

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO



Análise do valor económico de baterias em segunda vida

Stefan D. Steinmaier

VERSÃO DE TRABALHO

Mestrado Integrado em Engenharia Eletrotécnica e de Computadores

Orientador: Professor Dr. Adriano da Silva Carvalho

19 de janeiro de 2019

Resumo

A tecnologia em desenvolvimento dos EV é considerada como a melhor alternativa ao atual uso não sustentável de combustíveis fósseis. A bateria de um automóvel elétrico é considerada inadequada quando chega a 80% da sua capacidade nominal, aproximadamente [1], e do ponto de vista do consumidor é fundamental uma grande autonomia. Um aspeto muito abordado na literatura é a atribuição de uma segunda vida a este tipo de baterias em vários tipos de aplicações estacionárias.

Obter uma implementação com sucesso de um sistema com uma Bateria de Segunda Vida (BSV), é fundamental perceber a relação custo-benefício desta aplicação. É necessário estimar a Restante Vida Útil (RUL) de uma bateria, após determinadas condições de primeira e segunda vida definidas.

A finalidade deste documento é a modelação do envelhecimento de uma BSV e analisar a sua viabilidade em aplicações concretas. No início foi adotado e estudado o modelo considerado mais completo. Numa fase posterior do projeto, foram realizados testes práticos com o objetivo de calcular os parâmetros mais relevantes da bateria e de analisar a sua evolução.

Abstract

The Electric Vehicle (EV) is considered to be the best alternative to the non-sustainable consumption of fossil fuels. From the buyer's point of view, it is essential for an EV to have a great autonomy. An EV's battery is considered incapable when its nominal capacity reaches approximately 80% [1]. A possible second life application for these batteries is an emerging topic of discussion in literature.

In order to implement a successful implementation of a Second Life Battery (BSV) based system it is crucial to understand the cost-benefit of this application. The main goal is the estimation of the battery's Remaining Useful Life (RUL), under specific conditions.

This document seeks the understanding and parameterization of a BSV's ageing model and the viability of such application. At first, a complete model is studied, and latter, tests will be conducted in order to create a database that will be used to calculate its vital parameters and build its degradation model.

Agradecimentos

Agradeço aos meus pais, Ana e Stefan, que toda a minha vida estiveram presentes e nunca me deixaram falhar, mesmo quando falhei. Como posso eu agradecer às pessoas que nunca permitiram que me faltasse um livro, um caderno antes de ir para a escola? ÀS pessoas que, acima de tudo, me apoiam incondicionalmente? Tudo o que sou e serei o devo a vós. Ao meu irmão... Tu sabes porque.

Também agradeço à minha querida Patty Gadea pelo seu valioso apoio, pela sua presença, pela sua disponibilidade e pelo seu amor. Significas muito para mim. A todos os meus amigos mais chegados, o que a vida sem amigos? Aos PLG & Cia e Pipa, porque vocês são uma nova família e cinco anos pareceram cinco meses.

Gostaria também de deixar um agradecimento muito especial ao professor Adriano da Silva Carvalho, sempre disponível, apesar de todos os seus compromissos e, sobretudo, por todas as críticas e conselhos. Foi um prazer trabalhar consigo!

A todos o meu muito obrigado.

Stefan D. Steinmaier

“Obama out...”

Barak Obama

Conteúdo

1	Introdução às Baterias <i>Lithium-ion</i> e Características	1
1.1	Introdução	1
1.2	Enquadramento	2
1.3	Baterias de íão de Lítio	3
1.3.1	Especificações técnicas	3
1.4	Motivação e Objetivos	6
1.5	Organização do Documento	7
2	Revisão Bibliográfica e Parâmetros Associados ao Modelo de Degradação da Bateria	9
2.1	Parâmetros relativos à condição da bateria	11
2.1.1	Estado de saúde da bateria	11
2.1.2	Tensão em circuito aberto	11
2.1.3	Estado de carga atual	12
2.2	Parâmetros que afetam a degradação de uma bateria	13
2.2.1	Temperatura	13
2.2.2	Profundidade de Carga/Descarga (DoD)	14
2.3	Modelo de Degradação de uma Bateria de Segunda Vida	15
2.3.1	Aplicações Consideradas para a Segunda Vida	15
2.3.2	Metodologia dos Testes Efetuados	16
2.3.3	Resultados dos Testes, Conclusões e Proposta de Trabalho Futuro	17
2.4	Metodologia de trabalho futuro	17
3	Principais Técnicas de Estimação do Estado de Carga e Saúde de uma Bateria	21
3.1	Rede Neuronal Artificial (ANN)	21
3.2	<i>Regression Learner</i>	23
3.3	Lógica Difusa (<i>Fuzzy Logic</i>)	24
3.4	Filtro de Kalman (KF) e Filtro de Kalman Estendido (EKF)	25
3.5	Espectroscopia Eletroquímica de Impedância (EIS)	27
3.6	Método Baseado na Voltagem Medida	28
3.7	Teste de Impedância e Condutância	28
3.8	<i>Coulomb Counting e Enhanced Coulomb Counting</i>	29
4	Estudo e Preparação dos Dados Adquiridos	31
4.1	Introdução	31
4.2	Modelo Elétrico Equivalente	32
4.3	<i>Curve Fitting</i> : Caraterísticas e Aplicação	34
4.4	Solver <i>Add-in</i>	35
4.5	Análise dos Resultados Obtidos	36

4.5.1	DIA 17/07/2018	36
4.5.2	DIA 11/09/2018	37
4.5.3	DIA 06/11/2018	38
4.6	Conclusões	39
4.7	Validação e Comparação dos Resultados Obtidos	40
4.8	Proposta de Trabalho e Futura Maximização da Precisão de Estimação	41
5	Estudo da Taxa de Degradação da Bateria e Proposta de Predição com Base em <i>Machine Learning</i>	43
5.1	Análise e Pré-processamento da Base de Dados a Considerar nos Algoritmos Inteligentes	44
5.2	Rede Neuronal Artificial	45
5.2.1	Análise dos Resultados Obtidos da Aplicação da ANN de Série Temporal	45
5.3	<i>Regression Learner do Matlab</i>	47
5.4	Predição do Comportamento do SoH: ANN vs MRL	48
6	Conclusões e Trabalho Futuro	53
6.1	Conclusões	53
6.2	Proposta de Melhoria e Trabalho Futuro	54
A		55
B		57
C		59
C.1	NARX ANN	59
C.2	<i>Regression Learner do Matlab</i>	60
	Referências	63

Lista de Figuras

1.1	Degradação da capacidade ao longo de muitos ciclos de descarga	2
1.2	Alteração do ciclo de vida a diferenças de potencial de carga elevadas	5
1.3	Ciclo de vida em função da DoD	6
2.1	Degradação da bateria durante ciclos e durante armazenamento	10
2.2	Relação entre OCV e SoC durante uma descarga completa	12
2.3	Evolução da capacidade nominal em função do SoC atual e do tempo	13
2.4	(a) Evolução da capacidade nominal a diferentes temperaturas, 50% SoC; (b) e da resistência nominal nas mesmas circunstâncias; [2]	14
2.5	Evolução da capacidade nominal em diferentes intervalos de SoC	15
2.6	(a) Diagrama de blocos de uma aplicação de uma BSV num agregado familiar; (b) e de uma aplicação de <i>power smoothing</i> ; [3]	16
2.7	Perfil de corrente sintetizado de um mês, da aplicação de <i>power smoothing</i> (azul) e da aplicação residencial (laranja);	16
3.1	Arquitetura de uma ANN considerada no projeto.	22
3.2	Resultados da aplicação de uma ANN no projeto [4]	23
3.3	Um sistema de inferência <i>fuzzy</i> completo.	24
3.4	Estimação da capacidade da bateria em função da distancia percorrida por um EV [5].	27
3.5	Resultados obtidos e validados por [6], utilizando um método melhorado de <i>coulomb counting</i>	30
4.1	Circuito elétrico equivalente do modelo de baterias	32
4.2	Vout medido e Vout estimado ao longo do tempo, (17/7/18).	37
4.3	Vout medido e Vout estimado ao longo do tempo, (11/9/18).	38
4.4	Vout medido e Vout estimado ao longo do tempo, (6/11/18).	39
4.5	Circuito equivalente de <i>Thevenin</i> considerado por [7]	40
4.6	Erros associados à estimação de parâmetros, registados em [7]	41
5.1	Arquitetura da rede neuronal NARX.	45
5.2	Resultados obtidos do treino da rede neuronal.	46
5.3	Performance do treino da ANN.	47
5.4	Estado de treino da rede neuronal.	48
5.5	Resultados obtidos pelo MRL ao longo do tempo.	49
5.6	Evolução de Vin mediante a variação de temperatura.	50
5.7	Gráfico que relaciona os valores reais e estimados.	51
A.1	a	55

B.1	b	57
C.1	Predição da evolução do SoH com uma rede neuronal, aplicando um perfil de utilização idêntico a um EV.	59
C.2	Predição da evolução do SoH com uma rede neuronal, aplicando um perfil de utilização idêntico a um conjunto de casas.	60
C.3	Predição da evolução do SoH com o aplicação de regressão inteligente do <i>Matlab</i> , aplicando um perfil de utilização idêntico a um EV.	61
C.4	Predição da evolução do SoH com o aplicação de regressão inteligente do <i>Matlab</i> , aplicando um perfil de utilização idêntico a um conjunto de casas.	61

Abreviaturas e Símbolos

EV	Veículo(s) Elétrico(s)
BSV	Bateria(s) de Segunda Vida
RUL	Restante Vida Útil
SoH	Estado de Saúde de uma Bateria
SoC	Estado de Carga de uma Bateria
DoD	Profundidade de um ciclo de carga
FL-EOL	Fim da Primeira Vida de uma Bateria
RI	Resistência Interna
OCV	Tensão em Circuito Aberto
CCV	Tensão em Circuito Fechado
OPT	Temperatura de Operação

Capítulo 1

Introdução às Baterias *Lithium-ion* e Características

1.1 Introdução

O armazenamento de energia elétrica é um tema ainda em desenvolvimento e que se encontra totalmente presente no quotidiano, a nível mundial e atualmente, seria completamente impensável a sua inexistência. A principal forma de armazenamento de energia é feito através de baterias, que são selecionadas mediante os requisitos da sua aplicação. A partir do momento em que se tornou óbvio o consumo não sustentável de combustíveis fósseis, rapidamente, investigadores por todo o mundo procuraram alternativas, como por exemplo, automóveis híbridos.

