

Estratégia de carregamento Multi-estágio de Corrente Constante baseada em inteligência de enxame para baterias Li-ion

Versão final após defesa

Pedro Filipe Queijo Peixoto

Dissertação para obtenção do Grau de Mestre em
Engenharia Eletrotécnica e de Computadores
(2º ciclo de estudos)

Orientador: Professor Doutor José Álvaro Nunes Pombo

dezembro de 2025

Declaração de Integridade

Eu, Pedro Filipe Queijo Peixoto, que abaixo assino, estudante com o número de inscrição M12952 de/o Engenharia Eletrotécnica e de Computadores da Faculdade de Engenharia, declaro ter desenvolvido o presente trabalho e elaborado o presente texto em total consonância com o **Código de Integridades da Universidade da Beira Interior**.

Mais concretamente afirmo não ter incorrido em qualquer das variedades de Fraude Académica, e que aqui declaro conhecer, que em particular atendi à exigida referenciação de frases, extratos, imagens e outras formas de trabalho intelectual, e assumindo assim na íntegra as responsabilidades da autoria.

Universidade da Beira Interior, Covilhã 15 /12/2025

(assinatura conforme Cartão de Cidadão ou preferencialmente
assinatura digital no documento original se naquele mesmo formato)

Dedicatória

À minha avó Rosa que sempre deu a vida por todos o máximo que pode, e o que não pode. Apesar das enormes dificuldades que passou durante a sua vida, nunca deixou de ser um anjo para todos. Serás sempre lembrada por quem te ama.

Aos meus pais, pelo amor, carinho, suporte, compreensão e paciência ao longo de toda a minha vida, sem eles nada disto seria possível.

Agradecimentos

Ao concluir esta etapa, gostaria de agradecer a todos aqueles que estiveram presentes e me auxiliaram na elaboração da presente dissertação.

Quero deixar um agradecimento especial ao meu orientador, Professor Doutor José Álvaro Nunes Pombo, pelo acompanhamento contínuo durante a elaboração desta dissertação. Um enorme obrigado pela persistência, ensinamentos transmitidos (tanto teóricos como práticos), compreensão e paciência. Nada disto seria possível sem a sua orientação.

Agradeço também a todos os elementos do laboratório *Power Systems Cv* do Instituto de Telecomunicações, pelas ajudas e dicas na fase prática da dissertação.

Aos meus pais pela companhia, compreensão e ajuda. Agradeço por toda a confiança que tiveram em mim durante esta etapa. Também sem eles nada disto seria possível.

Aos meus amigos e namorada, pelo suporte, carinho e ajuda prestada ao longo desta dissertação.

Por último, agradecer a todos os meus familiares pelos conselhos e suporte ao longo desta fase da minha vida.

Um obrigado a todos.

Resumo

A crescente aposta nas fontes de energia renovável (ER) tem impulsionado de forma significativa a aderência dos sistemas de armazenamento de energia elétrica. Entre as diversas soluções existentes, as baterias de Li-ion destacam-se pela sua elevada densidade energética, eficiência e longos ciclos de vida, sendo amplamente utilizadas em veículos elétricos, sistemas estacionários e dispositivos portáteis. Contudo, os métodos de carregamento destas baterias continuam a ser fatores determinantes na sua durabilidade, eficiência e segurança. Estes influenciam diretamente os mecanismos de envelhecimento eletroquímico, podendo acelerar ou retardar a degradação consoante os parâmetros de carregamento definidos.

Neste contexto, a presente dissertação aborda o estudo, implementação e otimização do método de carregamento multi-estágio de corrente constante (MSCC) aplicado a baterias Li-ion, recorrendo ao algoritmo de otimização meta-heurístico *Particle Swarm Optimization* (PSO), com o objetivo de aumentar a adaptabilidade do processo de carregamento em função das condições internas e externas da bateria. Esta abordagem permite alcançar um melhor equilíbrio entre rapidez de carregamento e desempenho energético. Seguidamente, o problema de otimização é formulado de forma a minimizar o tempo total de carregamento, assegurando simultaneamente elevados níveis de autonomia, traduzidos por um estado de carga final (SOC) elevado.

No procedimento de otimização são estabelecidos os parâmetros interativos entre o MSCC e o PSO, assim como a estratégia adotada para calcular o estado de carga (SOC). O PSO ajusta dinamicamente os níveis de corrente e determina o perfil ótimo para cada fase do carregamento MSCC. Foram testadas configurações com quatro, cinco e sete patamares. Os resultados evidenciam que a formulação proposta constitui uma estratégia eficaz e flexível para a gestão otimizada do carregamento de baterias Li-ion, com potencial de aplicação em sistemas energéticos inteligentes.

Palavras-chave

Sistemas de armazenamento de energia elétrica; Baterias Li-ion; Estratégias de carregamento; Multi-estágio de corrente constante; Métodos de otimização; Algoritmos meta-heurísticos; *Particle Swarm Optimization*; Estado de carga.

Abstract

The growing commitment to renewable energy sources (RES) has significantly driven the adoption of electrical energy storage systems. Among the various available solutions, Li-ion batteries stand out due to their high energy density, efficiency, and long life cycle, being widely used in electric vehicles, stationary systems, and portable devices. However, the charging methods of these batteries remain key factors in determining their durability, efficiency, and safety. They directly influence electrochemical aging mechanisms, potentially accelerating or slowing degradation depending on the defined charging parameters.

In this context, the present dissertation addresses the study, implementation, and optimization of the Multi-Stage Constant Current (MSCC) charging method applied to Li-ion batteries, using the metaheuristic optimization algorithm Particle Swarm Optimization (PSO). The main objective is to increase the adaptability of the charging process according to the battery's internal and external conditions. This approach enables a better balance between charging speed and energy performance. Subsequently, the optimization problem is formulated to minimize the total charging time while simultaneously ensuring high levels of autonomy, reflected in a high final state of charge (SOC).

In the optimization procedure, the interactive parameters between MSCC and PSO are defined, as well as the adopted strategy to calculate the state of charge (SOC). The PSO algorithm dynamically adjusts the current levels and determines the optimal profile for each MSCC charging stage. Configurations with four, five, and seven stages were tested. The results demonstrate that the proposed formulation represents an effective and flexible strategy for the optimized management of Li-ion battery charging, with potential application in smart energy systems.

Keywords

Electrical energy storage systems; Li-ion batteries; Charging strategies; Multi-Stage Constant Current; Optimization methods; Metaheuristic algorithms; Particle Swarm Optimization; State of charge.

Índice

Capítulo 1	1
Introdução	1
1.1 Enquadramento	1
1.2 Objetivos e Motivação	11
1.3 Estrutura	12
Capítulo 2.....	13
Estado da Arte - estratégias de carregamento	13
2.1 Carregamento Corrente Constante – Tensão Constante (CC-CV).....	13
2.2 Carregamento por Pulsos de Corrente (PC).....	15
2.3 Carregamento Multi-estágio de Corrente Constante (MSCC)	19
2.4 Discussão dos vários métodos de carregamento	24
Capítulo 3.....	25
Formulação do problema e Algoritmos de Otimização	25
3.1 Formulação do problema	25
3.2 Métodos de Otimização (Algoritmos Meta-heurísticos)	26
3.2.1 <i>Particle Swarm Optimization</i> (PSO)	29
3.3 Procedimento Experimental	31
Capítulo 4.....	33
Processo e Resultados Experimentais	33
4.1 Procedimento de Otimização	33
4.2 Resultados Experimentais.....	36
4.2.1 Caso 1 - Resultados para quatro estágios	36
4.2.2 Caso 2 - Resultados para cinco estágios	37
4.2.3 Caso 3 - Resultados para sete estágios	39
Capítulo 5.....	41
Conclusão.....	41
5.1 Contextualização e considerações finais	41
5.2 Trabalhos futuros	43
Bibliografia	44
Apêndices.....	49
Apêndice A.....	50
Pseudocódigo do PSO.....	50
Apêndice B	52
Publicações científicas.....	52

Lista de Figuras

Figura 1.1 - Produção de Eletricidade de Portugal Continental em 2024 (adaptado de [10])	2
Figura 1.2 - Evolução da Potência Instalada em Portugal Continental (adaptado de [11]).....	3
Figura 2.1 - Carregamento CC-CV (obtido de um teste em laboratório).....	14
Figura 2.2 - Métodos PPC (adaptado de [33])	17
Figura 2.3 - Métodos NPC (adaptado de [33])	18
Figura 2.4 - Método MSCC de 5 estágios	20
Figura 3.1 - Taxinomia dos Algoritmos Meta-heurísticos (adaptado de [60])	28
Figura 3.2 – Diagrama de Estados do Particle Swarm Optimization.....	31
Figura 3.3 - Esquema do Procedimento Experimental	32
Figura 4.1 - Fluxograma do Procedimento Experimental.....	35
Figura 4.2 - Padrões de corrente investigados pelo PSO na configuração 4MSCC: (a) Perfis de Corrente de cada teste; (b) Intervalo de correntes de todos os testes, assim como o melhor perfil	36
Figura 4.3 - Padrões de tensão investigados pelo PSO na configuração 4MSCC: (a) Perfis de Tensão de cada teste; (b) Intervalo de tensões de todos os testes, assim como o melhor perfil ..	37
Figura 4.4 - Padrões do SOC investigados pelo PSO na configuração 4MSCC: (a) Perfis do SOC de cada teste; (b) Intervalo de SOC de todos os testes, assim como o melhor perfil	37
Figura 4.5 - Padrões de corrente investigados pelo PSO na configuração 5MSCC: (a) Perfis de Corrente de cada teste; (b) Intervalo de correntes de todos os testes, assim como o melhor perfil	38
Figura 4.6 - Padrões de tensão investigados pelo PSO na configuração 5MSCC: (a) Perfis de Tensão de cada teste; (b) Intervalo de tensões de todos os testes, assim como o melhor perfil ..	38
Figura 4.7 - Padrões do SOC investigados pelo PSO na configuração 5MSCC: (a) Perfis do SOC de cada teste; (b) Intervalo de SOC de todos os testes, assim como o melhor perfil	39
Figura 4.8 - Padrões de corrente investigados pelo PSO na configuração 7MSCC: (a) Perfis de Corrente de cada teste; (b) Intervalo de correntes de todos os testes, assim como o melhor perfil	40
Figura 4.9 - Padrões de tensão investigados pelo PSO na configuração 7MSCC: (a) Perfis de Tensão de cada teste; (b) Intervalo de tensões de todos os testes, assim como o melhor perfil ..	40
Figura 4.10 - Padrões do SOC investigados pelo PSO na configuração 7MSCC: (a) Perfis do SOC de cada teste; (b) Intervalo de SOC de todos os testes, assim como o melhor perfil	40

Lista de Tabelas

Tabela 2.1 - Diferentes métodos de Carregamento de Pulso (adaptado de [33])	16
Tabela 2.2 - Parâmetros e impactos - MSCC vs. CC-CV (adaptado de [42])	22

Lista de Acrónimos e Siglas

ABC	<i>Artificial Bee Colony</i>
ACO	<i>Ant Colony Optimization</i>
BBO	<i>Biogeography-Based Optimization</i>
BMS	<i>Sistema de Gestão de Bateria</i>
BSA	<i>Backtracking Search Algorithm</i>
BSO	<i>Brain Storm Optimization</i>
CC	<i>Corrente Constante</i>
CC-CV	<i>Corrente Constante – Tensão Constante</i>
CL-CV	<i>Perda Constante – Tensão Constante</i>
CP-CV	<i>Potência Constante – Tensão Constante</i>
CV	<i>Tensão Constante</i>
DE	<i>Differential Evolution</i>
EA	<i>Evolutionary Algorithm</i>
ER	<i>Energias Renováveis</i>
FPA	<i>Flower Pollination Algorithm</i>
GA	<i>Genetic Algorithm</i>
GSA	<i>Gravitational Search Algorithm</i>
GSK	<i>Gaining-Sharing Knowledge</i>
GWO	<i>Grey Wolf Optimizer</i>
HIA	<i>Human-Inspired Algorithm</i>
LIB	<i>Bateria de Li-ion</i>
LB	<i>Limite Inferior</i>
MSCC	<i>Multi-estágio de Corrente Constante</i>
MVO	<i>Multi-Verse Optimizer</i>
NPC	<i>Carregamento por Pulsos de Corrente Negativo</i>
OCP	<i>Padrão de Carga Ótimo</i>
OCV	<i>Tensão de Circuito Aberto</i>
PC	<i>Carregamento por Pulsos de Corrente</i>
PPC	<i>Carregamento por Pulsos de Corrente Positivo</i>
PSO	<i>Particle Swarm Optimization</i>
SA	<i>Simulated Annealing</i>
SCE	<i>Shuffled Complex Evolution</i>
SEI	<i>Solid Electrolyte Interphase</i>
SEO	<i>Social Emotional Optimization</i>
SOC	<i>Estado de Carga</i>
SOH	<i>Estado de Saúde</i>
SPO	<i>Spiral Optimization Algorithm</i>
TLBO	<i>Teaching-Learning-Based Optimization</i>
UB	<i>Limite Superior</i>

Lista de Símbolos

A	Amplitude de pulso não variável
A_i	Amplitude de pulso variável
α	Peso de ponderação ([0,1])
C_{cha}	Capacidade de carregamento da bateria
C_n	Capacidade nominal da bateria
C_{ref}	Capacidade de referência da bateria
D	Número de dimensões das partículas
D_p	<i>Duty-cycle</i>
E	Espaço de Procura
f	Frequência
f_{obj}	Função objetivo
g_{best}	Melhor posição global (PSO)
I	Amplitude de corrente
I_{bat}	Corrente aplicada à bateria
I_c	Corrente constante do método CC-CV
I_{cha}	Corrente constante do método CC-PC
I_d	Corrente de corte
I_{lb}	Limite inferior da corrente de carregamento
I_{max}	Corrente máxima aceitável de carregamento
I_{mean}	Amplitude de pulso de corrente média
I_{ng}	Amplitude de pulso de corrente negativo
I_n	Amplitude de corte do n-ésimo estágio
I_p	Amplitude de pulso de corrente positivo
I_r	Amplitude de pulso de corrente de repouso
I_t	Amplitude de corrente de carregamento num instante de tempo t
I_{ub}	Limite superior da corrente de carregamento
\hat{it}_{max}	Número máximo de iterações
k	Índice de iteração
lb	Limite inferior
n	Número de patamares de corrente
N	Número de partículas
N_n	Número de pulsos negativos
p_{best}	Melhor posição individual (PSO)
SOC_f	Estado de carga final
T	Período
T_{char}	Tempo total de carregamento
T_{max}	Tempo máximo admissível de carregamento (2 horas)
T_n	Período negativo
T_p	Período positivo
τ	Rácio do tempo entre CC e CV
t	Instante de tempo
t_n	Tempo de pulso de corrente negativo
t_p	Tempo de pulso de corrente positivo
t_r	Tempo de pulso de corrente de repouso
ub	Limite superior

$V_{cut-off}$	Tensão máxima de corte
V_i	Vetor de velocidades
V_{sw}	Tensão de troca
W	Largura de pulso não variável
W_i	Largura de pulso variável
X_i	Vetor de posição
x_i^0	Posição inicial da i -ésima partícula para $k=0$
ω	Fator de inércia

Capítulo 1

Introdução

1.1 Enquadramento

Os combustíveis fósseis/convencionais contribuem para a crescente preocupação com alterações climáticas, não só devido à sua natureza poluente (como os gases de efeito de estufa), como também à sua escassez [1]. A pandemia de 2021 e a Guerra da Rússia e Ucrânia aumentaram a inflação de preços drasticamente, provocando uma instabilidade nos mercados internacionais (tanto de energia elétrica, como de combustíveis fósseis) [2]. Como medida de combate, estabeleceram-se compromissos internacionais de descarbonização de modo a impulsionar uma transição energética baseada em fontes de energia sustentáveis, como o Acordo de Paris de 2015. Neste acordo, a comunidade internacional comprometeu-se a manter os níveis de aquecimento global abaixo dos 2°C, e solicitar esforços para limitar esse aumento para 1,5°C [3].

Neste cenário, as Energias Renováveis (ER), caracterizadas pela sua elevada capacidade regenerativa (praticamente inesgotáveis), assumem um papel fundamental como solução para superar a crise ambiental, oferecendo soluções ambientalmente responsáveis, devido à sua pegada carbónica significativamente inferior às fontes de energia convencionais. São limpas, pois possuem emissões reduzidas ou mesmo inexistentes de gases poluentes como os de efeito de estufa. Para além da manutenção não possuem custos adicionais como operações de reabastecimento. Como constituem um setor crescente no mercado, oferecem novas oportunidades de emprego [4], [5].

No entanto, apesar das suas vantagens ambientais e potencial técnico, estas fontes apresentam desafios técnicos e operacionais significativos, que dificultam a sua integração nos sistemas energéticos convencionais/tradicionais. A sua disponibilidade surge como um dos principais desafios técnicos: as ER possuem produção faseada, uma vez que não estão disponíveis 24 horas por dia, provocando volatilidade na produção de energia elétrica. A tecnologia utilizada, as infraestruturas e a mão de obra qualificada são outros desafios operacionais. Consciencialização/informação, políticas e regulamentos facilitadores, incentivos/subsídios governamentais, licenciamentos e procedimentos burocráticos, representam outros desafios da integração das ER [6], [7].

No caso português, essa realidade não é diferente. Na Resolução da Assembleia da República n.º 127/2025, de 10 de abril, foi aprovada a atualização do Plano Nacional de Energia e Clima 2030 (PNEC 2030), onde perspectiva-se que 96% da eletricidade produzida no sistema electroprodutor português seja de origem renovável em 2030 [8]. De modo a cumprir o PNEC 2030, Portugal tem-se destacado nas últimas décadas pelo forte investimento em energias renováveis, alcançando níveis de penetração superiores a 60% na produção de eletricidade, com destaque para a energia hídrica, eólica e, recentemente, solar [9].

Com base nas várias análises da Associação Portuguesa de Energias Renováveis (APREN), referente ao ano de 2024, entre 1 de janeiro e 31 de agosto, foram produzidos 31 443 GWh de eletricidade em Portugal Continental, dos quais 82,8 % tiveram origem renovável, como pode ser evidenciado na Figura 1.1 [10].

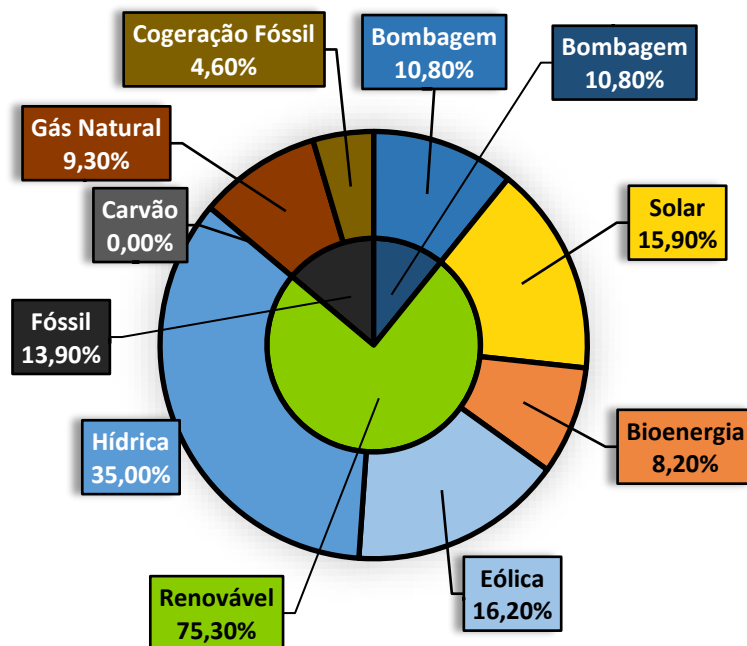


Figura 1.1 - Produção de Eletricidade de Portugal Continental em 2024 (adaptado de [10])

A partir do ano de 2020, houve um aumento significativo em relação à potência solar instalada em Portugal continental, passando de 1030 MW instalados para 3713 MW, o que significa um aumento de 260%, aproximadamente. É referenciado também pela APREN, que desde 2011 a potência fósil instalada tem vindo a diminuir, tendo a sua maior queda em 2021, com a desativação das centrais a combustíveis fósseis de Sines e do Pego. Estas tendências podem ser evidenciadas na Figura 1.2 [11].




Figura 1.2 - Evolução da Potência Instalada em Portugal Continental (adaptado de [11])

Em determinados períodos, o país já conseguiu satisfazer praticamente todo o consumo de energia elétrica exclusivamente com energia renovável. Contudo, a natureza intermitente da maioria das fontes de energia renováveis dificulta o equilíbrio entre oferta e procura de energia elétrica, exigindo ao sistema elétrico nacional uma maior capacidade de adaptação, tanto em termos de estabilidade como de flexibilidade. Essa capacidade de adaptação torna-se particularmente evidente em situações de baixa ou de elevada produção renovável ou de baixa/elevada procura.

No dia 28 de abril de 2025, em 5 segundos a Espanha perdeu 60% do seu potencial de produção de Energia que conseqüentemente provocou um apagão a nível nacional em Portugal [12]. Os dados da Direção Geral de Energia e Geologia (DGEG) (2023), indicam que 67,2% da energia total consumida em Portugal foi importada. Como tal, é imperativo que Portugal tenha um sistema elétrico nacional resiliente e independente de modo a evitar constrangimentos futuros [13].

Assim, a transição energética em Portugal, tal como em muitos outros países, depende cada vez mais da implementação de soluções técnicas que permitam acomodar um *mix* energético diversificado, dinâmico e resiliente.

Para assegurar a continuidade do percurso de descarbonização é fundamental o investimento em soluções técnicas avançadas e, simultaneamente, complementares. Entre as soluções prioritárias, destacam-se: o reforço das interligações elétricas no espaço europeu; a modernização e a digitalização das redes de energia elétrica (transporte e distribuição) através de redes inteligentes; a diversificação geográfica e

tecnológica das fontes renováveis; e, principalmente, a implementação de sistemas de armazenamento de energia elétrica. Estes últimos são essenciais para garantir a flexibilidade do sistema elétrico, permitindo armazenar o excedente energético produzido em momentos de baixa procura e utilizá-lo quando a produção é insuficiente. A implementação articulada destas soluções será determinante para consolidar um sistema elétrico mais robusto, resiliente e capaz de absorver um volume crescente de energias renováveis, sem comprometer a segurança nem a qualidade do fornecimento elétrico.

Os sistemas híbridos reversíveis (com bombagem) possuem a maior quota a nível mundial de armazenamento de energia elétrica, constituindo aproximadamente 92% do mercado em 2020, devido à sua natureza e fiabilidade. Os sistemas de armazenamento eletroquímico representaram 5,9%, sendo as baterias de lítio as mais predominantes, representando 90% deste tipo de armazenamento. Os restantes sistemas de armazenamento, como os volantes de inércia (*flywheels*), o armazenamento de energia por ar comprimido (CAES) e o armazenamento térmico, representaram coletivamente as menores percentagens, o que indica uma fase ainda embrionária e taxas de adoção mais reduzidas destas alternativas [14].

Entre as tecnologias de armazenamento de energia elétrica emergentes, as baterias de Li-ion (LIBs) ganharam uma ampla aceitação devido à sua elevada densidade energética, eficiência de conversão, tempo de resposta e ciclos de vida relativamente longos. Estas LIBs, comparativamente às anteriores baterias de chumbo-ácido, possuem características evidentes da sua superioridade, nomeadamente: Energia Específica (151 Wh/kg), Potência Específica (229 W/kg), Eficiência Ciclo Completo (87,37 %), Vida Útil (12,67 anos), Perda de carga Diária (0,17 %), Densidade Energética (311,67 kWh/m³), Densidade de Potência (1250 kW/m³). Já as baterias de chumbo-ácido, 30,58 Wh/kg, 181 W/kg, 76,36 %, 8,75 anos, 0,2666 %, 65 kWh/m³ e 75 kW/m³, respetivamente [15].

