarmas y desconexiones necesarias para cada categoría:

Tabla 5.3. Eventos de desconexión

Categoría	Elementos de disparo y alarma	Observaciones
Tensión	Protección contra sobretensión del módulo	Módulo OVP
	Protección contra baja tensión del módulo	Módulo UVP
	Protección contra sobretensión de rack	Rack OVP
	Protección adicional contra sobretensión de rack	Protección adicional
	Protección contra baja tensión del rack	Protección UVP
Temperatura	Protección contra sobre temperatura del módulo	Módulo OT

	Alarma de baja temperatura del módulo	Módulo UT
Corriente	Protección contra sobreintensidad del rack	Rack OCP

- Módulo OVP. Protección contra sobretensión del módulo (OVP, de las siglas en ingles “Over-Voltage Protection”). Causado porque la tensión máxima de la celda de litio-ion supera los 4,2V durante más de 5 segundos.

Actuación a realizar: Comparar la tensión de la celda con la de otras celdas y llevar a cabo el equilibrado de estas. Comprobar el estado de conexión del cable de detección de tensión.

- Módulo UVP. Protección contra baja tensión del módulo (UVP, de las siglas en ingles” Under-Voltage Protection”). Causado porque la tensión mínima de la celda es inferior a 2,5V durante más de 3 segundos

Actuación a realizar: Comparar la tensión de la celda con la de otras y realizar el equilibrado. Comprobar el estado de conexión del cable de detección de tensión.

- Rack OVP. Protección contra sobretensión del rack (OVP). Provocado porque la tensión del bastidor supera los 1108,8 V durante más de 5 segundos durante el proceso de carga.

Actuación a realizar: Comprobar el funcionamiento del PCS. Comprobar el nivel de tensión del Rack con OVP y reiniciarlo en el BMS si el valor es inferior.

- Rack UVP. Protección contra baja tensión del rack (UVP). Provocado porque la tensión del rack es inferior a 660V durante más de 3 segundos.

Actuación a realizar: Comprobar el funcionamiento del PCS. Comprobar el nivel de tensión del Rack con UVP y reiniciarlo en el BMS si el valor es superior. Compruebe el estado de conexión del cable de alta intensidad entre conmutadores.

Toda la información necesaria de los sistemas de baterías será proporcionada por el sistema BMS y el cliente podrá recoger toda la información por su propio EMS. Aunque el sistema de baterías de iones de litio no requiere ningún mantenimiento operativo periódico, se recomienda supervisar el estado de la batería mediante la comunicación del BMS.

5.4.2 Proveedor segundo.

En la Tabla 5.4 se detallan las especificaciones relativas al mantenimiento preventivo de los sistemas del BESS:

1. Programa de mantenimiento preventivo

Tabla 5.4. Plan de mantenimiento con código de tarea y responsable

Lista de mantenimiento preventivo			
PERIODO	N°	DESIGNACIÓN	OPERADOR
3 meses	PV01	<u>Antes de 1 año de garantía</u> - Mantenimiento periódico (trimestral) del sistema de aire acondicionado	Empresa de mantenimiento
6 meses	PV02	<u>Después de 1 año de garantía</u> - Mantenimiento periódico del sistema de extinción de incendios.	Empresa de mantenimiento
6 meses	PV03	Mantenimiento periódico del sistema de extinción de incendios.	Empresa de mantenimiento
1 año	PV04	Control y verificación visual	Electricista
1 año	PV05	Actualización del sistema de baterías	Electricista
2 años	PV06	Revisión y prueba de los dos años	Electricista
5 años	PV07	Chequeo y prueba de los 5 años	Electricista y técnico electrónico
10 años	PV08	Sustitución del sistema de aire acondicionado	Empresa de mantenimiento
10 años	PV09	Sustitución de la bombona de gas	Empresa de mantenimiento

2. Descripción y realización del mantenimiento.

A continuación, se muestran varios ejemplos de los mantenimientos preventivos “PV04”, “PV05”, “PV06”, “PV07” donde se detallan las descripciones de cómo realizar las actividades relativas a equipos eléctricos y baterías.

- Tareas del PV04 relativas a las cajas de equipos eléctricos.
1) Asegúrese de que los equipos eléctricos están en buen estado. Si un equipo está defectuoso, consulte su hoja de mantenimiento correctivo.

2) Compruebe las etiquetas de los equipos de la caja eléctrica.

Si falta una etiqueta o es ilegible, sustitúyala.

3) Compruebe los equipos eléctricos de protección (fusibles, disyuntores).

Si un equipo está defectuoso, consulte su hoja de mantenimiento correctivo.

4) Efectúe varios ciclos de apertura y cierre (para varios dispositivos de protección o corte).

5) Compruebe que todas las piezas que protegen contra el contacto están en posición y en buen estado.

- Tareas del PV05 relativas a las baterías.

1) Para las baterías en stock, realice un ciclo de carga hasta SOC = 50%. Para el procedimiento, consulte el manual del usuario de la batería Lithium-Ion. Módulo R1.

- Tareas del PV06 relativas a la comprobación de la caja de equipos eléctricos y prueba de 2 años.

1) Asegúrese de que los equipos eléctricos (conexiones de potencia, conexiones de cables...) están en buen estado. Si el equipo está defectuoso, consulte su hoja de mantenimiento correctivo.

2) Realice la prueba de funcionamiento y la puesta en servicio (véase "prueba"). Si el equipo está defectuoso, consulte su hoja de mantenimiento correctivo.

3) Asegúrese de que no hay corrosión en la estructura del armario.

4) Efectuar varios ciclos de apertura y cierre (para diversos dispositivos de protección o corte).

5) Realice una inspección termográfica con la alimentación conectada para detectar posibles puntos calientes. Para más información, póngase en contacto con el proveedor.

- Tareas del PV07 relativas a la comprobación y prueba de los 5 años.

- Inter ESSU (Energy Storage System Unit) conexiones de alimentación:

1) Hacer un control termográfico en carga. Póngase en contacto con el proveedor para más información.

- Conexiones de tierra:

1) Comprobar la resistencia de las conexiones. Si el equipo está defectuoso, reemplace la conexión del equipo de trenza. Consulte correctivo "Crr_20".

- ESSU:

1) Cambiar el ventilador del armario. Consulte correctivo "Crr_11".

5.4.3 Proveedor tercero.

En la Tabla 5.5 se detallan las especificaciones relativas al mantenimiento preventivo del sistema BESS:

Tabla 5.5. Plan de mantenimiento con tipo de operación y responsable

Mantenimiento de las baterías			
Operación	Descripción de la operación	Empresa	Intervalo de mantenimiento
Inspección visual	Comprobar en HMI (Human-Machine Interface) que la temperatura dentro del contenedor <i>EnergyHouse</i> se ha mantenido dentro del rango de $23 \pm 5^{\circ}\text{C}$.	Propietaria	Diario
	Comprobar en HMI la ausencia de anomalías o fallos.		
	Comprobar que no hay distorsiones en los cables. Comprobar que las partes metálicas no están oxidadas. Comprobar que no hay olor de productos químicos.	Propietaria	Mensual
Pruebas funcionales	Comprobar el correcto funcionamiento de los contactores de DC. Comprobar la presencia del voltaje auxiliar 24V _{DC} .	Propietaria	Anual

Para la extracción de un módulo de baterías del rack, consultar el procedimiento mostrado a continuación.

Puesto que un módulo de la batería pesa cerca de 54 kilogramos, se recomienda que sean dos personas las que manipulen una batería.

Acciones a llevar a cabo:

- 1) Abrir el seccionador general y los 8 seccionadores de cada rack de baterías en el PWC asociado al banco de baterías.
- 2) Desconectar los cables de alimentación 24 V_{DC} y de comunicación de la batería.

- 3) Retirar las tapas protectoras.
- 4) Desconectar y remover el cable del polo positivo que está conectado con el negativo del módulo de baterías de arriba.
- 5) Desconectar y remover el cable del polo negativo que está conectado con el polo positivo del módulo de la batería de abajo.
- 6) Poner nuevamente las tapas protectoras para evitar el contacto directo con la parte viva de las baterías.
- 7) Retirar los tornillos que fijan la batería al bastidor.

Ahora es posible el desplazamiento de la batería.

En caso de que las inspecciones del mantenimiento preventivo dieran como resultado algún mantenimiento correctivo, se llevarían a cabo las actuaciones pertinentes al respecto convenidas en cada manual o sección de mantenimiento correctivo.

5.4.4 Proveedor cuarto.

En el manual de mantenimiento predictivo del cuarto proveedor de baterías (sistema BESS) se detallan las tareas de mantenimiento de cada sistema o componente esencial y la frecuencia de realización, a la par de cómo se realizan las tareas.

En lo referente a las celdas de baterías se detalla lo siguiente en la Tabla 5.6:

1. Programa de mantenimiento para trabajos de servicio técnico.

El programa de mantenimiento debe realizarse cuando sea necesario o de acuerdo con los intervalos especificados. Sólo así se garantiza el funcionamiento sin averías del producto.

Antes de entrar en el sistema de almacenamiento de baterías, cambie el sistema de detección de fallos a tierra (GFDI o GFDI remoto) a funcionamiento aislado.

Tabla 5.6. Plan de mantenimiento con la descripción de la tarea

Tarea	Intervalo
Sustitución de la batería recargable de iones de litio.	10 años
Sustitución de la tarjeta Compact Flash Industrial.	10 años o después de un mensaje de error
Sustitución del ventilador interior.	14 años
Sustituir el ventilador del puente inversor.	14 años

Sustituir el GFDI.	Después de 7000 ciclos o 100 cortocircuitos
Sustitución del GFDI remoto.	Después de 7000 ciclos
Sustitución del dispositivo de cortocircuito trifásico.	Después de un cortocircuito

*GFDI: de las siglas en ingles" ground fault detection system". Sistema de detección de fallos a tierra.

En la *"Operations & Maintenance Best Practices – A Guide to Achieving Operational Efficiency"* (Sullivan *et al.*, 2010), se muestran algunas de las tecnologías empleadas para el mantenimiento predictivo para los equipos eléctricos, como son: inspección visual, termografía infrarroja, monitorización eléctrica, etc. Algunas de estas tecnologías son las que se utilizan en los ejemplos de mantenimientos preventivo que se han mostrado, como p.ej., la inspección termográfica que se utilizaba en los mantenimientos preventivos 6 y 7 por el proveedor 2 o inspecciones visuales, realizados por todos ellos también.

Como se ha mostrado en los ejemplos anteriores, de los cuatro BESS en cuestión, el mantenimiento preventivo se limita a llevar a cabo una serie de chequeos, a realizar en el periodo estimado en el manual, y verificar que el funcionamiento o los resultados de la verificación, son los adecuados. En caso de que estos resultados no lo sean, se realizará el mantenimiento correctivo determinado a tal efecto.

5.5. Desarrollo de una especificación técnica para la operación y el mantenimiento.

En los cuatro ejemplos de la sección anterior, se han expuesto las tareas de mantenimiento preventivo a nivel de fabricante o proveedor del servicio, pero estos siempre pueden verse modificados o incrementados por el cliente u operador del sistema BESS.

Así, por ejemplo, puede elaborarse una *"Especificación técnica para la operación y mantenimiento del BESS"* (entre propietario y proveedor) donde queden reflejados los servicios de mantenimiento oportunos a llevar a cabo por el contratista o proveedor de este. En dicho documento, no se refleja tanto "el cómo se hace" (esto queda precisado en los manuales del fabricante), sino "qué se hace", "cuándo", "por quién" y "por cuánto".