Hoje em dia os Veículos Elétricos (EV) são os maiores candidatos ao futuro dos transportes e é necessário progredir nessa direção para viabilizar esta tecnologia. Os principais produtores de EV trabalham diariamente com o objetivo de melhorar o desempenho das suas baterias, aumentando a densidade energética e diminuindo as perdas.

Basicamente, para este mercado crescer é necessário garantir ao consumidor que a aquisição de um EV é vantajoso em termos económicos. Recentemente, o tema de baterias de segunda vida (BSV), começou a ser tratado com mais insistência, isto porque, o aumento do tempo de vida de uma bateria constitui um potencial indicador da diminuição dos preços dos EV.

Apesar das BSV ser um tema ainda em estudo e desenvolvimento, existe ainda uma clara lacuna no que diz respeito á modelação do seu envelhecimento em determinadas aplicações. Este documento tem como objetivos:

- Identificar e estudar o modelo mais completo e robusto existente na literatura
- Estudar e compreender a influência de determinados parâmetros na degradação de uma BSV.
- Registrar e avaliar a evolução do estado de saúde da bateria ao longo de vários meses de utilização.

- Modelar o comportamento do SoH em função das variáveis consideradas importantes aplicando um método baseado em *Machine Learning*.
- Estimar o seu valor económico numa aplicação de segunda vida.

Este documento tem como objetivo a recolha, análise e estudo de dados provenientes de uma bateria de um EV, de forma a modelar o seu envelhecimento. As condições exigentes de utilização, são recolhidas e, posteriormente, a sua capacidade de transferir e armazenar energia é analisada ao longo do tempo. Obviamente, as condições de segunda vida serão muito menos exigentes que aquelas sentidas nos EV, e caso seja provado que este tipo de baterias têm utilidade em segundas aplicações, será dado mais um passo importante na evolução do mais provável sucessor dos automóveis com motores de combustão.

1.2 Enquadramento

Geralmente, as baterias presentes no EV são sujeitas a condições relativamente agressivas, durante grande parte da sua vida. É perceptível através da visualização da figura 1.1 que a degradação da uma bateria acontece de uma maneira relativamente lenta, até que atinge, aproximadamente, 80% da sua capacidade nominal. É à volta deste valor que se verifica o chamado “*curve knee*”, ou seja, a partir desse ponto, a taxa de degradação da bateria aumenta drasticamente. Mantendo as mesmas condições de utilização (requisitos dos EV), o Estado de Saúde (SoH) da bateria decresce gradualmente. Isto leva a uma significativa perda de autonomia num curto espaço de tempo. Daí ser recomendado aos utilizadores de EV a troca de bateria antes do começo deste período crítico.




Figura 1.1: Degradação da capacidade ao longo de muitos ciclos de descarga [8]

A questão mais pertinente que atualmente se impõe é a seguinte: suavizando as condições de utilização, ou seja, diminuindo as correntes de carga e DoD, até que ponto será viável a reutilização de uma bateria numa segunda vida?

Num contexto habitacional ou de pequenos empreendimentos, a utilização da energia proveniente de painéis solares ou geradores eólicos são soluções cada vez mais adotadas. Entre outras,

estas fontes de energia renovável, além de diminuir a pegada ecológica de uma infraestrutura, são considerados investimentos que trazem vantagens económicas a médio-longo prazo.

Por razões óbvias, a produção deste tipo de energia não é consistente com a sua demanda. Ou seja, haverá momentos do dia em que a energia produzida não é suficiente para alimentar a infraestrutura. Por outro lado, toda a energia produzida e não consumida é oferecida à rede com retorno muito reduzido. Podemos encontrar diversos projetos pela literatura, onde investigadores reúnem esforços e procuram compreender a viabilidade da segunda aplicação de uma bateria proveniente de EV.

Caso uma segunda aplicação deste tipo de baterias seja um projeto lucrativo poderá revelar-se um ponto importante na indústria dos EV. Isto porque, ao confirmar a viabilidade das BSV estas ganham um novo valor no mercado e, conseqüentemente, o custo de um EV tende a decrescer a curto prazo.

1.3 Baterias de íão de Lítio

Atualmente, existem inúmeros tipos de tecnologia de baterias, cada qual com prós e contras. Baterias distintas têm características físicas e de *performance* diferentes. Essa diversidade de características vai de encontro às necessidades do largo mercado de armazenamento de energia. Por exemplo, as baterias de ácido de chumbo são muito utilizadas em equipamentos hospitalares já que são consideradas as mais económicas em situações em que a sua dimensão é desprezável.

As baterias mais utilizadas no EV são *Lithium-ions*. É uma tecnologia claramente em desenvolvimento. Estas baterias têm um custo relativamente elevado e funcionam dentro de regimes restritos de segurança. São utilizadas quando se pretende maximizar a densidade energética e a minimização do seu peso.

1.3.1 Especificações técnicas

As características de uma bateria são definidas pelo seu fabricante e tem como objetivo distinção das mesmas. Deste modo, é possível eleger qual a bateria ideal para cada aplicação.

Nas seguintes secções, serão expostas as especificações mais relevantes para a construção do modelo.

1.3.1.1 Capacidade da bateria

A capacidade de uma bateria traduz a quantidade de energia que esta pode fornecer sobre determinadas condições. Geralmente, estes equipamentos são caracterizados pelos fabricantes em Ampere-hora (Ah), a determinadas condições de utilização. De notar que a capacidade real é fortemente dependente de fatores externos como a temperatura de utilização ou a profundidade dos ciclos de descarga. Condições de utilização mais exigentes aceleram o processo de envelhecimento de uma bateria.

Na literatura, geralmente, a capacidade de uma bateria é expressa entre 0% e 100% (capacidade nominal). A capacidade atual de uma bateria, expressa em percentagem da capacidade nominal, é um fator com extrema importância para perceber o SoH da mesma. Os primeiros estudos neste tema definiam o fim da primeira vida (FL-EOL) de uma bateria de um EV quando esta atinge o *threshold* de 70%-80% da capacidade nominal [1]. Estudos mais recentes, [3], provam que esse limite deve ser considerado mais elevado, 80%-85%. Nos estudos conduzidos por [3], é possível verificar que a degradação de algumas células atinge o *curve knee* muito perto dos 90%. Podemos concluir destes estudos que diferentes condições de utilização têm diferentes impactos na degradação da bateria. É importante notar que estes testes foram realizados seguindo perfis sintéticos de primeira e segunda vida e haverá sempre um erro associado.

1.3.1.2 Resistência Interna

A par com a capacidade da bateria, a resistência interna é o parâmetro com mais peso na definição de SoH. Geralmente medida em *milliohms* ($m\Omega$), a resistência interna, funciona como o "porteiro" da bateria [9]. É particularmente influente em aplicações que exigem grandes correntes de carga/descarga, como é o caso dos EV. O aumento da resistência interna de uma bateria provoca o aumento das perdas na resistência e, conseqüentemente, o aumento da temperatura durante o seu funcionamento. Como é expectável, a operação em temperaturas fora dos limites ideais, (geralmente definidos pelo fabricante), aumenta a taxa de envelhecimento de uma bateria. Analisando leis básicas de circuitos, é fácil compreender que, quanto maior a resistência interna (RI), menor é a queda de tensão nos terminais da bateria e menor é o desempenho da bateria.

De forma a calcular a RI de uma bateria existem dois métodos possíveis. O primeiro método baseado em corrente contínua, mede a queda de tensão a uma determinada corrente. Este método é utilizado para determinar a resistência pura (R) e fornece resultados verídicos para uma carga DC. O segundo método é baseado em corrente alternada (AC), onde os elementos reativos são considerados. Este método destina-se à determinação da impedância (Z).

Vários estudos realizados por [10] comprovam que, em condições de segunda vida exigentes, a elevada resistência interna é o principal fator que inviabiliza a sua segunda vida. Dentro deste tipo de condições, os resultados foram extremamente negativos, já que as BSV foram capazes de satisfazer os requisitos apenas por algumas semanas, sofrendo até de fenómenos de gasificação.

1.3.1.3 Tensão da Bateria

A tensão nominal é um parâmetro caracterizador de uma bateria, definido pelo fabricante. Quando uma bateria se encontra sobre carga, esta passa de uma condição de Tensão em Circuito Aberto (OCV) para uma condição de tensão em circuito fechado (CCV). À medida que uma bateria é carregada a CCV aumenta. Por outro lado, durante um descarregamento a CCV diminui até atingir a tensão de corte que, geralmente, define 0% de Estado de Carga (SoC) [9]. Uma elevada resistência interna provoca variações excessivas na CCV.

A maior parte dos fabricantes de baterias *Li-ion* definem a tensão nominal em 3.60V por célula. Porém, alguns produtores definem 3,70V/célula, conduzindo a um aumento da energia transferida, teoricamente. Este tipo de bateria com maior tensão de carga podem ser vantajosas em algumas aplicações, mas é importante notar que o seu ciclo de vida diminui substancialmente [11].

Através da análise da figura 1.2 é perceptível que, utilizando diferenças de potencial de carga excessivamente elevadas, o ciclo de vida é muito curto. Isto prova que não é boa prática operar nesta gama de valores de tensão em carga.




Figura 1.2: Alteração do ciclo de vida a diferenças de potencial de carga elevadas [12]

1.3.1.4 Ciclo de vida

A autonomia e o tempo de vida útil das baterias de qualquer EV são características que qualquer potencial comprador considera na escolha do seu produto. As baterias comercializadas atualmente procuram satisfazer os requisitos do mercado e, assim sendo, são concebidas para suportar muitos ciclos de carga e descarga.

Entende-se por ciclo de vida de uma bateria, o número de ciclos de carga e descarga que a mesma é capaz de suportar até que não seja capaz de cumprir certos requisitos de funcionamento. É possível estimar o ciclo de vida de uma bateria, considerando condições específicas. A vida operacional da bateria depende de inúmeras variáveis como a Profundidade do Ciclo de Carga (DoD), a temperatura ou a humidade [9]. Geralmente, o ciclo de vida de uma bateria é especificado pelo produtor, mediante certas condições.

É evidente que existe uma relação entre o número de ciclos completos de carga e descarga e o envelhecimento da bateria. Este facto está diretamente ligado à profundidade do(s) ciclo(s), como podemos observar em 1.3. É importante notar que uma bateria de um EV está sujeita a profundidades de descarga, representadas na parte superior desta figura, enquanto uma aplicação residencial exige profundidades de descarga, representadas na parte de baixo da mesma figura.