Atualmente, as LIBs são amplamente utilizadas tanto em aplicações móveis (veículos elétricos) como em sistemas estacionários ligados à rede elétrica [16], [17]. No entanto, apesar das suas vantagens, as baterias Li-ion apresentam limitações importantes. Um dos principais problemas é a degradação progressiva dos seus componentes internos ao longo dos ciclos de carregamento e descarregamento, o que resulta na perda de capacidade, aumento da resistência interna e redução da vida útil [18]. São dispendiosas, e, embora o custo tenha diminuído drasticamente nos últimos anos, ainda é bastante elevado, tornando muitos dos possíveis casos de uso em aplicações de grande escala inviáveis. É bastante complexo construir células de baterias de lítio que sejam seguras,

uma vez que são necessárias medidas adicionais para proteger contra incidentes de fuga térmica. Possuem limitações no fornecimento e reciclagem dos seus materiais constituintes, devido à agressividade da extração e uso do Lítio. Existe uma necessidade de sistemas de gestão de bateria (BMS), uma vez que uma má parametrização ou sobrecarga, temperatura, corrente ou outros, pode causar danos irreversíveis às baterias [19].

As principais funcionalidades que uma BMS deve controlar, de modo a garantir uma bateria estável, duradora e funcional são a monitorização, proteção, gestão de carregamento e descarregamento, comunicação, diagnóstico e gestão de todo o tipo de variáveis que constituem a bateria [20].

Neste contexto, a forma como as baterias Li-ion são carregadas assume um papel determinante na maximização da sua durabilidade, desempenho e segurança.

O processo de carregamento influencia diretamente os mecanismos de envelhecimento eletroquímico no interior das baterias, podendo, conforme os parâmetros definidos, acelerar ou retardar a sua degradação. Métodos de carregamento inadequados tendem a acelerar o desgaste dos materiais ativos, comprometer a integridade da camada *Solid Electrolyte Interphase* (SEI) e, conseqüentemente, reduzir significativamente a vida útil das baterias [21].

Carregar as baterias de Li-ion é uma tarefa desafiante, uma vez que se pretende obter um carregamento o mais rápido possível, mantendo a temperatura e a perda de vida, o mais pequenas possíveis, o que torna o processo contraditório [22]. Neste contexto, para o processo de carregamento ser eficiente e seguro, é necessário que a tensão e a corrente de carregamento da bateria sejam controladas de maneira a que não haja subcarregamento, sobrecarregamento, ou qualquer tipo de danificação da bateria [23].

Estes fatores têm implicações diretas na viabilidade económica dos sistemas de armazenamento de energia elétrica, ao reduzirem o tempo de vida útil e aumentarem os custos de manutenção e substituição. Para além disso, a redução do ciclo de vida das baterias contribui para um maior impacto ambiental, dada a necessidade de substituições frequentes e, conseqüentemente, aumenta a produção de resíduos difíceis de reciclar.

Prevê-se que em 2030, estarão cerca de 300 milhões de veículos elétricos a circular nas estradas, o que está a causar uma enorme demanda de LIBs. Apesar dos veículos elétricos serem mais amigáveis para o ambiente do que veículos de combustíveis tradicionais, a

extração mineral do lítio não é exatamente limpa. Para extrair uma tonelada de lítio, são necessárias 1900 toneladas de água, onde também é previsto que as reservas atuais não sejam suficientes para satisfazer as exigências de 2023-2025 a menos que haja uma reciclagem com eficiência de 90% [24].

Deste modo, é imperativo, não só impulsionar a reciclagem dos materiais da bateria, como também certificar que o seu devido funcionamento e conservação são cumpridos. Neste âmbito, a presente dissertação visa explorar a componente do carregamento, abordando algumas alternativas e os atuais procedimentos de carregamento na indústria, com foco principal no carregamento de multi-estágio de corrente constante.

Na indústria, o método de carregamento padrão para baterias Li-ion é o método de corrente constante – tensão constante (CC-CV) [25]. Este consiste, numa primeira fase, na aplicação de uma corrente de carregamento constante (CC) até a bateria atingir a tensão máxima ($V_{cut-off}$) [26]. Segue-se uma segunda fase, em que a tensão é mantida constante (CV) enquanto a corrente decresce progressivamente até valores residuais, indicando que a bateria está totalmente carregada [23], [27].

Entre as principais vantagens do método destaca-se a sua simplicidade de implementação e conseqüente facilidade de integração em sistemas comerciais. É também compatível com a maioria das composições químicas de baterias Li-ion, o que reforça a sua aplicabilidade universal. Adicionalmente, oferece um bom compromisso entre eficiência e durabilidade, sendo considerado seguro quando corretamente parametrizado [23], [28], [29].

No entanto, este método também apresenta algumas desvantagens. Uma das principais desvantagens é o tempo de carregamento relativamente longo na fase de tensão constante (CV), tornando o CC-CV inadequado para carregamentos rápidos. Além disso, o método CC-CV não é sensível ao estado de saúde (SOH) da bateria, i.e., não ajusta os parâmetros de carregamento em função da resistência interna e da temperatura, o que pode comprometer a eficiência e acelerar a degradação em determinadas condições [30]. Deste modo este carregamento reduz a eficiência de carregamento e os ciclos de vida da bateria [28].

A aplicação de correntes elevadas (*C-rates*) na fase inicial de corrente constante (CC), pode também originar um aumento significativo da temperatura, sobretudo em ambientes com menor capacidade de dissipação térmica. Esta elevação térmica, pode favorecer reações secundárias indesejadas, como o crescimento anômalo da camada SEI,

contribuindo para uma maior degradação [26], [31]. Alguns resultados também demonstram que 94,5% da perda de inventário de lítio (*loss of lithium inventory* ou LLI) ocorre na fase de tensão constante (CV) [29].

No estudo [32] são avaliados cinco métodos de carregamento para baterias de Li-ion: três variações do método CC-CV, o método de potência constante – tensão constante (CP-CV) e o método de perda constante – tensão constante (CL-CV) onde utilizaram a bateria da Panasonic NCR18650B com temperatura a 25 °C. Para aplicações que priorizam os efeitos de envelhecimento em ambientes de altas temperaturas o caso 2 de CC-CV mostrou melhores resultados. O caso 3 CC-CV mostrou uma melhoria no tempo de carregamento e eficiência. Quando se quer um tempo de carregamento mais rápido o método CP-CV mostrou melhor resultados. Por último, aplicações que enfatizem o aumento de temperatura e eficiência de carregamento, o CL-CV foi escolhido.

O estudo [29] desenvolveu um modelo analítico para relacionar os tempos de carregamento CC e CV com a degradação de baterias Li-ion. Identificou-se que o tempo CC diminui linearmente com a degradação, enquanto que o tempo CV varia com as condições de carregamento, como a temperatura, onde o aumento da mesma provocou também o aumento da curvatura exponencial entre o tempo de carregamento da fase CV com a capacidade de carga normalizada. Nisto, foi proposto um novo indicador de estado de saúde (SOH), o rácio do tempo CV-CC (τ), que é definido como a razão entre o tempo de carregamento na fase CC e o tempo de carregamento em CV.

Apesar destas limitações, o método CC-CV continua a ser amplamente utilizado, especialmente em aplicações onde a simplicidade, a segurança e a compatibilidade são prioritárias ou fundamentais. No entanto, para aplicações mais exigentes ou sensíveis à durabilidade das baterias, têm vindo a ser exploradas alternativas mais avançadas, como o método de carregamento Multi-estágio, método de carregamento por Pulsos [33] ou métodos de carregamento baseados em algoritmos de Inteligência Artificial e *Machine Learning* [34], [35].

Outro método de carregamento presente na literatura é o método de carregamento por Pulsos (*Pulse Charging*). Este método consiste em pulsos, tanto de corrente como de tensão, que sendo intercalados com tempos de repouso, carregam a bateria. Estes tempos de repouso são úteis para a eliminação da polarização que tende a ocorrer na camada SEI durante ou após um pulso, para garantir uma distribuição mais uniforme dos iões no eletrólito e reduzir o risco de formação indesejada de lítio (*lithium plating*) [36]. Além

do tempo de repouso e tempo de carregamento, temos também variáveis fulcrais como a frequência, o período, o *duty-cycle*, a amplitude de pulso, entre outros.

Quando devidamente elaborado e implementado, este carregamento por pulsos pode resultar em benefícios significativos, como maior eficiência energética e de carregamento da bateria, aumentar o número de ciclos de vida da bateria e reduzir o tempo de carregamento [37], [38].

Embora estas vantagens sejam bastantes significativas, este método também possui as suas desvantagens. Quando comparado com o método corrente constante (CC), com uma corrente semelhante, o método por pulsos periódico mostrou ter um efeito prejudicial para o desempenho das baterias de Li-ion [39].

Apesar do aumento da amplitude de corrente dos pulsos possa melhorar o tempo de carregamento, a capacidade da bateria diminui, isto porque o aumento de tais amplitudes significa também um aumento de temperatura, que põe em causa os ciclos de vida da bateria. As frequências a que o carregamento por pulsos de corrente decorre pode também impactar negativamente a vida bateria, como por exemplo no intervalo de 1Hz a 25Hz [33].

Apesar da maioria de carregamentos por pulsos ser maioritariamente de corrente, o autor em [38] propôs um carregamento por pulsos de tensão onde o *duty-cycle* é variado. Ao detetar os pulsos, este método de carregamento por pulsos de tensão de *duty-cycle* variado (DVVPCS) adapta dinamicamente o *duty-cycle* para controlar os pulsos de carregamento. Quando comparado com o tempo de carregamento do método CC-CV, o DVVPCS mostrou um melhoramento de 14%. Em termos de eficiência de carregamento, obteve uma melhoria de 3,4% quando comparado com o CC-CV.

Em [40] foi utilizado o método de carregamento por pulsos de corrente positivo (PPC), onde numa faixa de frequências de 0,05 Hz, 0,2 Hz, 1 Hz, 100 Hz e 2 kHz, os ciclos de vida da bateria foram estendidos em 72,8%, 52,8%, 20,6%, 42,2% e 105,5%, respetivamente, quando comparados com o método de carregamento corrente constante (CC).

O método de carregamento multi-estágio de corrente constante (MSCC) é um método de carregamento que procura otimizar o equilíbrio entre o tempo de carregamento, a segurança e a durabilidade da bateria. Este método divide o processo de carregamento em várias etapas/patamares, cada uma com parâmetros específicos de corrente [41]. A

corrente é reduzida de forma progressiva de forma a minimizar o stress eletroquímico e térmico sobre os materiais ativos que compõem a bateria [42], [43].

Este tipo de carregamento apresenta diversas vantagens em relação ao método padrão CC-CV. Em primeiro lugar, permite prolongar a vida útil da bateria, uma vez que evita os principais mecanismos de degradação associados a correntes elevadas, sobreaquecimentos e sobretensão (sobrecarga). Em segundo lugar, reduz a geração de calor ao longo do processo de carregamento, contribuindo para a estabilidade térmica e química das baterias, o que é fundamental para aplicações que exigem elevada fiabilidade e segurança. Além disso, permite alcançar uma maior eficiência em termos de tempo de carregamento, já que é possível aplicar correntes mais elevadas em fases seguras e controladas, sem comprometer a integridade da bateria [44].

No entanto, para maximizar a eficiência, reduzir o tempo de carregamento, prolongar e preservar a vida útil das baterias e, simultaneamente, garantir a segurança, é essencial interpretar/abordar o método de carregamento multi-estágio de corrente constante (MSCC) como um processo de otimização. Esta abordagem permite alcançar uma maior adaptabilidade do processo, através do ajuste dinâmico dos níveis de corrente em função das condições internas e externas da bateria, como por exemplo, a temperatura, o estado de carga, a tensão e a resistência interna. Três questões fundamentais caracterizam o problema de otimização.

A primeira está relacionada com a definição dos valores de corrente durante o processo de carregamento. A cada instante de tempo, é necessário determinar qual valor de corrente que será aplicado. Correntes muito elevadas permitem reduzir o tempo de carregamento, mas, no entanto, aumentam a temperatura interna e aceleram reações químicas internas indesejadas que levam à degradação da bateria. Por outro lado, correntes muito baixas são mais seguras, mas prolongam excessivamente o processo de carregamento.

A segunda questão prende-se com o critério que determina a transição entre os diferentes níveis de corrente. No método de carregamento multi-estágio de corrente constante (MSCC), o critério de transição pode ser determinado através de diferentes variáveis de controlo, como por exemplo, a tensão da bateria, o estado de carga (SOC), o tempo de carregamento ou até mesmo a temperatura. Estes critérios devem ser definidos com precisão para que as transições ocorram de forma eficiente, evitando reações químicas internas indesejadas e/ou sobretensões (sobrecarga). Um critério mal especificado pode

comprometer o desempenho global do processo de carregamento e, assim, afetar a durabilidade da bateria.

A terceira e última questão está relacionada com a definição do número (ideal) de níveis de corrente no perfil de carregamento. Um elevado número de níveis de corrente proporciona uma maior adaptabilidade do processo, permitindo um ajuste mais refinado e específico do processo de carregamento às condições da bateria, i.e., oferece uma resposta mais sensível ao estado de saúde da bateria (SOH). No entanto, um número reduzido de níveis de corrente simplifica o sistema de controlo e a sua implementação prática, embora possa comprometer a adaptabilidade e, conseqüentemente, o desempenho global do processo de carregamento. Assim, torna-se fundamental encontrar um equilíbrio adequado entre a complexidade e os ganhos em eficiência, tempo e segurança e que prolonguem a vida útil das baterias [44], [45], [46].

Esta adaptabilidade do método de carregamento multi-estágio de corrente constante torna-o especialmente adequado para aplicações exigentes, como veículos elétricos ou sistemas de armazenamento estacionário, onde o equilíbrio entre desempenho e durabilidade é essencial, i.e., a sua flexibilidade permite adaptar o perfil de carregamento a diferentes baterias (eletroquímicas), estado de saúde (SOH), resistência interna e condições ambientais, contribuindo para uma menor degradação [16].

Para alcançar esta adaptabilidade, o presente estudo propõe a aplicação do algoritmo *Particle Swarm Optimization* (PSO) como uma ferramenta para abordar, de forma integrada, duas das três questões fundamentais discutidas anteriormente, com o objetivo de tornar o processo de carregamento multi-estágio de corrente constante (MSCC) mais adaptável, eficiente e inteligente. Ao utilizar o PSO como método de otimização, pretende-se maximizar a eficiência energética, reduzir o tempo total de carregamento, prolongar a vida útil da bateria e garantir padrões de segurança elevados ao longo de todo o processo de carregamento.

Especificamente, o algoritmo PSO é utilizado para: (i) determinar os valores ótimos de corrente a serem aplicados em cada estágio de carregamento; e (ii) estabelecer o número ideal de estágios. Esta abordagem permite uma resposta mais sensível às condições internas e externas da bateria, como temperatura, resistência interna e estado de saúde (SOH), contribuindo para um processo de carregamento mais otimizado. Assim, esta dissertação procura contribuir para o desenvolvimento de sistemas de carregamento mais inteligentes, capazes de prolongar a vida útil da bateria, reduzir o tempo de carregamento e assegurar uma maior segurança operacional.

1.2 Objetivos e Motivação

Com o desenvolver da tecnologia e indústria 4.0, existe uma crescente necessidade de sistemas de energia renováveis. Estes sistemas são o principal foco atual, não só pela sua capacidade regenerativa, como também pela sua elevada sustentabilidade e preservação do meio ambiente. A sua influência é incontornável, especialmente nas áreas de produção de energia elétrica, no desenvolvimento de veículos elétricos e na área da construção habitacional. Deste modo, existem vários incentivos, não só a nível nacional como mundial, para impulsionar o crescimento e adoção deste tipo de energias renováveis.

No entanto, visto possuírem uma natureza de produção de energia intermitente, surge uma necessidade indispensável de sistemas capazes de armazenar essa mesma energia elétrica. Dentro desta necessidade, existe um enorme foco nas baterias eletroquímicas como sistemas de armazenamento de energia elétrica. De facto, as principais e atuais baterias, que apresentam melhor capacidade de armazenamento, são as baterias de Li-ion (LIBs). Estas baterias apesar de já serem implementadas nas diversas áreas referidas, ainda possuem uma necessidade de controlo, visto que uma má parametrização e gestão pode levar a resultados catastróficos e alto impacto ambiental.

Para garantir um uso adequado e ciclos de vida maiores nas LIBs, a abordagem principal passa por garantir que o seu carregamento é devidamente exercido. Na atualidade o método de carregamento mais utilizado é o de corrente constante - tensão constante (CC-CV), que apesar de fácil implementação e simplicidade, não é apropriado a carregamentos rápidos. Nisto, a presente dissertação visa estudar, implementar e otimizar um dos métodos alternativos mais promissor presente na literatura, o carregamento multi-estágio de corrente constante (MSCC).

Na literatura existe um espaço considerável de resultados inconclusivos/inconsistentes, no que toca a este tipo de carregamento: qual o número de patamares de corrente necessários; quais as *C-rates* ótimas; quanto tempo demora o carregamento MSCC; qual o mínimo tempo necessário para um carregamento MSCC ser bem sucedido, sem pôr em causa a capacidade da bateria; pode este método atingir um nível de Estado de Carga (SOC) confiável. Isto são questões que a presente dissertação procura responder.

Para garantir uma boa implementação deste método de carregamento MSCC, a presente dissertação também visa otimizar este mesmo processo de carregamento. Para tal também será implementado um algoritmo de otimização meta heurístico, de modo a

controlar dinamicamente o MSCC, e garantir que este possui um tempo de carregamento, preservando a capacidade da bateria, apropriado para o carregamento rápido das baterias de Li-ion (LIBs).

1.3 Estrutura

A presente dissertação está organizada em cinco capítulos. O capítulo 2 é constituído pelo estado de arte – estratégias de carregamento. Neste capítulo são descritos sucintamente os princípios e *standards* dos carregamentos das LIBs, assim como os seus principais desafios que enfrentam. Nas secções deste capítulo os métodos de carregamento das baterias são explorados em grande detalhe, avaliando parâmetros como o tempo de carregamento, os ciclos de vida totais, o estado de carga (SOC), o estado de saúde (SOH), a eficiência de carregamento, assim como vantagens e desvantagens de cada um. Estas secções referem-se respetivamente aos métodos de carregamento corrente constante – tensão constante (CC-CV), pulsos de corrente (PC) e multi-estágio de corrente constante (MSCC).

O capítulo 3 é constituído pela Formulação do Problema, Métodos de Optimização (Algoritmos Meta-heurísticos) e Procedimento experimental. A formulação do problema consiste na função objetivo que se pretende minimizar de modo a encontrar a solução ótima para o MSCC. São abordados os algoritmos meta-heurísticos, explicando os seus diferentes ramos. É feita uma análise e contextualização do *Particle Swarm Optimization* (PSO), e como este desempenha o papel principal de como otimizar o processo de carregamento de baterias. No fim deste capítulo, é descrito o Procedimento Experimental, onde consta o *hardware* e *software* utilizado.

O capítulo 4 apresenta os resultados obtidos em ambiente laboratorial e a sua respetiva análise. Neste capítulo são apresentados 3 casos de estudo do MSCC - 4, 5 e 7 estágios, incluindo os melhores resultados de cada caso, como patamares de correntes, *C-rates*, tempo de carregamento e valor da função objetivo.

O capítulo 5 apresenta as conclusões finais e trabalhos futuros. É feito um resumo do que foi abordado ao longo de toda a dissertação assim como considerações finais, posto os resultados obtidos no capítulo anterior. Por último, são sugeridas melhorias e/ou considerações relativas a trabalhos futuros.

Capítulo 2

Estado da Arte - estratégias de carregamento

O carregamento de baterias de Li-ion (LIBs) tem sido alvo de intensa investigação devido ao seu impacto ambiental, à durabilidade e ao desempenho. Atualmente, estas baterias são geralmente carregadas pelos métodos corrente constante – tensão constante (CC-CV) ou potência constante – tensão constante (CP-CV) [25].

Apesar das vantagens das LIBs, estas apresentam limitações significativas, sendo a degradação progressiva dos componentes internos durante os ciclos de vida um dos principais problemas. Isto resulta na perda gradual de capacidade, no aumento da resistência interna e na redução da vida útil da bateria.

O processo de carregamento influencia diretamente os mecanismos de envelhecimento eletroquímico, podendo acelerar ou retardar a degradação consoante os parâmetros de carregamento definidos. Métodos de carregamento inadequados tendem a acelerar o desgaste dos materiais ativos e a comprometer a integridade da camada *Solid Electrolyte Interphase* (SEI) [21], reduzindo assim a durabilidade das células e aumentando os custos de manutenção e substituição.

Para evitar estas desvantagens, e preservar as LIBs, é necessário garantir uma estratégia de carregamento adequada e eficaz. Para tal, vários parâmetros da bateria são analisados de modo a prevenir os riscos associados a carregamentos mal parametrizados, entre eles os mais importantes: o estado de carga (SOC), que indica a capacidade restante [47]; a tensão; a corrente; a temperatura; e o tempo de carregamento. As estratégias de carregamento típicas para as LIBs, que são estudadas nas secções seguintes, comprovam a importância destes parâmetros no contexto de estratégias de carregamento.

2.1 Carregamento Corrente Constante – Tensão Constante (CC-CV)

O carregamento corrente constante-tensão constante (CC-CV) é bifásico, onde a primeira etapa é o carregamento a uma corrente constante e a segunda etapa é o carregamento a tensão constante. Na primeira fase deste tipo de carregamento, de corrente constante (CC), pressupondo que a bateria se encontra descarregada, é inicialmente definida uma corrente constante controlada (I_c), que possui como objetivo aumentar gradualmente a tensão, até ser atingido uma percentagem de 80% do estado de carga (SOC), ou a tensão

máxima de corte ($V_{cut-off}$) ser alcançada, que no caso das LIBs é tipicamente 4,2 V [28], [29].

Assim que uma destas duas condições se verifique, ocorre a transição de estágio para tensão constante (CV). Nesta segunda etapa, a tensão da bateria é controlada, de modo a ser mantida a um valor constante de $V_{cut-off}$. A corrente da bateria, por consequência desta priorização da tensão, diminui gradualmente, de modo a finalizar o carregamento. O carregamento é concluído quando a corrente da bateria é inferior à corrente de corte (I_d), tipicamente inferior a 3% da corrente de carregamento, ou seja, 0,03 $C-rate$ [29].

Na Figura 2.1 é ilustrado um carregamento típico corrente constante – tensão constante (CC-CV) que foi realizado durante a elaboração desta dissertação.

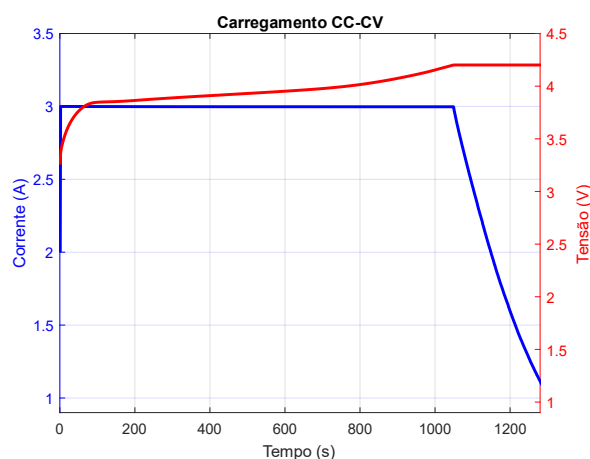


Figura 2.1 - Carregamento CC-CV (obtido de um teste em laboratório)

A velocidade deste carregamento depende principalmente da I_c de carregamento definida, no entanto, o tempo de carregamento não pode ser diminuído só a partir do aumento de I_c , uma vez que isso causa um aumento de tempo de carregamento na fase de tensão constante (CV). Isto deve-se à natureza das características resistivas das LIBs [48]. Em geral, a taxa de carregamento recomendada para as LIBs é de 0,5 a 1 C. Por exemplo, os fabricantes de baterias recomendam uma taxa de carregamento igual ou inferior a 0,8 C para prolongar a vida útil da bateria [25].