En el "qué se hace", p. ej., pueden incluirse las tareas de monitorización del BESS o qué tipo de mantenimiento se va a realizar (correctivo, preventivo,

predictivo, mixtos). También pueden incluirse, previa negociación, indicadores *KPI* (Key Performance Indicators) (Luque *et al.*, 2023) que midan la utilización del BESS o establezcan niveles de servicio entre proveedor y contratista.

En el “cuándo se hace” quedarán reflejadas las frecuencias de estos servicios, que, p. ej., en el caso de mantenimientos preventivos, deberán tener en cuenta los tiempos del fabricante, para no incumplir los acuerdos de garantías.

Por último, el “por quién”, especificará que personas o empresas deben realizar las labores y qué requisitos técnicos y de seguridad deben cumplir para su desempeño, p.ej., formación, normativa, etc. Finalmente, el “por cuánto” reflejará el coste de los servicios realizados.

Así, p. ej. en el documento estudiado para esta tesis, los servicios de mantenimiento se desglosan en *servicios predefinidos* con un precio fijo, cuyo servicio está programando, y *servicios bajo demanda* para intervenciones correctivas donde se facilita una lista de precios con los costes hora/hombre y una lista de piezas de repuesto con el precio por artículo.

Además, en este tipo de especificación, también se pueden incluir indisponibilidades y penalizaciones por incumplimientos. Las indisponibilidades (en el caso que nos ocupa), están directamente ligadas a la degradación de las celdas, y en este sentido, cuanto mejor sea el sistema de mantenimiento predictivo (en caso de haberlo), mayor será la capacidad de actuación en tiempo y por tanto menor el periodo de indisponibilidad.

Esto nos lleva a formalizar la idea de lo importante que es el estado de salud de las celdas del BESS, ya que, si se reduce drásticamente su capacidad antes del tiempo establecido, puede llevar al incumplimiento del contrato de garantías, del contrato de mantenimiento y por ende a costes económicos extraordinarios o mermas en la operación del BESS, que reducen los ingresos por el mismo.

Como hemos mencionado anteriormente, en la *especificación técnica para el mantenimiento del BESS* estudiada, se definen los servicios predefinidos como las tareas de mantenimiento preventivo, y los servicios bajo demanda para intervenciones correctivas (localización de averías, reparación y suministro de material), en caso de ser necesarias o estimada su realización por el cliente. Así, se especifica que el mantenimiento preventivo consiste en inspecciones visuales, verificaciones del correcto funcionamiento del sistema y sustitución rutinaria de componentes específicos. Estas comprobaciones y su alcance se detallarán en una lista en la *especificación técnica*. Así, el contratista presentará

al propietario del BESS un plan detallado de mantenimiento preventivo, con las actividades a realizar y su planificación, de acuerdo con las mejores prácticas de la industria y los manuales operativos y de mantenimiento de los fabricantes de cada equipo.

En esta especificación técnica se detalla también que, durante el mantenimiento, cualquier daño detectado o potencial, se comunicará al responsable de la empresa y se solucionará si es posible. El proveedor de servicios de O&M garantizará la disponibilidad de consumibles y materiales recomendados por el fabricante en el plazo acordado entre ambos.

En lo referente a los servicios de monitorización y supervisión, en este documento se especifica que el contratista deberá supervisar el funcionamiento correcto de todos los equipos: transformadores, cuadros de distribución y relés de protección de media tensión, sensores de temperatura de las salas, ventiladores, etc. Y por supuesto los específicos de un sistema BESS, como son los equipos de conversión de energía (PCS), los racks de baterías, los dispositivos de comunicación, el sistema BMS y EMS.

Así, para las baterías se deberán controlar los siguientes parámetros:

- Las tensiones de los racks y de celdas.
- La temperatura de los racks, módulos y celdas.
- La temperatura ambiente del contenedor del BESS.
- Valores monitorizados por el BMS, resistencia interna de la celda y entre celdas.
- Ciclos de carga.
- C-rate de carga y descarga.

5.6. Mejora de la operación mediante el mantenimiento predictivo basado en DSRM-MML

Como ya se comentó, (Fioravanti *et al.*, 2020) consideran que el uso de la supervisión predictiva en el hardware convencional de los BESS, está dificultado por las limitaciones en la disponibilidad de canales de comunicación y la potencia de procesamiento de los dispositivos de gestión (BMS) de las baterías, al implicar un alto volumen de datos de los módulos, racks y del sistema en general, para la identificación de indicadores de fallos.

Siendo el BMS el dispositivo que ayudaría en esta tarea a priori, exponen sin embargo, que el problema subyace en que no todos los BMS actuales están

diseñados para reconocer fallos que se produzcan más allá de los inmediatos de la propia batería (por ejemplo, celdas, módulos), y además pueden no tener el rendimiento necesario para procesar todos los datos de señales generados (tensión, corrientes, temperaturas, sobre-tensiones, etc.).

Argumentan, que el análisis predictivo debe tener el apoyo de los datos del EMS, y estos carecen a menudo de comunicación directa con la fuente de todas las señales de medida (el BMS). Esto hace que la posible detección de un fallo por su parte, no se comunique siempre al EMS, aguas arriba, lo que limita las acciones preventivas de los operadores del sistema BESS.

Según los autores, el enfoque de supervisión correcto para los BESS debería centrarse en crear indicadores que proporcionen características como las de la Tabla 5.7. El objetivo es identificar indicadores de posibles fallos, e intervenir preventivamente en el BESS en operación, sin que la intervención produzca un problema. Sin embargo alegan que, las relaciones causales entre los indicadores de fallos y el potencial de estos para dar lugar a fallos mayores, no se evidencian fácilmente.

Tabla 5.7. Características clave de los indicadores para el seguimiento/monitorización predictiva.

Elemento	Descripción
Elemento temporal	Días de aviso en lugar de minutos u horas.
	No todos los fallos tendrán plazos largos, pero todo lo que pueda ampliar el plazo puede minimizar los fallos destructivos.
Avisos procesables	Señalar los componentes que necesitan sustitución.
	Dar tiempo para examinar las zonas que provocan el aviso.
Acciones recuperables	Las medidas de seguridad destinadas a evitar fallos catastróficos y amenazas para la seguridad humana pueden acabar destruyendo la unidad ("irrecuperable").
	La acción "recuperable" debe tener un impacto mínimo en el sistema.

Así, establecen que se debe crear una metodología que identifique las relaciones entre indicadores y fallos que puedan rastrearse y controlarse en estos sistemas. Poniendo el foco en la fase de diseño, ya que es en ese momento cuando se puede dimensionar el sistema (BMS, EMS, comunicaciones, sensores, etc.), para desarrollar esta metodología. Adaptar un sistema instalado y en operación es mucho más costoso.

A la vista de esto y dado el potencial de la metodología DSRM-MML, se realiza una propuesta de mejora de los planes de mantenimiento existentes, dándoles un carácter predictivo. Este objetivo ha quedado realizado, tal como se argumenta en esta sección, mediante el uso del nuevo indicador DSRa y la metodología DSRM-MML de cuantificación de la degradación del BESS, para su

uso en un sistema de mantenimiento predictivo de tiempo real. Esto mejoraría la disponibilidad de los racks y los SBMS del BESS, ya que permitiría conocer en todo momento el estado del *estrés* de los racks y actuar en consecuencia.

Cuando los indicadores en los cuales se basan los modelos predictivos se reducen en número, esto hace reducir significativamente los costes de monitorización y del sistema predictivo, por tres motivos:

- (1) Se reducen los costes en sistemas de comunicación, al reducirse los recursos necesarios para ello, debido a la necesidad menor en el número de sensores y de canales de comunicación.
- (2) La reducción de costes en los sensores de medida. Debido a la disminución del número de variables necesarias empleadas en el modelo.
- (3) La reducción de costes en los sistemas de procesamiento, ya que se reduce la complejidad de los modelos y los tiempos empleados para la predicción.

Por tanto, este nuevo indicador DSR cumple los retos expuestos anteriormente:

- (1) En lo referente al ahorro de costes, ya que sólo necesita de la variable tensión e intensidad (en su variante DSRa) para su determinación, reduciendo los sensores a implantar (sólo dos), los canales de comunicación de BMS y BMS-EMS y la potencia de procesamiento debido a la simplificación de los cálculos.
- (2) En lo relativo a su implantación en un sistema en producción, sin necesidad de haberlo planificado en su diseño, ya que como se ha demostrado, se puede calcular en de *manera continuada*, una vez el BESS ha sido puesto en producción y está operando.

Los planes de mantenimiento predictivos son más específicos que los preventivos, y deben realizarse “ad hoc” al sistema y al modo de operación de este. En el caso que nos ocupa, este indicador y metodología desarrollada hace que esta labor sea muy simple y con el empleo de pocos recursos.

Así, los beneficios de este DSRa radican en que, puede instalarse en cualquier BESS ya en operación, pudiendo ser esta operación de cualquiera de los tipos mencionados. Su implantación no implica un aumento de costes, y reduce la utilización de sistemas de predicción de mayor coste, como p.ej., termografías, pruebas de rendimiento fuera de la operación, herramientas complejas predictivas, etc.

5.7. Mejoras concretas planteadas y debidas al uso de la metodología DSRM-MML.

Llegado este momento, podemos plantear mejoras estimadas, sobre los manuales de mantenimiento mostrados para los 4 proveedores, basadas en las tareas de medición de la degradación planteadas en las mismas.

1. En el mantenimiento preventivo del proveedor primero, tal como se muestra en la Fig. 5.1, se realizan tareas de calibración del SOH, donde se lleva a cabo una prueba de capacidad al rack, previa desconexión de este del sistema BESS en operación. Esto provoca una indisponibilidad total o parcial de la capacidad del BESS para llevar a cabo esta acción.

	2. Ejecutar el comando de encendido del contactor DC para cada rack individual y comprobar si el estado del sensor del contactor es correcto.
Calibración SOH	1. 1. Cargue el sistema de baterías al 100% del SOC utilizando el método estándar de carga CCCV.
	2. Esperar 30 minutos
	3. Descargue el sistema de baterías hasta el 5% del SOC utilizando el método estándar de descarga CC.
	4. Esperar 30 minutos y volver a cargar el sistema de baterías para prepararlo de nuevo para la operación.
Comprobación	1. Compruebe si la batería se dispara o se activa la alarma durante la

Fig. 5.1. Sección de la Tabla 5.1.

Con el uso del indicador DSRa y la metodología elaborada en esta tesis, no es necesario esta pérdida de capacidad parcial o total, ya que su medida se puede establecer con los datos de la operación.

Las ventajas asociadas a la no realización de esta tarea, o al menos, no de una forma tan recurrente, son:

- (1) Relativas a la operación. La “*no perdida de disponibilidad*” tanto en capacidad como en tiempo, como se ha mencionado, y además la disminución del deterioro de los racks del BESS, al no someterlos al *estrés* sufrido por la realización de esta prueba.
 - (2) Relativas al ahorro de costes. Disminución del número de horas de mantenimiento y por tanto del personal establecido para ello.
2. De igual forma, dentro de las tareas de mantenimiento realizadas por el proveedor segundo, las tareas marcadas como PV06 y PV07, llevan a cabo un control termográfico en carga, para detectar puntos calientes, tanto en conexiones como en módulos y racks. Este aumento de la temperatura, dentro de los racks, se ve incrementado con el transcurso

de los ciclos de vida del BESS, tal como se mostró en la Fig. 4.11 del Capítulo 4 de esta tesis, donde se veía que las temperaturas frente a los niveles de tensión aumentan a lo largo de su vida. Este efecto se ha demostrado también en diferentes estudios, y su relación con la degradación de las celdas de las baterías, (Kafadarova *et al.*, 2022) (Tian, Xiong and Shen, 2020).