Depth of discharge	Discharge cycles (NMC / LiPO4)
100% DoD	~300 / 600
80% DoD	~400 / 900
60% DoD	~600 / 1,500
40% DoD	~1,000 / 3,000
20% DoD	~2,000 / 9,000
10% DoD	~6,000 / 15,000

Figura 1.3: Ciclo de vida em função da DoD [11]

1.4 Motivação e Objetivos

Atualmente, os EV são considerados a solução mais provável aos veículos que utilizam combustíveis fósseis. A exploração desse tipo de recursos não é sustentável, e a previsão é para uma crise nos combustíveis fósseis num futuro próximo. Além de serem um fator muito influente na atual crise ecológica, este tipo de combustível tende a encarecer gradualmente à medida que se vai tornando mais escasso. Por todas estas razões, é fundamental encontrar uma solução. Atualmente, muitas esperanças estão depositadas nos EV, concentrando a atenção de inúmeros investigadores no aumento do seu rendimento. Um dos fatores mais importantes para a conquista do mercado é a redução dos preços dos automóveis elétricos que, atualmente, ainda são relativamente caros. Possuir um EV é, nos dias de hoje, ainda um luxo.

Para que todas as classes sociais e laborais comecem a ter acesso a este tipo de mercado é fundamental a redução dos preços. Nesta dissertação é estudada a evolução do comportamento de uma bateria em utilização num EV, e proposto um modelo que procura prever o comportamento da bateria ao longo de muito tempo de utilização. Este modelo é utilizado para perceber a influência de determinadas condições de utilização na degradação do SoC e analisar até que ponto é rentável a instalação de um sistema de armazenamento de energia, por exemplo, solar ou eólica, utilizando BSV. Caso uma segunda aplicação deste tipo de baterias, seja um projeto lucrativo, poderá revelar-se um ponto importante na indústria dos EV. Isto porque, ao confirmar a viabilidade das BSV, estas ganharam um novo valor no mercado e, consequentemente, o custo de um EV tende a decrescer a curto prazo.

1.5 Organização do Documento

Este projeto inicia-se com uma breve revisão bibliográfica da literatura de trabalhos semelhantes ao proposto nesta dissertação. Este capítulo destina-se ao estudo e compreensão dos projetos realizados anteriormente.

Posteriormente, é efetuado um estudo, relativamente aprofundado, dos diferentes métodos utilizados na estimação do SoH. Este estudo possibilita a escolha dos melhores algoritmos que serão, posteriormente, aplicados. Os resultados são documentados e uma conclusão do projeto é feita. Finalmente, uma proposta de trabalho futura é documentada e fundamentada.

No início de cada capítulo, é realizada uma breve descrição da ordem de trabalhos do mesmo.

Capítulo 2

Revisão Bibliográfica e Parâmetros Associados ao Modelo de Degradação da Bateria

Com a crescente imposição dos EV como a mais provável alternativa aos veículos movidos combustíveis fósseis, surge a direta necessidade de viabilizar esta alternativa. Atualmente, o grande entrave desta tecnologia é o rendimento das suas baterias. Como descrito na secção 1.4, o desenvolvimento das bateria *Li-ion* tem sido exponencial, contudo, não foi possível ainda confirmar a rentabilidade de investir num EV.

Qualquer tipo de bateria, a partir do momento em que inicia a sua vida ativa, está sujeita a dois principais fatores de envelhecimento, *Calendar Ageing* e *Cycling Ageing* [13]. Por um lado, é atribuído o termo, *Calendar Ageing* ao fenómeno de envelhecimento a que uma bateria está sujeita, quando armazena uma certa quantidade de energia entre períodos de carga ou descarga. O envelhecimento por efeito de calendário, depende fortemente da temperatura ambiente, do SoC atual e da quantidade de tempo que a bateria foi sujeita a estas condições. A figura 2.3 ilustra um teste realizado a 35°C, onde é analisada a evolução da capacidade atual com diferentes SoC. É perceptível que, quanto maior o SoC, mais rápida é a sua perda de capacidade. Fenómenos como o auto-descarregamento, ou o aumento da resistência interna podem ocorrer durante esta fase de armazenamento da energia [14].

Por outro lado, *Cycling Ageing* é a evolução da saúde da bateria enquanto está sujeita a operações de ciclos de carga e descarga. A compreensão destes dois conceitos e, acima de tudo a interação entre eles (figura 2.1), é fundamental para a construção de um modelo robusto [15].

Já foram feitas diversas tentativas de modelação de baterias de segunda vida, para diferentes propósitos. Hart, em [17], propõe um modelo de uma BSV para a utilização numa micro-rede CERTS. Ambrose, em [18], aborda a possibilidade da utilização de BSV num contexto rural ou de um país em desenvolvimento, onde seriam utilizadas como centrais de armazenamento de energia. Neste artigo, Ambrose sugere que os EV, que serão vendidos até 2020, irão produzir 120–549GWh




Figura 2.1: Degradação da bateria durante ciclos e durante armazenamento [16]

em energia que potencialmente poderia estar armazenada. Vários outros autores, [1] e [19], consideram ligar uma BSV à rede elétrica, onde servirá de armazém de energia. Neste conceito, é tomado em conta a variação do custo da energia nos diferentes momentos do dia, ou seja, a BSV será carregada nos momentos em que a energia tem um baixo custo.

Durante a utilização das baterias de Li-ion nos EV, estas estão sujeitas a condições de utilização relativamente agressivas, que conduzem a uma gradual diminuição de *performance*. Diversos são os fatores que estimulam o envelhecimento da bateria. Constantes ciclos de carga, grandes DoD e a temperatura da bateria durante a sua utilização são exemplos de fatores que afetam a degradação da bateria e deverão ser consideradas e incluídas no seu modelo. Ao fim de muitos ciclos de carga e descarga, a bateria degrada-se até um ponto que não é útil na indústria automóvel. A existência de uma solução viável para estas baterias, tal como o armazenamento de energia gerada por fontes renováveis, traz inúmeras vantagens tanto do ponto de vista económico como ecológico [1].

Grande parte dos estudos sobre problemas de modelação do envelhecimento de uma bateria, realizados anteriormente, utilizam perfis sintéticos de modo a estudar o comportamento dos principais indicadores de saúde.

Tal como em [3], a primeira vida da bateria é simulada através de perfis realísticos de EV, com ciclos de carga baseados em *Worldwide Harmonized Light Duty Test cycle* (WLTC). O WLTC foi criado e desenvolvido com o objetivo de se tornar um teste global, para que seja possível a comparação de certos parâmetros, tal como o consumo de combustível, em diferentes regiões do planeta. Este teste está dividido em quatro fases, em que diferentes velocidades médias são aplicadas. Em cada fase, várias paragens e acelerações são efetuadas de modo a criar um padrão realista de condução [20].

É de esperar que o nível de exigência da primeira vida de uma bateria seja determinante na *performance* da mesma numa segunda aplicação. De modo a construir um modelo robusto e viável do envelhecimento de uma BSV, é fundamental uma correta monitorização dos parâmetros que são

indicadores da condição atual da bateria, secção 2.1, e a correta identificação dos parâmetros que afetam o envelhecimento de uma bateria, secção 2.2.

Compreender e definir quais são esses parâmetros é o primeiro passo na construção de um modelo completo.

2.1 Parâmetros relativos à condição da bateria

2.1.1 Estado de saúde da bateria

O SoH é um indicador de saúde expresso em percentagem, que traduz o estado atual dos parâmetros mais relevantes de uma bateria, como a capacidade de reter energia, ou as *source and sink currents*, comparado às suas características nominais (bateria nova) [21].

Na generalidade dos casos, o SoH de uma bateria é o indicador mais relevante da sua condição.

Como não é possível medir diretamente o SoH, ainda é um tema muito debatido, atualmente na literatura [22]. A controvérsia nesta definição deve-se às inúmeras variáveis que devem, ou não, ser consideradas como indicadores de *performance*. Ademais, cada indicador tem um "peso" distinto. Ou seja, fatores como a capacidade atual e a resistência interna, são os mais importantes na definição de SoH. Fatores como o OCV em *full charge*, também são parâmetros diretamente relacionados.

Este indicador relativo à condição da bateria, normalmente, é usado como *input* de qualquer modelo de envelhecimento de uma bateria [23]. Dentro de um contexto onde se pretende modelar o envelhecimento de uma BSV, é extremamente importante a correta estimativa do SoH tanto no fim da sua primeira vida, como no decorrer da sua segunda aplicação.

2.1.2 Tensão em circuito aberto

A OCV de uma célula de uma bateria é definida como a diferença de potencial entre o eletrodo positivo e o eletrodo negativo. Idealmente, a OCV deve ser medida em cada eletrodo, de uma forma independente [24].

Baterias de alta potência são, geralmente, caracterizadas por operarem com valores de OCV relativamente altos, que consequentemente, reduzem o ciclo de vida de uma bateria e a tornam mais instável [21].

A OCV representa a diferenças de potencial da bateria sem corrente de carga e é, muitas vezes utilizado como um dado adicional de forma a compreender o seu estado atual de saúde. De forma a medir corretamente a OCV de uma bateria *Li-ion* é necessário esperar o seu estado estável.

A correta medição da OCV é especialmente relevante porque pode ser utilizada para determinar o SoC da bateria. Isto deve-se ao facto da OCV estar correlacionada com a concentração do eletrólito, que varia com o seu estado atual de carga [25]. A figura 2.2 ilustra explicitamente esta relação.




Figura 2.2: Relação entre OCV e SoC durante uma descarga completa [25]

2.1.3 Estado de carga atual

O estado de carga atual de uma bateria pode ser definido como a capacidade atual, ou seja, a quantidade de carga disponível neste momento na bateria expressa como percentagem da capacidade máxima que a bateria pode armazenar [9]. O SoC é considerado 0% quando a bateria está completamente descarregada e 100% quando totalmente carregada. Obter uma boa estimativa do SoC e perceber a sua evolução temporal é um fator muito importante também na concretização do modelo de envelhecimento.

Existem várias metodologias de forma a determinar o SoC, sendo o mais utilizado, e mais simples, o método de *Coulomb Counting* [23]. Diversos estudos realizados já foram capazes de comprovar que com a manutenção do SoC dentro de valores ideais, a taxa de envelhecimento da bateria reduz drasticamente (Fig. 2.3, e Fig. 2.5). Relativamente à figura 2.3 é possível compreender a elevada perda de capacidade num curto espaço de tempo, quando o SoC inicial da bateria é 100%.