Sendo assim, é necessária uma abordagem cuidadosa na seleção de parâmetros, visto que o tempo das fases deste carregamento são inversamente proporcionais. Com uma corrente de carregamento elevada no modo CC, o tempo de estágio pode ser diminuído, mas por sua vez irá aumentar o tempo de CV, e vice-versa.

Apesar de ser o método de carregamento padrão, este possui vantagens e desvantagens.

Algumas das vantagens deste método de carregamento são: a sua simplicidade de implementação e consequente facilidade de integração em sistemas comerciais; é também compatível com a maioria das composições químicas de baterias Li-ion, o que reforça a sua aplicabilidade universal; oferece um bom compromisso entre eficiência e durabilidade, sendo considerado seguro quando corretamente parametrizado [23], [26], [28], [29], [49].

No entanto, este método também apresenta algumas desvantagens. Uma das principais desvantagens é o tempo de carregamento relativamente longo na fase de tensão constante (CV), tornando o CC-CV inapropriado para carregamentos rápidos. Além disso, o método CC-CV não é sensível ao estado de saúde da bateria (SOH), i.e., não ajusta os parâmetros de carregamento em função da resistência interna, que varia de acordo com o estado de carga (SOC), e da temperatura, o que pode comprometer a eficiência e acelerar a degradação em determinadas condições [30], deste modo, este carregamento reduz a eficiência de carregamento e os ciclos de vida da bateria [28].

A aplicação de taxas de correntes elevadas (*C-rates*) na fase inicial de corrente constante (CC), pode também originar um aumento significativo da temperatura, sobretudo em ambientes com menor capacidade de dissipação térmica. Esta elevação térmica, pode favorecer reações secundárias indesejadas, como o crescimento anômalo da camada SEI, contribuindo para uma maior degradação [26], [31], [49]. Alguns resultados também demonstram que 94,5% da perda de inventário de lítio (*loss of lithium inventory* ou LLI) ocorre na fase de tensão constante (CV) [29].

2.2 Carregamento por Pulsos de Corrente (PC)

Na literatura existe também o método de carregamento por pulsos de corrente (PC). Esta estratégia de carregamento injeta corrente na bateria sob a forma de pulsos, de modo a carregar e a proporcionar um período de descanso, para que os iões se disseminem e se neutralizem, ou seja, o intervalo de descanso é o tempo sem corrente entre o final de um pulso e o próximo pulso positivo ou negativo. Neste método a taxa de carregamento é dependente da corrente média, que é controlada variando a largura dos pulsos [50], [51].

Consoante o referido em [33], este método possui duas variações principais, o método de pulso de corrente e o método de pulso de tensão. A diferença principal entre estes dois métodos é a estratégia de controlo durante o carregamento, ou seja, enquanto o pulso de corrente é implementado para carregar a célula da bateria através do uso de um método de carregamento definido previamente, o modo de pulso de tensão é implementado com

o objetivo de alcançar a corrente média necessária, a partir do controlo do *duty-cycle* ou da frequência do dispositivo de comutação.

Dentro deste tipo de carregamento existem variações e metodologias diferentes, onde existem seis modos fundamentais de pulsos de corrente: modo de pulso de corrente positiva (PPC); modo de pulso de corrente - corrente constante (PCCC); modo de pulso de corrente negativa (NPC); modo de pulso de corrente alternada (APC); modo de corrente sinusoidal-*ripple* (SRC) e modo de corrente alternada sinusoidal-*ripple* (ASRC) [40].

As variáveis do modo PPC são de modo geral a frequência, o *duty-cycle* e a amplitude. Para o modo NPC, o número e amplitude das correntes de pulso negativas, bem como o tempo de relaxamento, são considerados os principais fatores que impactam a vida útil e o desempenho do carregamento das baterias de Li-ion [33].

Com base no que já foi mencionado anteriormente sobre este método de carregamento e considerando as suas variantes, a Tabela 2.1, a Figura 2.2 e a Figura 2.3 resumem a abordagem típica a cada tipo de carregamento de pulso e as equações e variáveis que os compõem [33], [40], [50], [51].

Tabela 2.1 - Diferentes métodos de Carregamento por Pulsos de Corrente (adaptado de [33])

Método PC	Nome	Período	Variáveis e Equações	Breve Descrição
PPC Padrão	Pulso de Corrente Positivo	$T = t_p + t_r$	T e $D_p = \frac{t_p}{T}$	Corrente é zero durante o tempo de repouso (t_r). $I_r=0$
PCCC	Pulso de Corrente-Corrente Constante	$T = t_p + t_r$	$I_{mean} = \frac{I_p t_p + I_r t_r}{T}$	Corrente positiva durante tempo de repouso (t_r). $I_r > 0$
PPC	PWM Pulso com Modulação de Largura	$T > W_i$	W_i, A e T	Largura variável (W_i) equivalente a t_p
	PAM Pulso com Modulação de Amplitude	$T > W$	W, A_i e T	Amplitude variável (A_i) equivalente a I_p
CC-PC	Corrente Constante-Pulso de Corrente	$T = t_p + t_r$ em PC	I_{cha} e V_{sw}	Começa em CC com I_{cha} constante. Assim que atinge V_{sw} muda para PC
PC-CV	Pulso de Corrente-Tensão Constante	$T = t_p + t_r$ em PC	T e V_{sw}	Começa em PPC padrão, e após V_{sw} muda para CV

Tabela 2.1 – (continuação)

Método PC	Nome	Período	Variáveis e Equações	Breve Descrição
NPC Padrão	Pulso de Corrente Negativo	$T = t_p + t_r + t_n$	T, I_p e I_{ng}	Semelhante ao PPC, porém acrescenta corrente e tempo negativos (I_{ng} e t_n)
ACP	Pulso de Corrente Alternada	$T = t_p + t_n$	T, I_p e I_{ng}	Semelhante ao PPC, porém substitui t_r e I_r por I_{ng} e t_n
NPC CC-CVNP	CC-CV com Pulso de Corrente Negativo	$T = \frac{C_{cha}}{I_p}$	T, N_n, V_{sw} e $t_p = \frac{T}{N_n} - (t_n + t_r)$	Começa com NPC padrão e assim que atingir V_{sw} muda para CV
MCC-CVNP	CC-CV com Pulso de Corrente Negativo Multi-estágio	$T = \frac{C_{cha}}{I_p}$	$I_{p,i}$ e $I_{ng,i}$	Semelhante ao CC-CVNP, porém no estado NPC, I_p e I_{ng} vão decrementando a amplitude

Onde f representa a frequência, T o período, D_p o *duty-cycle*. Dependente do método de carregamento por pulsos, temos como variáveis secundárias T_p e T_n os períodos positivo e negativo, I_p , I_{ng} e I_r as amplitudes de pulso de corrente positiva, negativa e de repouso, t_p , t_n e t_r os tempos de pulso positivo, negativo e de repouso, I_{mean} a amplitude de pulso de corrente média, I_{cha} a corrente constante do método CC-PC, C_{cha} a capacidade de carregamento da bateria, C_{ref} a capacidade de referência da bateria, N_n o número de pulsos negativos, V_{sw} a tensão máxima de troca, A_i e A a amplitude do pulso variável e não variável, W_i e W a largura do pulso variável e não variável, respectivamente.

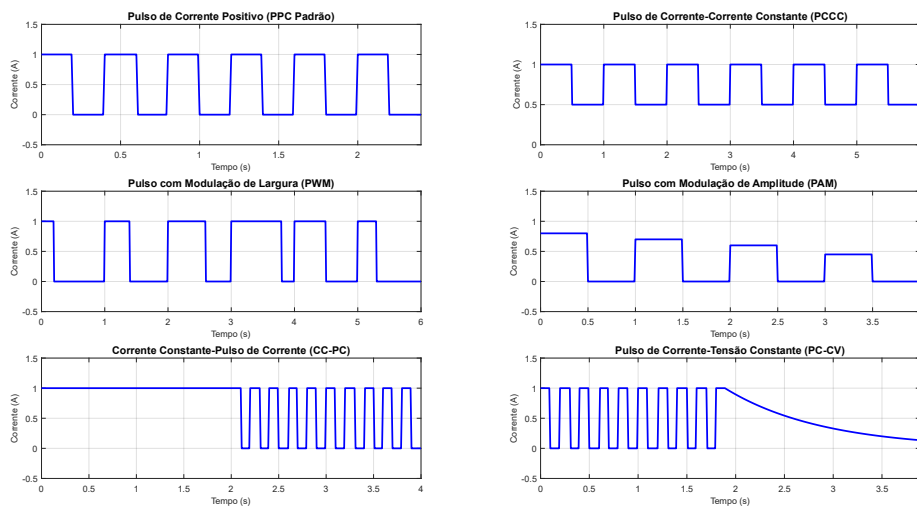


Figura 2.2 - Métodos PPC (adaptado de [33])

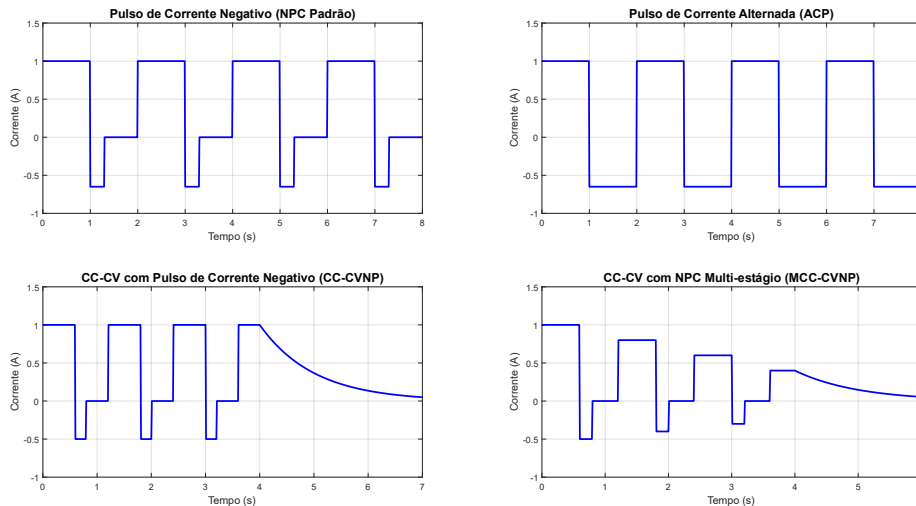


Figura 2.3 - Métodos NPC (adaptado de [33])

Este método de carregamento por pulsos de corrente, possui certas vantagens e desvantagens. Temos como benefícios o aceleração significativo do processo de carregamento, tornando este método apropriado para carregamento rápido. A capacidade de alterar periodicamente a corrente de carregamento, como por exemplo, a capacidade da corrente negativa ajudar a reduzir a tensão de polarização que é causada pelo pulso positivo, possibilitando a polarização na direção oposta, de modo a garantir a estabilidade da interface do ânodo e inibir o crescimento da camada *Solid Electrolyte Interphase* (SEI), que poderia afetar negativamente a bateria, e ainda a vantagem de aumentar os ciclos de vida da bateria [50], [51], [52].

Nos resultados apresentados em [33], pode-se verificar que no método PPC a escolha de uma frequência adequada, numa faixa entre 1Hz a 100kHz, causou o maior impacto positivo na vida da bateria, e ainda que um aumento do *duty-cycle* provocou um período de carregamento maior e um período de repouso menor, causando tempos de carregamento menores. É referido também que no caso do método de carregamento NPC, um perfil com um número de pulsos negativos menores e uma corrente negativa reduzida poderia aumentar a capacidade de carregamento e reduzir o impacto na capacidade da bateria.

Este método de carregamento PC também possui desvantagens que podem pôr em causa o funcionamento e capacidade da bateria. Uma alta taxa de corrente pode provocar uma alteração de tensão indesejada, que consequentemente pode levar a que a tensão nos terminais da bateria exceda significativamente a tensão máxima recomendada e se aproxime do limite de segurança, danificando a mesma e pondo em causa o seu

funcionamento [51]. Este método, tendo muitas variáveis de controlo, torna-se complexo, requerendo um cuidado elevado na seleção de valores adequados, visto que uma corrente de pulso mal parametrizada pode levar ao aumento de temperatura, que por sua vez pode levar a reações químicas indesejadas no interior da bateria [52].

É mencionado também em [33], que no método PPC, o aumento da amplitude da corrente, apesar de ser benéfico para o tempo de carregamento, causou um aumento de temperatura indesejado, que afetou negativamente a segurança e a duração do sistema da bateria. Já no método NPC, um elevado tempo e uma elevada amplitude da corrente de pulso negativa resultou em tempos de carregamento mais lentos, visto que pulsos negativos provocam um descarregamento da bateria, e tal como no método PPC, o aumento da amplitude da corrente negativa também levou ao aumento da temperatura e consequentemente à redução da vida da bateria.

2.3 Carregamento Multi-estágio de Corrente Constante (MSCC)

O carregamento multi-estágio de corrente constante (MSCC) é constituído por vários estágios de Corrente Constante (CC), como pode ser evidenciado na Figura 2.4, e a amplitude de corrente aplicada é decrementada à medida que se avança nos estágios, onde a troca de estágio depende dos critérios de transição utilizados, que serão posteriormente abordados.

De forma mais detalhada, no método de carregamento MSCC, a tensão nos terminais da bateria aumenta em cada estágio em função da corrente aplicada. Assim que um dos critérios de transição de estágio se verificar, como por exemplo a tensão máxima de corte ($V_{cut-off}$), procede-se à mudança para o estágio seguinte, reduzindo a amplitude de corrente (I) para o valor subsequente. Este processo repete-se sequencialmente até ao último estágio definido pelo perfil de corrente estipulado. Posto isto, as correntes deste método de carregamento que são gradualmente reduzidas, respeitam a inequação: $I_{max} \geq I_1 > I_2 > \dots > I_n$, onde I_{max} é a corrente máxima aceitável de carregamento da bateria e I_n a amplitude da corrente do n -ésimo estágio [53].

Este método visa melhorar a eficiência de carregamento, reduzir o aumento de temperatura durante o carregamento, reduzir o tempo de carregamento e prolongar os ciclos de vida úteis das baterias, principalmente as baterias de Li-ion (LIB's) [16], [54].

Existem várias implementações e estudos na literatura onde se definem diferentes parâmetros e variáveis, como por exemplo, o número de estágios, critérios de transição de estágios, seleção do *C-rates* para cada estágio, etc. [16].

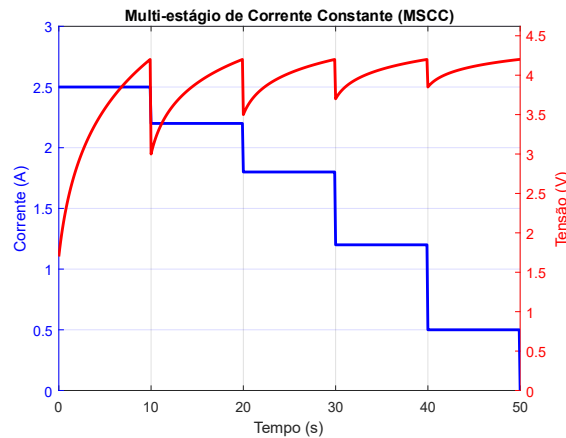


Figura 2.4 - Método MSCC de 5 estágios

Este método de carregamento possui os seguintes critérios de transição de estágio [16]:

- **Critério baseado no Tempo** - neste critério, o método de transição de estágio é o tempo; o intervalo de tempo é escolhido com base nos intervalos de SOC; as taxas de corrente (*C-rates*) são selecionadas aleatoriamente.
- **Critério baseado no SOC** - neste critério a percentagem do SOC é que define a transição de estágio; a estimativa do SOC é uma tarefa desafiante.
- **Critério baseado na Tensão** - neste critério é selecionado um nível de tensão para transitar de estágio e o valor da corrente de carregamento, onde os valores da tensão variaram de 3,6 V a 4,2 V; Estes valores de tensão são definidos aleatoriamente.
- **Critério baseado na Tensão máxima ($V_{cut-off}$)** - é o método de transição de estágio mais utilizado na literatura; assim que $V_{cut-off}$ é alcançada durante o carregamento, a corrente é reduzida (transição de estágio), e o carregamento continua até que a tensão de corte seja alcançada novamente; o número de estágios de corrente é definido previamente ao carregamento.

Outra variável importante neste método de carregamento é o número de estágios a serem utilizados durante o carregamento. Afinal, qual é o número de estágios necessário para o carregamento das LIB's ser mais eficiente, mais rápido e menos impactante na vida da bateria? Existem diversas considerações e trabalhos desenvolvidos na literatura sobre o número de estágios.

Em [55] o autor colocou uma bateria de Li-ion da LG numa câmara térmica e através de sensores, fontes externas e de um computador simulou vários carregamentos de MSCC, onde utilizou o critério de transição de tensão máxima para mudança entre estágios. Nesta experiência o autor utilizou cinco estágios totais, que após vários MSCC elaborados, de modo a comparar o melhor resultado, posteriormente comparou com o método de carregamento CC-CV. O MSCC proposto de cinco estágios foi capaz de carregar a capacidade da bateria até 100%, demorou 12% menos tempo a carregar, a eficiência de carregamento foi melhorada em 0,54% e a energia de carga foi reduzida em 1,8% quando comparado com o método CC-CV.

Em [56] é usada uma bateria genérica 18650, uma câmara térmica com temperatura constante, e colocou outras três baterias para ter resultados paralelos. No carregamento MSCC, utilizou diferentes números de estágios, tendo também avaliado diferentes parâmetros. Obteve como resultados o seguinte:

- Uma estratégia de três estágios, com parâmetros $1C-0,5C-0,3C$ com SOC de 70-80-100%, alcançou 88% da capacidade convencional (2,52 Ah) e reduziu o tempo de carregamento para 69% (4480s) quando comparado com o método CC-CV;
- Outra estratégia de três estágios, com parâmetros $1C-0,5C-0,75C$ com SOC de 40-80-100%, obteve a mesma capacidade (2,52 Ah), mas levou mais de tempo do que o MSCC anterior, representando 78% (5061s) do tempo de carregamento comparativamente ao método CC-CV;
- Por último, uma estratégia de dois estágios ($1C-0,5C$), que obteve uma capacidade de carregamento de 82%, e tempo de carregamento de 54% (3530s) em relação ao método CC-CV.

Pode-se observar que nos diferentes MSCC realizados existe uma relação inversa, ou seja, quando um carregamento oferece tempos mais rápidos, a capacidade de carregamento é reduzida. Cada estratégia depende da prioridade do carregamento, se se pretende velocidade ou preservação da bateria.

Em [42] é proposto cinco casos de MSCC com dez estágios cada, de modo a estudar a influência destes nos ciclos de vida da bateria, tempos de carregamento e impacto na capacidade da bateria. Na Tabela 2.2 podemos observar os resultados deste estudo, onde cada caso de MSCC é comparado com um protocolo CC-CV de referência.

Tabela 2.2 - Parâmetros e impactos - MSCC vs. CC-CV (adaptado de [42])

Caso	Tempo total (min)	Tempo de CC-CV (min)	Temperatura (°C)	Ciclos de vida vs. CC-CV
MSCC - A	65	61	25	700 a 800 vs. 330
MSCC - B	52	61	25	450 vs. 330
MSCC - C	37	46	25	1200 vs. 600
MSCC - D	91	66	5	400 vs. 100
MSCC - E	44	53	45	1200 vs. 900 a 1000

Podemos também concluir deste trabalho que as variantes do MSCC reduzem ou atrasam consistentemente a perda de capacidade em comparação com o método CCCV.

Em particular, o MSCC-C, após 1200 ciclos de vida teve apenas uma perda de 25% da capacidade quando comparado com 30% de perda de capacidade no fim de vida (600 ciclos) do protocolo CC-CV de referência.

Tendo em consideração o que já foi mencionado e esclarecido anteriormente sobre o método de carregamento MSCC, de modo a concluir este capítulo, aborda-se agora as principais vantagens e desafios associados a este método, com base no que vários autores mencionam na literatura e que também pode ser constatado nos seus artigos e trabalhos experimentais.

Conforme a pesquisa realizada, podem-se retirar algumas desvantagens associadas ao método de carregamento MSCC. Começando pelo facto de taxas de corrente de carregamento elevadas (*C-rates*) causarem polarização, ou seja, a decomposição do lítio, formando o denominado *lithium plating*. De facto, elevadas correntes que excedam a corrente máxima definida pelo fabricante podem provocar o aumento excessivo da temperatura, que ultimamente provoca a degradação e afeta negativamente a vida útil da bateria, diminuindo drasticamente os ciclos de vida totais das baterias [36], [54]. O mesmo pode-se verificar quando a tensão aplicada à bateria excede a tensão máxima definida pelo fabricante, afetando também negativamente a vida útil da bateria [16]. Outra limitação do método de carregamento MSCC é a sua alta necessidade de prever com precisão o SOC e a tensão da bateria como é também constatado em [16].

Apesar destas desvantagens serem bastante significativas e impactantes nos vários parâmetros da bateria, é de notar que todas estas podem ser controladas ou até suprimidas com uma abordagem cuidadosa e uma otimização das variáveis associadas a este método de carregamento.

Portanto, as vantagens associadas a este método são: o facto de este suprimir o aumento de temperatura, atingindo temperaturas máximas mais baixas [41], [57]; carrega mais rápido, reduzindo o tempo necessário para carregar a bateria, uma vez que é um método mais simples e eficaz do que um CC-CV típico [16], [36], [41], [57].

Em [57] é referido que o método MSCC desenvolvido obteve uma redução de tempo de 37%, de 6105s do método CC-CV para 3846s do MSCC.

De facto, este método de carregamento permite diminuir o tempo de carregamento sem aumentar ou até mesmo reduzir o grau de degradação da bateria, causando uma perda de desempenho reduzida, prolongando a vida útil da bateria, especialmente das LIB's, fazendo com que estas possam durar mais ciclos de vida [16], [36], [42], [57].

Muitas vezes para obter o máximo que este método de carregamento possibilita, tem de se ter em conta que é extremamente necessário definir um balanço entre esse mesmo tempo de carregamento e o envelhecimento, ou seja a degradação da bateria [57].

Em [53] é referido ainda que o MSCC aumenta a flexibilidade uma vez que pode ser aplicado sem aumentar a complexidade de controlo.

O método de carregamento MSCC permite também um ajuste mais refinado do que o protocolo CC-CV, uma vez que reduz a corrente nas últimas etapas do processo de carregamento para evitar mecanismos de envelhecimento amplificados por altos níveis de SOC [42]. É também ainda mencionado em que protocolos otimizados podem melhorar os ciclos de vida úteis da bateria, que segundo [16], a redução progressiva das *C-rates* reduz o efeito de polarização nas LIB's.

No mesmo assunto, em [55] é referido que um Padrão de Carga Ótimo (OCP), que pode ser obtido de forma bastante simplificada, ajuda a que o trabalho e o tempo possam ser reduzidos significativamente na fase inicial de preparação.

Os estudos [16], [55] mencionam que outra vantagem do MSCC é o facto de não utilizar a fase de tensão constante (CV), que aplica stress constante à bateria, uma vez que tensões elevadas podem intensificar o processo de oxidação do eletrólito. Deste modo, ao eliminar a etapa CV, este método garante que o processo de oxidação é reduzido, garantindo um aumento na vida útil da bateria.

O método 5S-CC (MSCC com 5 estágios) desenvolvido em [54] apresentou resultados e conclusões também já referidas anteriormente. Este método carregou a bateria de forma

benéfica para o estado de saúde da bateria (SOH) e, além disso, conseguiu alcançar uma variação de temperatura inferior quando comparado com o CC-CV. Adicionalmente, verificou-se que foi vantajoso em termos de degradação dos materiais da bateria, já que temperaturas mais altas afetam negativamente a estabilidade dos componentes internos da bateria.