En este caso, el empleo del indicador DSRa puede establecer una comparativa de los racks que tienen una mayor temperatura, alcanzada en la operación a lo largo de los ciclos de carga, debido a la relación existente entre la degradación de las celdas y su aumento de la temperatura de trabajo durante los ciclos de carga (Fig. 4.11), y sustituir así, las inspecciones termográficas. Este punto puede ser tenido en consideración para futuros trabajos de investigación en los BESS.

3. En el planteamiento expuesto para el mantenimiento del proveedor tercero, la labor fijada como mantenimiento preventivo es la inspección visual principalmente. Esto conlleva, en los momentos pertinentes, la extracción de los módulos del rack, tarea laboriosa y peligrosa, por lo que se describe en el manual.

Mediante el uso del indicador DSRa y la metodología establecida en esta tesis, es posible realizar un diagnóstico del estado de la degradación de cada rack, en comparación cuantitativa con el resto de los que forman cada SBMS.

4. El proveedor cuarto establece la sustitución de las baterías cada 10 años, para *“garantizar el funcionamiento sin averías del producto.”*

Mediante el uso del indicador DSR y la metodología establecida en esta tesis, es posible proceder a la sustitución sólo de las baterías con un nivel de degradación establecido como máximo. Siendo el método de mantenimiento utilizado para esta elección un mantenimiento basado en la condición, y no en la planificación o en la prevención. Esto permite un ahorro de costes muy relevante, debido a la sustitución de los recursos necesarios, no de los recursos planificados.

5.8. Puntos destacados del capítulo

En este Capítulo 5, después de **introducir en qué consisten los principales tipos de mantenimientos** aplicados a sistemas eléctricos y sus características, se ha expuesto la necesidad de implantar programas de mantenimiento

preventivo en los BESS, para tener una mayor eficiencia en el mantenimiento y operación de estos sistemas, con el consecuente ahorro de costes.

En segundo lugar, se han presentado **cuatro ejemplos de planes de mantenimiento preventivo** llevados a cabo por cuatro empresas del sector o fabricantes de LIB.

Estos cuatro planes de **mantenimiento preventivo se limitan a realizar chequeos** en periodos estimados y verificar el resultado adecuado. Si los resultados no son los esperados, se realiza el mantenimiento correctivo determinado a tal efecto.

Se ha presentado también, en qué consiste la elaboración de una **“Especificación técnica para la operación y mantenimiento del BESS”**, realizada entre propietario y proveedor del servicio, donde generalmente se **refleja el alcance del servicio** que el proveedor quiere realizar, en lo que a mantenimiento se refiere: tipo de mantenimiento, medios, costes, tiempos, KPI, penalizaciones, repercusiones, etc.

Posteriormente se han argumentado varias **dificultades planteadas** por (Fioravanti *et al.*, 2020) **para el uso de la supervisión predictiva**:

- (1) **Alto volumen de datos** debido al número elevado de señales.
- (2) Dificultad en la identificación de indicadores de fallo.
- (3) **El hardware** convencional de los BESS **está limitado**, en lo referente a la disponibilidad de canales y procesamiento principalmente.
- (4) Por lo general los BMS actuales no están diseñados para reconocer fallos.
- (5) **El BMS no tiene comunicación “aguas arriba”** con el EMS, para análisis predictivo, comunicación **de fallos**.

También exponen el **enfoque de supervisión correcto**, que consiste en:

- (1) Focalizar los recursos en crear indicadores que proporcionen características.
- (2) Intervenir preventivamente en el BESS en operación, sin que la intervención produzca un problema.
- (3) **Crear metodologías** que identifique las **relaciones entre indicador y fallo**, que puedan rastrearse y controlarse.
- (4) Desarrollar estas **labores en la fase de diseño del BESS**, para dimensionar correctamente sus sistemas predictivos.

- (5) La adaptación de un sistema instalado y en operación es mucho más costoso.

Por último, y en línea con el enfoque correcto, se enumeran **los beneficios de las propuestas de mejora** realizadas en los cuatro *planes de mantenimiento* preventivos expuestos en este capítulo, dado el potencial del DSRa y de la metodología DSRM-MML. Estos **se enumeran** a continuación:

- ✓ **Mejora la disponibilidad** de los racks y los SBMS del BESS,
- ✓ Permite **conocer, en tiempo real, el estado del estrés de los racks** y actuar en consecuencia.
- ✓ **Los indicadores**, en los cuales se basan los modelos predictivos, **se reducen** en número.
- ✓ Reducción significativa de los costes de monitorización por tres motivos:
 - Reducción de costes en **sensores**.
 - Reducción de costes en la **comunicación**.
 - Reducción de costes en los **sistemas de procesamiento**.
- ✓ Esta metodología **puede instalarse en cualquier BESS ya en operación**, sin haberse tenido en cuenta en la fase de diseño.

Capítulo 6

Conclusiones, contribuciones y futuros desarrollos

Estructura de la tesis: **Capítulo 6**

Introducción y Estado del Arte

Identificación de un nuevo indicador de salud (DSR)

Arquitectura y características del BESS en estudio

Aplicación del nuevo DSR en un BESS

operando en regulación de frecuencia

Mantenimiento aplicado a un BESS

por medio de la metodología desarrollada

- **Conclusiones, contribuciones y futuros desarrollos** •

- En este capítulo final, se presentan las conclusiones de la tesis, las contribuciones más significativas y los posibles desarrollos a efectuar en el futuro.

6.1. Conclusiones de la tesis

Las conclusiones de la tesis se presentan focalizadas en los diversos capítulos:

Dentro del Capítulo 1, centrado en el **estado del arte**, se han visto las **carencias** que hay en la aplicación de multitud de indicadores y metodologías aplicadas a LIB que, por norma general, no son susceptibles de implantar en dispositivos de uso real, por su complejidad, falta de pragmatismo, etc.

Es aquí donde se encontró la motivación primera, que dio paso al objetivo de suplir esa carencia de indicadores *“poco útiles”*.

En la revisión de la **literatura científica relativa a los BESS**, también se ha planteado la **escasez de literatura existente** que empleen métodos de predicción del SOH. Esto es debido a las siguientes dificultades, encontradas en el estado del arte:

- ✓ La evolución de **la degradación difiere** al aplicarse las condiciones reales de funcionamiento.
- ✓ **Los estudios** realizados con datos de VE **no han sido probados con datos de BESS**.
- ✓ Existe **poca investigación** para aplicaciones BESS.
- ✓ Los **modelos contruidos para LIB** son **poco fiables** en aplicaciones de BESS.

En la literatura científica **no se ha encontrado ningún estudio** para la estimación del **SOH de un BESS** como el analizado en la tesis, operado con corrientes de carga y descarga muy volátiles. Al no existir literatura al respecto, se ha planteado el objetivo de **desarrollar una metodología** que proporcione esta carencia.

Por último, en lo referente al **estado del arte del mantenimiento** de los BESS, se puede concluir que también existe poca literatura científica y la que hay, plantea las **siguientes necesidades**:

- ✓ **Conocer el SOH es crucial** para el mantenimiento predictivo.
- ✓ El uso del **mantenimiento predictivo no se ha desarrollado** plenamente aún.
- ✓ **El mantenimiento predictivo evita fallos** catastróficos.

- ✓ Un mantenimiento predictivo **implica una recopilación de datos** en muchos niveles.

También se han encontrado **los siguientes retos** para poder aplicar la monitorización predictiva:

- ✓ **Limitación del hardware** de los BESS, para su uso en comunicaciones y computación.
- ✓ **Limitación de los BMS** en diseño para la realización de monitorización.
- ✓ **Limitación del EMS** en diseño para actuaciones preventivas.
- ✓ **Dificultad para la identificación de HI** y para el desarrollo de modelos que no intervengan el funcionamiento normal del BESS.

Teniendo en cuenta estas necesidades planteadas en el estado del arte referido al mantenimiento, se ha planteado el objetivo de **aplicar la metodología desarrollada en la tesis al BESS**.

En el Capítulo 2, debido a la motivación referida en el estado del arte, fue posible la investigación y desarrollo de **un indicador de degradación aplicable** a las LIB, que **por sí solo es capaz de estimar la degradación sufrida por una LIB**, con sólo disponer de algunos fragmentos de tensión de carga.

Este nuevo indicador del estado de la degradación de las LIB llamado **DSR**, es sensible al envejecimiento y nos puede adelantar incluso su fallo total (Fig. 2.6). Sus características principales son:

- ✓ Su **alta sensibilidad** ante la degradación de la LIB.
- ✓ **Cuantificación de la capacidad** perdida sin la necesidad de realización de una *prueba intrusiva*.
- ✓ **Medición directa y rápida**.
- ✓ Obtención de **forma sencilla**.

Estas características hacen que disponga de las siguientes ventajas frente a otros indicadores existentes:

- ✓ Su **eficiencia**, debido a su simpleza de cálculo vs. su sensibilidad con la capacidad.
- ✓ **Alto índice de correlación** con el SOH de las LIB.
- ✓ **Tiempo reducido** necesario para su medición.
- ✓ **Seguimiento en tiempo real** de la tendencia de la degradación de la LIB.
- ✓ Puede **adelantar un fallo total**.

- ✓ Indicador independiente y **sustitutivo del SOH tradicional**.
- ✓ **Facilidad de implementación** en el BMS.
- ✓ Se puede realizar el **cálculo de la degradación** en todo el rango de tensiones de carga.
- ✓ **Sólo es necesaria la tensión** para su cálculo, siendo por ello muy robusto frente a fallos.
- ✓ **Ahorro en sensores**.

Se ha demostrado también que su **uso es generalizable con las LIB que cumpla con el entorno de operación** establecido. Y tiene resultados muy precisos cuando se utiliza como entrada de modelos de predicción. Los **resultados de ello** se han comparado con modelos del estado del arte, obteniendo una alta precisión, $R^2 = 0,98$ para datos desconocidos en todos los modelos utilizados.

Las conclusiones referentes al Capítulo 3, van encaminadas a la necesidad de realizar el equilibrio celular para el buen funcionamiento del BESS, ya que de no realizarlo puede repercutir en:

- Un **embalamiento término**.
- Mayor **degradación** de las celdas.
- **Carga incompleta** del paquete de celdas
- **Uso incompleto** de la energía almacenada en los paquetes.

De este capítulo también se puede concluir que el BESS es un sistema complejo, que engloba muchos componentes relacionados entre sí, cuyas **variables más significativas** a tener en cuenta son los **229 racks**, y que estos racks están formados por **60.192** celdas que pueden almacenar una **energía máxima de 17.370 kWh**.

El Capítulo 4 quizá sea el de las conclusiones de mayor relevancia en la investigación, debido a que:

- ✓ La **aplicación el indicador DSR** elaborado en el Capítulo 2 **al BESS**, **permite evaluar** de una manera rápida, **el nivel de degradación** de los SBMS del BESS.
- ✓ El desarrollo del nuevo **indicador DSRa**, que trabaja en entornos de **intensidad variable y ciclos no recurrentes** permite su uso en un entorno de operación volátil **como el del BESS**.

- ✓ El desarrollo de la metodología **DSRM-MML**, que utiliza el indicador DSRa y un método de predicción mediante el uso de tres modelos, es capaz de identificar el estado de degradación de un BESS.
- ✓ Los datos obtenidos de la aplicación de esta metodología permiten, de manera cuantitativa, **establecer los niveles de degradación de los SBMS** que forman del BESS y así, poner el foco en los que tienen mayor necesidad de realización de un proceso de mantenimiento correctivo.