A precisão da identificação do SoC, é um aspeto muito importante em sistemas de gestão de baterias. Uma má estimativa poderá levar a danos significativos e a uma redução do seu tempo de vida [25].




Figura 2.3: Evolução da capacidade nominal em função do SoC atual e do tempo [16]

2.2 Parâmetros que afetam a degradação de uma bateria

É possível perceber, através de propostas de modelação de diversos autores, que a escolha dos parâmetros para descrever o modelo, não é uma ideia consensual. Atualmente, esta área está em claro desenvolvimento, em busca de preencher as incertezas que ainda se verificam.

Quanto mais completa for a caracterização destes parâmetros, mais robusta será a modelação. A realização de testes práticos servirá para perceber o peso de cada variável, ou seja, o grau de importância que determinada variável tem sobre o desgaste de uma bateria.

2.2.1 Temperatura

Tanto o desempenho, como o envelhecimento de uma bateria são largamente afetados pela temperatura a que esta opera. Manter a temperatura de operação dentro de parâmetros ótimos, maximiza a capacidade nominal real da bateria e minimiza o impacto no envelhecimento da mesma.

A temperatura ambiente e a condição da resistência interna da bateria são os fatores que mais contribuem para a variação de temperatura de operação. Por um lado, a temperatura ambiente afeta claramente a *performance* da bateria. Testes realizados por [24], demonstram que baixando

a temperatura ambiente de 45°C para 5°C, a capacidade de uma bateria diminui 17,1% a 0,5 Coulomb na descarga. Por outro lado, o aumento da resistência interna, provoca o aumento da quantidade de energia dissipada na forma de calor na carga. Estudos realizados por [10] relatam um fracasso total na tentativa de introduzir uma BSV numa aplicação com requisitos exigentes. Os autores concluem que, devido à resistência interna da BSV estar demasiado elevada (degradada), os requisitos da aplicação provocaram o sobreaquecimento da célula, a sua dilatação e efeitos de gasificação.




Figura 2.4: (a) Evolução da capacidade nominal a diferentes temperaturas, 50% SoC; (b) e da resistência nominal nas mesmas circunstâncias; [2]

As baterias de *Li-ion* são capazes de operar entre -20°C e 65°C durante o carregamento, e entre -40°C e 65°C durante a descarga [26]. Quanto mais perto dos limites da temperatura de operação (OPT), menor é a eficiência da bateria. Estudos realizados por [24] a par dos resultados obtidos neste projeto, suportam a ideia que a *performance* da bateria é maximizada, operando entre os 25°C e 35°C, contrariando trabalhos mais antigos, onde a OPT ideal estava definida entre os 15°C e 35°C. Na figura 2.4, é flagrante o aumento da taxa de degradação à medida que a temperatura aumenta.

2.2.2 Profundidade de Carga/Descarga (DoD)

A profundidade de descarga é a percentagem da capacidade que foi descarregada, expressa em percentagem da sua capacidade nominal [9]. O DoD é, então, a variação do SoC de uma bateria durante uma descarga. Quanto menor for a profundidade dos ciclos de carga aplicados a uma bateria, menor é também o seu efeito de degradação [11]. Apesar de nem sempre ser coerente num contexto de utilização real, realizar ciclos com DoD relativamente pequeno e manter os valores de SoC longe dos extremos de carga (100% SoC, 0% SoC), é boa prática da gestão da condição de saúde de uma bateria. Pela análise da figura 2.5, é possível compreender a discrepância em termos de perda de capacidade em função no número de ciclos de carga.

Outro aspeto a ter em consideração na análise da figura 2.5 é que as duas curvas representadas a azul, indicam dois testes diferentes onde o mesmo DoD é aplicado. É notório o relativo menor

desgaste na bateria onde os níveis de SoC, (25%- 75%), foram mantidos distantes dos extremos, (curva azul claro).




Figura 2.5: Evolução da capacidade nominal em diferentes intervalos de SoC [11]

2.3 Modelo de Degradação de uma Bateria de Segunda Vida

O conceito de baterias de segunda vida surge pouco depois da introdução dos EV, mas a tentativa de modelação é um assunto muito mais recente. Durante a investigação deste tema começou a ficar perceptível a lacuna na literatura de modelos robustos. Como visto, com alguns exemplos, no início do Capítulo 2, muitos foram os autores que abordaram o tema das BSV, mas muito poucos os que o obtiveram resultados esclarecedores. Isto deve-se, não só, ao facto de inúmeras variáveis afetarem a degradação de uma bateria, mas também à ambiguidade na construção de perfis de utilização.

Neste projeto, foi adotado, com o objetivo de estudo, o modelo descrito em [3], complementando-o com as importantes noções de *Calendar Ageing* e *Cycling Ageing*, particularmente bem descritas em [13]. Este modelo foi selecionado porque é considerado muito completo e contempla variações em todos os parâmetros que afetam a degradação de uma bateria.

2.3.1 Aplicações Consideradas para a Segunda Vida

Duas aplicações foram consideradas de modo a testar a segunda vida das baterias. Por um lado, é considerado um agregado familiar, composto por painéis fotovoltaicos, montados no telhado, e um sistema de armazenamento de energia, baseado em BSV. Esta aplicação é caracterizada por ser pouco exigente para a bateria em termos de taxa de corrente e DoD. A figura 2.6(a) representa o diagrama de blocos desta aplicação.

Por outro lado, é considerado um sistema de armazenamento de energia que pretende, como objetivo, atenuar a variação de potência de uma planta fotovoltaica de grande escala. Dada a natureza intermitente das fontes de energia renovável, são fornecidas à rede grandes variações de potência. Por este motivo, a introdução de um sistema baseado em BSV, de forma a atenuar estas grandes variações de potência, é considerado uma aplicação exigente para as baterias, tanto nas taxas de corrente pedidas, como no DoD e no número de ciclos por ano. O diagrama de blocos da aplicação de *power smoothing* é apresentado na figura 2.6(b). A diferença de exigência das aplicações pode ser comprovada analisando a figura 2.7.




Figura 2.6: (a) Diagrama de blocos de uma aplicação de uma BSV num agregado familiar; (b) e de uma aplicação de *power smoothing*; [3]




Figura 2.7: Perfil de corrente sintetizado de um mês, da aplicação de *power smoothing* (azul) e da aplicação residencial (laranja) [3]

2.3.2 Metodologia dos Testes Efetuados

As baterias consideradas nesta análise são todas de 20 Ah NMC/C, tipologia *Li-ion*. É expectável que o SoH, das células no fim da sua primeira vida, seja um fator determinante na *performance* e degradação durante a segunda vida. Por isso, as células, testadas numa segunda vida, foram envelhecidas segundo dois perfis de aplicação diferentes, a) Um perfil padrão de envelhecimento (WLTC) e b) com condições estáticas de envelhecimento.

Para testar as células numa segunda aplicação são construídas duas *stacks* homogéneas e duas heterogéneas, todas elas utilizadas na aplicação de *power smoothing*. As *stacks* homogéneas são compostas por três células ligadas em série que foram sujeitas a condições de primeira vida muito semelhantes. As *stacks* heterogéneas são constituídas por a) três células com condições de primeira vida e SoH atual completamente distintas, e b) duas células com condições de primeira vida semelhantes e uma terceira célula submetida a condições diferentes das primeiras duas. Os diferentes graus de heterogeneidade são impostos com a finalidade de avaliar a sua influencia durante uma segunda vida.

Para testar a aplicação residencial são utilizadas duas células com condições muito diferentes de primeira vida. É possível encontrar todos os detalhes dos testes realizados no Anexo A.

2.3.3 Resultados dos Testes, Conclusões e Proposta de Trabalho Futuro

Os testes realizados permitiram retirar algumas conclusões mas, tal como esperado, ainda existem diversas questões por resolver.

À primeira vista, é claramente perceptível que as células com uma primeira vida mais exigente e com níveis de SoH menores que 85%, (aproximadamente), foram completamente incapazes de satisfazer os requisitos da aplicação de *power smoothing*. O facto desta incapacidade revelada, encontra-se no aumento exponencial da resistência interna. Os resultados, comprovam também, que o *threshold*, considerado standard de 70%-80% da capacidade, [1], para o fim da primeira vida, é inadequado. Quanto às células testadas num contexto residencial, a célula representada por C14, demonstrara ser capaz de satisfazer os requisitos, mas é importante notar que começou a sua segunda vida com níveis bastantes elevados de saúde. A célula representada por C15 inicia a segunda aplicação com indicadores de saúde bem inferiores ao *threshold* padrão de 80%-85%. Apesar de se ter verificado um ligeiro abrandamento na taxa de degradação, podemos afirmar que os resultados são prometedores, mas inconclusivos, já que o SoH, no início da segunda vida, era muito baixo.

Num contexto geral, os resultados são prometedores, mas ainda há muito trabalho de investigação a fazer. Por exemplo, nenhuma *stack* foi construída com o intuito de ser testada dentro do contexto residencial. Uma boa abordagem futura a este tema, poderia incidir sobre o facto de nunca terem sido testadas várias células ligadas num contexto pouco exigente de segunda vida. Para complementar estes possíveis testes, seria interessante estudar, pormenorizadamente, os efeitos do *calendar ageing* e, se possível, reproduzi-los na prática.

2.4 Metodologia de trabalho futuro

Tal como descritos nas secções anteriores, de modo a construir um modelo robusto é fundamental a compreensão dos fatores que influenciam a degradação de uma bateria. Dado o extenso número de fatores que participam no envelhecimento da bateria, é necessário definir quais serão considerados na construção do modelo. Na generalidade dos testes realizados na literatura são consideradas 3 variáveis: temperatura, profundidade de ciclos e corrente de carga e descarga.