2.4 Discussão dos vários métodos de carregamento

Após o estudo dos métodos de carregamento corrente constante–tensão constante (CC-CV), pulso de corrente (PC) e multi-estágio de corrente constante (MSCC), torna-se necessário selecionar o método mais adequado para a presente investigação.

Embora o método CC-CV seja o mais amplamente utilizado, revela-se pouco viável para aplicações de carregamento rápido, devido à sua transição de estados. Caso a passagem de CC para CV ocorra de forma demasiado rápida, ou a fase de CC seja prolongada em excesso, o tempo total de carregamento pode aumentar significativamente, além de poder originar temperaturas elevadas que comprometem a integridade e a vida útil da bateria [36]. Adicionalmente, por ser um método amplamente estudado e pouco fiável, foi considerado inadequado para a componente experimental da presente dissertação.

Por sua vez, o método de carregamento por pulsos de corrente (PC) apresenta bons resultados, mas requer uma abordagem bastante cuidadosa devido à sua complexidade. Além disso, exige equipamentos específicos e dispendiosos, uma vez que opera com altas frequências, o que o torna menos executável para a presente aplicação experimental.

Deste modo, o método multi-estágio de corrente constante (MSCC) surge como uma alternativa promissora. Este será o método adotado na componente experimental desta dissertação, por ser eficaz, de implementação simples e ainda pouco explorado na literatura, apresentando resultados inconsistentes que justificam um estudo mais aprofundado.

Os trabalhos e estudos de diversos autores referidos anteriormente também influenciaram fortemente esta escolha, uma vez que as principais desvantagens do MSCC apenas se verificam quando o processo de otimização é insuficientemente desenvolvido ou pouco rigoroso.

Capítulo 3

Formulação do problema e Algoritmos de Otimização

3.1 Formulação do problema

A formulação do problema de otimização tem como objetivo minimizar o tempo total de carregamento e, simultaneamente, maximizar o estado de carga final (SOC_f). A escolha do tempo de carregamento e do estado de carga final, como critérios na formulação da função objetivo, permite alcançar um compromisso entre rapidez de carregamento e desempenho energético. O tempo de carregamento reflete a necessidade de reduzir a duração do processo de carregamento (um aspeto crítico em aplicações com restrições temporais).

Por outro lado, o SOC final indica a quantidade efetiva de energia acumulada, sendo diretamente associado à autonomia e à disponibilidade energética. No entanto, como estes dois critérios ou fatores são expressos em unidades diferentes, torna-se necessário proceder à sua normalização, de forma a permitir uma comparação equitativa e a integração numa única função objetivo.

Adicionalmente, foi introduzido um peso de ponderação α , que permite ajustar a influência relativa de cada fator na função objetivo. Este fator de ponderação pode ser ajustado de acordo com as prioridades do sistema por exemplo, favorecendo a autonomia ou o tempo de carregamento, consoante a aplicação. Com base nestas considerações, a função objetivo pode ser expressa de forma combinada, permitindo ao algoritmo de otimização (neste caso, o PSO) encontrar uma solução que represente um compromisso adequado entre desempenho energético e rapidez no carregamento.

$$f_{obj} = \alpha \times \left(\frac{T_{char}}{T_{max}} \right) + (1 - \alpha) \times (1 - SOC_f) \quad (3.1)$$

O problema de otimização é sujeito às seguintes restrições:

$$0.9 \leq SOC_f \leq 1 \quad (3.2)$$

$$T_{char} \leq T_{max} \quad (3.3)$$

$$I_{lb} \leq I_t \leq I_{ub} \quad (3.4)$$

$$I_t \leq I_{t-1} \quad (3.5)$$

Onde T_{char} representa o tempo total de carregamento; T_{max} o tempo máximo admissível para o processo de carregamento (neste estudo foi definido como 2 horas); α o fator de ponderação compreendido entre $[0,1]$; I_t a corrente de carregamento no instante de tempo t ; I_{lb} e I_{ub} os limites inferiores e superiores da corrente de carregamento, respetivamente.

As restrições estipuladas no problema de otimização contribuem para a segurança e durabilidade da bateria. Ao incentivar a maximização do SOC dentro de limites operacionais pré-estabelecidos, evita-se a exposição da bateria a condições de sobrecarga ou aquecimento excessivo, promovendo uma gestão energética mais eficiente e segura.

Além disso, a imposição de restrições explícitas sobre o tempo de carregamento e a corrente de carregamento garante que a solução obtida pelo algoritmo de otimização respeite os parâmetros técnicos, incluindo valores de corrente admissíveis, monotonia decrescente da corrente de carregamento e restrições térmicas.

3.2 Métodos de Otimização (Algoritmos Meta-heurísticos)

Os algoritmos meta-heurísticos são métodos de otimização que visam procurar, num espaço de procura definido, a melhor solução para um determinado problema de minimização ou maximização. Ao contrário das técnicas tradicionais de otimização que fazem a linearização da função objetivo, ou que utilizam derivadas e gradientes, os algoritmos meta-heurísticos empregam estratégias avançadas em busca da melhor solução. Encontrar o equilíbrio ideal, entre exploração global e exploração local, é um aspeto crucial de qualquer algoritmo meta-heurístico [58].

Estes algoritmos são categorizados por evolutivos, físicos, de enxame, humanos e híbridos [58], [59], [60].

Os evolutivos são algoritmos inspirados na teoria da evolução de Darwin, onde cada iteração representa uma geração. Cada geração é composta por uma seleção da geração anterior (ascendentes), recombinação (*crossover*), mutação e seleção natural. Enquanto a recombinação e a mutação são responsáveis pela exploração global, os ascendentes e seleção natural são responsáveis pela exploração local. Alguns exemplos destes algoritmos evolutivos são: *Backtracking Search Algorithm* (BSA) [61]; *Biogeography-Based Optimization* (BBO) [62]; *Differential Evolution* (DE) [63], [64]; *Genetic Algorithm* (GA) [65]; *Shuffled Complex Evolution* (SCE) [66], [67].

Os físicos são algoritmos que replicam as leis da física ou química ao longo do processo de otimização de maneira a encontrar a melhor solução. De facto, estas técnicas de otimização são motivadas por os princípios físicos e químicos da natureza. Por exemplo o algoritmo do *Simulated Annealing* (SA) baseia-se num processo de tratamento térmico metalúrgico (recozimento), começando por inicializar a temperatura e lentamente decrementando-a. Já o *Gravitational Search Algorithm* (GSA) é influenciado pela gravidade e o movimento das partículas, ou seja, simula a interação de corpos celestes de modo a analisar as dificuldades do processo de otimização. Este GSA exerce forças gravitacionais de modo a atrair soluções promissoras para certas zonas do espaço de procura e modifica as suas posições consoante a massa e aceleração dos agentes. Alguns dos principais algoritmos meta-heurísticos físico-inspirados são: *Gravitational Search Algorithm* (GSA) [68]; *Multiverse Optimizer* (MVO) [69], [70]; *Simulated Annealing* (SA) [71], [72]; *Spiral Optimization* (SPO) [73]; *Wind Driven Optimization* (WDO) [74], [75].

Em terceiro temos os algoritmos meta-heurísticos baseados em enxames. Estes algoritmos de inteligência de enxame que mimetizam o comportamento social de um grupo de animais e a forma como comunicam entre si, o que pode influenciar diretamente o movimento individual de cada agente. Como tal, existe um equilíbrio entre exploração local (associado a cada agente, *exploitation*), e exploração global (*exploration*) que equivale à pesquisa pela melhor solução no espaço de procura. Alguns dos principais meta-heurísticos de enxame são: *Particle Swarm Optimization* (PSO) [76], [77]; *Grey Wolf Optimizer* (GWO) [78]; *Flower Pollination Algorithm* (FPA) [79], [80]; *Artificial Bee Colony* (ABC) [81]; *Ant Colony Optimization* (ACO) [82].

Os algoritmos meta-heurísticos humanos são inspirados nas interações sociais ou padrões comportamentais das pessoas. Estes usam tais comportamentos humanos para resolver problemas de otimização. Por exemplo, a maneira como se geram ideias influenciou a origem do algoritmo *Brainstorm Optimization* (BSO). Este algoritmo resolve problemas de otimização através da criação, aceso e refinamento de potenciais soluções, usando a procura coletiva. O *Teaching-Learning-based Optimization* (TLBO) aplica a influência que os professores exercem sobre os alunos, fazendo com que estes últimos explorem novos conceitos e ideias, de modo a encontrar uma solução ótima. De modo a desenvolver possíveis soluções ótimas este algoritmo adota táticas instrutivas como a exploração local, exploração global e a troca de conhecimento entre agentes. Alguns exemplos dos meta-heurísticos inspirados em humanos são: *Teaching-Learning-based Optimization* (TLBO) [83]; *Human-Inspired Algorithm* (HIA) [84], [85], [86];

Brainstorm Optimization (BSO) [87]; *Social Emotional Optimization* (SEO) [88], [89]; *Gaining-sharing Knowledge* (GSK) [90].

Por último temos os meta-heurísticos híbridos, criados através da fusão/combinção dos operadores mais eficazes de outros algoritmos meta-heurísticos. Este tipo de algoritmos possui uma técnica aperfeiçoada que ajuda a eliminar a retenção em falsos locais ótimos, evitando a convergência prematura, de modo a aumentar a eficiência e eficácia da exploração do espaço de procura. Alguns dos algoritmos híbridos são: PSO-GWO [91]; HPSO-MVO [92]; GA-ACO [93]; TLBO-GWO [94].

A Figura 3.1 sintetiza os diversos ramos dos algoritmos meta-heurísticos mencionados anteriormente.

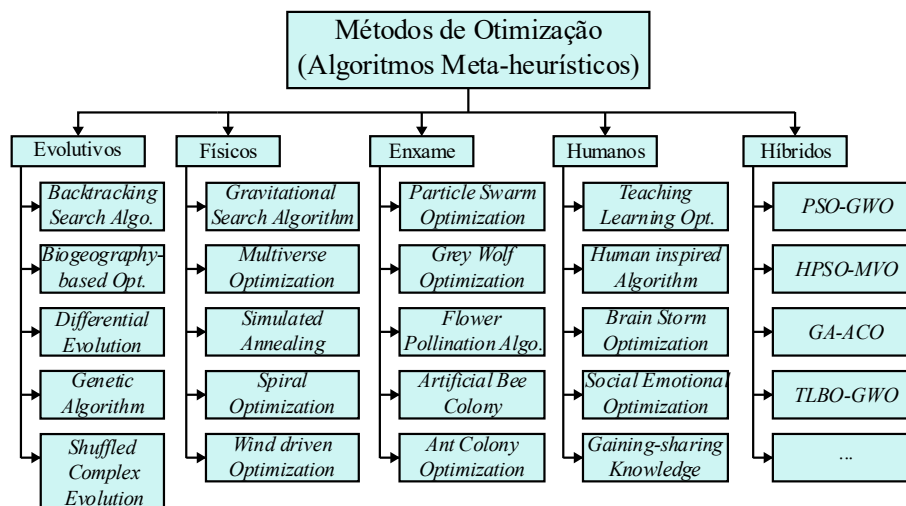


Figura 3.1 - Taxinomia dos Algoritmos Meta-heurísticos (adaptado de [60])

Existe uma extensa literatura em redor dos métodos de otimização com base nos algoritmos meta-heurísticos. Devido à sua enorme abrangência, fácil implementação, viabilidade, consistência e simplicidade, quando comparado com os outros algoritmos meta-heurísticos, o *Particle Swarm Optimization* (PSO) é o algoritmo que a presente dissertação irá recorrer para o processo de otimização do método de Carregamento multi-estágio de corrente constante (MSCC). Ao usar o PSO como método de otimização, o objetivo é maximizar a eficiência energética, reduzir o tempo total de carregamento, estender a vida da bateria, e certificar uma elevada segurança durante todo o processo.

3.2.1 Particle Swarm Optimization (PSO)

O algoritmo meta-heurístico *Particle Swarm Optimization* (PSO) mimetiza o comportamento que algumas espécies de animais adotam na procura de alimento. Esses conjuntos de animais (enxames) são considerados como partículas ou agentes. O enxame de N partículas move-se num espaço de procura de D dimensões com o objetivo de encontrar a melhor solução para o problema de otimização consoante as variáveis do problema real a resolver [95].

De modo a encontrar a melhor solução, tem de ser definido o referido espaço de procura, que é delimitado segundo o limite superior e o limite inferior, que na literatura são referidos como *upper bound* (UB) e *lower bound* (LB), respetivamente. O limite superior é dado por $UB = [ub_1, ub_2, \dots, ub_D]$ e o limite inferior é dado por $LB = [lb_1, lb_2, \dots, lb_D]$. Deve-se inicializar as partículas respeitando a equação $x_i^0 \sim E(UB, LB)^D$, onde x_i^0 representa a posição inicial ($k = 0$, visto ser a primeira iteração) de todas as partículas do enxame, que são iniciadas aleatoriamente (\sim) num espaço de procura E definido com valores de limite UB^D e LB^D .

A cada partícula de índice i estão associados os vetores de velocidade atual $V_i = [v_{i1}, v_{i2}, \dots, v_{iD}]$ e de posição atual $X_i = [x_{i1}, x_{i2}, \dots, x_{iD}]$, para $i = 1, 2, \dots, N$. Para obter a melhor solução, cada partícula move-se em direção à melhor posição atingida anteriormente por essa mesma partícula (p_{best}) e à melhor posição global encontrada por o enxame (g_{best}), sendo que a velocidade desse movimento tem em conta a velocidade anterior da partícula, ponderada por um fator de inércia (ω), a experiência dessa partícula (fator cognitivo) e a experiência das restantes partículas da população (fator social), que são atualizadas a cada iteração, isto é, a cada iteração as melhores posições pessoais e globais são atualizadas.

Deste modo as partículas vão-se deslocar, atualizando-se conforme as Equações 3.6 e 3.7 que descrevem a velocidade e a posição de cada partícula, respetivamente [96]:

$$v_{i,j}^{k+1} = \omega v_{i,j}^k + c_1 r_1 (p_{best_{i,j}}^k - x_{i,j}^k) + c_2 r_2 (g_{best_{i,j}}^k - x_{i,j}^k) \quad (3.6)$$

$$x_{i,j}^{k+1} = x_{i,j}^k + v_{i,j}^{k+1} \quad (3.7)$$

onde $v_{i,j}^{k+1}$ e $x_{i,j}^{k+1}$ representam a velocidade e a posição da i -ésima partícula na j -ésima

dimensão (onde $j = 1, 2, \dots, D$) para a k -ésima iteração, respetivamente; ω representa o fator da inércia que controla a exploração global e a exploração local, anteriormente mencionado; c_1 e c_2 os coeficientes de aceleração cognitivo e social, respetivamente; r_1 e r_2 números aleatórios com uma distribuição uniforme no intervalo $[0,1]$.

O p_{best} e o g_{best} mencionados anteriormente dependem da intenção de resolução do problema em questão: se se pretende minimizar ou maximizar. Deste modo os valores de p_{best} e g_{best} são dados pelas Equações 3.8 e 3.9 seguintes:

$$p_{best_i}^k = x_i^* \text{ tal que } f(x_i^*) = \begin{cases} \min f_{obj}(x_i^k), & \text{se for minimização,} \\ \max f_{obj}(x_i^k), & \text{se for maximização.} \end{cases} \quad (3.8)$$

$$g_{best}^k = x_*^k \text{ tal que } f(x_*^k) = \begin{cases} \min_i f_{obj}(x_i^k), & \text{se for minimização,} \\ \max_i f_{obj}(x_i^k), & \text{se for maximização.} \end{cases} \quad (3.9)$$

onde k indica o índice da iteração em que o melhor valor da função objetivo f_{obj} a ser otimizada foi encontrado até ao momento, x_i^* representa a melhor posição pessoal alcançada pela i -ésima partícula até ao momento e x_*^k representa a melhor solução global encontrada pelo enxame até à iteração atual k .

A Figura 3.2 ilustra o funcionamento típico do *Particle Swarm Optimization* (PSO), com base no que foi descrito anteriormente.

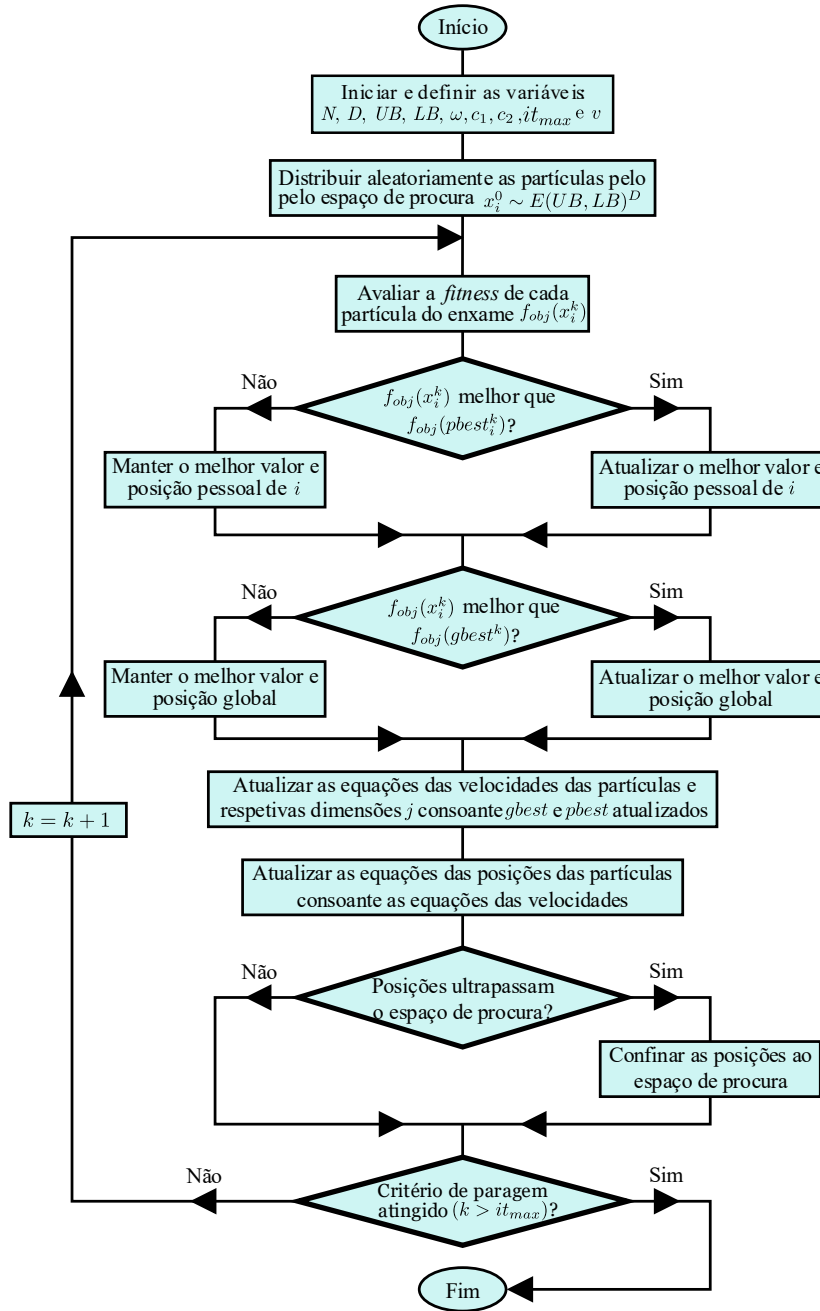


Figura 3.2 – Diagrama de Estados do Particle Swarm Optimization

3.3 Procedimento Experimental

Foi implementado um *setup* experimental composto por diversos equipamentos eletrónicos interligados, com o objetivo de controlar, monitorizar e adquirir dados em tempo real de forma precisa e confiável. A bateria Li-ion utilizada nos ensaios (Samsung ICR18650-26H com uma capacidade de 2.55 Ah) foi acondicionada no interior de uma câmara térmica, de modo a garantir condições ambientais estáveis durante todo o processo de carregamento e descarregamento. Este controlo térmico é fundamental para

evitar variações de temperatura que possam comprometer o comportamento eletroquímico da bateria. A temperatura da câmara térmica é controlada por um microcontrolador *Arduino Mega 2560*, que atua em tempo real com base nas medições internas.

O carregamento da bateria é realizado através de uma fonte de alimentação DC programável RIGOL DP811A. Esta fonte é essencial para aplicar os diferentes perfis de corrente definidos pelo algoritmo de otimização PSO, ajustando automaticamente o *C-rate* em cada estágio do carregamento, de acordo com os parâmetros determinados. Para o processo de descarregamento, foi utilizada uma carga eletrónica DC RIGOL DL3021A, que simula condições reais de operação ao impor perfis de descarregamentos controlados, consistentes e predefinidos. A monitorização dos parâmetros elétricos, como a corrente e a tensão, foi feita com um multímetro digital de precisão RIGOL DM3058E, assegurando a fiabilidade das medições ao longo de todos os ensaios.

A coordenação, gestão e controlo de todo o sistema foi realizada através de um computador com software MATLAB, que executa o algoritmo PSO, gera os perfis de carregamento, comunica com os dispositivos através de interfaces USB e série, recolhe automaticamente os dados experimentais em tempo real e efetua os cálculos necessários para a avaliação do desempenho e da eficácia do método proposto. Este *setup* experimental, totalmente automatizado, permitiu a realização de testes repetitivos com elevada consistência e precisão, sendo fundamental para validar a eficiência do método proposto em tempo real.

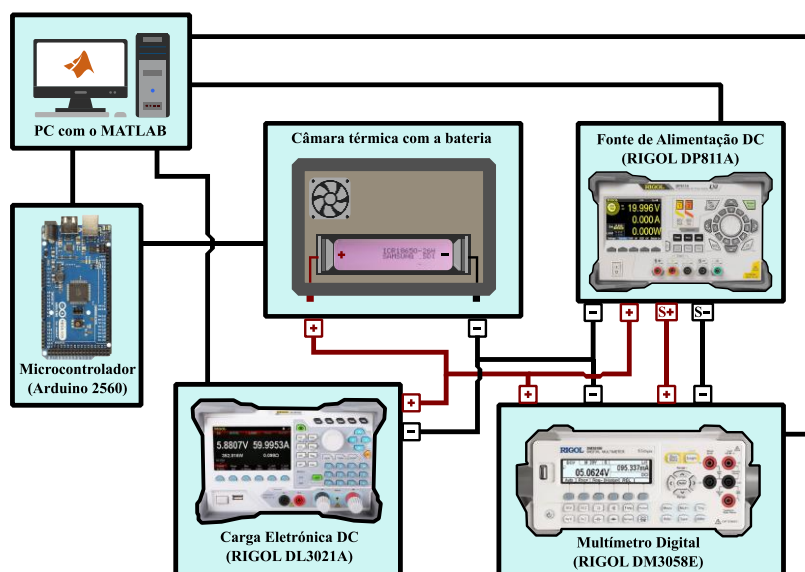


Figura 3.3 - Esquema do Procedimento Experimental

Capítulo 4

Processo e Resultados Experimentais

4.1 Procedimento de Otimização

O processo de otimização foi estruturado de acordo com um procedimento iterativo baseado no algoritmo *Particle Swarm Optimization* (PSO). A metodologia adotada encontra-se representada esquematicamente na Figura 4.1 que ilustra tanto a lógica de funcionamento do algoritmo como o ciclo completo de carregamento e descarregamento utilizado nos ensaios experimentais. Numa fase inicial, são definidos os principais parâmetros do algoritmo PSO, nomeadamente: o número de partículas na população (N), o número máximo de iterações (it_{max}), a dimensão do problema (D), e os coeficientes de inércia (ω), cognitivo (c_1) e social (c_2). Neste trabalho foram considerados um fator cognitivo e social igual a dois ($c_1 = c_2 = 2$), um fator de inércia de 0,6 e uma população (N) de cinco indivíduos e número máximo de iterações de dez ($it_{max} = 10$). O número de indivíduos e o número máximo de iterações foram selecionados em função do custo computacional, que envolve todo o processo de otimização.