Como **conclusión de esta nueva metodología del capítulo**, hay que mencionar que su aplicación **permite** detectar comportamientos problemáticos dentro de cada uno de los SBMS, y por medio de los indicadores ELowV (%), **estimar de forma cuantitativa la degradación del BESS, con tan sólo las señales de tensión e intensidad** de su operación de carga.

Además , el uso de **esta metodología DSRM-MML posibilita una mayor eficiencia en el mantenimiento** de los BESS, conociendo el estado de salud de los SBMS sin alterar la operación, focalizando los recursos donde se necesitan, tal como plantean (Fioravanti *et al.*, 2020).

Finalmente, como **conclusiones del Capítulo 5** de la tesis, que enlaza con el párrafo anterior, podemos citar:

Los mantenimientos realizados en los cuatro BESS analizados en esta tesis se limitaban a la realización de tareas preventivas o correctivas.

Las dificultades planteadas por (Fioravanti *et al.*, 2020) para la realización predictiva de un mantenimiento son:

- **El alto volumen de datos** necesarios.
- Dificultad en la identificación de indicadores de fallo.
- **El hardware** diseñado para los BESS **está limitado**.
- Los **BMS no están diseñados para reconocer fallos**.
- El **EMS no tiene comunicación con el BMS para el análisis predictivo**.

Se ha analizado, por otro lado, el **enfoque de supervisión correcto** que sería necesario realizar para un mantenimiento predictivo:

- **Crear indicadores** que proporcionen FOI.

- **Crear metodologías** que identifiquen las **relaciones entre indicador y fallo**.
- Desarrollar estas **labores en la fase de diseño del BESS**, para dimensionar correctamente sus sistemas predictivos.
- **Intervenir preventivamente en el BESS** en operación, sin que la intervención produzca un problema.

Con el objetivo de mejorar los cuatro mantenimientos, actualmente realizados en los BESS operativos vistos en el Capítulo 5.4, se ha utilizado la metodología DSRM-MML desarrollada en la tesis para plantear mejoras. Así, los beneficios por el uso de esta metodología son:

- ✓ Permite **conocer en tiempo real el estado del estrés de los racks** y actuar en consecuencia.
- ✓ **Los indicadores**, en los cuales se basan los modelos predictivos, **se reducen** en número.
- ✓ Reducción significativa de los costes de monitorización debido a la disminución **de las comunicaciones y de los sistemas de procesamiento**.
- ✓ Esta metodología **puede instalarse en cualquier BESS ya en operación**, sin haberse tenido en cuenta en la fase de diseño.
- ✓ **Mejora la disponibilidad** de los racks y los SBMS del BESS.

Como conclusión final de esta tesis, expresar **que el uso de esta metodología DSRM-MML** establecida, **posibilita** como primer hito, el **conocimiento de la degradación cuantitativa** de las partes y conjunto del BESS. Como segundo hito, **ayuda** significativamente a la **realización de un mantenimiento predictivo**, ya que, con su uso se logran realizar las tareas de monitorización sobre este, necesarias para llevar a cabo un mantenimiento predictivo.

Además cumple con los dos grandes retos planteados por (Fioravanti *et al.*, 2020): **se puede implantar en cualquier BESS** sin haber sido planificado en la fase de diseño y **no es necesario interrumpir la operación** para su *medida*.

6.2. Contribuciones de la tesis y publicaciones

La principal contribución de esta tesis ha sido **proponer una solución al problema existente** del desconocimiento del estado de la **degradación de las LIB que forman los BESS, sin interrumpir su operación**.

El desconocimiento de esta degradación, cuando se opera un BESS, tiene **consecuencias en su funcionamiento y durabilidad**, ya que impide una correcta utilización de este, de las partes que lo integran y también de la realización de un mantenimiento responsable y eficiente. Cabe recordar que los BESS son sistemas de alto coste de inversión con un retorno de medio a largo plazo. Por ello, es sumamente importante el conocimiento del estado de su degradación.

Para la realización de esta solución, y como **primera contribución**, se elaboró un **indicador de salud DSR** que es sensible a la degradación, y se mide con las tensiones de carga de las LIB. Este indicador, por sí solo, nos aporta una estimación de la degradación de la batería, pero además posibilita su uso en modelos predictivos y la comparación de resultados con los expuestos en el estado del arte.

Los resultados de esta contribución dieron lugar al artículo “*An Online Fade Capacity Estimation of Lithium-Ion Battery Using a New Health Indicator Based Only on a Short Period of the Charging Voltage Profile*”, publicado en la revista de impacto indexada en el Journal Citation Report “IEEE Access” JCR: 3.9 Q2 (2022)

Una **segunda contribución** de esta tesis es el segundo **indicador** de degradación **DSRv**, que amplía el rango de uso del DSR para corrientes no constantes, siendo posible su utilización en LIB que se cargan con intensidades no constantes.

La **tercera contribución** es una **metodología desarrollada** en esta tesis llamada **DSRM-MML**, que junto con un indicador subyacente al DSR, llamado **DSRa**, permite **cuantificar la degradación de un BESS**, cualquiera que sea su dimensión, operación o estado de implantación. No siendo necesario que dicha implantación se haya tenido en cuenta en la fase de diseño, **y no interrumpiendo la operación del BESS** para poder llevarla a cabo, cumpliendo así los **retos planteados** por (Fioravanti *et al.*, 2020). Esto se debe a que esta metodología basa sus estimaciones en el indicador DSRa, que sólo utiliza medidas tomadas de la operación básica del BESS (tensión e intensidad).

Estas **contribuciones han sido probadas** en esta tesis con los **datos reales de un BESS**, con un tipo de operación volátil y compleja, pero aun así, se ha llegado a estimar cuantitativamente dicha degradación del BESS y compararla con la real, utilizando la metodología establecida.

Los resultados de esto han dado lugar al paper “*Measuring the degradation of a power grid-connected BESS using a new data-driven indicator*”, enviado y

en 2ª revisión a la revista “Journal of Energy Storage”, indexada en el Journal Citation Report con JCR: 9.4 Q1 (2022)

Habiendo contribuido con esta metodología a la cuantificación de la degradación de un BESS, aún quedan trabajos surgidos de aquí y con posibilidad de desarrollo a futuro.

6.3. Futuribles desarrollos

Como se mostró en el Capítulo 4.5, los cuadrantes abarcados por los indicadores DSR, DSRv y DSRa son tres. Aunque el sector III, que abarca intensidades NO constantes y ciclos NO recurrentes, es el más *extremo* en cuanto a su operación, aún es necesario probar su desempeño en el cuadrante IV, con ciclos NO recurrentes e intensidad constantes.

Previsiblemente, el indicador DSRa desarrollará su función adecuadamente, ya que como se ha comentado, lo hace en el sector III que es más extremo, pero aun así, su demostración queda como futuribles trabajos.

De igual forma se podría comprobar en futuras investigaciones, el uso del indicador DSRa trabajando en los sectores I y II. Siendo previsible que su desempeño sería similar al del DSR y DSRv, ya que, a intensidades constantes, el DSRa tendrá una tendencia idéntica que el DSR, pero con una la constante *intensidad* que los hará diferentes.

También se pueden plantear futuros trabajos de desarrollo enfocados a la implantación y seguimiento de la metodología DSRM-MML desarrollada, en un BESS a lo largo de su vida. De esta forma podrían medirse los ahorros obtenidos en la operación y mantenimiento.

Otros futuribles trabajos de investigación pueden ir encaminados al uso de este indicador con otros tipos de baterías, con una química diferente, para poder ampliar así su *espectro* de utilización en el universo de los BESS.

Del mismo modo, pueden realizarse labores de investigación mediante el uso del indicador DSR en LIB implantadas en VE, ya que su operación y recursos, encajan perfectamente con los establecidos y necesarios para el uso del DSR, sin necesidad de sistemas de ML para su implantación.

Para finalizar, exponer que futuribles desarrollos de este indicador DSR y la metodología DSRM-MML tienen cabida en cualquier dispositivo que disponga de una batería electroquímica, con independencia del tamaño, complejidad y utilización que se le dé.

Bibliografía

- **Abdeltawab, H. and Mohamed, Y. A. R. I. (2021)** 'Batteries Maintenance Schedule Optimization for Profit Maximization', *Proceedings of the 2021 IEEE 28th International Conference on Electronics, Electrical Engineering and Computing, INTERCON 2021*. IEEE, pp. 1–4. doi: 10.1109/INTERCON52678.2021.9532738.
- **Ahmad, A. B. et al. (2019)** 'Cell balancing topologies in battery energy storage systems: A review', *Lecture Notes in Electrical Engineering*, 547(2021), pp. 159–165. doi: 10.1007/978-981-13-6447-1_20.
- **Alvarez-Monteserin, I. and Sanz-Bobi, M. A. (2022)** 'An Online Fade Capacity Estimation of Lithium-Ion Battery Using a New Health Indicator Based Only on a Short Period of the Charging Voltage Profile', *IEEE Access*. IEEE, 10, pp. 11138–11146. doi: 10.1109/ACCESS.2022.3143107.
- **Attia, P. M. et al. (2022)** "Knees" in Lithium-Ion Battery Aging Trajectories', *Journal of The Electrochemical Society*. IOP Publishing, 169(6), p. 060517. doi: 10.1149/1945-7111/ac6d13.
- **Azad, F. S. et al. (2020)** 'Active cell balancing of li-ion batteries using single capacitor and single lc series resonant circuit', *Bulletin of Electrical Engineering and Informatics*, 9(4), pp. 1318–1325. doi: 10.11591/eei.v9i4.1944.
- **Bak, T. and Lee, S. (2019)** 'Accurate estimation of battery SOH and RUL based on a progressive lstm with a time compensated entropy index', *Proceedings of the Annual Conference of the Prognostics and Health Management Society, PHM*, 11(1), pp. 1–10. doi: 10.36001/phmconf.2019.v11i1.833.
- **Bian, X. et al. (2020)** 'A Novel Model-based Voltage Construction Method for Robust State-of-health Estimation of Lithium-ion Batteries', *IEEE Transactions on Industrial Electronics*, 0046(c), pp. 1–1. doi: 10.1109/TIE.2020.3044779.
- **Borbujo, I. C. et al. (2021)** 'Heavy duty transport decarbonization: Legislation and Standards for Hydrogen and Battery Electric Buses and Heavy-Duty Trucks', *2021 IEEE Vehicle Power and Propulsion Conference, VPPC 2021 - ProceedingS*, pp. 21–26. doi: 10.1109/VPPC53923.2021.9699373.
- **Braun, J. A. et al. (2022)** 'State of charge and state of health diagnosis of batteries with voltage-controlled models', *Journal of Power Sources*, 544(August). doi: 10.1016/j.jpowsour.2022.231828.
- **Von Bülow, F., Mentz, J. and Meisen, T. (2021)** 'State of health forecasting of Lithium-ion batteries applicable in real-world operational conditions', *Journal of Energy Storage*. Elsevier Ltd, 44(PB), p. 103439. doi: 10.1016/j.est.2021.103439.