Outros fatores são considerados desprezáveis devido ao reduzido grau de influência e à sua imprevisibilidade. Numa fase inicial deste projeto será definida a forma como serão recolhidos e processados os dados. Os dados serão recolhidos com um dos seguintes modos:

- 1) A primeira possibilidade será o contacto com uma companhia que opera na mobilidade elétrica, onde será feito um pedido de envio de dados de utilização. Caso exista uma companhia que monitorize as condições de operação e a evolução dos parâmetros indicadores do estado de saúde das suas baterias, uma hipótese seria o procedimento de solicitação de um pedido de acesso a estes dados. A provável elevada quantidade de dados de contexto real seria um aspeto muito positivo na construção do modelo de envelhecimento.
- 2) A segunda possibilidade estará na realização de testes práticos com a utilização de perfis sintéticos de degradação em ambientes práticos controlados. As baterias seriam adquiridas de uma companhia a definir, depois de uma primeira vida na mobilidade elétrica. Essas baterias seriam agrupadas em módulos e expostas às mais diversas condições de utilização. A ideia será expor esses módulos a constantes cargas e descargas em diferentes temperaturas, correntes e com diferentes DoD. Desses procedimentos experimentais, são recolhidos os dados que serão utilizados na construção do modelo.
- 3) A terceira possibilidade é também a menos provável de ser utilizada. A ideia seria recolher os dados experimentais obtidos pelos autores do modelo descrito na secção anterior [3]. Com esses dados seria aplicado um método baseado em inteligência artificial para reproduzir o modelo. Esta possibilidade tem as desvantagens no limite de dados existentes.

Os resultados serão organizados e estudados, seguindo-se a aplicação de um algoritmo computacional. Este algoritmo é baseado nas amostras que forem consideradas. Conforme a quantidade de dados que forem recolhidos, será escolhido o algoritmo computacional que melhor satisfaça o objetivo do projeto. Existem três formas distintas de abordar este problema:

A) Redes Neurais Artificiais. Este algoritmo é baseado em aprendizagem e é muito eficaz se os dados de treino forem bons em termos quantitativos e qualitativos. Ao correr os algoritmos de aprendizagem, a rede neuronal irá atribuir diferentes pesos aos inputs (condições de utilização da bateria). Dessa forma, a degradação da bateria será modelizada como a soma de três variáveis de degradação, (temperatura, corrente de carga e DoD), sendo que cada uma com um diferente grau de importância.

B) Toolbox de Fitting do Matlab. Esta aplicação providencia funções que criam curvas de fitting mediante os dados existentes. É possível proceder a análises de regressão usando a biblioteca de modelos lineares e não lineares. Esta biblioteca também oferece parâmetros otimizados e condições iniciais de forma a melhorar a qualidade do fit [27].

C) Algoritmos Genéticos (GA). Os GA são uma família de modelos computacionais inspirados pela evolução. [27] Estes algoritmos codificam uma potencial solução para um problema específico aplicando operadores de recombinação a estruturas de dados e procuram a solução ótima ao longo de várias iterações. Durante as seguintes semanas, várias horas de trabalho foram dedicadas no estudo mais aprofundado deste tipo de algoritmos com o objetivo de perceber a sua utilidade na modelização deste tipo de problema.

No Anexo [B.1](#) está disponível o diagrama de gantt.

Capítulo 3

Principais Técnicas de Estimação do Estado de Carga e Saúde de uma Bateria

A introdução deste capítulo tem como principal objetivo apresentar os principais métodos de estimação do SoC e SoH. A correta identificação destes parâmetros ao longo do tempo constitui um bom indicador de sucesso da modelação. Neste projeto, os métodos baseados em *machine learning* foram considerados mais efetivos para abordar o problema.

3.1 Rede Neuronal Artificial (ANN)

Uma rede neuronal artificial, tal como o nome indicia, é um sistema computacional, superficialmente baseado nas redes neuronais que constituem os cérebros dos animais. Uma ANN é uma estrutura que foi desenvolvida com o intuito de processar dados extremamente complexos, não lineares e com pouco conhecimento sobre o modelo matemático da aplicação em questão. Este método tem a capacidade de “aprender” a realizar diferentes tarefas após o seu treino com um certo dataset. Quando treinada corretamente, uma ANN revelar-se-á uma ferramenta extremamente poderosa na resolução de problemas complexos.

Sistemas complexos com dinâmicas internas complicadas, podem ser facilmente modelados por uma rede neuronal, não sendo necessário ter conhecimento do mecanismo interno da bateria, nem do seu modelo, [28]. Uma rede neuronal, quando propriamente trabalhada, é capaz de lidar com dinâmicas não lineares, como as que encontradas na variação do SoH de uma bateria.

Para um bom treino de uma ANN, é necessário a obtenção de um conjunto bastante robusto de inputs e outputs que, no caso deste projeto, foram adquiridos através de medições em efetuadas em contexto real. O tipo de dados utilizado na aprendizagem é um fator muito importante, dado que, estes devem ser capazes de descrever corretamente o comportamento de uma bateria. Estes dados serão utilizados como entradas e saídas da rede neuronal, de forma a treinar a ANN com

sucesso. Após o cessar da fase de aprendizagem, consoante o erro mínimo pretendido, segue-se a a fase da validação da rede em situações de estimação real, [29], [30].

No projeto realizado por Briat, O. [4], uma ANN probabilística é utilizada para estimar o SoH de uma bateria Li-ion. A arquitetura da rede proposta neste projeto está visível na figura 3.1, onde constantes ciclos de carga/descarga foram executados de forma a testar o ciclo de vida da bateria em estudo. Os dados obtidos através das medições dos constantes ciclos foram posteriormente utilizados para treinar a ANN com o intuito de estimar o SoH da bateria.




Figura 3.1: Arquitetura de uma ANN considerada no projeto.

A escolha dos parâmetros que vão ser utilizados como entradas do sistema, é também uma escolha importante, visto que quantos mais parâmetros a rede tiver em consideração, mais precisa vai ser. No entanto, é necessário haver um compromisso entre a quantidade de entradas e a complexidade da rede, [31]. Os resultados obtidos em [4] foram bastante satisfatórios e podem ser observados na figura 3.2, mas é importante ter em conta que se tratam de perfis de degradação acelerados e sintéticos. As condições de utilização, tais como a temperatura, a variação de SoC ou a magnitude da corrente, são consideradas influentes na degradação da bateria.

Apesar da homogeneidade na escolha das variáveis relevantes ao modelo e dos bons resultados obtidos, a utilização de ANN requer formatos de dados bastante específicos de modo a providenciar bons resultados.




Figura 3.2: Resultados da aplicação de uma ANN no projeto [4]

3.2 Regression Learner

Entende-se por regressão (linear ou não linear) a medida estatística que procura determinar a relação entre uma variável dependente (*output*) e uma ou várias variáveis independentes (*predictors*). Existem dois tipos básicos de regressão, linear e multilinear, utilizados em problemas mais simples, e ainda vários métodos de regressão não linear, que são necessários em problemas onde a base de dados utilizado na construção do modelo é muito complexo.

O presente projeto procura perceber o efeito de diferentes variáveis na degradação de uma bateria e, como é de esperar, os dados serão modelados por uma função descrita por uma combinação não linear dos parâmetros do modelo. Numa regressão não linear, um modelo estatístico na forma,

$$y(t) \approx f(x(t), \beta) \quad (3.1)$$

Relacionando um vetor de variáveis independentes e as suas observações associadas. A função f não é linear nos componentes do vetor de parâmetros β .

A regressão dos dados recolhidos será realizada com o auxílio da ferramenta *Matlab*. Em versões relativamente recentes desta ferramenta, está disponível uma aplicação baseada em *machine learning*, denominada *Regression Learner App*. Esta aplicação tem como finalidade treinar interativamente, validar e construir modelos de regressão. O *Regression Learner do Matlab* tem a grande vantagem de permitir a comparação entre os distintos algoritmos de treino. Ou seja, após definir os previsores e respetivas respostas, é possível treinar vários modelos com os diferentes

algoritmos incorporados na aplicação. Simultaneamente, é possível definir quais as variáveis mais importantes na construção do modelo e ativar o PCA. Quando o treino dos modelos é finalizado, é possível comparar as suas características mais relevantes e, posteriormente, escolher o melhor modelo. Um modelo que apresente erros relativamente menores não é, obrigatoriamente, o melhor modelo. Por vezes, um modelo com erros um pouco superiores pode ser um melhor modelo para o problema em questão.

Após a comparação e avaliação dos modelos elaborados, esta aplicação permite exportar ou gerar código do modelo escolhido.

3.3 Lógica Difusa (*Fuzzy Logic*)

O método de aprendizagem computacional, baseado em lógica difusa, na prática, pode ser definido como a atribuição de qualquer número real, entre 0 e 1, a uma variável com o valor lógico verdadeiro. Ou seja, em comparação com a tradicional lógica Booleana, (0 -False, 1 -True), este tipo de controlo introduz o conceito de parcialmente verdadeiro, onde verdadeiro pode tomar qualquer valor real entre falso (0) e completamente verdadeiro (1), [32].

De uma forma geral, as variáveis incluídas neste método são categorizadas por grupos, cada qual representado de forma linguística. No contexto deste projeto, a variável “Estado de saúde” poderia ser categorizada como “Não saudável”, “Pouco Saudável”, “Saudável”, por exemplo. A ambiguidade e redundância, características na implementação da lógica difusa, tornam este método bastante eficaz a lidar com situações de incerteza e onde não há um profundo conhecimento do modelo matemático. A representação linguística das variáveis tornam o processo mais intuitivo e simples para o utilizador. Na figura 3.3, está representado um diagrama de blocos de um sistema de inferência *fuzzy*.




Figura 3.3: Um sistema de inferência *fuzzy* completo.

Após a definição das entradas e saídas e das suas respectivas descrições linguísticas, deverão ser criadas regras que procuram modelar as variações dos parâmetros do sistema. As regras, quando bem definidas, são capazes de aproximar com precisão várias dinâmicas não lineares de um sistema, [33].

Em [34] está descrito um método prático de predição do SoC e SoH de um sistema de baterias. O método consiste na aplicação de lógica difusa com o objetivo de analisar a evolução de *performance* de um sistema de baterias, em função do seu envelhecimento, para diferentes temperaturas e SoC. Os dados são obtidos através de medições de espectroscopia de impedância em células com diferentes SoH. Finalmente, os resultados obtidos são processados de forma a serem utilizados num sistema baseado em lógica difusa, com o objetivo de estimar os estados de saúde e carga das diferentes células. Os resultados apresentados mostram um modelo de degradação com resultados satisfatórios e comprovam a clara influencia da temperatura na degradação da bateria.

Posteriormente, o modelo construído pela lógica fuzzy tem a capacidade de ser utilizado como uma ferramenta preditiva. Após a leitura dos dados de entrada e saída, é criado um modelo baseado em relações entre variáveis, que poderá ser utilizado para calcular valores futuros, neste caso de SoH, mediante novas condições de utilização.