Além disso, estabelece-se o número de patamares de corrente (n) do perfil de carregamento, bem como os limites mínimo (lb) de $0.1C$ e máximo (ub) de $1.77C$ admissíveis para a corrente em cada estágio.

Define-se ainda o critério de transição entre patamares, que nesta dissertação é baseado na tensão máxima da bateria (4,2V), conforme especificado pelo fabricante. Cada partícula gerada pelo PSO corresponde a um vetor de correntes, *i. e.*, $[I_1, I_2, \dots, I_n]$, que representa um perfil de carregamento MSCC. Esse perfil é fisicamente testado no *setup* experimental, iniciando-se o processo de carregamento com a aplicação sequencial dos valores de corrente definidos. A fonte de alimentação programável ajusta dinamicamente os níveis de corrente, enquanto diversos parâmetros são monitorizados em tempo real: o tempo de carregamento, o estado de carga (SOC) e temperatura da bateria.

O SOC pode ser determinado de forma direta, baseada na medição de parâmetros físicos da bateria, como tensão, corrente, impedância, temperatura, resistência interna e outros parâmetros que possuam uma correlação com a bateria. Os métodos existentes de estimativa de SOC da bateria podem ser classificados em: contagem de coulombs [49] e

[50]; medição da tensão de circuito aberto (OCV) [51] e [52]; baseado em modelo; redes neurais artificiais; e método de espectroscopia de impedância eletroquímica.

Na presente dissertação é utilizada a contagem de Coulombs, que é a técnica mais utilizada na literatura, uma vez que possui alta precisão em cálculos de curto-tempo, e por ser uma técnica de fácil implementação.

A Equação 4.1 representa o cálculo do SOC a cada instante de tempo,

$$SOC(t) = SOC(t_0) + \frac{1}{C_n} \int_{t_0}^{t_0+t} I_{bat}(d\gamma) * 100\% \quad (4.1)$$

onde $SOC(t_0)$ representa o SOC do carregamento ao instante de tempo inicial (t_0), C_n a capacidade nominal da bateria e I_{bat} a corrente a ser aplicada á bateria. Como o método CC é altamente sensível ao SOC inicial, é necessário estimar o SOC inicial previamente devido à acumulação de erro que é produzido, onde este ocorre devido à ampla resolução do sensor e ao ruído.

Posto isto, concluído o carregamento, a bateria entra numa fase de repouso, permitindo a estabilização térmica e eletroquímica.

Paralelamente, a função objetivo é avaliada com base em duas métricas principais: o tempo de carregamento e o estado de carga, resultando num valor de desempenho associado a cada partícula. Estas métricas são normalizadas para garantir compatibilidade de unidades e são combinadas numa única função objetivo, através de um fator de ponderação α , que permite ajustar o equilíbrio entre rapidez de carregamento e autonomia. Em seguida, é realizado o descarregamento a corrente constante com uma taxa de 1C, simulando um ciclo completo de utilização. Após nova fase de repouso, o ciclo é repetido com o perfil de corrente correspondente à próxima partícula. Estes ensaios são conduzidos dentro de uma câmara térmica com temperatura controlada, de forma a eliminar a influência de variáveis ambientais nos resultados. Avaliadas todas as partículas pertencentes à população, e com base no seu desempenho, é determinado o $pbest$ e o $gbest$. De seguida, o PSO calcula a velocidade das partículas através da Equação 3.6, com o objetivo gera novas partículas, i.e., novos perfis de carregamento.

No entanto, para garantir que as partículas se mantêm dentro dos limites admissíveis de corrente definidos, é aplicado um critério de verificação após cada atualização: se o valor de corrente calculado exceder o limite superior, é automaticamente ajustado para esse

valor máximo; se ficar abaixo do limite inferior, é igualmente corrigido. Este mecanismo assegura a viabilidade prática e a segurança de todos os perfis testados. O processo de otimização é repetido até que se atinja o critério de paragem, neste caso, o número máximo de iterações. Esta metodologia, totalmente automatizada, permite explorar de forma sistemática e eficiente múltiplas configurações de carregamento MSCC, com o objetivo de encontrar o perfil ótimo que maximize o desempenho da bateria em termos de eficiência energética e tempo de carregamento, garantindo simultaneamente a segurança operacional e a longevidade.

Consoante o que foi referido anteriormente neste capítulo 4, tanto como no capítulo 3, a Figura 4.1 representa todo este procedimento experimental e de otimização, mencionando as equações que estão na base de todo o funcionamento.

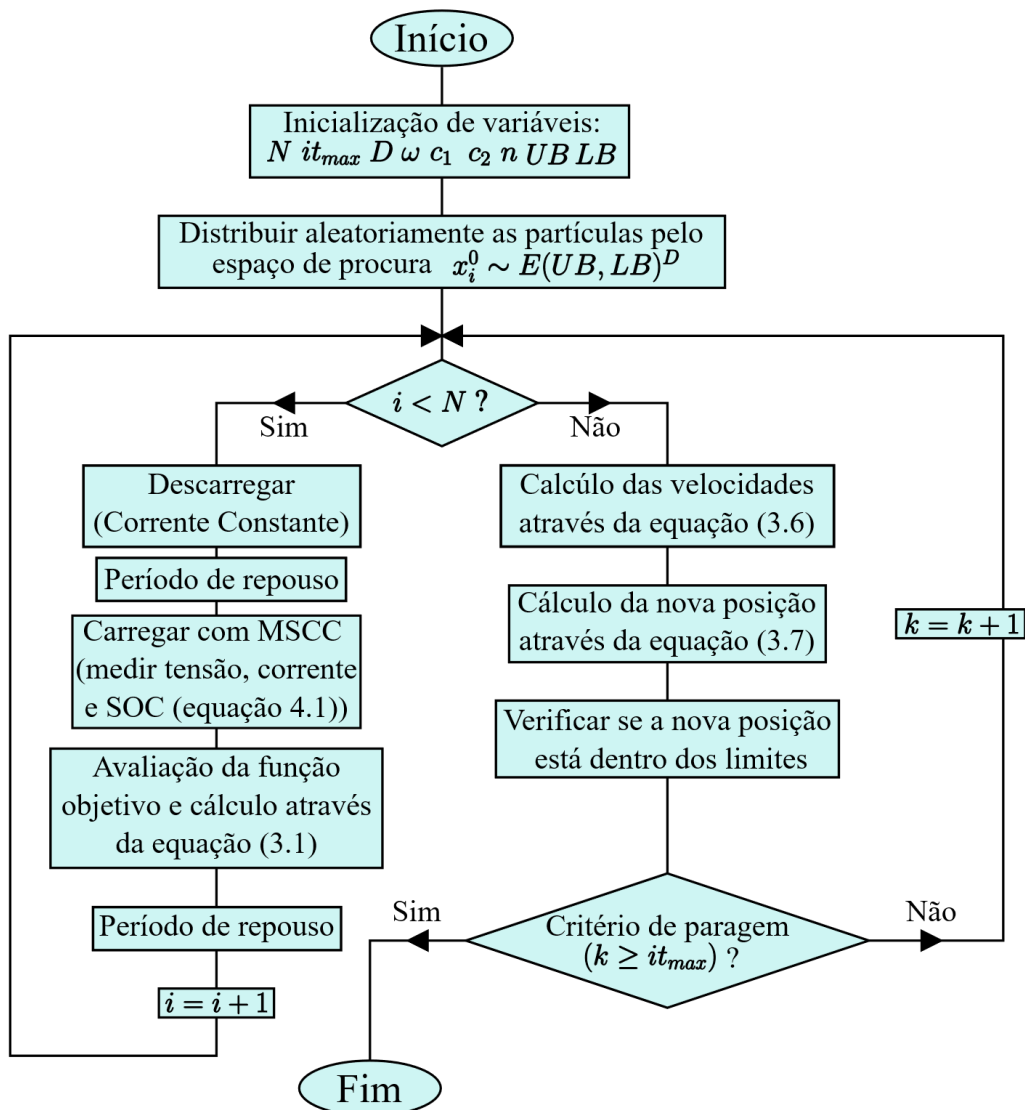


Figura 4.1 - Fluxograma do Procedimento Experimental

4.2 Resultados Experimentais

Nesta secção, são apresentados e analisados os resultados experimentais para a estratégia de carregamento multi-estágio de corrente constante (MSCC), implementada com 4, 5 e 7 estágios. O principal objetivo consiste em avaliar de forma sistemática o impacto do número de patamares e dos respetivos valores e taxas de corrente (*C-rates*) em cada fase do carregamento, no desempenho global do processo de carregamento. A análise foca-se em indicadores-chave como o tempo total de carregamento, a eficiência energética e o estado de carga (SOC) final.

4.2.1 Caso 1 - Resultados para quatro estágios

Nesta subsecção são apresentados os resultados do processo de otimização do método de carregamento multi-estágio de corrente constante com quatro patamares de corrente (4MSCC). A Figura 4.2 ilustra os 15 melhores perfis de corrente obtidos em cada teste (Figura 4.2a) e a região com os diferentes perfis de corrente explorados pelo algoritmo de otimização PSO, bem como o perfil ótimo de corrente identificado (Figura 4.2b).

No caso do 4MSCC, o perfil de corrente ótimo encontrado foi de [4.4886A, 2.6997A, 1.5132A, 1.2986A], correspondendo a taxas de corrente (*C-rate*) de [1.7602C, 1.0587C, 0.5934C, 0.50924C]. Este perfil resultou numa função objetivo de $f_{obj} = 0.3174$, com um tempo total de carregamento de aproximadamente 35 minutos e estado de carga (SOC) final próximo dos 98%.

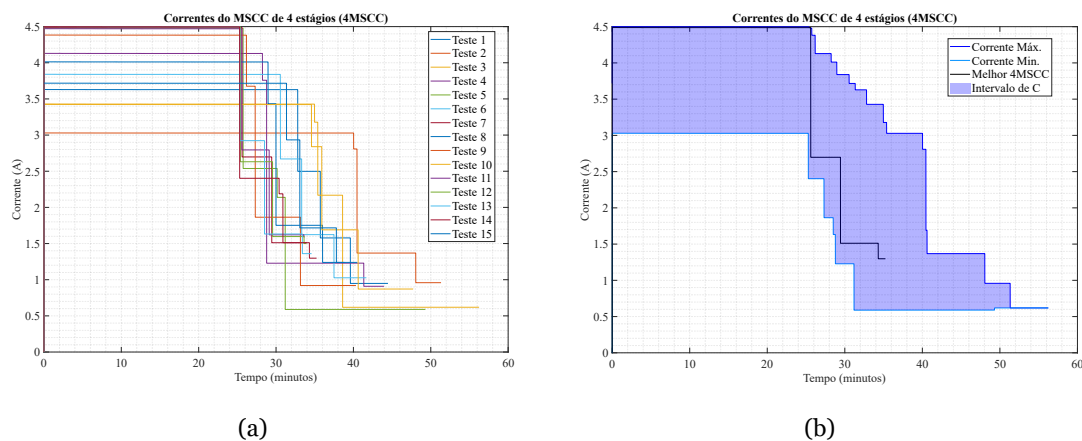


Figura 4.2 - Padrões de corrente investigados pelo PSO na configuração 4MSCC: (a) Perfis de Corrente de cada teste; (b) Intervalo de correntes de todos os testes, assim como o melhor perfil

A Figura 4.3 mostra a evolução da tensão da bateria relativamente aos perfis de corrente explorados, evidenciando as variações de tensão correspondentes a cada patamar de corrente. Já a Figura 4.4 mostra a evolução do SOC com base nos perfis de corrente

avaliados pelo PSO, permitindo analisar o impacto dos diferentes perfis de carregamento na autonomia da bateria.

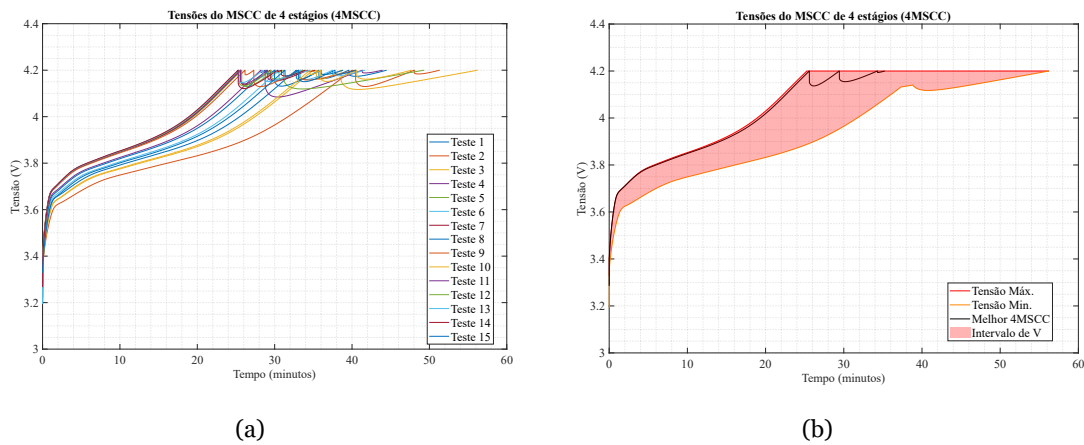


Figura 4.3 - Padrões de tensão investigados pelo PSO na configuração 4MSCC: (a) Perfis de Tensão de cada teste; (b) Intervalo de tensões de todos os testes, assim como o melhor perfil

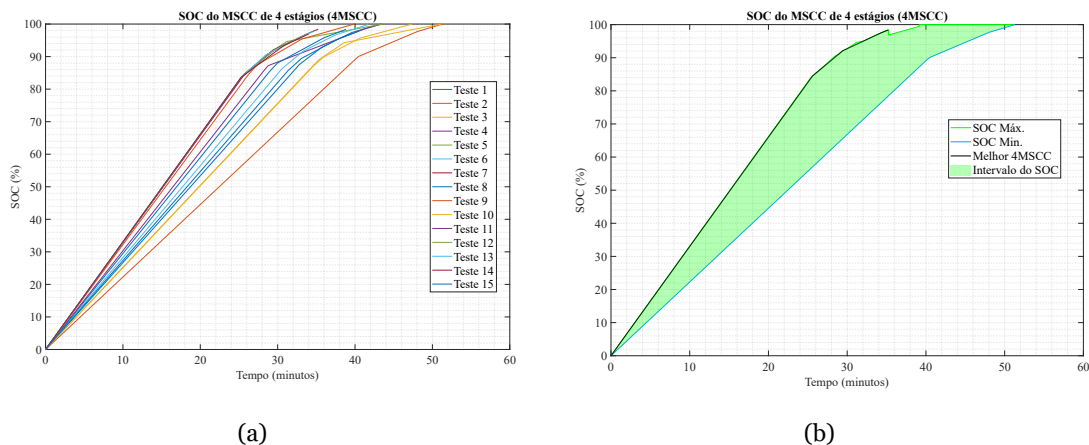


Figura 4.4 - Padrões de SOC investigados pelo PSO na configuração 4MSCC: (a) Perfis do SOC de cada teste; (b) Intervalo de SOC de todos os testes, assim como o melhor perfil

4.2.2 Caso 2 - Resultados para cinco estágios

As Figuras 4.5, 4.6 e 4.7 apresentam os 10 melhores resultados obtidos pelo procedimento de otimização aplicado ao método de carregamento multi-estágio de corrente constante com cinco patamares de corrente (5MSCC). O perfil ótimo de corrente encontrado foi de [4.5A, 3.2956A, 3.2252A, 2.2661A, 1.8126A] o que corresponde a taxas de corrente (*C-rate*) de [1.7647C, 1.2924C, 1.2648C, 0.88867C, 0.71081C].

Este perfil resultou num valor da função objetivo de $f_{obj} = 0.3149$ e num tempo total de carregamento de aproximadamente de 32 minutos, evidenciando uma melhoria em

relação ao caso com quatro patamares. Adicionalmente, o perfil de corrente identificado permitiu alcançar um estado de carga (SOC) final próximo dos 96%, evidenciando um compromisso eficaz entre a rapidez e o desempenho energético.




Figura 4.5 - Padrões de corrente investigados pelo PSO na configuração 5MSCC: (a) Perfis de Corrente de cada teste; (b) Intervalo de correntes de todos os testes, assim como o melhor perfil

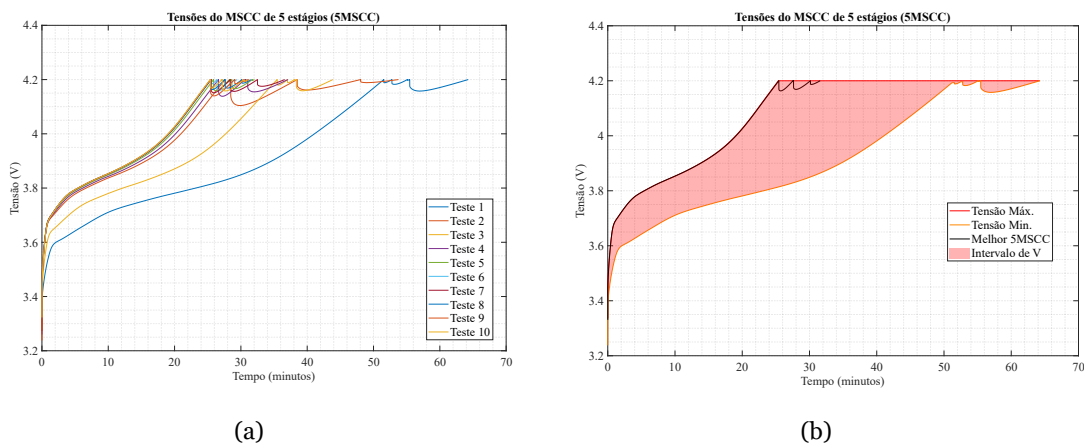


Figura 4.6 - Padrões de tensão investigados pelo PSO na configuração 5MSCC: (a) Perfis de Tensão de cada teste; (b) Intervalo de tensões de todos os testes, assim como o melhor perfil

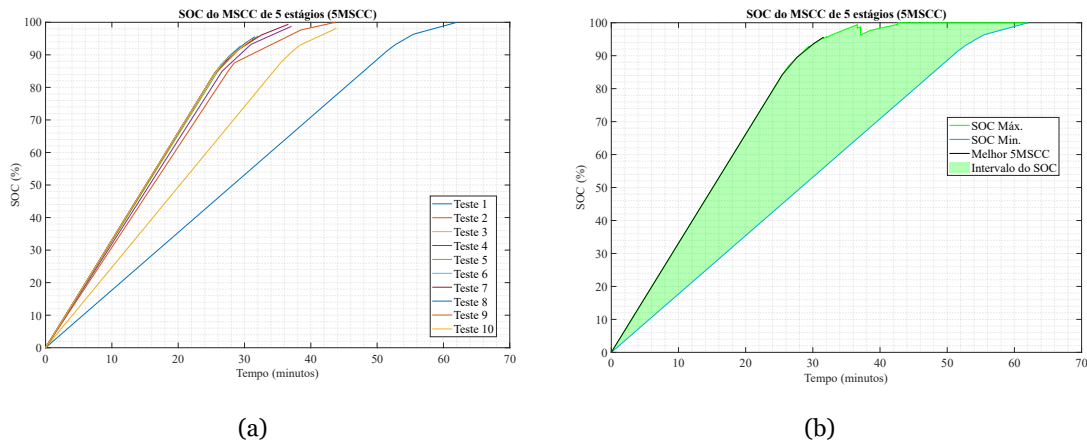
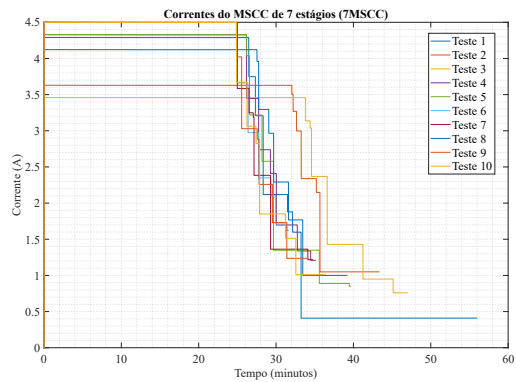


Figura 4.7 - Padrões do SOC investigados pelo PSO na configuração 5MSCC: (a) Perfis do SOC de cada teste; (b) Intervalo de SOC de todos os testes, assim como o melhor perfil

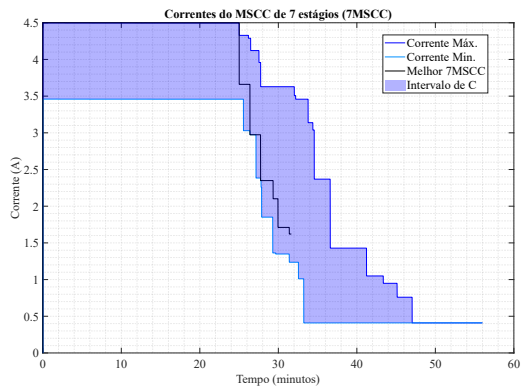
4.2.3 Caso 3 - Resultados para sete estágios

Por último, as Figuras 4.8, 4.9 e 4.10 apresentam os 10 melhores resultados obtidos pelo procedimento de otimização aplicado ao método de carregamento multi-estágio de corrente constante com sete patamares de corrente (7MSCC). A melhor solução (perfil de corrente) encontrada pelo algoritmo foi de [4.5A, 3.6624A, 2.9756A, 2.3508A, 2.1031A, 1.7132A, 1.6226A], com um perfil ótimo de corrente de equivalente a taxas de corrente (*C-rate*) de [1.7647C, 1.4362C, 1.1669C, 0.92187C, 0.82473C, 0.67184C, 0.63632C].

Este perfil resultou num valor da função objetivo de $f_{obj}=0,3187$, com um tempo total de carregamento de aproximadamente 32 minutos e estado de carga (SOC) final próximo dos 95%. Apesar de não reduzir significativamente o tempo em relação ao caso com cinco patamares, o aumento do número de estágios permite uma transição mais gradual entre os níveis de corrente, o que pode favorecer a estabilidade eletroquímica e a durabilidade da bateria.

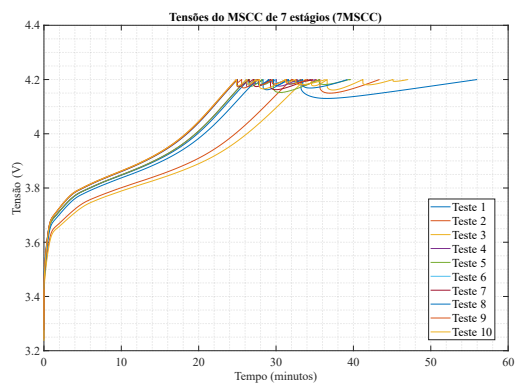


(a)




(b)

Figura 4.8 - Padrões de corrente investigados pelo PSO na configuração 7MSCC: (a) Perfis de Corrente de cada teste; (b) Intervalo de correntes de todos os testes, assim como o melhor perfil

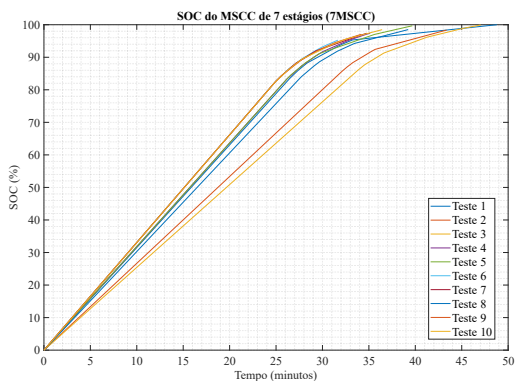


(a)

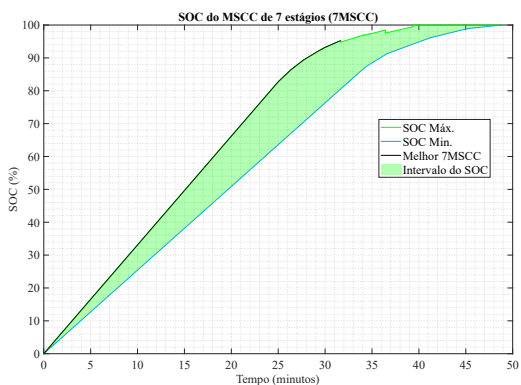


(b)

Figura 4.9 - Padrões de tensão investigados pelo PSO na configuração 7MSCC: (a) Perfis de Tensão de cada teste; (b) Intervalo de tensões de todos os testes, assim como o melhor perfil



(a)



(b)

Figura 4.10 - Padrões do SOC investigados pelo PSO na configuração 7MSCC: (a) Perfis do SOC de cada teste; (b) Intervalo de SOC de todos os testes, assim como o melhor perfil

Capítulo 5

Conclusão

5.1 Contextualização e considerações finais

Foram abordados diversos tópicos, nomeadamente as limitações e impactos ambientais associados aos combustíveis fósseis, cuja utilização contribui para as alterações climáticas e para a instabilidade nos mercados energéticos. Foi também destacada a importância dos compromissos internacionais que impulsionam a transição para fontes de energia sustentáveis. Entre estas, as energias renováveis (ER) assumem particular relevância devido à sua reduzida pegada carbónica, carácter inesgotável e o seu contributo socioeconómico. Foi mencionado que a sua integração enfrenta desafios técnicos e operacionais, relacionados com a intermitência da produção, requisitos tecnológicos e infraestruturais, bem como obstáculos regulatórios e burocráticos, exigindo medidas políticas e incentivos adequados para a sua plena consolidação. Nestas desvantagens de intermitência, os sistemas de armazenamento de energia foram sucintamente introduzidos.