- **Cai, L. et al. (2019)** 'An evolutionary framework for lithium-ion battery state of health estimation', *Journal of Power Sources*. Elsevier, 412, pp. 615–622. doi: 10.1016/J.JPOWSOUR.2018.12.001.
- **Calcuttawala, M. S. and Alhaider, F. (2021)** 'State of Health estimation of Lithium-ion batteries using operational data', *NEIS 2021 - Conference on Sustainable Energy Supply and Energy Storage Systems*, 1, pp. 105–112.
- **Chen, J. C. et al. (2021)** 'Combining empirical mode decomposition and deep recurrent neural networks for predictive maintenance of lithium-ion battery', *Advanced Engineering Informatics*. Elsevier Ltd, 50(August), p. 101405. doi: 10.1016/j.aei.2021.101405.
- **Chen, L. et al. (2018)** 'A new state-of-health estimation method for lithium-ion batteries through the intrinsic relationship between ohmic internal resistance and capacity', *Measurement*. Elsevier, 116, pp. 586–595. doi: 10.1016/J.MEASUREMENT.2017.11.016.
- **Chen, L. et al. (2021)** 'Battery state-of-health estimation based on a metabolic extreme learning machine combining degradation state model and error compensation', *Energy*. Elsevier Ltd, 215, p. 119078. doi: 10.1016/j.energy.2020.119078.
- **Chen, Y. et al. (2016)** 'A MultiWinding Transformer Cell-to-Cell Active Equalization Method for Lithium-Ion Batteries with Reduced Number of Driving Circuits', *IEEE Transactions on Power Electronics*. IEEE, 31(7), pp. 4916–4929. doi: 10.1109/TPEL.2015.2482500.
- **Chen, Z. et al. (2019)** 'State of health estimation of lithium-ion batteries based on fixed size LS-SVM', *2018 IEEE Vehicle Power and Propulsion Conference, VPPC 2018 - Proceedings*. IEEE. doi: 10.1109/VPPC.2018.8605041.
- **Chen, Z. et al. (2022)** 'Online state of health monitoring of lithium-ion battery based on model error spectrum for electric vehicle applications', *Journal of Energy Storage*. Elsevier Ltd, 45(October 2021), p. 103507. doi: 10.1016/j.est.2021.103507.
- **Cui, S. and Joe, I. (2021)** 'A Dynamic Spatial-Temporal Attention-Based GRU Model with Healthy Features for State-of-Health Estimation of Lithium-Ion Batteries', *IEEE Access*, 9, pp. 27374–27388. doi: 10.1109/ACCESS.2021.3058018.
- **Deng, Z. et al. (2020)** 'General Discharge Voltage Information Enabled Health Evaluation for Lithium-Ion Batteries', *IEEE/ASME Transactions on Mechatronics*, 4435(2019), pp. 1–1. doi: 10.1109/tmech.2020.3040010.
- **Dimitrov, B., Collier, G. and Cruden, A. (2019)** 'Design and experimental verification of voltage measurement circuits based on linear optocouplers with galvanic isolation for battery management systems', *World Electric Vehicle*

Journal, 10(4). doi: 10.3390/wevj10040059.

- **Duraisamy, T. and Kaliyaperumal, D. (2021)** 'Machine Learning-Based Optimal Cell Balancing Mechanism for Electric Vehicle Battery Management System', *IEEE Access. IEEE*, 9, pp. 132846–132861. doi: 10.1109/ACCESS.2021.3115255.
- **EASE (2018)** 'Enel Develops a Stand-alone Battery Energy Storage System in UK, European Association for Storage of Energy'. Available at: <https://ease-storage.eu/news/enel-develops-a-stand-alone-battery-energy-storage-system-in-uk/> (Accessed: 1 December 2023).
- **Edge, J. S. et al. (2021)** 'Lithium ion battery degradation: what you need to know', *Physical Chemistry Chemical Physics. Royal Society of Chemistry*, 23(14), pp. 8200–8221. doi: 10.1039/d1cp00359c.
- **Feng, X. et al. (2019)** 'Online State-of-Health Estimation for Li-Ion Battery Using Partial Charging Segment Based on Support Vector Machine', *IEEE Transactions on Vehicular Technology. IEEE*, 68(9), pp. 8583–8592. doi: 10.1109/TVT.2019.2927120.
- **Fioravanti, R. et al. (2020)** 'Predictive-Maintenance Practices For Operational Safety of Battery Energy Storage Systems', *IEEE Power and Energy Magazine*, 18(6), pp. 86–97. doi: 10.1109/MPE.2020.3014542.
- **Grünwald, P. D. (2007)** 'Linear Regression', in 'The Minimum Description Length Principle'. MIT Press, pp. 335–368.
- **Guha, A. and Patra, A. (2017)** 'State of Health Estimation of Lithium-Ion Batteries Using Capacity Fade and Internal Resistance Growth Models', *IEEE Transactions on Transportation Electrification*. doi: 10.1109/TTE.2017.2776558.
- **Hamar, J. C. et al. (2021)** 'State-of-health estimation using a neural network trained on vehicle data', *Journal of Power Sources. Elsevier B.V.*, 512(September). doi: 10.1016/j.jpowsour.2021.230493.
- **Han, D. et al. (2022)** 'Health indicator evaluation for battery pack inconsistency and SOH estimation based on LSTM'. *IEEE*.
- **He, J. et al. (2020)** 'State-of-Health Estimation of Lithium-Ion Batteries Using Incremental Capacity Analysis Based on Voltage-Capacity Model', *IEEE Transactions on Transportation Electrification*, 6(2), pp. 417–426. doi: 10.1109/TTE.2020.2994543.
- **Hemavathi Sugumar (2021)** 'Overview of cell balancing methods for Li-ion battery technology', *Energy Storage*, 3(2). doi: 10.1002/est2.203.
- **Huo, Q. et al. (2021)** 'Bayesian Network Based State-of-Health Estimation for Battery on Electric Vehicle Application and its Validation through Real-World Data', *IEEE Access*, 9, pp. 11328–11341. doi: 10.1109/ACCESS.2021.3050557.

- **IEEE Standards Coordinating Committee 21 IEEE (2009)** *Guide for Design, Operation, and Maintenance of Battery Energy Storage Systems, both Stationary and Mobile, and Applications Integrated with Electric Power Systems*, IEEE SA.
- **Jia, J. et al. (2021)** 'A multi-scale state of health prediction framework of lithium-ion batteries considering the temperature variation during battery discharge', *Journal of Energy Storage*. Elsevier Ltd, 42(201901), p. 103076. doi: 10.1016/j.est.2021.103076.
- **Kafadarova, N. et al. (2022)** 'State of Health Determination of Batteries by Analyzing the Rate of Increase of Their Temperature', 2022 IEEE 9th Electronics System-Integration Technology Conference, ESTC 2022 - Proceedings. IEEE, pp. 492–497. doi: 10.1109/ESTC55720.2022.9939440.
- **Kaur, K. et al. (2021)** 'Deep learning networks for capacity estimation for monitoring SOH of Li-ion batteries for electric vehicles', *International Journal of Energy Research*, 45(2), pp. 3113–3128. doi: 10.1002/er.6005.
- **Keller, J. M., Liu, D. and Fogel, D. B. (2016)** 'Multilayer Neural Networks and Backpropagation', in *Fundamentals of Computational Intelligence: Neural Networks, Fuzzy Systems, and Evolutionary Computation*. IEEE, pp. 35–60. Available at: <http://ieeexplore.ieee.org/document/7547444>.
- **Khaleghi Rahimian, S. and Tang, Y. (2023)** 'A Practical Data-Driven Battery State-of-Health Estimation for Electric Vehicles', *IEEE Transactions on Industrial Electronics*, 70(2), pp. 1973–1982. doi: 10.1109/TIE.2022.3165295.
- **Kim, M. Y. et al. (2014)** 'A chain structure of switched capacitor for improved cell balancing speed of lithium-ion batteries', *IEEE Transactions on Industrial Electronics*. IEEE, 61(8), pp. 3989–3999. doi: 10.1109/TIE.2013.2288195.
- **Lee, J. H. and Lee, I. S. (2021)** 'Online Estimation Algorithm of SOC and SOH Using Neural Network for Lithium Battery', *Proceedings of the 3rd IEEE Eurasia Conference on IOT, Communication and Engineering 2021, ECICE 2021*. IEEE, pp. 568–571. doi: 10.1109/ECICE52819.2021.9645632.
- **Lee, P. Y. et al. (2022)** 'Principle component analysis-based optimized feature extraction merged with nonlinear regression model for improved state-of-health prediction', *Journal of Energy Storage*. Elsevier Ltd, 48(September 2021), p. 104026. doi: 10.1016/j.est.2022.104026.
- **Li, J. et al. (2015)** 'Discharge capacity estimation for Li-ion batteries based on particle filter under multi-operating conditions', *Energy*. Elsevier Ltd, 86, pp. 638–648. doi: 10.1016/j.energy.2015.04.021.
- **Li, S. et al. (2022)** 'Aging Mitigation for Battery Energy Storage System in Electric Vehicles', *IEEE Transactions on Smart Grid*, (September), pp. 1–12. doi: 10.1109/TSG.2022.3210041.

- **Li, Yi et al. (2019)** 'Data-driven health estimation and lifetime prediction of lithium-ion batteries: A review', *Renewable and Sustainable Energy Reviews*, 113(June). doi: 10.1016/j.rser.2019.109254.
- **Li, Yuanyuan et al. (2019)** 'Lithium-ion battery state of health monitoring based on ensemble learning', *IEEE Access. IEEE*, 7, pp. 8754–8762. doi: 10.1109/ACCESS.2019.2891063.
- **Liu, D. et al. (2018)** 'An on-line state of health estimation of lithium-ion battery using unscented particle filter', *IEEE Access. IEEE*, 6, pp. 40990–41001. doi: 10.1109/ACCESS.2018.2854224.
- **Liu, W., Xu, Y. and Feng, X. (2020)** 'A Hierarchical and Flexible Data-Driven Method for Online State-Of-Health Estimation of Li-ion Battery', *IEEE Transactions on Vehicular Technology*, 9545(c). doi: 10.1109/TVT.2020.3037088.
- **Liu, W. and Yan, X. (2020)** 'Data-Driven Online Health Estimation of Li-Ion Batteries Using A Novel Energy-Based Health Indicator', *IEEE Transactions on Energy Conversion*, 35(3), pp. 1715–1718. doi: 10.1109/TEC.2020.2995112.
- **Locorotondo, E. et al. (2020)** 'Electrical lithium battery performance model for second life applications', *Proceedings - 2020 IEEE International Conference on Environment and Electrical Engineering and 2020 IEEE Industrial and Commercial Power Systems Europe, IEEEIC / I and CPS Europe 2020*, pp. 0–5. doi: 10.1109/IEEEIC/ICPSEurope49358.2020.9160496.
- **Luque, J. et al. (2023)** 'Machine Learning Estimation of Battery Efficiency and Related Key Performance Indicators in Smart Energy Systems', *Energies*, 16(14). doi: 10.3390/en16145548.
- **Medrano Márquez, J. Á., González Ajuech, V. L. and de León Santiago, V. M. (2017)** *Mantenimiento: Técnicas y aplicaciones industriales*. Grupo Editorial Patria. Available at: <https://books.google.es/books?id=hZCDwAAQBAJ>.
- **Meng, J. et al. (2020)** 'An optimized ensemble learning framework for lithium-ion Battery State of Health estimation in energy storage system', *Energy. Elsevier Ltd*, 206, p. 118140. doi: 10.1016/j.energy.2020.118140.
- **MESA (2018)** 'MESA-ESS Specification', *Mesastandards*. Available at: <http://mesastandards.org/wp-content/uploads/MESA-ESS-Specification-December-2018-Version-1.pdf>.
- **Mestrallet, F. et al. (2014)** 'Multiphase interleaved converter for lithium battery active balancing', *IEEE Transactions on Power Electronics. IEEE*, 29(6), pp. 2874–2881. doi: 10.1109/TPEL.2013.2276152.
- **Mora, A. (2009)** 'Mantenimiento - planeación, ejecución y control'. Alpha Editorial. Available at: <https://books.google.es/books?id=TYc3DQAAQBAJ>.