Tal como acontece nas ANN, a lógica fuzzy é um método bastante eficaz a lidar com incerteza e modelos desconhecidos mas para uma correta aplicação deste método é necessário um conjunto de dados bastante completo que diferencie e caracterize as diferentes variáveis e a relação entre elas. No entanto, este método apresenta uma dificuldade de implementação e esforço computacional muito elevados e, por este motivo, é necessário criar um compromisso entre estes fatores e a precisão pretendida na modelação, [35].

3.4 Filtro de Kalman (KF) e Filtro de Kalman Estendido (EKF)

O Filtro de Kalman pode ser definido como um estimador inteligente, possivelmente ótimo, que é capaz de estimar o valor atual de um estado variante no tempo de um sistema dinâmico, [23]. Diversos métodos baseados em KF têm vindo a ser utilizados com frequência para estimar a evolução de diferentes parâmetros de relevo de uma bateria, como o seu SoC e SoH, apresentando resultados satisfatórios.

Muito genericamente, qualquer sistema dinâmico causal, tal como uma bateria, gera as suas saídas em função das entradas atuais e anteriores. É também conveniente assumir a existência de um vetor de “estado” no sistema, onde esse estado sumariza o efeito de todas as entradas anteriores do sistema. Nos estudos realizados em [23], um método baseado no KF foi aplicado, assumindo cada célula da bateria estudada como um sistema dinâmico cujas entradas são diversos fatores experienciados pelas células, e a saída a voltagem nos terminais da bateria. Neste exemplo, o vetor de “estado” pode, por exemplo, incluir o SoC, o SoH e dinâmica de relaxamento.

Através do modelo dinâmico, do sistema de baterias em espaço de estados é possível implementar o filtro de Kalman para estimar os parâmetros desconhecidos da descrição do modelo. O KF começa por estimar o estado seguinte do sistema dinâmico e os limites do erro associados a essa estimação. Os valores estimados são, posteriormente, comparados com as medições efetuados e os parâmetros dos filtros atualizados. Este filtro tem diversas vantagens associadas tais como a capacidade de lidar com ruído.

Atuando sobre sistemas lineares o KF é considerado ótimo. Por diversos motivos, tais como a quantidade de variáveis envolvidas e a complexidade das reações que ocorrem na operação de uma bateria, será difícil aproximar o sistema de uma bateria a um sistema linear, pelo que a utilização do KF não será o mais indicado. Na generalidade da literatura, é utilizado uma adaptação do KF a sistemas não lineares, o filtro de kalman estendido (EKF). Este filtro segue os mesmos princípios do KF mas tem a capacidade de estimar os parâmetros desconhecidos de um modelo não linear, como é o caso do modelo de degradação de uma bateria. O EKF tem a vantagem de conseguir lidar com este tipo de sistemas em que os dados são processados em tempo real, como é o caso de alguns estudos já realizados [36].

De notar que o EKF não é ótimo mas, geralmente, é muito eficaz. Em [37], o sistema não linear é modelado da seguinte forma:

$$x_{k+1} = f(x_k, u_k) + w_k \quad (3.2)$$

$$y_k = g(x_k, u_k) + v_k \quad (3.3)$$

Onde w_k e v_k são processos estocásticos gaussianos com média nula e com as matrizes covariância E_w e E_v , respetivamente. $f(x_k, u_k)$ é uma função não linear de transição de estado e $g(x_k, u_k)$ é uma função não linear de medição [37].

A cada intervalo de tempo, $f(x_k, u_k)$ e $g(x_k, u_k)$ são linearizadas por uma expansão em série de Taylor de primeira ordem, com o objetivo de descrever o estado real do sistema como uma função com entradas conhecidas, compostas u_k e $\hat{x}_k$, e também, entradas compostas por ruído w_k e v_k .

$$x_{k+1} \approx \bar{A}_k x_k + f(\bar{x}_k, u_k) - \bar{A}_k \bar{x}_k + w_k \quad (3.4)$$

$$y_k \approx \bar{C}_k x_k + g(\bar{x}_k, u_k) - \bar{C}_k \bar{x}_k + v_k \quad (3.5)$$

Em [5], são divulgados os resultados deste projeto e uma perspetiva curiosa é apresentada: a evolução da capacidade de uma bateria em função da distância percorrida por um EV durante a sua utilização, figura 3.4.

O erro de estimação do melhor modelo preditivo utilizado neste projeto foi bastante reduzido, geralmente sempre inferior da 2.5%, que é um bom indicador quanto à precisão da estimação. Um argumento contra a utilização do EKF para estimar o SoH é a complexidade da sua implementação. A utilização de um método mais simples seria ideal, porém, o erro de estimação acumula enquanto a integração de ampere-hora, e a divergência é garantida, [5].




Figura 3.4: Estimação da capacidade da bateria em função da distancia percorrida por um EV [5].

3.5 Espectroscopia Eletroquímica de Impedância (EIS)

A espectroscopia eletroquímica da impedância, em inglês Electrochemical Impedance Spectroscopy, (EIS), é uma técnica que consiste na aplicação de um potencial elétrico variável sob uma célula eletroquímica, com o principal objetivo da medição da impedância de uma bateria. Através dos resultados obtidos, posteriormente, é possível estimar o SoC e o SoH.

Este método necessita da realização de um número relativamente elevado de ensaios de forma a compreender os comportamentos dos parâmetros medidos da bateria, em diferentes fases da sua vida. De forma a aplicar este método corretamente, é fundamental a utilização de ferramentas capazes de ler a impedância interna de uma bateria, a diferentes frequências, enquanto está sujeita a ciclos de carga e descarga. Os resultados deste tipo de medições são geralmente apresentados na forma de diagramas de *Nyquist*.

Tal como se pode verificar em diversos outros métodos de estimação do SoH, o EIS necessita do conhecimento do modelo matemático do sistema de baterias. Neste caso, é imperativo perceber a relação entre o aumento da impedância e o SoH. A impedância de uma bateria diminui com o aumento do SOC, [38].

Este processo pode ser implementado de forma online ou offline, no entanto a aplicação desta técnica é um processo bastante complicado, já que esta opção tem um custo e tempo de implementação muito elevados. Outra desvantagem deste método é a necessidade do conhecimento claro do modelo elétrico da bateria para que seja possível medir a impedância interna. É também importante notar que o modelo matemático utilizado numa bateria, será diferente em diferentes modelos de baterias.

3.6 Método Baseado na Voltagem Medida

O método experimental baseado na tensão da bateria, para medição do SoC, e futura estimação do SoH, é uma técnica relativamente muito utilizada, apesar da sua imprecisão. A facilidade de implementação e os baixos custos associados são os principais fatores que promovem a utilização deste método.

Medir o SoC, utilizando o método de voltagem, é um processo simples, mas pode ser impreciso, devido a fatores como a cinética eletroquímica da bateria ou a temperatura [23], que alteram significativamente as relações existentes entre estes parâmetros, (definidas, geralmente, pelo fabricante). O erro mais flagrante na aplicação deste método ocorre quando as medições são efetuadas com um reduzido intervalo de tempo após uma carga ou descarga. A agitação resultante destas ações altera os valores da voltagem e as medições serão falaciosas. A grande parte dos produtores e da literatura recomendam o repouso da bateria, em circuito aberto, durante, pelo menos, quatro horas. Isto significa que a aplicação desta técnica torna-se impossível em baterias que estão em *active-duty*, ou seja, é um método *offline*.

Cada tipo de bateria tem o seu próprio, e único, padrão de descarga, [39]. De um modo geral, os produtores de baterias fornecem, na *datasheet*, a relação existente entre a tensão e o SoC ou a temperatura mas, de igual forma, a probabilidade das medições serem comprometidas é bastante elevada. É possível tornar este método mais preciso, compensando a medição da voltagem com um termo de correção proporcional á corrente da bateria e usando uma tabela, (fornecida pelo fabricante ou obtida experimentalmente), que relacione a OCV com a temperatura, [23]

A necessidade da estabilidade na voltagem da bateria torna este método pouco conveniente e prático de implementar. Ademais, a aplicação do método de voltagem significa a interrupção do funcionamento de um sistema, ao contrário de outros métodos [23].

3.7 Teste de Impedância e Condutância

Através do estudo da generalidade da literatura ou, então, da análise do circuito equivalente da bateria, é um facto que a impedância da bateria aumenta com a sua utilização ao longo do tempo. Cada produtor de baterias tem as suas convenções e definições para impedância e condutância, baseado nas metodologias de testes utilizadas [40].

Um exemplo de um teste à impedância/ condutância, normalmente efetuado, envolve a aplicação de uma pequena voltagem AC, denominada “E”, com amplitude e frequência conhecidas sobre uma célula e, simultaneamente, a medição da corrente AC em fase “I”, que passa na mesma célula.

- A impedância “Z” é calculada diretamente através da lei de Ohm, $Z=E/I$;
- A condutância “C” é calculada de forma similar, e é o inverso da impedância, $C=I/E$.

Atualmente, estão disponíveis no mercado alguns dispositivos com a capacidade de estimar com alguma precisão a resistência interna de uma bateria.

3.8 Coulomb Counting e Enhanced Coulomb Counting

O método de *Coulomb Counting* é bastante apropriado no que toca à estimação do SoC de uma bateria de *Li-ion* com altas eficiências de carga e descarga. Através da análise das características de carga e descarga, é possível compreender a conveniência desta técnica na estimação do SoC em baterias de *Li-ion* [6]. Além do SoC, é possível avaliar e estimar o SoH através da capacidade máxima atual da mesma bateria. Em [41], é desenvolvido um projeto que procura demonstrar a precisão e eficácia desta técnica, aliado a um EFK, na estimação do SoC.

Esta técnica, também conhecida pela técnica de contagem de Ampere-hora, ou de integração de corrente, é um dos métodos mais utilizados para a estimação online do SoC de equipamentos como computadores portáteis ou dispositivos médicos e baseia-se na utilização de leituras da corrente aplicada na bateria, sendo esta corrente integrada ao longo do seu tempo de utilização. Este método de estimação do SoC pode ser descrito pela equação:

$$SOC = SOC_{to} + \frac{1}{Crated} \int_{t_0}^{t_0+\tau} (I_b + I_{loss}) dt \quad (3.6)$$

, onde o SOC(t0) representa o SOC inicial, Crated, a capacidade nominal, Ib, a corrente aplicada na bateria, e Iloss, a corrente consumida pelas reações de perdas.