Foi referido o facto de as LIBs possuírem vantagens evidentemente superiores a outras alternativas de armazenamento. Neste contexto das LIBs, foram introduzidos resumidamente os principais tipos de carregamento destas baterias, com o principal foco no multi-estágio de corrente constante (MSCC). Para otimizar o carregamento de multi-estágio de corrente constante foi introduzido o *Particle Swarm Optimization* (PSO), destacando a sua adaptabilidade e facilidade de implementação.

Foi abordado o carregamento da LIBs, uma vez que estas são alvo de investigação graças ao seu impacto ambiental, à durabilidade e desempenho. Referiu-se os métodos típicos de carregamento deste tipo de baterias. Foram exploradas algumas desvantagens das LIBs, como por exemplo a degradação progressiva dos componentes internos e o impacto que tem na redução dos ciclos de vida. Foi também mencionado que os métodos de carregamento podem acelerar o desgaste da camada *Solid Electrolyte Interphase* (SEI), quando mal parametrizados. Foram ainda brevemente mencionados os parâmetros vitais para um carregamento eficaz.

Com isto, foi explicado em detalhe como são abordados de uma maneira geral os principais métodos de carregamento, respetivamente o carregamento corrente constante – tensão constante (CC-CV), o carregamento por pulsos de corrente (PC) e o

carregamento multi-estágio de corrente constante (MSCC). O principal foco foi analisar o comportamento e abordagem típica de cada tipo de carregamento assim como vantagens e desvantagens associadas. O carregamento multi-estágio de corrente constante, sendo o método escolhido, foi avaliado em maior detalhe.

Foi explicada a formulação do problema de otimização, que tinha como objetivo minimizar o tempo total de carregamento e, simultaneamente, maximizar o estado de carga final. A função objetiva que se minimizou, foi demonstrada pela equação 3.1, que estava sujeita às restrições das equações 3.2 a 3.5. Posteriormente, foi feito um estudo breve dos diferentes tipos de métodos de otimização, os algoritmos meta-heurísticos, que são utilizados para problemas de otimização não só de engenharia, como também de diferentes áreas. Também foi explicada a razão de adoção do *Particle Swarm Optimization* (PSO), como método de otimização do carregamento multi-estágio de corrente constante (MSCC). O PSO foi explicado em grande detalhe. De seguida, foi descrito o procedimento experimental, onde foi referido o *hardware* e *software* utilizado para elaborar os testes de carregamento e respetiva otimização.

Foi explicado o procedimento de otimização, demonstrando a integração das variáveis referentes ao tipo de baterias utilizadas (Samsung ICR18650-26H), as variáveis e restrições da formulação do problema, e variáveis do carregamento MSCC, no contexto do PSO implementado, via MATLAB. Foram referidas as diversas abordagens para a medição fidedigna do SOC, no entanto na presente dissertação, foi adotado o método de contagem de Coulombs. Por fim, foram demonstrados os resultados obtidos de todo o processo de estudo desta dissertação, onde podemos concluir que o número de patamares de corrente mais adequado a este tipo de carregamento MSCC é 5. Dentro dos resultados que foram obtidos para testes de 5 patamares de corrente, a simulação 8 apresentou o perfil ótimo com patamares de corrente [4.5A, 3.2956A, 3.2252A, 2.2661A, 1.8126A], com respetivas *C-rate* de [1.7647C, 1.2924C, 1.2648C, 0.88867C, 0.71081C], em que a função objetivo obteve o valor mínimo de 0.3149. Nesta simulação o tempo de carregamento mínimo obtido foi de 32 minutos.

Deste modo, o método de carregamento que foi otimizado na presente dissertação mostrou-se versátil e de elevada adaptabilidade, quando se pretende o carregamento rápido das LIBs. Esta abordagem demonstrou ainda que a implementação do MSCC nas LIBs pode ser feita de forma rápida e eficaz, preservando a eficiência e integridade da bateria, demonstrando a segurança e facilidade de implementação.

5.2 Trabalhos futuros

Uma vez que o estudo, implementação e otimização de métodos de carregamento de baterias é um processo bastante demorado e que requer uma abordagem bastante organizada e metodológica, quando aplicado a uma única célula de bateria, surge diversos aspetos que ficam por resolver/esclarecer, assim como variáveis que ficam por explorar.

Deste modo, ao longo do desenvolvimento da presente dissertação, assim como perto da sua conclusão, foram identificadas as seguintes ideias e possíveis melhorias de trabalhos futuros: o número de simulações pode ser maior, uma vez que mais testes leva a resultados mais precisos; implementar diferentes números de estágios que o presente estudo não verificou; uma vez que os testes obtidos foram em alturas de temperaturas amenas, e como tal a temperatura, apesar de ser monitorizada, não foi considerada na formulação do problema, seria preferível inclui-la num trabalho futuro; construir uma câmara térmica que suporte um maior número de células ou implementar o estudo num *pack* de baterias.

Bibliografia

- [1] M. Thirunavukkarasu, Y. Sawle, e H. Lala, «A comprehensive review on optimization of hybrid renewable energy systems using various optimization techniques», *Renew. Sustain. Energy Rev.*, vol. 176, p. 113192, abr. 2023, doi: 10.1016/j.rser.2023.113192.
- [2] «Global Energy Crisis – Topics», IEA. Acedido: 16 de julho de 2025. [Online]. Disponível em: <https://www.iea.org/topics/global-energy-crisis>
- [3] S. Chen, Z. Li, e W. Li, «Integrating high share of renewable energy into power system using customer-sited energy storage», *Renew. Sustain. Energy Rev.*, vol. 143, p. 110893, jun. 2021, doi: 10.1016/j.rser.2021.110893.
- [4] M. Cakir e I. Colak, «Advantages of Using Renewable Energy Sources in Smart Grids», doi: 10.1109/ICSMARTGRID55722.2022.9848612.
- [5] T.-Z. Ang, M. Salem, M. Kamarol, H. S. Das, M. A. Nazari, e N. Prabakaran, «A comprehensive study of renewable energy sources: Classifications, challenges and suggestions», *Energy Strategy Rev.*, vol. 43, p. 100939, set. 2022, doi: 10.1016/j.esr.2022.100939.
- [6] A. G. Olabi e M. A. Abdelkareem, «Renewable energy and climate change», *Renew. Sustain. Energy Rev.*, vol. 158, p. 112111, abr. 2022, doi: 10.1016/j.rser.2022.112111.
- [7] E. Sayed *et al.*, «Renewable Energy and Energy Storage Systems», *Energies*, vol. 16, n.º 3, p. 1415, fev. 2023, doi: 10.3390/en16031415.
- [8] «Resolução da Assembleia da República n.º 127/2025 | DR». Acedido: 16 de julho de 2025. [Online]. Disponível em: <https://diariodarepublica.pt/dr/detalhe/resolucao-assembleia-republica/127-2025-914597185>
- [9] «Energias renováveis», AICEP. Acedido: 16 de julho de 2025. [Online]. Disponível em: <https://www.portugalglobal.pt/investimento/principais-setores/energias-renovaveis/>
- [10] «APREN - Produção». Acedido: 16 de julho de 2025. [Online]. Disponível em: <https://www.apren.pt/pt/energias-renovaveis/producao>
- [11] «APREN - Potência». Acedido: 16 de julho de 2025. [Online]. Disponível em: <https://www.apren.pt/pt/energias-renovaveis/potencia>
- [12] «Presidente da espanhola Red Eléctrica desvincula apagão das renováveis», euronews. Acedido: 16 de julho de 2025. [Online]. Disponível em: <https://pt.euronews.com/my-europe/2025/04/30/presidente-da-espanhola-red-electrica-desvincula-apagao-das-energias-renovaveis-nao-voltar>
- [13] «dgeg-bes-2023-en.pdf». Acedido: 16 de julho de 2025. [Online]. Disponível em: <https://www.dgeg.gov.pt/media/4jnf4vbw/dgeg-bes-2023-en.pdf>
- [14] S. Serag, A. Echhelh, e B. Morrone, «Hydroelectric and Hydrogen Storage Systems for Electric Energy Produced from Renewable Energy Sources», *Energy Eng.*, vol. 121, n.º 10, pp. 2719–2741, 2024, doi: 10.32604/ee.2024.054424.
- [15] A. A. Kebede *et al.*, «Techno-economic analysis of lithium-ion and lead-acid batteries in stationary energy storage application», *J. Energy Storage*, vol. 40, p. 102748, ago. 2021, doi: 10.1016/j.est.2021.102748.
- [16] M. Usman Tahir, A. Sangwongwanich, D.-I. Stroe, e F. Blaabjerg, «Overview of multi-stage charging strategies for Li-ion batteries», *J. Energy Chem.*, vol. 84, pp. 228–241, set. 2023, doi: 10.1016/j.jechem.2023.05.023.
- [17] M. Rouholamini *et al.*, «A Review of Modeling, Management, and Applications of Grid-Connected Li-Ion Battery Storage Systems», *IEEE Trans. Smart Grid*, vol. 13, n.º 6, pp. 4505–4524, nov. 2022, doi: 10.1109/tsg.2022.3188598.
- [18] J. S. Menye, M. B. Camara, e B. Dakyo, «Lithium Battery Degradation and Failure Mechanisms: A State-of-the-Art Review», *Energies*, vol. 18, n.º 2. Multidisciplinary Digital Publishing Institute (MDPI), janeiro de 2025. doi: 10.3390/en18020342.
- [19] M. Killer, M. Farrokhsersht, e N. G. Paterakis, «Implementation of large-scale Li-ion battery energy storage systems within the EMEA region», *Applied Energy*, vol. 260. Elsevier Ltd, fevereiro de 2020. doi: 10.1016/j.apenergy.2019.114166.
- [20] H. Gabbar, A. Othman, e M. Abdussami, «Review of Battery Management Systems (BMS) Development and Industrial Standards», *Technologies*, vol. 9, n.º 2, p. 28, abr. 2021, doi: 10.3390/technologies9020028.
- [21] Y. Li, J. Guo, K. Pedersen, L. Gurevich, e D.-I. Stroe, «Investigation of multi-step fast charging protocol and aging mechanism for commercial NMC/graphite lithium-ion

- batteries», *J. Energy Chem.*, vol. 80, pp. 237–246, mai. 2023, doi: 10.1016/j.jechem.2023.01.016.
- [22] G. Zhao, Y. Wang, e Z. Chen, «Health-aware multi-stage charging strategy for lithium-ion batteries based on whale optimization algorithm», *J. Energy Storage*, vol. 55, p. 105620, nov. 2022, doi: 10.1016/j.est.2022.105620.
- [23] J. S. Sophia, N. G. Iyer, e N. S. B, «A Review on Charge Control Techniques for Batteries in Electric Vehicles», doi: 10.1109/ICAECT54875.2022.9808007.
- [24] R. P. Sheth, N. S. Ranawat, A. Chakraborty, R. P. Mishra, e M. Khandelwal, «The Lithium-Ion Battery Recycling Process from a Circular Economy Perspective—A Review and Future Directions», *Energies*, vol. 16, n.º 7, p. 3228, abr. 2023, doi: 10.3390/en16073228.
- [25] C. Chen, Z. Wei, e A. C. Knoll, «Charging Optimization for Li-Ion Battery in Electric Vehicles: A Review», *IEEE Trans. Transp. Electrification*, vol. 8, n.º 3, pp. 3068–3089, set. 2022, doi: 10.1109/tte.2021.3135525.
- [26] B. Bose, A. Garg, B. K. Panigrahi, e J. Kim, «Study on Li-ion battery fast charging strategies: Review, challenges and proposed charging framework», *J. Energy Storage*, vol. 55, p. 105507, nov. 2022, doi: 10.1016/j.est.2022.105507.
- [27] Y.-S. Hwang, S.-C. Wang, F.-C. Yang, e J.-J. Chen, «New Compact CMOS Li-Ion Battery Charger Using Charge-Pump Technique for Portable Applications», *IEEE Trans. Circuits Syst. Regul. Pap.*, vol. 54, n.º 4, pp. 705–712, abr. 2007, doi: 10.1109/tcsi.2007.890605.
- [28] R. T. Villuri, M. Singh, e Y. Beck, «Experimental analysis of electric vehicle’s Li-ion battery with constant pulse and constant voltage charging method», *Int. J. Energy Res.*, vol. 46, n.º 15, pp. 22365–22385, dez. 2022, doi: 10.1002/er.8708.
- [29] H. Liu *et al.*, «An analytical model for the CC-CV charge of Li-ion batteries with application to degradation analysis», *J. Energy Storage*, vol. 29, p. 101342, jun. 2020, doi: 10.1016/j.est.2020.101342.
- [30] M. Khalid, F. Ahmad, B. K. Panigrahi, e L. Al-Fagih, «A comprehensive review on advanced charging topologies and methodologies for electric vehicle battery», *J. Energy Storage*, vol. 53, p. 105084, set. 2022, doi: 10.1016/j.est.2022.105084.
- [31] S. S. Raja, H. Karneddi, e D. Ronanki, «Performance Evaluation of Charging Techniques for Lithium-Ion Batteries», em *2024 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*, Mangalore, India: IEEE, dez. 2024, pp. 1–6. doi: 10.1109/pedes61459.2024.10961257.
- [32] G.-J. ; Chen, W.-H. Chung, G.-J. Chen, e W.-H. Chung, «Evaluation of Charging Methods for Lithium-Ion Batteries», 2023, doi: 10.3390/electronics12194095.
- [33] X. Huang *et al.*, «A Review of Pulsed Current Technique for Lithium-ion Batteries», *Energies*, vol. 13, n.º 10, p. 2458, mai. 2020, doi: 10.3390/en13102458.
- [34] S. Shahriar, A. R. Al-Ali, A. H. Osman, S. Dhou, e M. Nijim, «Prediction of EV Charging Behavior Using Machine Learning», *IEEE Access*, vol. 9, pp. 111576–111586, 2021, doi: 10.1109/access.2021.3103119.
- [35] E. Yaghoubi, E. Yaghoubi, A. Khamees, D. Razmi, e T. Lu, «A systematic review and meta-analysis of machine learning, deep learning, and ensemble learning approaches in predicting EV charging behavior», *Eng. Appl. Artif. Intell.*, vol. 135, p. 108789, set. 2024, doi: 10.1016/j.engappai.2024.108789.
- [36] K. K. Duru, C. Karra, P. Venkatachalam, S. A. Betha, A. Anish Madhavan, e S. Kalluri, «Critical Insights Into Fast Charging Techniques for Lithium-Ion Batteries in Electric Vehicles», *IEEE Trans. Device Mater. Reliab.*, vol. 21, n.º 1, pp. 137–152, mar. 2021, doi: 10.1109/tdmr.2021.3051840.
- [37] J. M. Amanor-Boadu e A. Guiseppi-Elie, «Improved Performance of Li-ion Polymer Batteries Through Improved Pulse Charging Algorithm», *Appl. Sci.*, vol. 10, n.º 3, p. 895, jan. 2020, doi: 10.3390/app10030895.
- [38] Liang-Rui Chen, «Design of Duty-Varied Voltage Pulse Charger for Improving Li-Ion Battery-Charging Response», *IEEE Trans. Ind. Electron.*, vol. 56, n.º 2, pp. 480–487, fev. 2009, doi: 10.1109/TIE.2008.2002725.
- [39] F. Savoye, P. Venet, M. Millet, e J. Groot, «Impact of Periodic Current Pulses on Li-Ion Battery Performance», *IEEE Trans. Ind. Electron.*, vol. 59, n.º 9, pp. 3481–3488, set. 2012, doi: 10.1109/tie.2011.2172172.
- [40] X. Huang *et al.*, «Lithium-Ion Battery Lifetime Extension With Positive Pulsed Current Charging», *IEEE Trans. Ind. Electron.*, vol. 71, n.º 1, pp. 484–492, jan. 2024, doi: 10.1109/tie.2023.3250850.

- [41] M. Nizam, H. Maghfiroh, B. Irfani, I. Inayati, e A. Ma'arif, «Designing and Prototyping of Lithium-Ion Charging System Using Multi-Step Constant Current Method», *World Electr. Veh. J.*, vol. 13, n.º 10, p. 178, set. 2022, doi: 10.3390/wevj13100178.
- [42] R. Mathieu, O. Briat, P. Gyan, e J.-M. Vinassa, «Fast charging for electric vehicles applications: Numerical optimization of a multi-stage charging protocol for lithium-ion battery and impact on cycle life», *J. Energy Storage*, vol. 40, p. 102756, ago. 2021, doi: 10.1016/j.est.2021.102756.
- [43] M. Jiao *et al.*, «Balancing Charging Efficiency and Thermal Safety: A Comparative Analysis of Multistage Constant Current Charging Protocols», *Ind. Eng. Chem. Res.*, vol. 63, n.º 22, pp. 10054–10066, jun. 2024, doi: 10.1021/acs.iecr.4c00971.
- [44] G. Ji, L. He, T. Wu, e G. Cui, «The design of fast charging strategy for lithium-ion batteries and intelligent application: A comprehensive review», *Appl. Energy*, vol. 377, p. 124538, jan. 2025, doi: 10.1016/j.apenergy.2024.124538.
- [45] Y. Gao, J. Jiang, C. Zhang, W. Zhang, Z. Ma, e Y. Jiang, «Lithium-ion battery aging mechanisms and life model under different charging stresses», *J. Power Sources*, vol. 356, pp. 103–114, 2017, doi: 10.1016/j.jpowsour.2017.04.084.
- [46] J. G. Qu, Z. Y. Jiang, e J. F. Zhang, «Investigation on lithium-ion battery degradation induced by combined effect of current rate and operating temperature during fast charging», *J. Energy Storage*, vol. 52, ago. 2022, doi: 10.1016/j.est.2022.104811.
- [47] A. Rahman e X. Lin, «Li-ion battery individual electrode state of charge and degradation monitoring using battery casing through auto curve matching for standard CCCV charging profile», *Appl. Energy*, vol. 321, p. 119367, set. 2022, doi: 10.1016/j.apenergy.2022.119367.
- [48] S. Park *et al.*, «A Deep Reinforcement Learning Framework for Fast Charging of Li-Ion Batteries», *IEEE Trans. Transp. Electrification*, vol. 8, n.º 2, pp. 2770–2784, jun. 2022, doi: 10.1109/TTE.2022.3140316.
- [49] J. S. S, K. R, S. P, N. G. Iyer, A. M, e N. S. B, «A Review on Charge Control Techniques for Batteries in Electric Vehicles», em *2022 Second International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT)*, Bhilai, India: IEEE, abr. 2022, pp. 1–6. doi: 10.1109/icaect54875.2022.9808007.
- [50] M. Brenna, F. Foiadelli, C. Leone, e M. Longo, «Electric Vehicles Charging Technology Review and Optimal Size Estimation», *J. Electr. Eng. Technol.*, vol. 15, n.º 6, pp. 2539–2552, nov. 2020, doi: 10.1007/s42835-020-00547-x.
- [51] Y. Qin *et al.*, «A rapid lithium-ion battery heating method based on bidirectional pulsed current: Heating effect and impact on battery life», *Appl. Energy*, vol. 280, p. 115957, dez. 2020, doi: 10.1016/j.apenergy.2020.115957.
- [52] W. Xie *et al.*, «Challenges and opportunities toward fast-charging of lithium-ion batteries», *J. Energy Storage*, vol. 32, p. 101837, dez. 2020, doi: 10.1016/j.est.2020.101837.
- [53] L. Jiang *et al.*, «Optimization of multi-stage constant current charging pattern based on Taguchi method for Li-Ion battery», *Appl. Energy*, vol. 259, p. 114148, fev. 2020, doi: 10.1016/j.apenergy.2019.114148.
- [54] K. Kumar e K. Pareek, «Fast charging of lithium-ion battery using multistage charging and optimization with Grey relational analysis», *J. Energy Storage*, vol. 68, p. 107704, set. 2023, doi: 10.1016/j.est.2023.107704.
- [55] A. B. Khan e W. Choi, «Optimal Charge Pattern for the High-Performance Multistage Constant Current Charge Method for the Li-Ion Batteries», *IEEE Trans. Energy Convers.*, vol. 33, n.º 3, pp. 1132–1140, set. 2018, doi: 10.1109/tec.2018.2801381.
- [56] D. Ji *et al.*, «Research on adaptability of charging strategy for electric vehicle power battery», *J. Power Sources*, vol. 437, p. 226911, out. 2019, doi: 10.1016/j.jpowsour.2019.226911.
- [57] Y. Li, K. Li, Y. Xie, J. Liu, C. Fu, e B. Liu, «Optimized charging of lithium-ion battery for electric vehicles: Adaptive multistage constant current–constant voltage charging strategy», *Renew. Energy*, vol. 146, pp. 2688–2699, fev. 2020, doi: 10.1016/j.renene.2019.08.077.
- [58] V. Tomar, M. Bansal, e P. Singh, «Metaheuristic Algorithms for Optimization: A Brief Review», em *RAiSE-2023*, MDPI, mar. 2024, p. 238. doi: 10.3390/engproc2023059238.
- [59] M. Kaveh e M. S. Mesgari, «Application of Meta-Heuristic Algorithms for Training Neural Networks and Deep Learning Architectures: A Comprehensive Review», *Neural Process. Lett.*, vol. 55, n.º 4, pp. 4519–4622, ago. 2023, doi: 10.1007/s11063-022-11055-6.
- [60] H. G. G. Nunes, D. M. R. Duarte, J. A. N. Pombo, S. J. P. S. Mariano, e M. R. A. Calado, «Comparative study of MPPT metaheuristics for PV systems under partial shading conditions», em *2022 International Conference on Smart Energy Systems and*