- **Oji, T. et al. (2021)** 'Data-Driven Methods for Battery SOH Estimation: Survey and a Critical Analysis', *IEEE Access. IEEE*, 9, pp. 126903–126916. doi: 10.1109/ACCESS.2021.3111927.
- **OSIsoft (2020)** 'Visualizar datos de PI System' Available at: <https://www.aveva.com/en/products/aveva-pi-system/>. (Accessed:1 December 2023).
- **Paidi, R. and Gudey, S. K. (2022)** 'Active and Passive Cell Balancing Techniques for Li-Ion Batteries used in EVs', *2022 IEEE International Power and Renewable Energy Conference (IPRECON)*, Kollam, India. *IEEE*, pp. 1–6. doi: 10.1109/iprecon55716.2022.10059573.
- **Palencia, O. G. (2011)** 'Gestión Moderna del Mantenimiento Industrial. Principios fundamentales'. Ediciones de la U. Available at: <https://books.google.es/books?id=lyejDwAAQBAJ>.
- **Pan, H. et al. (2018)** 'Novel battery state-of-health online estimation method using multiple health indicators and an extreme learning machine', *Energy. Elsevier Ltd*, 160, pp. 466–477. doi: 10.1016/j.energy.2018.06.220.
- **Phung, T. H., Collet, A. and Crebier, J. C. (2014)** 'An optimized topology for next-to-next balancing of series-connected lithium-ion cells', *IEEE Transactions on Power Electronics. IEEE*, 29(9), pp. 4603–4613. doi: 10.1109/TPEL.2013.2284797.
- **Qu, F. et al. (2022)** 'Systematic Overview of Active Battery Equalization Structures: Mathematical Modeling and Performance Evaluation', *IEEE Transactions on Energy Conversion. IEEE*, 37(3), pp. 1685–1703. doi: 10.1109/TEC.2022.3142818.
- **Qu, J. et al. (2019)** 'A Neural-Network-Based Method for RUL Prediction and SOH Monitoring of Lithium-Ion Battery', *IEEE Access. IEEE*, 7, pp. 87178–87191. doi: 10.1109/ACCESS.2019.2925468.
- **Rasmussen, C. E. and C. K. I. W. (2006)** 'Gaussian processes for machine learning.', *International journal of neural systems*. 2006 Massachusetts Institute of Technology. doi: 10.1142/S0129065704001899.
- **Reniers, J M, G Mulder, and D. A. H. (2020)** *Oxford Energy Trading Battery Degradation Dataset*, University of Oxford. Available at: <https://ora.ox.ac.uk/objects/uuid:9aae61af-2949-49f1-8ad5-6aea448979e5>.
- **Ruan, H. et al. (2021)** 'State of Health Estimation of Lithium-ion Battery Based on Constant-Voltage Charging Reconstruction', *IEEE Journal of Emerging and Selected Topics in Power Electronics. IEEE*, 6777(c). doi: 10.1109/JESTPE.2021.3098836.
- **Schimpe, M. et al. (2018)** 'Comprehensive Modeling of Temperature-Dependent

Degradation Mechanisms in Lithium Iron Phosphate Batteries, *Journal of The Electrochemical Society*, 165(2), pp. A181–A193. doi: 10.1149/2.1181714jes.

- **Schweiger, H. G. et al. (2010)** 'Comparison of several methods for determining the internal resistance of lithium ion cells', *Sensors*, 10(6), pp. 5604–5625. doi: 10.3390/s100605604.
- **Shang, Y. et al. (2015)** 'A cell-to-cell battery equalizer with zero-current switching and zero-voltage gap based on quasi-resonant *I*c converter and boost converter', *IEEE Transactions on Power Electronics*. IEEE, 30(7), pp. 3731–3747. doi: 10.1109/TPEL.2014.2345672.
- **Shang, Y. et al. (2017)** 'An Automatic Equalizer Based on Forward-Flyback Converter for Series-Connected Battery Strings', *IEEE Transactions on Industrial Electronics*. IEEE, 64(7), pp. 5380–5391. doi: 10.1109/TIE.2017.2674617.
- **She, C. et al. (2021)** 'Battery State of Health Estimation Based on Incremental Capacity Analysis Method: Synthesizing from Cell-Level Test to Real-World Application', *IEEE Journal of Emerging and Selected Topics in Power Electronics*, pp. 1–11. doi: 10.1109/JESTPE.2021.3112754.
- **Shen, P. et al. (2018)** 'The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles', *IEEE Transactions on Vehicular Technology*. doi: 10.1109/TVT.2017.2751613.
- **Smith, K. et al. (2018)** 'Performance and health test procedure for grid energy storage systems', *IEEE Power and Energy Society General Meeting, 2018-Janua*, pp. 1–5. doi: 10.1109/PESGM.2017.8274326.
- **Soon Ng, K. et al. (2009)** 'Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries', *Applied Energy*, 86, pp. 1506–1511. doi: 10.1016/j.apenergy.2008.11.021.
- **Sullivan, G. P. et al. (2010)** 'Operations & Maintenance Best Practices: A Guide to Achieving Operational Efficiency', *Federal Energy Management Program*, (August 2010), p. 321. Available at: http://www1.eere.energy.gov/femp/pdfs/omguide_complete.pdf.
- **Tan, Y. and Zhao, G. (2020)** 'Transfer learning with long short-term memory network for state-of-health prediction of lithium-ion batteries', *IEEE Transactions on Industrial Electronics*. IEEE, 67(10), pp. 8723–8731. doi: 10.1109/TIE.2019.2946551.
- **Tian, J., Xiong, R. and Shen, W. (2020)** 'State-of-Health Estimation Based on Differential Temperature for Lithium Ion Batteries', *IEEE Transactions on Power Electronics*. IEEE, 35(10), pp. 10363–10373. doi: 10.1109/TPEL.2020.2978493.
- **Tian, J., Xiong, R. and Yu, Q. (2019)** 'Fractional-Order Model-Based Incremental Capacity Analysis for Degradation State Recognition of Lithium-Ion Batteries',

IEEE Transactions on Industrial Electronics. doi: 10.1109/TIE.2018.2798606.

- **Timilsina, L. et al. (2023)** 'Battery Degradation in Electric and Hybrid Electric Vehicles: A Survey Study', *IEEE Access*. IEEE, 11(May), pp. 42431–42462. doi: 10.1109/ACCESS.2023.3271287.
- **Tran, M. K. et al. (2022)** 'A Review of Lithium-Ion Battery Thermal Runaway Modeling and Diagnosis Approaches', *Processes*, 10(6). doi: 10.3390/pr10061192.
- **Urquizo, J. and Singh, P. (2023)** 'A review of health estimation methods for Lithium-ion batteries in Electric Vehicles and their relevance for Battery Energy Storage Systems', *Journal of Energy Storage*. Elsevier Ltd, 73(PD), p. 109194. doi: 10.1016/j.est.2023.109194.
- **Vichard, L. et al. (2021)** 'A method to estimate battery SOH indicators based on vehicle operating data only', *Energy*. Elsevier Ltd, 225, p. 120235. doi: 10.1016/j.energy.2021.120235.
- **Wang, J. et al. (2022)** 'State of health estimation based on modified Gaussian process regression for lithium-ion batteries', *Journal of Energy Storage*. Elsevier Ltd, 51(March), p. 104512. doi: 10.1016/j.est.2022.104512.
- **Wang, L. et al. (2016)** 'On-board state of health estimation of LiFePO₄ battery pack through differential voltage analysis', *Applied Energy*. Elsevier Ltd, 168, pp. 465–472. doi: 10.1016/j.apenergy.2016.01.125.
- **Wang, Z. et al. (2019)** 'State of health estimation of lithium-ion batteries based on the constant voltage charging curve', *Energy*. Elsevier Ltd, 167, pp. 661–669. doi: 10.1016/j.energy.2018.11.008.
- **Wei, Y. et al. (2019)** 'Switch Matrix Algorithm for Series Lithium Battery Pack Equilibrium Based on Derived Acceleration Information Gauss-Seidel', *Mathematical Problems in Engineering*, 2019. doi: 10.1155/2019/8075453.
- **Wei, Z. et al. (2022)** 'Multistage State of Health Estimation of Lithium-Ion Battery with High Tolerance to Heavily Partial Charging', *IEEE Transactions on Power Electronics*. IEEE, 37(6), pp. 7432–7442. doi: 10.1109/TPEL.2022.3144504.
- **Weng, C. et al. (2013)** 'On-board state of health monitoring of lithium-ion batteries using incremental capacity analysis with support vector regression', *Journal of Power Sources*, 235, pp. 36–44. doi: 10.1016/j.jpowsour.2013.02.012.
- **Wu, J. et al. (2022)** 'State of health estimation of lithium-ion batteries using Autoencoders and Ensemble Learning', *Journal of Energy Storage*, 55(August). doi: 10.1016/j.est.2022.105708.
- **Wu, Q. et al. (2021)** 'An Intelligent Preventive Maintenance Method based on Reinforcement Learning for Battery Energy Storage Systems', *IEEE Transactions*

- on *Industrial Informatics*. IEEE, 17(12), pp. 8254–8264. doi: 10.1109/TII.2021.3066257.
- **Wu, Y. et al. (2020)** 'State of Health Estimation for Lithium-Ion Batteries Based on Healthy Features and Long Short-Term Memory', *IEEE Access*, 8, pp. 28533–28547. doi: 10.1109/ACCESS.2020.2972344.
 - **Xu, J. et al. (2013)** 'SOC based battery cell balancing with a novel topology and reduced component count', *Energies*, 6(6), pp. 2726–2740. doi: 10.3390/en6062726.
 - **Yang, S. et al. (2021)** 'A voltage reconstruction model based on partial charging curve for state-of-health estimation of lithium-ion batteries', *Journal of Energy Storage*. Elsevier Ltd, 35(August 2020), p. 102271. doi: 10.1016/j.est.2021.102271.
 - **Yao, H. et al. (2020)** 'Novel Lithium-Ion Battery State-of-Health Estimation Method Using a Genetic Programming Model', *IEEE Access*, 8, pp. 95333–95344. doi: 10.1109/ACCESS.2020.2995899.
 - **You, G. W., Park, S. and Oh, D. (2017)** 'Diagnosis of Electric Vehicle Batteries Using Recurrent Neural Networks', *IEEE Transactions on Industrial Electronics*. IEEE, 64(6), pp. 4885–4893. doi: 10.1109/TIE.2017.2674593.
 - **Yu, Q. et al. (2021)** 'A model-based sensor fault diagnosis scheme for batteries in electric vehicles', *Energies*, 14(4). doi: 10.3390/en14040829.
 - **Zhang, L. et al. (2022)** 'Improved Cycle Aging Cost Model for Battery Energy Storage Systems Considering More Accurate Battery Life Degradation', *IEEE Access*, 10, pp. 297–307. doi: 10.1109/ACCESS.2021.3139075.
 - **Zhang, Q. et al. (2021)** 'State-of-health estimation of batteries in an energy storage system based on the actual operating parameters', *Journal of Power Sources*. Elsevier B.V., 506(April 2021), p. 230162. doi: 10.1016/j.jpowsour.2021.230162.
 - **Zhang, Y. and Tian, Z. (2019)** 'State of health of lithium ion battery estimation based on charging process', *Proceedings of 2019 IEEE 3rd Advanced Information Management, Communicates, Electronic and Automation Control Conference, IMCEC 2019, (Imcec)*, pp. 688–692. doi: 10.1109/IMCEC46724.2019.8984001.
 - **Zhao, C. et al. (2021)** 'Data-driven State of Health Modeling of Battery Energy Storage Systems Providing Grid Services', *2021 11th International Conference on Power, Energy and Electrical Engineering, CPEEE 2021*, (64018), pp. 43–49. doi: 10.1109/CPEEE51686.2021.9383356.
 - **Zou, Y. et al. (2015)** 'Combined State of Charge and State of Health estimation over lithium-ion battery cell cycle lifespan for electric vehicles', *Journal of Power Sources*. Elsevier B.V., 273, pp. 793–803. doi: 10.1016/j.jpowsour.2014.09.146.