Posteriormente, a capacidade restante é calculada, simplesmente acumulando as cargas transferidas na bateria. A precisão deste método é bastante dependente do erro de medição da corrente da bateria e da qualidade de estimação do SoC inicial.

Através da capacidade posteriormente conhecida, (que pode ser memorizada ou estimada com base nas condições de operação iniciais), pode ser calculado o SoC da bateria, integrando as correntes de carga e descarga sobre os períodos de operação. Contudo, a carga libertada é sempre inferior à carga armazenada, ou seja, existem perdas durante as cargas e as descargas. Estas perdas, adicionadas aos fenómenos de auto descarga, causam erros acumulativos nas estimações. Para uma estimação mais exata do SoC, e consequentemente do SoH de uma bateria, é importante ter em consideração estes fatores. Adicionalmente, o SoC inicial da bateria deve ser calibrado regularmente, dado aos fenómenos de envelhecimento a que a bateria é sujeita.

Com o objetivo de ultrapassar este tipo de falhas e maximizar a precisão de estimação deste método, inúmeros investigadores começaram a propor algoritmos melhorados. Estas versões aprimoradas do método de *Coulomb Counting* propõem a adição de um outro método, por exemplo, baseado em inteligência computacional, com o objetivo de melhorar as estimações dos parâmetros do SoC e SoH para baterias de Li-ion. Por exemplo, em [6], o estado de saúde inicial da bateria é obtido através das voltagens de carga e descarga ou da OCV. Posteriormente, as perdas são compensadas com base nas eficiências de carga e descarga através de uma recalibração dinâmica da capacidade máxima atual da bateria em estudo. O SoH é avaliado simultaneamente.

Na figura 3.5 podemos analisar os resultados de [6], onde é possível verificar o contraste entre o método de *Coulomb Counting* e a sua versão melhorada, onde foram aplicadas correções de parâmetros.




Figura 3.5: Resultados obtidos e validados por [6], utilizando um método melhorado de *coulomb counting*.

É também notório, na análise do documento que o erro, após diversas aplicações do método melhorado de *coulomb counting* (ECC), estabiliza, contrariamente ao que acontece com a versão tradicional, CC. No caso desta aplicação, onde um método baseado em inteligência computacional, EFK, são previsíveis os elevados requisitos computacionais e de hardware. Estes fatores podem inviabilizar a aplicação deste algoritmo. Segundo [39], apesar das técnicas de CC e ECC serem consideradas bastante precisas, existem diversos relatos do contrário. Estudos realizados em *smartphones* e EV demonstram erros na estimação do SoC de mais de 10%. Num contexto de um EV, esta deficiência na estimação poderá ser considerado um problema grave.

Capítulo 4

Estudo e Preparação dos Dados Adquiridos

Este capítulo tem como objetivo a apresentação e análise dos dados adquiridos relativos à utilização de uma bateria Li-ion, bem como o estudo e estimação do modelo elétrico da bateria e seus parâmetros. Em qualquer exercício de modelação de comportamentos não lineares, a dimensão e a qualidade da base de dados utilizada é fundamental. A qualidade da base de dados é um conceito relativo e complicado de quantificar.

4.1 Introdução

Ao contrário de um dataset linear, a estimação do SoH de uma bateria está longe de ser capaz de representar as relações entre os parâmetros de entrada e saída com clareza. Ou seja, mediante determinadas condições de utilização, a variação registada dos diferentes parâmetros (de entrada e saída), segue padrões inconstantes e dependentes de diversas variáveis. A utilização de algoritmos baseados em inteligência computacional torna-se muito conveniente na procura e estimação deste tipo de padrões inconstantes. A qualidade dos exercícios de estimação está diretamente relacionada com a qualidade do algoritmo escolhido e do dataset utilizado.

A base de dados utilizada neste projeto foi adquirida através da monitorização de um módulo de baterias de 7kWh, conectadas em série, que esteve em operação num EV entre 8/5/2018 e 6/11/2018, (exceto o mês de agosto). Dado que os percursos efetuados diariamente são idênticos e a degradação da bateria é relativamente lenta, foram analisados os dados recolhidos em cada segunda feira deste período de operação. Desta forma, a variação de qualquer parâmetro indicador do SoH é mais perceptível. Resumindo, a cada segunda feira em que a bateria operou, foram registados os valores da corrente de carga/descarga (I_b), da tensão medida nos terminais da bateria (V_{out}), a evolução do SoC (%SoC), bem como as temperaturas máximas e mínimas (T_{max} , T_{min}), ao longo do tempo. Com exceção do dia 9/10/18, (onde só se verifica registo de atividade a partir das 13:30h, horário de Portugal continental), todas as outras amostram denotam um claro paralelismo, tanto no horário de funcionamento como na ordem de DoD e SoC. Portanto, na maioria

das amostras, foram registados os parâmetros acima descritos ao longo de mais de 10 horas de funcionamento, (07:00h até 18:00h, aproximadamente). Em média, as medições foram atualizadas a 1Hz, permitindo o acesso a mais de 45 000 medições por cada segunda-feira.

Dado ao enorme volume de informação contida nas amostras selecionadas é fundamental proceder à organização da base de dados. Este exercício é extremamente importante, por um lado, de forma a estruturar e organizar dados atuais e agilizar a leitura dos dados em programas de *machine learning*, por outro lado, também facilita e automatiza a possível receção de dados futuros e organiza visualmente o ambiente de trabalho, tornando os cálculos e as decisões efetuadas muito mais intuitivas. Ruído ou deficiência em algumas medições são fatores que também devem ser considerados, apesar de que a dimensão das amostras poderá torná-los desprezíveis.

A forma mais elucidativa de clarificar a preparação e organização da base de dados é, em simultâneo com a apresentação do circuito equivalente da bateria e dos seus parâmetros. Isto porque, vários parâmetros deste modelo elétrico são desconhecidos e serão estimados através de um exercício de fitting, com base nas amostras recolhidas.

4.2 Modelo Elétrico Equivalente

O circuito equivalente de uma bateria de Lítio é um assunto ainda em estudo na literatura. Neste projeto foi considerado um circuito equivalente que descreve com precisão os fenómenos eletroquímicos que ocorrem durante o ciclo de vida da bateria, apresentado na figura 4.1, onde V_{in} é a tensão gerada total da bateria, sem perdas; I_{bat} , (positiva em descarga, negativa em carga), é a corrente que passa no circuito; R_{int} é a resistência ohmica interna; os paralelos de R_1 - C_1 e R_2 - C_2 são elementos representativos da termodinâmica eletroquímica da bateria; I_1 e I_2 as correntes instantâneas em R_1 e R_2 , respetivamente; e, finalmente, V_{out} é tensão nos terminais da bateria, ou seja, a tensão gerada real para a carga, já considerando as perdas internas do circuito.




Figura 4.1: Circuito elétrico equivalente do modelo de baterias

Importante notar que apenas alguns destes parâmetros podem ser diretamente medidos. V_{out} e I_{bat} foram parâmetros constantemente monitorizados ao longo do tempo e com diferentes SoC. Sabendo que os condensadores se comportam como curto circuito no instante em que se encontram completamente descarregados, R_{int} é também possível de ser calculado. Nos instantes em que $I_1=I_2=0$, ou seja, quando a bateria não está sujeita a perdas não ohmicas, (ou quando são desprezáveis), então:

$$V_{in_1} : \quad V_{in} = I_{bat1} \times R_{int} + V_{out1} \quad (4.1)$$

$$V_{in_2} : \quad V_{in} = I_{bat2} \times R_{int} + V_{out2} \quad (4.2)$$

Então, sabendo que V_{in} é igual para iguais condições de SoC, temperatura e SoH, foram recolhidas duas amostras com estas condições: SoC $\approx$ 100%, I_{bat1} = 16A, V_{out1} = 686.8V, I_{bat2} = 248A, V_{out2} = 673.2V.

Igualando as duas equações, resta uma incógnita. Desta forma foi possível concluir com bastante precisão que $R_{int} \approx 0.058 \Omega$. Segue-se o exercício de estimação dos dois elementos RC e de V_{in} , parâmetros que não permitem a medição de forma direta. A importância da precisa estimação de V_{in} é extremamente elevada, já que a evolução de V_{in} , com SoC=100%, está diretamente ligada com a evolução da capacidade máxima real da bateria. Isto significa que, quando a bateria é totalmente carregada, quanto maior V_{in} , maior a sua capacidade de transferir energia para a carga. O decréscimo de V_{in} , ao longo do tempo de operação, é um forte indicador do SoH da bateria. Para isso a correta identificação e estimação dos restantes parâmetros do circuito é fundamental.

Analisando as leis básicas de circuitos, nomeadamente as regras de *Kirchhoff* é possível deduzir que:

$$V_{in} = V_{rint} + V_{RC1} + V_{RC2} + V_{out} \quad (4.3)$$

$$V_{rint} = I \times R_{int} \quad (4.4)$$

Em que V_{rint} é a queda de tensão na resistência interna ohmica e V_{rc1} e V_{rc2} as quedas de tensão nos elementos RC, representativos dos fenómenos termodinâmicos. Da equação (esta em cima), são conhecidos devido às medições efetuadas V_{out} . V_{rint} , pela lei de Ohm, é o resultado da multiplicação da corrente na bateria ao longo do tempo pela sua resistência interna ohmica, acima estimada.

Durante a carga de um condensador, as suas placas acumulam a mesma quantidade de cargas (opostas), verificando-se entre elas um aumento da diferença de potencial.

$$V_{RCn} = I \times R_n - V_{in} \cdot e^{(-t/\tau)}$$

$$(4.6)$$

Onde $I \times R_n$ é a máxima diferença de potencial possível no elemento RC_n , que se aproxima deste valor à medida que a tensão no condensador converge para 0. τ é a constante de tempo de cada elemento RC, ou seja,

$$\tau_n = R_n \times C_n \quad (4.7)$$

Por uma questão intuitiva, τ_1 e τ_2 são mantidos nas equações e estimados durante os exercícios de fitting. C_1 e C_2 são posteriormente calculados, pela equação (acima). Então, juntando as equações 4.7, 4.5 e 4.3, obtém-se a seguinte expressão,

$$V_{in} = I_{bat} \times R_{int} + (I_{bat} \times R_1 - V_{in} \cdot e^{-t/\tau_1}) + (I_{bat} \times R_2 - V_{in} \cdot e^{-t/\tau_2}) + V_{out} \quad (4.8)$$

Devido à possibilidade da medição do parâmetro V_{out} , é importante apresentar a expressão em função dos parâmetros desconhecidos, de forma a proceder ao exercício de fitting. Por uma questão de organização, as variáveis I e V_{in} foram colocadas em evidência.

$$V_{out} = V_{in} \times (1 + e^{-t/\tau_1} + e^{-t/\tau_2}) - I_{bat} \times (R_{int} + R_1 + R_2) \quad (4.9)$$

4.3 Curve Fitting: Características e Aplicação

É denominado por *curve fitting* o processo de construção de uma curva, função matemática ou superfície, que melhor se ajusta a uma série de dados, possivelmente sujeito a restrições. O *curve fitting* pode envolver interpolação, onde um *fit* exato dos dados é necessário, ou utilizar *smoothing*, que, como o nome indica, uma função aproximada é construída para representar o conjunto de dados. É um conceito relativamente relacionado com regressão analítica.