- Technologies (SEST)*, Eindhoven, Netherlands: IEEE, set. 2022, pp. 1–6. doi: 10.1109/sest53650.2022.9898422.
- [61] P. Civicioglu, «Backtracking Search Optimization Algorithm for numerical optimization problems», *Appl. Math. Comput.*, vol. 219, n.º 15, pp. 8121–8144, abr. 2013, doi: 10.1016/j.amc.2013.02.017.
- [62] D. Simon, «Biogeography-Based Optimization», *IEEE Trans. Evol. Comput.*, vol. 12, n.º 6, pp. 702–713, dez. 2008, doi: 10.1109/TEVC.2008.919004.
- [63] J. Wang, L. Li, D. Niu, e Z. Tan, «An annual load forecasting model based on support vector regression with differential evolution algorithm», *Appl. Energy*, vol. 94, pp. 65–70, jun. 2012, doi: 10.1016/j.apenergy.2012.01.010.
- [64] K. R. Opara e J. Arabas, «Differential Evolution: A survey of theoretical analyses», *Swarm Evol. Comput.*, vol. 44, pp. 546–558, fev. 2019, doi: 10.1016/j.swevo.2018.06.010.
- [65] G. R. Harik, F. G. Lobo, e D. E. Goldberg, «The compact genetic algorithm», *IEEE Trans. Evol. Comput.*, vol. 3, n.º 4, pp. 287–297, 1999, doi: 10.1109/4235.797971.
- [66] Q. Y. Duan, V. K. Gupta, e S. Sorooshian, «Shuffled complex evolution approach for effective and efficient global minimization», *J. Optim. Theory Appl.*, vol. 76, n.º 3, pp. 501–521, mar. 1993, doi: 10.1007/BF00939380.
- [67] X. Gao *et al.*, «Parameter extraction of solar cell models using improved shuffled complex evolution algorithm», *Energy Convers. Manag.*, vol. 157, pp. 460–479, fev. 2018, doi: 10.1016/j.enconman.2017.12.033.
- [68] E. Rashedi, H. Nezamabadi-pour, e S. Saryazdi, «GSA: A Gravitational Search Algorithm», *Inf. Sci.*, vol. 179, n.º 13, pp. 2232–2248, jun. 2009, doi: 10.1016/j.ins.2009.03.004.
- [69] P. Ghannadi e S. S. Kourehli, «Multiverse optimizer for structural damage detection: Numerical study and experimental validation», *Struct. Des. Tall Spec. Build.*, vol. 29, n.º 13, p. e1777, set. 2020, doi: 10.1002/tal.1777.
- [70] A. A. Rosales-Muñoz, L. F. Grisales-Noreña, J. Montano, O. D. Montoya, e A.-J. Perea-Moreno, «Application of the Multiverse Optimization Method to Solve the Optimal Power Flow Problem in Direct Current Electrical Networks», *Sustainability*, vol. 13, n.º 16, p. 8703, ago. 2021, doi: 10.3390/su13168703.
- [71] R. A. Rutenbar, «Simulated annealing algorithms: an overview», *IEEE Circuits Devices Mag.*, vol. 5, n.º 1, pp. 19–26, jan. 1989, doi: 10.1109/101.17235.
- [72] L. M. R. Rere, M. I. Fanany, e A. M. Arymurthy, «Simulated Annealing Algorithm for Deep Learning», *Procedia Comput. Sci.*, vol. 72, pp. 137–144, 2015, doi: 10.1016/j.procs.2015.12.114.
- [73] K. Tamura e K. Yasuda, «The Spiral Optimization Algorithm: Convergence Conditions and Settings», *IEEE Trans. Syst. Man Cybern. Syst.*, vol. 50, n.º 1, pp. 360–375, jan. 2020, doi: 10.1109/TSMC.2017.2695577.
- [74] Z. Bayraktar, M. Komurcu, J. A. Bossard, e D. H. Werner, «The Wind Driven Optimization Technique and its Application in Electromagnetics», *IEEE Trans. Antennas Propag.*, vol. 61, n.º 5, pp. 2745–2757, mai. 2013, doi: 10.1109/TAP.2013.2238654.
- [75] Z. Bayraktar, M. Komurcu, e D. H. Werner, «Wind Driven Optimization (WDO): A novel nature-inspired optimization algorithm and its application to electromagnetics», em *2010 IEEE Antennas and Propagation Society International Symposium*, Toronto, ON: IEEE, jul. 2010, pp. 1–4. doi: 10.1109/APS.2010.5562213.
- [76] J. Kennedy e R. Eberhart, «Particle swarm optimization», em *Proceedings of ICNN'95 - International Conference on Neural Networks*, Perth, WA, Australia: IEEE, pp. 1942–1948. doi: 10.1109/icnn.1995.488968.
- [77] D. Wang, D. Tan, e L. Liu, «Particle swarm optimization algorithm: an overview», *Soft Comput.*, vol. 22, n.º 2, pp. 387–408, jan. 2018, doi: 10.1007/s00500-016-2474-6.
- [78] S. Mirjalili, S. M. Mirjalili, e A. Lewis, «Grey Wolf Optimizer», *Adv. Eng. Softw.*, vol. 69, pp. 46–61, mar. 2014, doi: 10.1016/j.advengsoft.2013.12.007.
- [79] M. Abdel-Basset e L. A. Shawky, «Flower pollination algorithm: a comprehensive review», *Artif. Intell. Rev.*, vol. 52, n.º 4, pp. 2533–2557, dez. 2019, doi: 10.1007/s10462-018-9624-4.
- [80] X.-S. Yang, «Flower Pollination Algorithm for Global Optimization», em *Unconventional Computation and Natural Computation*, vol. 7445, J. Durand-Lose e N. Jonoska, Eds., em *Lecture Notes in Computer Science*, vol. 7445. , Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, pp. 240–249. doi: 10.1007/978-3-642-32894-7_27.
- [81] D. Karaboga e B. Basturk, «A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm», *J. Glob. Optim.*, vol. 39, n.º 3, pp. 459–471, out. 2007, doi: 10.1007/s10898-007-9149-x.

- [82] M. Dorigo, M. Birattari, e T. Stutzle, «Ant colony optimization», *IEEE Comput. Intell. Mag.*, vol. 1, n.º 4, pp. 28–39, nov. 2006, doi: 10.1109/mci.2006.329691.
- [83] R. V. Rao, V. J. Savsani, e D. P. Vakharia, «Teaching–learning-based optimization: A novel method for constrained mechanical design optimization problems», *Comput.-Aided Des.*, vol. 43, n.º 3, pp. 303–315, mar. 2011, doi: 10.1016/j.cad.2010.12.015.
- [84] M. Verij Kazemi e E. Fazeli Veysari, «A new optimization algorithm inspired by the quest for the evolution of human society: Human felicity algorithm», *Expert Syst. Appl.*, vol. 193, p. 116468, mai. 2022, doi: 10.1016/j.eswa.2021.116468.
- [85] T. Sharifi, M. Mirsalim, F. Soleimani Gharehchopogh, e S. Mirjalili, «Cultural history optimization algorithm: a new human-inspired metaheuristic algorithm for engineering optimization problems», *Neural Comput. Appl.*, vol. 37, n.º 25, pp. 21009–21068, set. 2025, doi: 10.1007/s00521-025-11379-z.
- [86] R. Rai, A. Das, S. Ray, e K. G. Dhal, «Human-Inspired Optimization Algorithms: Theoretical Foundations, Algorithms, Open-Research Issues and Application for Multi-Level Thresholding», *Arch. Comput. Methods Eng.*, vol. 29, n.º 7, pp. 5313–5352, nov. 2022, doi: 10.1007/s11831-022-09766-z.
- [87] A. Aldhafeeri e Y. Rahmat-Samii, «Brain Storm Optimization for Electromagnetic Applications: Continuous and Discrete», *IEEE Trans. Antennas Propag.*, vol. 67, n.º 4, pp. 2710–2722, abr. 2019, doi: 10.1109/TAP.2019.2894318.
- [88] Z. Guo, X. Yue, H. Yang, K. Liu, e X. Liu, «Enhancing social emotional optimization algorithm using local search», *Soft Comput.*, vol. 21, n.º 24, pp. 7393–7404, dez. 2017, doi: 10.1007/s00500-016-2282-z.
- [89] Z. Cui e X. Cai, «Using social cognitive optimization algorithm to solve nonlinear equations», em *9th IEEE International Conference on Cognitive Informatics (ICCI'10)*, Beijing, China: IEEE, jul. 2010, pp. 199–203. doi: 10.1109/COGINF.2010.5599742.
- [90] A. W. Mohamed, A. A. Hadi, e A. K. Mohamed, «Gaining-sharing knowledge based algorithm for solving optimization problems: a novel nature-inspired algorithm», *Int. J. Mach. Learn. Cybern.*, vol. 11, n.º 7, pp. 1501–1529, jul. 2020, doi: 10.1007/s13042-019-01053-x.
- [91] F. A. Şenel, F. Gökçe, A. S. Yüksel, e T. Yiğit, «A novel hybrid PSO–GWO algorithm for optimization problems», *Eng. Comput.*, vol. 35, n.º 4, pp. 1359–1373, out. 2019, doi: 10.1007/s00366-018-0668-5.
- [92] P. Jangir, S. A. Parmar, I. N. Trivedi, e R. H. Bhesdadiya, «A novel hybrid Particle Swarm Optimizer with multi verse optimizer for global numerical optimization and Optimal Reactive Power Dispatch problem», *Eng. Sci. Technol. Int. J.*, vol. 20, n.º 2, pp. 570–586, abr. 2017, doi: 10.1016/j.jestch.2016.10.007.
- [93] Z. Zuhri e I. V. Papatungan, «A Hybrid Optimization Algorithm based on Genetic Algorithm and Ant Colony Optimization», *Int. J. Artif. Intell. Appl.*, vol. 4, n.º 5, pp. 63–75, set. 2013, doi: 10.5121/ijai.2013.4505.
- [94] M. Azarshab, M. Fathian, e B. Amiri, «An enhanced Teaching–Learning–Based Optimization (TLBO) with Grey Wolf Optimizer (GWO) for text feature selection and clustering», 2024.
- [95] A. G. Gad, «Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review», *Arch. Comput. Methods Eng.*, vol. 29, n.º 5, pp. 2531–2561, ago. 2022, doi: 10.1007/s11831-021-09694-4.
- [96] E. H. Houssein, A. G. Gad, K. Hussain, e P. N. Suganthan, «Major Advances in Particle Swarm Optimization: Theory, Analysis, and Application», *Swarm Evol. Comput.*, vol. 63, p. 100868, jun. 2021, doi: 10.1016/j.swevo.2021.100868.
- [97] W.-Y. Chang, «The State of Charge Estimating Methods for Battery: A Review», *ISRN Appl. Math.*, vol. 2013, pp. 1–7, jul. 2013, doi: 10.1155/2013/953792.
- [98] K. S. Ng, C. S. Moo, Y. P. Chen, e Y. C. Hsieh, «Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries», *Appl. Energy*, vol. 86, n.º 9, pp. 1506–1511, set. 2009, doi: 10.1016/J.APENERGY.2008.11.021.
- [99] X. Lai, Y. Zheng, e T. Sun, «A comparative study of different equivalent circuit models for estimating state-of-charge of lithium-ion batteries», *Electrochimica Acta*, vol. 259, pp. 566–577, jan. 2018, doi: 10.1016/j.electacta.2017.10.153.
- [100] J. Tian, R. Xiong, W. Shen, e F. Sun, «Electrode ageing estimation and open circuit voltage reconstruction for lithium ion batteries», *Energy Storage Mater.*, vol. 37, pp. 283–295, mai. 2021, doi: 10.1016/J.ENS.M.2021.02.018.

Apêndices

Apêndice A

Pseudocódigo do PSO

Apêndice B

Publicações científicas

A Swarm Intelligence-Based Multistage Charging Strategy for Lithium-Ion Batteries

Pedro F.Q. Peixoto
University of Beira Interior
Covilhã, Portugal
pedro.peixoto@ubi.pt

Jose A.N. Pombo
IT-Instituto de
Telecomunicações
University of Beira Interior
Covilhã, Portugal
jose.pombo@ubi.pt

Silvio J.P.S. Mariano
IT-Instituto de
Telecomunicações
University of Beira Interior
Covilhã, Portugal
sm@ubi.pt

Maria R.A. Calado
IT-Instituto de
Telecomunicações
University of Beira Interior
Covilhã, Portugal
rc@ubi.pt

Abstract— This article applies the Particle Swarm Optimization (PSO) algorithm to optimize the Multi-stage Constant Current (MSCC) charging method, to increase the adaptability of the charging process based on the battery's internal and external conditions. This approach enables a better balance between fast charging and energy performance. The optimization problem is formulated to minimize the total charging time while simultaneously ensuring high levels of autonomy, reflected in a high final state of charge (SOC). The results demonstrate that the proposed formulation is an effective and flexible strategy for the optimized management of Li-ion battery charging, with potential applications in smart energy systems.

Keywords— *Li-ion batteries; Battery charging; Particle Swarm Optimization (PSO); Multi-stage Constant Current (MSCC); Energy storage systems.*

I. INTRODUCTION

The growing concern about climate change, the instability of international markets (both for electricity and fossil fuels), and international decarbonization commitments have driven an energy transition based on sustainable energy sources. [1]. In this context, renewable energy sources play a fundamental role, offering environmentally responsible, clean, and virtually inexhaustible solutions for electricity generation. [2]. However, despite their environmental advantages and technical potential, these sources present significant technical and operational challenges, which hinder their integration into conventional energy systems. [3].

The intermittent and non-dispatchable nature of most renewable energy sources makes it difficult to balance electricity supply and demand, requiring the power system to have greater adaptability in terms of both stability and flexibility [4]. This adaptive capacity becomes particularly evident in situations of low or high renewable generation, or during periods of low or high demand. Thus, the energy transition increasingly depends on the implementation of technical solutions capable of accommodating a diverse, dynamic, and resilient energy mix. [5]. To ensure the continuity of the decarbonization path, it is essential to invest in advanced and, at the same time, complementary technical solutions [6]. Among the priority solutions are: the

This work is supported by the European Regional Development Fund (FEDER), through the Regional Operational Programme of Centre (CENTRO 2030) of the Portugal 2030 framework [Project EM2ECO - CENTRO2030-FEDER-01470600]. This work is funded by FCT/MECI through national funds and when applicable cofunded EU funds under UID/50008: Instituto de Telecomunicações.

reinforcement of electrical interconnections within the European space [7];

the modernization and digitalization of electricity networks (both transmission and distribution) through smart grids [8]; the geographical and technological diversification of renewable energy sources [9]; and, most importantly, the implementation of electrical energy storage systems [10]. The latter are essential to ensuring the flexibility of the power system, allowing surplus energy produced during periods of low demand to be stored and used when production is insufficient. The coordinated implementation of these solutions will be crucial to consolidating a more robust and resilient electricity system, capable of integrating an increasing share of renewable energy without compromising supply security or quality [10].

Among the emerging electrical energy storage technologies, lithium-ion (Li-ion) batteries have gained widespread acceptance due to their high energy density, conversion efficiency, fast response time, and relatively long lifecycle [11]. Currently, these batteries are widely used in both mobile applications (such as electric vehicles) and stationary systems connected to the electrical grid. However, despite their advantages, Li-ion batteries exhibit significant limitations. One of the main issues is the progressive degradation of their internal components over their lifecycle, which leads to a gradual loss of capacity, an increase in internal resistance, and a reduction in overall lifespan [12].

The charging process has a direct influence on the electrochemical aging mechanisms within batteries, potentially accelerating or slowing their degradation depending on the defined parameters. Inadequate charging methods tend to accelerate the wear of active materials, compromise the integrity of the Solid Electrolyte Interphase (SEI) layer, and consequently lead to a significant reduction in battery lifespan [13]. These factors have direct implications for the economic viability of electrical energy storage systems, as they reduce service life and increase maintenance and replacement costs. Furthermore, the reduction in battery lifecycle contributes to a greater environmental impact due to the need for frequent replacements, which in turn increases the production of waste that is difficult to recycle.

The standard charging method in the industry for Li-ion batteries is the Constant Current – Constant Voltage (CC-CV) method. This consists, in the first phase of applying a constant charging current until the battery reaches the maximum

voltage (cut-off voltage). This is followed by a second phase, where the voltage is kept constant while the current progressively decreases to residual values, indicating that the battery is fully charged [14].

Among the main advantages of the method are its simplicity of implementation and consequent ease of integration into commercial systems. It is also compatible with most Li-ion battery chemistries, which reinforces its universal applicability. Additionally, it offers a good balance between efficiency and durability and is considered safe when properly parameterized. However, this method also presents some disadvantages. One of the primary drawbacks is the relatively long charging time during the constant voltage phase. Furthermore, the CC-CV method is not sensitive to the battery's state of health (SOH), i.e., it does not adjust charging parameters based on internal resistance and temperature, which may compromise efficiency and accelerate degradation under certain conditions. The application of high currents during the initial phase can also lead to a significant increase in temperature, especially in environments with limited thermal dissipation capacity. This thermal rise can promote undesired side reactions, such as abnormal growth of the SEI layer, contributing to accelerated degradation [15], [16].

Despite these limitations, the CC-CV method remains widely used, especially in applications where simplicity, safety, and compatibility are priorities or fundamental requirements. However, for more demanding applications or those sensitive to battery durability, more advanced alternatives have been explored, such as the multistage charging method, pulse charging methods [17], and charging methods based on artificial intelligence and machine learning algorithms [18], [19].

The multistage charging method aims to optimize the balance between charging time, safety, and battery durability. This method divides the charging process into several stages (or levels), each with specific current parameters. The current is progressively reduced to minimize electrochemical and thermal stress on the active materials that make up the battery. This type of charging offers several advantages over the standard CC-CV method. Firstly, it helps extend the battery's lifespan by avoiding the main degradation mechanisms associated with high currents, overheating, and overvoltage. Secondly, it reduces heat generation throughout the charging process, contributing to the thermal and chemical stability of the batteries—an essential factor for applications requiring high reliability and safety. Additionally, it allows for greater efficiency in terms of charging time, as higher currents can be applied during safe and controlled phases without compromising battery integrity [20].

However, to maximize efficiency, reduce charging time, extend and preserve battery lifespan, and simultaneously ensure safety, it is essential to approach the multistage charging method as an optimization process. This approach enables greater adaptability of the process through the dynamic adjustment of current levels based on the battery's internal and external conditions, such as temperature, state of charge (SOC), voltage, and internal resistance.

Three fundamental questions characterize the optimization problem. The first concerns defining the current values during the charging process. At each moment, it is necessary

to determine the current value to be applied. Very high currents can reduce charging time but increase internal temperature and accelerate undesirable internal chemical reactions that lead to battery degradation. On the other hand, very low currents are safer but excessively prolong the charging process.

The second question relates to the criterion that determines the transition between different current stages. In the multistage charging method, the transition criterion can be defined using various control variables, such as battery voltage, state of charge (SOC), charging time, or even temperature. These criteria must be precisely defined to ensure efficient transitions, avoiding undesired internal chemical reactions and/or overvoltage (overcharging). A poorly specified criterion may compromise the overall performance of the charging process and thus affect battery durability.

The third and final question concerns defining the (ideal) number of current stages in the charging profile. A high number of current levels provides greater adaptability, allowing for a more refined and specific adjustment of the charging process to the battery's conditions—that is, it offers a more sensitive response to the battery's state of health (SOH). However, a reduced number of current levels simplifies the control system and its practical implementation, although it may compromise adaptability and, consequently, the overall charging process performance. Therefore, it is essential to find a suitable balance between complexity and gains in efficiency, time, and safety that ultimately prolong battery life [21], [22], [23].

The adaptability of the multistage charging method makes it especially suitable for demanding applications such as electric vehicles or stationary storage systems, where balancing performance and durability is essential. Its flexibility allows the charging profile to be adjusted to different battery chemistries, state of health, internal resistance, and environmental conditions, thereby contributing to reduced degradation [24]. To achieve this adaptability, the present study proposes the application of the Particle Swarm Optimization (PSO) algorithm as a tool to address, in an integrated manner, two of the three fundamental questions discussed previously, with the goal of making the multistage charging process more adaptable, efficient, and intelligent. By using PSO as the optimization method, the aim is to maximize energy efficiency, reduce total charging time, extend battery lifespan, and ensure high safety standards throughout the process.

Specifically, the PSO algorithm is employed to: (i) determine the optimal current values to be applied at each charging stage; and (ii) establish the ideal number of stages. This approach enables a more sensitive response to the battery's internal and external conditions, such as temperature, internal resistance, and state of health (SOH), contributing to a more optimized charging process. Thus, this work aims to contribute to the development of smarter charging systems capable of extending battery life, reducing charging time, and ensuring greater operational safety.

This article is organized into six sections. Section II presents the main characteristics of the Multi-stage Constant Current (MSCC) charging method; Section III describes the Particle Swarm Optimization (PSO) algorithm; Section IV

formulates the optimization problem and details the procedure carried out; Section V evaluates the performance of the optimization process applied to the MSCC charging method; and finally, Section VI summarizes the main conclusions of the work.

II. MULTI-STAGE CONSTANT CURRENT (MSCC) CHARGING STRATEGIES FOR LI-ION BATTERIES

The Multi-stage Constant Current (MSCC) charging method consists of the sequential application of multiple stages (or levels) of constant current, where the current level is progressively reduced as the charging process advances. The transition between stages is regulated by specific criteria, which directly influence the efficiency of the charging method, safety, and battery longevity. Figure 1 presents the different existing transition criteria, highlighting the four main ones addressed in the specialized literature: time-based, state of charge (SOC)-based, voltage-based, and maximum voltage (cut-off voltage)-based criteria [24].

Figure 1(a) illustrates the time-based transition criterion, in which the charging current is reduced after predefined time intervals. This method has the advantage of being simple to implement; however, it does not consider the internal and external conditions of the battery, such as temperature, SOC, or internal resistance, which can result in an inefficient charging process or, in more critical cases, accelerate the degradation of the battery's electrochemical components.

Figure 1(b) depicts the state of charge (SOC)-based criterion. In this case, the transition between stages occurs whenever the SOC reaches predefined values. This approach offers greater adaptability, as it is more sensitive to the actual state of the battery. However, its effectiveness strongly depends on the accuracy of SOC estimation, a task subject to uncertainties, especially in real-time systems.

Figure 1(c) shows the voltage-based criterion, in which stage transitions are defined by voltage threshold values. As the voltage reaches each of these thresholds, the current is adjusted to a lower level. However, voltage threshold values are often empirically defined, which may compromise process efficiency.

Finally, Figure 1(d) presents the maximum voltage (cut-off voltage)-based criterion, the most widely adopted in the literature. In this method, the stage transition is determined when the cell voltage reaches the maximum value specified by the manufacturer (usually 4.2 V for Li-ion batteries). When this voltage is reached, the current is reduced to a new level, and charging continues until this value is again reached. Although this criterion is simple, robust, and effective in many situations, it may not fully exploit the optimization potential of the charging process, especially when considering variables such as ambient temperature, battery aging, or internal resistance.

Given the diversity of approaches and the challenges associated with defining and parameterizing charging profiles, the need for more intelligent and adaptive solutions becomes evident. The application of optimization algorithms, such as Particle Swarm Optimization (PSO), emerges as a promising alternative. This type of approach allows for the automatic determination of the optimal current values for each stage, the most suitable transition criteria, and the ideal number of stages, maximizing charging efficiency, reducing the required

time, extending battery life, and ensuring high levels of operational safety [25].

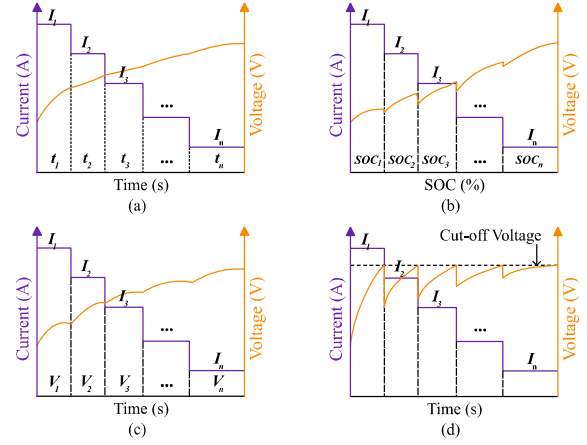


Fig. 1. Multi-stage Constant Current (MSCC) variants with different transition criteria (adapted from [24]).