Anexo I:

Histogramas de datos




Fig. I.1. Distribuciones de las tensiones de los 19 rack para el SBMS1.




Fig. I.2. Distribuciones de las intensidades de los 19 rack para el SBMS1.




Fig. I.3. Distribuciones de los DSRa de los 19 rack para el SBMS1.




Fig. I.4. Distribuciones de las tensiones de los 19 rack para el SBMS2.




Fig. I.5. Distribuciones de las intensidades de los 19 rack para el SBMS2.




Fig. I.6. Distribuciones de los DSRa de los 19 rack para el SBMS2.




Fig. I.7. Distribuciones de las tensiones de los 19 rack para el SBMS3.




Fig. I.8. Distribuciones de las intensidades de los 19 rack para el SBMS3.




Fig. I.9. Distribuciones de los DSRa de los 19 rack para el SBM33.




Fig. I.10. Distribuciones de las tensiones de los 19 rack para el BM56.




Fig. I.11. Distribuciones de las intensidades de los 19 rack para el SBMS6.




Fig. I.12. Distribuciones de los DSRa de los 19 rack para el SBMS6.




Fig. I.13. Distribuciones de las tensiones de los 19 rack para el SBMS8.




Fig. I.14. Distribuciones de las intensidades de los 19 rack para el SBMS8.




Fig. I.15. Distribuciones de los DSRa de los 19 rack para el SBMS8.




Fig. I.16. Distribuciones de las tensiones de los 19 rack para el SBMS12.




Fig. I.17. Distribuciones de las intensidades de los 19 rack para el SBMS12.




Fig. I.18. Distribuciones de los DSRa de los 19 rack para el SBMS12.

Anexo II:

Hiperparámetros de los modelos




Fig. II.1. Esquema e Hiperpárametros del modelo ensemble SBMS1.

Tabla II.1. Errores R ² de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS1.										
Ensemble SBMS1	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,60	0,66	0,80	0,67	0,24	0,32	0,77	0,83	0,93	0,88

Ensemble SBMS1	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,74	0,64	0,69	0,28	0,12	0,20	0,25	0,35	0,62

Modelo Ensemble SBMS2




Fig. II.2. Esquema e Hiperparámetros del modelo ensemble SBMS2.

Tabla II.2. Errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS2.

Ensemble SBMS2	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,92	0,94	0,84	0,92	0,89	0,93	0,65	0,92	0,82	0,89

Ensemble SBMS2	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,88	0,93	0,90	0,97	0,93	0,90	0,91	0,93	0,83

Modelo Ensemble SBMS3




Fig. II.3. Esquema e Hiperparámetros del modelo ensemble SBMS3.

Tabla II.3. Errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS3.

Ensemble SBMS3	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,92	0,94	0,84	0,92	0,89	0,93	0,65	0,92	0,82	0,89

Ensemble SBMS3	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,88	0,93	0,90	0,97	0,93	0,90	0,91	0,93	0,83

Modelo Ensemble SBMS6




Fig. II.4. Esquema e Hiperparámetros del modelo ensemble SBMS6

Tabla II.4. Errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS6.

Ensemble SBMS6	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,88	0,77	0,80	0,76	0,82	0,84	0,93	0,88	0,92	0,92

Ensemble SBMS6	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,88	0,84	0,78	0,84	0,85	0,79	0,89	0,89	0,73

Modelo Ensemble BMS12




Fig. II.5. Esquema e Hiperparámetros del modelo ensemble SBMS12

Tabla II.5. Errores R2 de los 19 modelos ensemble, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS12.

Ensemble SBMS12	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,52	0,78	0,88	0,73	0,56	0,62	0,56	0,51	0,73	0,42

Ensemble SBMS12	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,77	0,84	0,54	0,20	0,12	0,59	0,25	0,65	0,74




Fig. II.6. Esquema e Hiperparámetros del modelo SVM SBMS1.

Tabla II.6. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS1.

SVM SBMS1	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,60	0,66	0,80	0,67	0,24	0,32	0,77	0,83	0,93	0,88

SVM SBMS1	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,74	0,64	0,69	0,28	0,12	0,20	0,25	0,35	0,62

Modelo SVM SBMS2




Fig. II.7. Esquema e Hiperparámetros del modelo SVM SBMS2.

Tabla II.7. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS2.

SVM SBMS2	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,92	0,94	0,84	0,92	0,89	0,93	0,65	0,92	0,82	0,89

SVM SBMS2	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,88	0,93	0,90	0,97	0,93	0,90	0,91	0,93	0,83




Fig. II.8. Esquema e Hiperparámetros del modelo SVM SBMS3.

Tabla II.8. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS3.

SVM SBMS3	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R² [%]	0,72	0,63	0,36	0,41	0,42	0,45	0,74	0,77	0,80	0,57

SVM SBMS3	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R² [%]	0,79	0,80	0,44	0,82	0,70	0,75	0,63	0,62	0,61




Fig. II.9. Esquema e Hiperparametros del modelo SVM SBMS6.

Tabla II.9. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS6.

SVM SBMS6	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,88	0,77	0,80	0,76	0,82	0,84	0,93	0,88	0,92	0,92

SVM SBMS6	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,88	0,84	0,78	0,84	0,85	0,79	0,89	0,89	0,73





Fig. II.10. Esquema e Hiperparámetros del modelo SVM SBMS12.

Tabla II.10. Errores R2 de los 19 modelos SVM, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS12.

SVM SBMS12	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R²[%]	0,52	0,78	0,88	0,73	0,56	0,62	0,56	0,51	0,73	0,42

SVM SBMS12	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R²[%]	0,77	0,84	0,54	0,20	0,12	0,59	0,25	0,65	0,74

Modelo LR SBMS1



Hiperparametros del Modelo

Entradas	Coefficientes	Salida Rack1	Salida Rack2	Salida Rack3	Salida Rack4	Salida Rack5	Salida Rack6	Salida Rack7	Salida Rack8	Salida Rack9	Salida Rack10
(cte.) Intercept	1.48493E-06	2.98665E-07	2.55127E-06	1.41495E-06	3.91969E-06	5.61083E-08	3.16422E-07	-1.33479E-06	9.11494E-07	1.64073E-06	
DSRa de Rack1	p1	0	0.266620234	-0.05557748	0.040405612	0.063722775	-0.098100542	0.234418888	-0.061700698	0.170401296	-0.242124685
DSRa de Rack2	p2	0.198902124	0	-0.012675922	-0.095063254	0.727707858	0.038374568	-0.356584047	-0.073744211	-0.12926683	0.179408721
DSRa de Rack3	p3	0.047775213	0.349256726	0	0.761397231	-0.49858141	0.856845907	-0.242957871	0.333562399	0.138269758	0.533230805
DSRa de Rack4	p4	0.144526322	-0.286380812	0.037707062	0	-0.101119078	-0.436131216	-0.148582727	0.500047719	0.169772762	0.229417245
DSRa de Rack5	p5	-0.022699205	0.175819075	-0.104997649	-0.006116676	0	0.191369078	0.144463345	-0.168854187	-0.16893609	0.476932373
DSRa de Rack6	p6	0.055936413	-0.193258253	0.671480566	-0.914071243	0.723942527	0	-0.095848961	0.749582024	0.174436789	-0.922519844
DSRa de Rack7	p7	-0.278819089	-0.043098991	0.058604235	-0.263788147	0.079944863	-0.168107589	0	-0.106175705	-0.22187116	-0.007570522
DSRa de Rack8	p8	0.189159095	-0.181934943	-0.10038766	0.24820717	0.118709327	0.104696089	0.241821172	0	0.213724349	0.007849335
DSRa de Rack9	p9	-0.255681753	0.3380125	0.089360587	0.624969544	-0.317337797	0.454867614	-0.31875824	0.512347585	0	0.62633534
DSRa de Rack10	p10	0.364949117	0.002667424	0.16904312	-0.1677927	0.158675715	-0.291225961	0.049370567	0.320544086	0.439613477	0
DSRa de Rack11	p11	-0.067499767	-0.0400261	-0.151997688	0.304311121	-0.087687492	0.072725875	0.246279834	0.075515924	-0.0412466	0.206565921
DSRa de Rack12	p12	0.175853091	0.274631343	0.023947711	-0.054749301	-0.044511984	-0.019769779	0.130114689	-0.098167861	-0.09020741	0.104784607
DSRa de Rack13	p13	-0.268687717	-0.142423696	0.035450514	-0.285859157	0.072748656	-0.085079941	0.577111659	0.216892241	0.52331374	-0.315182803
DSRa de Rack14	p14	-0.339619327	-0.149621956	-0.759536942	0.302692292	0.151307493	0.365155449	-8.21501E-05	-0.236486979	0.191105864	-0.152613355
DSRa de Rack15	p15	0.165597808	-0.029673359	0.039025474	-0.022037981	0.001813972	-0.016614984	-0.266277589	-0.114466742	-0.17966576	-0.00798751
DSRa de Rack16	p16	-0.225304044	-0.134773193	0.138748923	-0.233624374	-0.249876674	-0.045566074	0.181661153	0.01202027	0.246020793	0.306588108
DSRa de Rack17	p17	0.177509166	0.425942233	0.18209242	0.751207328	-0.016626816	0.376921743	-0.073190858	-0.079055363	-0.28760668	0.316238827
DSRa de Rack18	p18	0.180148554	-0.055941967	-0.047184075	0.084736368	0.025322518	0.016213653	0.257459678	0.04320155	-0.12083466	0.148181523
DSRa de Rack19	p19	0.576695856	0.585791793	0.477797582	0.025153668	-0.057811612	-0.220809935	0.303509688	-0.004957119	-0.07878987	-0.47681054