III. PARTICLE SWARM OPTIMIZATION ALGORITHM (PSO)

The metaheuristic Particle Swarm Optimization (PSO) algorithm mimics the behaviour exhibited by certain animal species when searching for food. These groups of animals are considered as particles or agents that move within a multidimensional search space and are evaluated at each iteration using a given objective function, with the aim of finding the best solution to the optimization problem [26]. In optimization problems, a set of n_p particles is randomly generated in a multidimensional search space of dimension dim , where each particle i has a position vector $X_i = [x_{i,1}, x_{i,2}, \dots, x_{i,dim}]$ and a velocity vector $V_i = [v_{i,1}, v_{i,2}, \dots, v_{i,dim}]$, for $i = 1, 2, \dots, n_p$. The velocity at which each particle moves within the search space considers its previous velocity weighted by an inertia factor (w), the particle's own experience (cognitive factor), and the experience of the entire particle population (social factor). The best position found by each particle is called the personal best ($pbest$) and the best position found by the entire population is known as the global best ($gbest$). These values are updated at each iteration whenever better personal or global positions are found, and the velocity and position vectors are calculated according to equations (1) and (2), respectively [27].

$$v_{i,dim}^{k+1} = \omega \cdot v_{i,dim}^k + c_1 \cdot r_1 \cdot (pbest_{i,dim}^k - x_{i,dim}^k) + c_2 \cdot r_2 \cdot (gbest_{dim}^k - x_{i,dim}^k) \quad (1)$$

$$x_{i,dim}^{k+1} = x_{i,dim}^k + v_{i,dim}^{k+1} \quad (2)$$

where $v_{i,dim}^{k+1}$ e $x_{i,dim}^{k+1}$ represent the velocity and position of the i -th particle in the dim -th dimension at the k -th iteration, respectively; ω denotes the inertia factor; c_1 is the cognitive acceleration coefficient; c_2 is the social acceleration coefficient; r_1 and r_2 are random values uniformly distributed over the interval $[0, 1]$.

IV. PROBLEM FORMULATION AND OPTIMIZATION PROCEDURE

This section presents the formulation of the optimization problem, as well as the procedure adopted for its resolution.

The objective is to identify the charging profile that provides the best compromise between autonomy and charging time, while simultaneously ensuring durability and safety. To this end, the Particle Swarm Optimization (PSO) algorithm was used, a metaheuristic technique widely recognized for its ability to efficiently explore complex and nonlinear search spaces—an essential feature for high-complexity problems.

A. Problem Formulation

The formulation of the optimization problem aims to minimize the total charging time while simultaneously maximizing the final state of charge (SOC_f). The choice of charging time and final state of charge as criteria in the objective function formulation allows for achieving a balance between charging speed and energy performance. Charging time reflects the need to reduce the duration of the charging process, a critical aspect in applications with time constraints. On the other hand, the final SOC indicates the effective amount of energy stored, which is directly associated with autonomy and energy availability.

However, since these two criteria are expressed in different units, normalization is necessary to enable equitable comparison and integration into a single objective function. Additionally, a weighting factor α was introduced to adjust the relative influence of each criterion in the objective function. This weighting factor can be tuned according to system priorities—for example, favouring autonomy or charging time depending on the application. Based on these considerations, the objective function can be expressed in a combined form, allowing the optimization algorithm (in this case, PSO) to find a solution that represents an appropriate compromise between energy performance and charging speed.

$$f_{obj} = \alpha \times \left(\frac{T_{char}}{T_{max}} \right) + (1 - \alpha) \times (1 - SOC_f) \quad (3)$$

The optimization problem is subject to the following constraints:

$$0.9 \leq SOC_f \leq 1 \quad (4)$$

$$T_{char} \leq T_{max} \quad (5)$$

$$I_{lb} \leq I_t \leq I_{ub} \quad (6)$$

$$I_t \leq I_{t-1} \quad (7)$$

where T_{char} represents the total charging time; T_{max} is the maximum allowable charging time (set to 2 hours in this study); α is the weighting factor within the interval $[0,1]$; I_t is the charging current at time t ; I_{lb} and I_{ub} are the lower and upper bounds of the charging current, respectively.

The constraints imposed in the optimization problem contribute to the safety and longevity of the battery. By encouraging the maximization of SOC within predefined operational limits, exposure of the battery to conditions of overcharging or excessive heating is avoided, promoting more efficient and safer energy management. Moreover, the explicit constraints on charging time and current ensure that the solution obtained by the optimization algorithm respects technical parameters, including permissible current values, the monotonic decreasing nature of the charging current, and thermal restrictions.

B. Experimental Setup

An experimental setup composed of various interconnected electronic devices was implemented with the objective of precisely and reliably controlling, monitoring, and acquiring real-time data. The Li-ion battery used in the tests (Samsung ICR18650-26H with a capacity of 2.6 Ah) was housed inside a thermal chamber to ensure stable environmental conditions throughout the charging and discharging processes. This thermal control is essential to avoid temperature fluctuations that could compromise the battery's electrochemical behaviour. The temperature of the thermal chamber is regulated in real time by an Arduino Mega 2560 microcontroller based on internal measurements.

Battery charging is performed using a programmable DC power supply, the RIGOL DP811A. This power supply is essential to apply the different current profiles defined by the PSO optimization algorithm, automatically adjusting the C-rate at each charging stage according to the determined parameters. For the discharging process, a RIGOL DL3021A DC electronic load was used, simulating real operating conditions by imposing controlled, consistent, and predefined discharge profiles. Electrical parameters such as current and voltage were monitored using a precision digital multimeter, the RIGOL DM3058E, ensuring measurement reliability throughout all tests.

The coordination, management, and control of the entire system were performed via a computer running MATLAB software, which executes the PSO algorithm, generates the charging profiles, communicates with the devices through USB and serial interfaces, automatically collects experimental data in real time, and performs the necessary calculations to evaluate the performance and effectiveness of the proposed method. This fully automated experimental setup allowed for repetitive tests with high consistency and precision, being fundamental to validate the efficiency of the proposed method in real time.

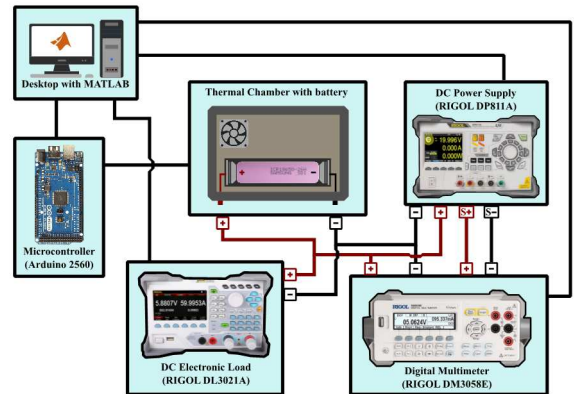


Fig. 2. Experimental Setup.

C. Optimization Procedure

The optimization process was structured according to an iterative procedure based on the Particle Swarm Optimization (PSO) algorithm. The adopted methodology is schematically represented in Fig. 3, which illustrates both the algorithm's operating logic and the complete charge-discharge cycle used in the experimental tests. Initially, the main parameters of the PSO algorithm are defined, namely: the number of particles in the population (n_p), the maximum number of iterations

(it_{max}), the problem dimension (d), and the inertia (w), cognitive (c_1) and social (c_2) coefficients. Additionally, the number of current stages (n) of the charging profile is established, as well as the minimum and maximum allowable current limits for each stage. The transition criterion between stages is also defined, which in this work is based on the battery's maximum voltage (4.2V), as specified by the manufacturer.

Each particle generated by the PSO corresponds to a current vector, *i. e.*, $[I_1, I_2, \dots, I_n]$, representing an MSCC charging profile. This profile is physically tested in the experimental setup, initiating the charging process with the sequential application of the defined current values. The programmable power supply dynamically adjusts the current levels, while various parameters are monitored in real time: charging time, state of charge (SOC), and battery temperature. Upon completion of charging, the battery enters a rest phase, allowing thermal and electrochemical stabilization. In parallel, the objective function is evaluated based on two main metrics: charging time and state of charge (equations x and x), resulting in a performance value associated with each particle. These metrics are normalized to ensure unit compatibility and are combined into a single objective function using a weighting factor α , which allows the balance between charging speed and autonomy to be adjusted. Next, the battery is discharged at a constant current with a 1C rate, simulating a complete usage cycle. After another rest phase, the cycle is repeated with the current profile corresponding to the next particle. These tests are conducted inside a temperature-controlled thermal chamber in order to eliminate the influence of environmental variables on the results. Once all particles in the population have been evaluated and their performance assessed, the personal best ($pbest$) and global best ($gbest$) are determined. Then, PSO calculates the velocity of the particles using equation x, with the aim of generating new particles, *i. e.*, new charging profiles.

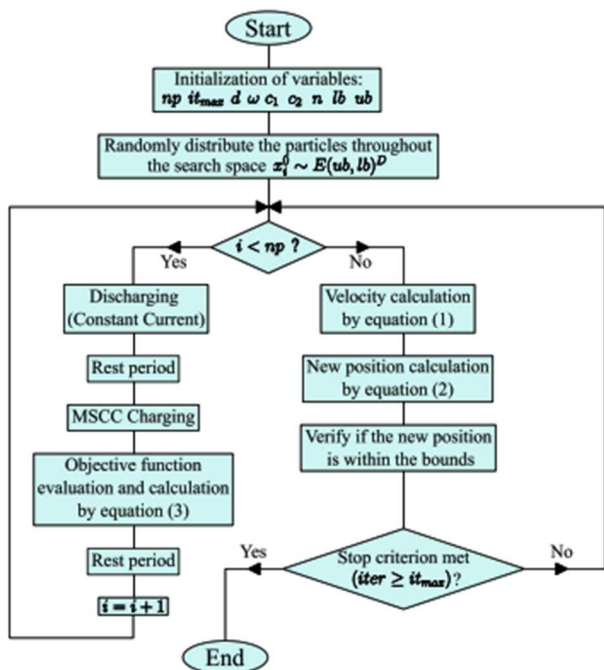


Fig. 3. Flowchart of the Optimization Procedure.

However, to ensure that the particles remain within the defined allowable current limits, a verification criterion is applied after each update: if the calculated current value exceeds the upper limit, it is automatically adjusted to that maximum value; if it falls below the lower limit, it is likewise corrected. This mechanism ensures the practical feasibility and safety of all tested profiles. The optimization process is repeated until the stopping criterion is met, in this case, the maximum number of iterations. This fully automated methodology enables the systematic and efficient exploration of multiple MSCC charging configurations, with the goal of identifying the optimal profile that maximizes battery performance in terms of energy efficiency and charging time, while simultaneously ensuring operational safety and longevity.

V. EXPERIMENTAL RESULTS

This section presents and analyses the experimental results for the Multi-stage Constant Current (MSCC) charging strategy, implemented with 4, 5, and 7 stages. The main objective is to systematically evaluate the impact of the number of stages and the corresponding current values (C-rates) at each charging phase on the overall performance of the charging process. The analysis focuses on key indicators such as total charging time, energy efficiency, and final state of charge (SOC).

A. Results for 4 stages

This subsection presents the optimization results of the Multi-stage Constant Current (MSCC) charging method with four current stages (4MSCC). Fig. 4 illustrates the region explored by the Particle Swarm Optimization (PSO) algorithm, including the different current profiles tested and the optimal current profile identified.

For the 4MSCC case, the optimal current profile obtained was [4.4886A, 2.6997A, 1.5132A, 1.2986A], corresponding to C-rate values of [1.7602C, 1.0587C, 0.5934C, 0.50924C]. This profile resulted in an objective function value of $f_{obj} = 0.3174$, with a total charging time of approximately 35 minutes. Figure 5 shows the battery voltage evolution associated with the current profiles explored, highlighting the voltage variations corresponding to each current stage. Fig. 6 presents the SOC progression based on the current profiles evaluated by the PSO algorithm, allowing the analysis of how each charging profile impacts the battery's final autonomy.




Fig. 4. Current patterns investigated by PSO in the 4MSCC configuration.

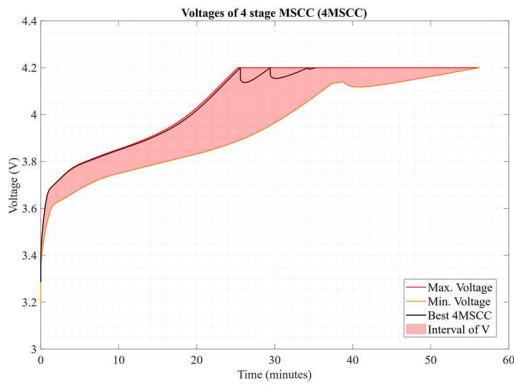


Fig. 5. Voltage profiles investigated by PSO in the 4MSCC configuration.

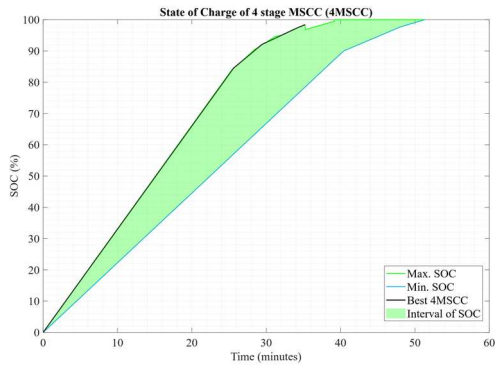


Fig. 6. SOC profiles investigated by PSO in the 4MSCC configuration.

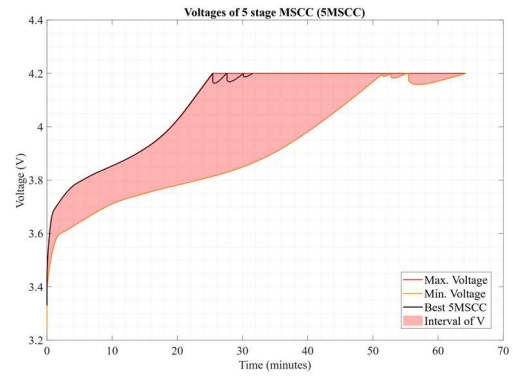


Fig. 8. Voltage profiles investigated by PSO in the 5MSCC configuration.




Fig. 9. SOC profiles investigated by PSO in the 5MSCC configuration.

B. Results for 5 stages

Figs. 7, 8 e 9 present the results obtained from the optimization procedure applied to the Multi-stage Constant Current (MSCC) charging method with five current stages (5MSCC). The optimal current profile identified was [4.5A, 3.2956A, 3.2252A, 2.2661A, 1.8126A] corresponding to C-rate values of [1.7647C, 1.2924C, 1.2648C, 0.88867C, 0.71081C]. This profile resulted in an objective function value of $f_{obj} = 0.3149$ and a total charging time of approximately 32 minutes, showing an improvement compared to the four-stage case. Additionally, the identified current profile allowed the battery to reach a final state of charge (SOC) close to 96%, demonstrating an effective trade-off between charging speed and energy performance.




Fig. 7. Current patterns investigated by PSO in the 5MSCC configuration.

C. Results for 7 stages

Finally, Figs. 10, 11 e 12 present the results obtained from the optimization procedure applied to the Multi-stage Constant Current (MSCC) charging method with seven current stages (7MSCC). The best solution (current profile) found by the algorithm was [4.5A, 3.6624A, 2.9756A, 2.3508A, 2.1031A, 1.7132A, 1.6226A], corresponding to C-rate values of [1.7647C, 1.4362C, 1.1669C, 0.92187C, 0.82473C, 0.67184C, 0.63632C]. This profile resulted in an objective function value of $f_{obj}=0,3187$, with a total charging time of approximately 32 minutes. Although the time was not significantly reduced compared to the five-stage case, the increased number of stages enables a smoother transition between current levels, which may favor electrochemical stability and enhance battery longevity.

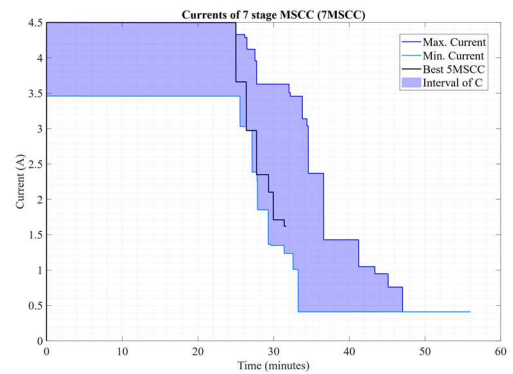


Fig. 10. Current patterns investigated by PSO in the 7MSCC configuration.

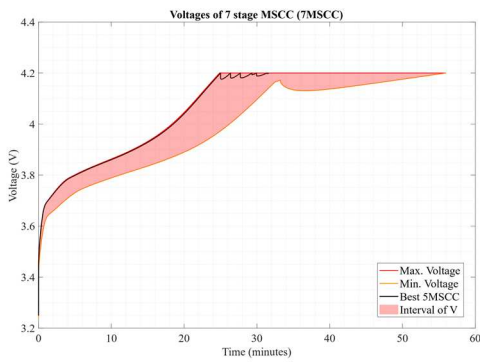


Fig. 11. Voltage profiles investigated by PSO in the 7MSCC configuration.

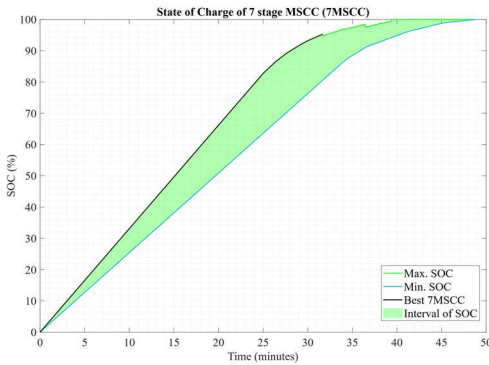


Fig. 12. SOC profiles investigated by PSO in the 4MSCC configuration.

VI. CONCLUSION

This article presented the application of the Particle Swarm Optimization (PSO) algorithm to define optimized charging profiles for the Multi-stage Constant Current (MSCC) method, aiming to increase the adaptability of the charging process to both internal (such as resistance and state of health of the battery) and external (such as ambient temperature) conditions. The experimental results demonstrated that integrating metaheuristic techniques like PSO can significantly contribute to the development of smarter, more efficient, and adaptive charging strategies. Such approaches help enhance energy performance, reduce charging time, and extend battery lifespan, representing meaningful advances in energy storage system management.

REFERENCES

- [1] M. Thirunavukkarasu, Y. Sawle, and H. Lala, "A comprehensive review on optimization of hybrid renewable energy systems using various optimization techniques," *Renewable and Sustainable Energy Reviews*, vol. 176, p. 113192, Apr. 2023.
- [2] T. Z. Ang, M. Salem, M. Kamarol, H. S. Das, M. A. Nazari, and N. Prabaharan, "A comprehensive study of renewable energy sources: Classifications, challenges and suggestions," *Energy Strategy Reviews*, vol. 43, p. 100939, Sep. 2022.
- [3] A. G. Olabi and M. A. Abdelkareem, "Renewable energy and climate change," *Renewable and Sustainable Energy Reviews*, vol. 158, p. 112111, Apr. 2022.
- [4] E. T. Sayed et al., "Renewable Energy and Energy Storage Systems," 2023.
- [5] F. Ahmed, D. Al Kez, S. McLoone, R. J. Best, C. Cameron, and A. Foley, "Dynamic grid stability in low carbon power systems with minimum inertia," *Renew Energy*, vol. 210, pp. 486–506, Jul. 2023.

- [6] O. Apata, "Decarbonization pathways through multi-energy system planning," *Energy Reports*, vol. 13, pp. 4477–4490, Jun. 2025.
- [7] Imdadullah, B. Alamri, M. A. Hossain, and M. S. Jamil Asghar, "Electric power network interconnection: A review on current status, future prospects and research direction," Sep. 01, 2021, MDPI.
- [8] M. L. Tuballa and M. L. Abundo, "A review of the development of Smart Grid technologies," Jun. 01, 2016, Elsevier Ltd..
- [9] D. Fadly and F. Fontes, "Geographical proximity and renewable energy diffusion: An empirical approach," *Energy Policy*, vol. 129, pp. 422–435, Jun. 2019.
- [10] M. M. Rana et al., "Applications of energy storage systems in power grids with and without renewable energy integration — A comprehensive review," Sep. 15, 2023, Elsevier Ltd..
- [11] Z. Lin, D. Li, and Y. Zou, "Energy efficiency of lithium-ion batteries: Influential factors and long-term degradation," *J Energy Storage*, vol. 74, Dec. 2023.
- [12] S. Vonsien and R. Madlener, "Li-ion battery storage in private households with PV systems: Analyzing the economic impacts of battery aging and pooling," *J Energy Storage*, vol. 29, Jun. 2020.
- [13] Y. Li, J. Guo, K. Pedersen, L. Gurevich, and D. I. Stroe, "Investigation of multi-step fast charging protocol and aging mechanism for commercial NMC/graphite lithium-ion batteries," *Journal of Energy Chemistry*, vol. 80, pp. 237–246, May 2023.
- [14] J. S. Sophia, N. G. Iyer, and N. S. B, "A Review on Charge Control Techniques for Batteries in Electric Vehicles".
- [15] B. Bose, A. Garg, B. K. Panigrahi, and J. Kim, "Study on Li-ion battery fast charging strategies: Review, challenges and proposed charging framework," *J Energy Storage*, vol. 55, p. 105507, Nov. 2022.
- [16] S. S. Raja, H. Karneddi, and D. Ronanki, "Performance Evaluation of Charging Techniques for Lithium-Ion Batteries," in *Proceedings of the International Conference on Power Electronics, Drives, and Energy Systems for Industrial Growth, PEDES*, Institute of Electrical and Electronics Engineers Inc., 2024.
- [17] X. Huang et al., "A Review of Pulsed Current Technique for Lithium-ion Batteries," May 2020.
- [18] S. Shahriar, A. R. Al-Ali, A. H. Osman, S. Dhau, and M. Nijim, "Prediction of EV charging behavior using machine learning," *IEEE Access*, vol. 9, pp. 111576–111586, 2021.
- [19] E. Yaghoubi, E. Yaghoubi, A. Khamees, D. Razmi, and T. Lu, "A systematic review and meta-analysis of machine learning, deep learning, and ensemble learning approaches in predicting EV charging behavior," *Eng Appl Artif Intell*, vol. 135, Sep. 2024.
- [20] R. Mathieu, O. Briat, P. Gyan, and J. M. Vinassa, "Fast charging for electric vehicles applications: Numerical optimization of a multi-stage charging protocol for lithium-ion battery and impact on cycle life," *J Energy Storage*, vol. 40, Aug. 2021.
- [21] Y. Gao, J. Jiang, C. Zhang, W. Zhang, Z. Ma, and Y. Jiang, "Lithium-ion battery aging mechanisms and life model under different charging stresses," *J Power Sources*, vol. 356, pp. 103–114, 2017.
- [22] J. G. Qu, Z. Y. Jiang, and J. F. Zhang, "Investigation on lithium-ion battery degradation induced by combined effect of current rate and operating temperature during fast charging," *J Energy Storage*, vol. 52, Aug. 2022.
- [23] G. Ji, L. He, T. Wu, and G. Cui, "The design of fast charging strategy for lithium-ion batteries and intelligent application: A comprehensive review," *Appl Energy*, vol. 377, Jan. 2025.
- [24] M. Usman Tahir, A. Sangwongwanich, D. I. Stroe, and F. Blaabjerg, "Overview of multi-stage charging strategies for Li-ion batteries," *Journal of Energy Chemistry*, vol. 84, pp. 228–241, Sep. 2023.
- [25] T. M. Shami, A. A. El-Saleh, M. Alswaiti, Q. Al-Tashi, M. A. Summakieh, and S. Mirjalili, "Particle Swarm Optimization: A Comprehensive Survey," *IEEE Access*, vol. 10, pp. 10031–10061, 2022.
- [26] A. G. Gad, "Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review," *Archives of Computational Methods in Engineering*, vol. 29, pp. 2531–2561, 2022.
- [27] E. H. Houssein, A. G. Gad, K. Hussain, and P. N. Suganthan, "Major Advances in Particle Swarm Optimization: Theory, Analysis, and Application," *Swarm Evol Comput*, vol. 63, Jun. 2