Entradas	Coefficientes	Salida Rack11	Salida Rack12	Salida Rack13	Salida Rack14	Salida Rack15	Salida Rack16	Salida Rack17	Salida Rack18	Salida Rack19
(cte.) Intercept	5.17692E-07	-1.69719E-06	7.81557E-08	2.96143E-06	-3.86448E-07	-0.15406E-07	-1.24755E-06	7.19398E-07	-2.72E-06	
DSRa de Rack1	p1	0.1592607	-0.115649957	-0.257880895	-0.126696789	0.545745772	0.21827779	-0.188660699	-0.1846672	-0.4850727
DSRa de Rack2	p2	0.229021301	0.14307984	-0.074974673	-0.045471818	0.031387702	-0.128664579	0.193531272	-0.05764936	0.500586516
DSRa de Rack3	p3	-0.209176899	0.2033496	0.220412912	-0.921340959	-0.267195345	0.059947603	-0.13357026	-0.343912553	0.505173885
DSRa de Rack4	p4	-0.115551294	0.21007444	0.097365962	0.036539815	-0.561439791	-0.142771141	0.349088018	0.200250617	0.422814963
DSRa de Rack5	p5	0.051608861	-0.026477226	-0.064700476	-0.009470935	0.273430892	-0.111397087	-0.022756297	0.245544717	0.195768987
DSRa de Rack6	p6	0.045641328	-0.027665581	-0.066845924	0.534807017	0.036779909	0.225052939	0.183648721	-0.073907564	-0.38039087
DSRa de Rack7	p7	-0.080558228	0.104545463	0.196503952	0.098771056	-0.041696992	0.04388646	-0.0346299	0.163168638	0.071133661
DSRa de Rack8	p8	-0.374837732	0.176433867	0.276685909	-0.106377144	-0.048148783	-0.160673408	0.072516798	-0.000695924	0.154611097
DSRa de Rack9	p9	0.335003146	-0.238664309	-0.030657205	0.180170274	0.099429088	0.177316605	-0.229381615	-0.051521832	-0.29989058
DSRa de Rack10	p10	0.089758655	-0.003051287	-0.141040345	0.040084456	0.290316824	0.057892335	0.043129236	0.238634093	-0.425648412
DSRa de Rack11	p11	0	0.523318414	0.691451575	-0.115592926	-0.162365121	-0.393555521	-0.260612832	0.479488657	0.194870026
DSRa de Rack12	p12	0.216664927	0	0.051852478	-0.026027592	-0.37661165	0.273083334	0.009892747	-0.128872358	-0.159514416
DSRa de Rack13	p13	0.695081293	0.5211386206	0	0.0214365	-0.029914287	0.039230062	0.093838516	-0.196871751	0.217681258
DSRa de Rack14	p14	0.011187499	-0.242882215	0.049409852	0	0.554752896	0.158351486	0.331321786	0.179494423	0.589021954
DSRa de Rack15	p15	-0.014650359	-0.011515743	0.120239988	0.050048011	0	0.013971379	0.07519789	-0.068219755	0.014497196
DSRa de Rack16	p16	-0.327228656	0.386309482	0.238174667	0.17573696	0.244789028	0	0.291749465	0.248245404	0.256177021
DSRa de Rack17	p17	0.283393915	0.021050871	-0.345080028	0.393009204	0.646634409	0.556919995	0	0.246043277	-0.71037969
DSRa de Rack18	p18	-0.012484602	-0.226854358	0.06263138	0.002738669	-0.3401472	0.145993697	0.327083808	0	0.121512612
DSRa de Rack19	p19	0.024560085	-0.309643547	-0.037028458	0.482645868	0.284829916	0.298156845	-0.258180568	0.144827418	0

Fig. II.11. Esquema e Hiperparámetros del modelo LR SBMS1.

Tabla II.11. Errores R2 de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS1.

LR SBMS1	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,74	0,74	0,80	-0,43	0,90	0,99	0,57	0,38	0,87	0,83

LR SBMS1	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,95	0,57	0,89	0,98	0,92	0,96	0,99	0,98	0,91




Fig. II.12. Esquema e Hiperparámetros del modelo LR SBMS2.

Tabla II.12. Tabla con los errores R2 de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS2.

LR SBMS2	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,93	0,81	0,80	0,84	0,70	0,80	0,54	0,89	0,94	0,56

LR SBMS2	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,70	0,75	0,73	0,93	0,88	0,87	0,88	0,93	0,74




Fig. II.13. Esquema e Hiperparámetros del modelo LR SBMS3.

Tabla II.13. Tabla con los errores R2 de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS3.

LR SBMS3	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,83	0,76	0,76	0,62	0,85	0,80	0,91	0,80	0,89	0,78

LR SBMS3	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,80	0,72	0,85	0,80	0,81	0,80	0,79	0,81	0,72





Fig. II.14. Esquema e Hiperparámetros del modelo LR SBMS6.

Tabla II.14. Tabla con los errores R2 de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS6.

LR SBMS6	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,79	0,57	0,90	0,93	0,88	0,81	0,87	0,93	0,87	0,68

LR SBMS6	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,77	0,90	0,46	0,97	0,90	0,91	0,91	0,65	0,37

Modelo LR SBMS12



Hiperparametros del Modelo

Entradas	Coefficientes	Salida Rack1	Salida Rack2	Salida Rack3	Salida Rack4	Salida Rack5	Salida Rack6	Salida Rack7	Salida Rack8	Salida Rack9	Salida Rack10
(cte.) Intercept	-1.92881E-06	1.40085E-06	-1.7397E-06	-2.71987E-06	-1.3512E-06	1.60714E-06	-3.33047E-07	-7.61688E-08	1.03346E-06	3.40066E-06	
DSRa de Rack1	p1	0	0.312300126	-0.18339626	-0.017650923	0.257312492	-0.0554912	0.467775438	-0.089162263	-0.299409301	0.145511502
DSRa de Rack2	p2	0.2545902	0	0.079086159	0.347827588	-0.346915211	0.341700307	0.034436369	0.114581525	0.178300621	-0.254605775
DSRa de Rack3	p3	-0.148389165	0.128970581	0	-0.458907203	-0.008160024	0.076102648	0.069630891	0.443313602	-0.183002029	0.36085474
DSRa de Rack4	p4	-0.194136837	0.402962705	-0.194025029	0	0.066711714	0.005786192	0.084024489	0.374396657	0.116432708	0.018344181
DSRa de Rack5	p5	0.55019981	-0.438351666	-0.120194724	0.171378737	0	0.648190806	-0.303928348	0.14647594	0.55044376	-0.094071052
DSRa de Rack6	p6	0.053195789	0.089622515	-0.092731907	0.010352418	0.077575947	0	0.290664691	0.043784106	-0.047658814	0.01285639
DSRa de Rack7	p7	0.255897723	0.027169263	0.058890251	0.119774735	-0.166414997	0.715108211	0	-0.107334258	0.193789017	0.010702373
DSRa de Rack8	p8	0.110534111	-0.138413493	0.635889137	0.579013117	-0.128406905	0.651376054	-0.448147701	0	0.253030534	0.448433936
DSRa de Rack9	p9	-0.083285842	0.141664447	-0.108776248	0.24275092	0.596460015	-0.402046901	0.428509636	0.109272412	0	-0.06403311
DSRa de Rack10	p10	0.079621525	-0.10585839	0.225151748	-0.110237412	0.033126016	-0.625819309	0.353657224	0.523961852	0.026534955	0
DSRa de Rack11	p11	-0.135570323	-0.043800584	0.026327719	-0.025009736	0.166974409	-0.129351999	-0.041392842	0.076708352	0.045927012	-0.131870901
DSRa de Rack12	p12	0.248366853	-0.021755748	0.44891254	0.421500727	0.270960853	0.250634634	0.021475756	-0.372746278	-0.299325894	0.171598156
DSRa de Rack13	p13	-0.057426777	0.053343449	0.02139856	0.036097578	-0.120307571	-0.149794141	-0.057265471	0.055853465	0.226331842	-0.130631089
DSRa de Rack14	p14	-0.034921187	-0.075807115	-0.118898483	0.084915966	0.045903571	0.190090036	0.15052343	0.131404358	-0.208904733	-0.008747804
DSRa de Rack15	p15	-0.009424102	0.001065899	-0.005090204	-0.039016638	0.050560448	-0.246906791	-0.026799084	0.005918805	0.021674036	0.03476414
DSRa de Rack16	p16	-0.063859846	0.823479269	-0.134308759	0.225286377	0.375214268	-0.665602262	0.299952838	-0.098081083	-0.02860346	-0.242933213
DSRa de Rack17	p17	0.1437779	0.042903672	0.018626101	-0.054960607	0.205630001	0.173142519	0.03021735	-0.08160304	-0.223804504	0.246089891
DSRa de Rack18	p18	-0.043612818	-0.133757603	0.197266852	-0.201959829	-0.155169214	-0.13540871	-0.013362993	-0.018079834	0.365441411	-0.092906092
DSRa de Rack19	p19	0.188944156	-0.13875734	0.385802256	-0.124389827	-0.126052857	0.202349513	-0.313348472	-0.293246848	0.328370399	0.362019245

Entradas	Coefficientes	Salida Rack11	Salida Rack12	Salida Rack13	Salida Rack14	Salida Rack15	Salida Rack16	Salida Rack17	Salida Rack18	Salida Rack19
(cte.) Intercept	-1.07249E-07	1.26572E-06	9.70114E-08	3.77457E-07	1.81314E-06	9.09865E-07	-3.39677E-07	-6.92799E-07	2.24676E-07	
DSRa de Rack1	p1	-0.27847047	0.214414239	0.039433634	0.117573469	-0.307712063	-0.104609154	0.096315918	0.360726014	
DSRa de Rack2	p2	-0.208418189	0.061077286	0.356778066	-0.31867425	0.176467348	0.374451211	0.098861254	-0.161994634	-0.110233755
DSRa de Rack3	p3	0.159663609	0.216258923	0.085606396	-0.255677834	0.422665413	0.150094977	0.129191661	0.42508367	0.468262406
DSRa de Rack4	p4	0.351132105	0.131109266	0.034751339	0.091406389	0.287526607	0.010522503	0.034483257	-0.17499887	0.166494833
DSRa de Rack5	p5	0.706418577	0.210265165	-0.075340166	0.206253325	-0.020781226	0.069266114	0.536514701	-0.246743775	-0.070189322
DSRa de Rack6	p6	0.078097353	0.012590881	-0.26953677	0.0825763	-0.26784037	0.010137128	0.05360515	0.154686765	0.037938113
DSRa de Rack7	p7	-0.012805507	0.011942866	0.066181695	0.187510721	-0.090328784	-0.036157574	0.007457984	0.043592942	-0.113539132
DSRa de Rack8	p8	-0.006084575	-0.128645423	0.113587395	0.213762615	-0.143165616	-0.151581356	0.097896544	-0.249716293	-0.568726309
DSRa de Rack9	p9	0.123225943	-0.341470524	0.324132781	-0.587606451	0.103826455	0.035718694	-0.140465869	0.707997019	0.298596344
DSRa de Rack10	p10	-0.162928104	0.252403921	-0.036414756	0.401018548	0.43335869	-0.012446108	-0.416801721	-0.366193583	0.320117215
DSRa de Rack11	p11	0	0.203399745	0.15349073	0.098211689	-0.094487506	0.081512538	0.04024932	-0.246731212	0.045919819
DSRa de Rack12	p12	0.072106086	0	0.073220281	-0.527739816	-0.238622406	-0.019082662	0.027212365	0.828288899	-0.277136496
DSRa de Rack13	p13	0.234632751	0.165007456	0	0.433079806	-0.049750525	0.015596626	0.027662796	-0.170078344	-0.149087418
DSRa de Rack14	p14	0.011456564	-0.1248701	0.44732944	0	0.353416239	-0.029727524	-0.00902377	0.171766411	0.09456201
DSRa de Rack15	p15	-0.103076055	0.009912989	-0.309666688	0.20754843	0	0.140534167	0.287290865	0.001957953	-0.144760808
DSRa de Rack16	p16	0.129694299	-0.015170924	-0.078319534	0.245690888	0.112980788	0	-0.105102833	0.171301804	0.663009095
DSRa de Rack17	p17	-0.120759347	-0.322582314	0.165443045	0.001104137	0.060596056	-0.026349548	0	0.346500061	0.128466245
DSRa de Rack18	p18	-0.004750928	0.474373905	-0.035776097	0.401891058	0.304333978	0.120682273	0.589866738	0	-0.209749832
DSRa de Rack19	p19	-0.015516326	-0.093098588	-0.184341635	0.039267097	-0.268248558	0.349581149	-0.171414556	-0.292319468	0

Fig. II.15. Esquema e Hiperparámetros del modelo LR SBMS12.

Tabla II.15. Tabla con los errores R² de los 19 modelos LR, del Rack1 al Rack19 con el conjunto de datos de prueba del SBMS12.

LR SBMS12	Rack1	Rack2	Rack3	Rack4	Rack5	Rack6	Rack7	Rack8	Rack9	Rack10
R ² [%]	0,88	0,79	0,73	0,75	0,88	0,14	0,71	0,78	0,38	0,87

LR SBMS12	Rack11	Rack12	Rack13	Rack14	Rack15	Rack16	Rack17	Rack18	Rack19
R ² [%]	0,75	0,83	-0,21	0,92	0,50	0,89	0,48	-0,78	0,69