Com a estimação dos parâmetros do circuito equivalente da bateria em mente, foram considerados duas aplicações: a *curve fitting toolbox do Matlab* e a *solver toolbox do Excel*. As duas aplicações oferecem a possibilidade de ajustar curvas e superfícies com relativa facilidade, mas devido a fatores técnicos, o exercício de *fitting* foi executado com auxílio à ferramenta *solver e*. Posteriormente, os resultados foram reavaliados com o auxílio do *Matlab*.

O primeiro passo para realizar um exercício de *fitting* é a seleção dos dados a utilizar. A utilização de toda a base de dados é inconcebível por diversos motivos, tais como peso computacional

envolvido ou o fator da travagem regenerativa, por exemplo. É fundamental ter em conta que V_{in} é a tensão total da bateria sem perdas, e está diretamente ligada com o SoC; então, de forma a poder ser considerada uma constante nesta tarefa de *fitting*, a sequência de amostras considerada têm de revelar uma variação praticamente nula do SoC. O número de amostras selecionadas deve respeitar este compromisso de forma a minimizar o erro de estimação.

Da totalidade da base de dados utilizada neste projeto, foram selecionadas três amostras de dias diferentes com objetivo de realizar uma análise mais completa do circuito. As amostras selecionadas contêm medições correspondentes a 30-50 segundos e apresentam, no máximo, valores de variação de SoC de 0,5%. Por uma questão da redução da complexidade do exercício de *fitting*, foram selecionadas amostras em que a corrente varia ao longo do tempo, apenas com valores positivos, ou seja, a bateria está sempre em descarga, sem qualquer efeito de fenómenos de travagem regenerativa. As amostras de cada dia foram isoladas e preparadas para o *fitting*.

O programa utilizado neste projeto facilita bastante a operação deste tipo de dados e apresenta inúmeros operadores matemáticos e estatísticos extremamente úteis, porém, não tem uma aplicação direta e intuitiva de *fitting*. Neste projeto, a lacuna da aplicação direta de *fitting* foi contornada, com um método que garante erro mínimo nos parâmetros pretendidos. Após a dedução da expressão matemática de V_{out} em função dos restantes parâmetros do circuito, foram isolados e colocados lado a lado:

- V_{out} medido;
- I_{bat} medido;
- Tempo total da amostra, em segundos, ($0 < t < t_{máx}$);
- V_{out} estimado pelo modelo do circuito;
- Erro quadrático entre cada V_{out} medido e estimado.

De notar que na primeira iteração deste exercício, as condições iniciais de R_1 , R_2 , C_1 , C_2 e V_{in} foram definidos de uma forma relativamente aleatória. Foram também desenhados gráficos temporais onde os valores medidos e estimados de V_{out} são comparados, facilitando a visualização do efeito da mudança de cada variável nos resultados.

A partir do erro quadrático foi calculado o erro raiz-média-quadrático (RMSE), que é um medidor de precisão relativo, frequentemente calculado neste tipo de exercícios e constitui um bom indicador da qualidade das estimações. Ou seja, considerando as mesmas amostras, quanto menor for o RMSE, maior a qualidade das estimações.

4.4 Solver Add-in

O solver é um programa add-in disponível no Microsoft Excel que tem a capacidade de procurar soluções ótimas (máximo e mínimo) para uma fórmula numa célula (célula objetivo), sujeita a condições ou limites. Este programa trabalha com um grupo definido de células, denominadas

variáveis de decisão, que são utilizadas para computar as fórmulas no objetivo e restringir outras células, [42]. O Solver ajusta os valores das variáveis de decisão de modo a satisfazer os limites das células restringidas e produzir o resultado esperado para a célula objetivo.

A célula que contém o cálculo do RMSE foi definida como célula objetivo. As variáveis de decisão são, neste caso, os parâmetros desconhecidos do circuito equivalente da bateria. Resumindo, para a aplicação do solver, foram introduzidas as seguintes condições:

- **Objetivo:** Minimizar RMSE;
- **Variáveis de decisão:**
 - V_{in} , com valor inicial 680V e condição $V_{in} > V_{out}$;
 - R_1 e R_2 , com valor inicial 0.1 e condição $R_n > 0$;
 - τ_1 e τ_2 , com valores iniciais 0.0001s e condição $\tau_n = R_n \times C_n$.

Estas iterações foram repetidas para várias amostras com o solver constantemente em busca do menor RMSE possível. Os resultados obtidos foram registrados para análise e, à primeira vista, aparentam ser satisfatórios.

4.5 Análise dos Resultados Obtidos

Os testes realizados nas amostras selecionadas de três dias distintos, demonstram resultados semelhantes entre si. Da análise dos resultados obtidos, foi possível tecer conclusões relativamente aos parâmetros desconhecidos.

4.5.1 DIA 17/07/2018

Uma amostra de 79 valores de corrente e tensão foram registrados durante 53 segundos. V_{out} foi estimado, segundo a equação matemática deduzida, e após a aplicação do solver, o erro quadrático médio (MSE) é de apenas 2,98V, ou seja, aproximadamente 0,5% do valor nominal de tensão da amostra. O RMSE mínimo conseguido foi 1,72. Os resultados da simulação podem ser observados na tabela 4.5.1.

Resultados 17/7/18	
V_{in}	684,76
τ_1	0,00001
τ_2	0,001
R_1	0,001
R_2	0,01

Através da análise da figura 4.2, é possível observar um gráfico que ilustra a evolução de V_{out} medido e estimado.




Figura 4.2: Vout medido e Vout estimado ao longo do tempo, (17/7/18).

4.5.2 DIA 11/09/2018

Uma amostra de 53 valores de corrente e tensão, registados ao longo de 52 segundos. Após a estimação de Vout, o MSE foi 5,44V. O RMSE mínimo atingido foi 3,33. Os resultados da simulação podem ser observados na tabela 4.5.2.

Resultados 11/9/18	
Vin	680
τ_1	0,0016
τ_2	0,04875
R1	0,0086
R2	0,001

Na figura 4.3, é possível encontrar um gráfico que ilustra a proximidade das estimações conseguidas e das medições efetuadas.




Figura 4.3: Vout medido e Vout estimado ao longo do tempo, (11/9/18).

4.5.3 DIA 06/11/2018

Uma amostra de 62 valores de corrente e tensão, registados durante 36 segundos. Após a estimação de Vout, o MSE foi 3,69V. O RMSE mínimo atingido foi 1,91. Os resultados da simulação podem ser observados na tabela 4.5.3.

Resultados 11/9/18	
Vin	685,51
τ_1	0,0016
τ_2	0,05711
R1	0,0023
R2	0,0083

Na figura 4.4, é possível encontrar o gráfico que ilustra Vout estimado conseguidas e medido, ao longo do tempo.




Figura 4.4: Vout medido e Vout estimado ao longo do tempo, (6/11/18).

4.6 Conclusões

Os resultados obtidos foram bastante semelhantes aos valores que teoricamente seriam de esperar. Quanto ao parâmetro V_{in} , considerado constante num curto espaço de tempo, apresenta um decréscimo entre a primeira e a terceira amostra, podendo este ser um indicador muito forte da evolução do SoH da bateria. O motivo de V_{in} , na segunda amostra, ser o valor mais baixo registado pode ser atribuído ao facto de a amostra ter sido recolhida num SoC ligeiramente inferior e também a erros inevitáveis associados a estimações e aproximações. Os restantes quatro parâmetros estimados foram os elementos RC do circuito. É possível verificar que a estimação, feita com base na amostra do dia 17-07-2018, apresenta, não só maiores erros associados, como também resultados em ordens de grandeza bastante distintas das restantes estimações. Quanto às duas amostras com menores erros associados, (11-09-2018 e 6-11-2018), é inegável o paralelismo verificado nas estimações, permitindo verificar estes resultados com relativa certeza. Resumindo, as constantes de tempo dos elementos RC do circuito, τ_{thau1} e τ_{thau2} , podem ser aproximadamente quantificadas, 1.6ms e 57ms, respetivamente. A $R1$ e $R2$, devido à proximidade das estimações, são atribuídos os valores estimados com menores erros associados, $R1=2.3\text{mohm}$ e $R2=2\text{mohm}$.

Alguns dos parâmetros estimados neste exercício, encontram-se um pouco distantes dos valores esperados e podem ser explicados pela impossibilidade de utilização de amostras demasiado extensas, aliadas à resolução de 3,4V verificada nos medidores de tensão. A taxa de atualização das leituras, pode levar ao registo de valores distantes de tensão, em medições consecutivas, constituindo também um possível fator de erro. Fatores como pequenos erros de medição, ou capacidade de atualização dos dados adquiridos também foram tomados em conta.

4.7 Validação e Comparação dos Resultados Obtidos

Com o objetivo de comprovar e perceber a qualidade das estimações realizadas num contexto geral, foi realizada uma breve revisão bibliográfica aos autores que investigaram este tema. É perceptível que relativamente poucos investigadores conseguiram, com sucesso, estimar parâmetros desconhecidos de baterias idênticas às utilizadas neste projeto. Alguns projetos, como [43], trabalharam com diferentes tipologias de baterias, com a estimação de alguns parâmetros relativamente semelhantes, contudo, é inadequado tecer comparações entre ambos. Em [7] um exercício de *fitting*, em tudo similar ao aqui descrito, propõe estimar os parâmetros de uma bateria li-ion com o recurso a um EKF. Na figura 4.5, podemos observar o circuito equivalente de *Thevenin* proposto pelos autores para abordar este problema.




Figura 4.5: Circuito equivalente de *Thevenin* considerado por [7]

Este projeto propõe a direta determinação dos parâmetros desconhecidos, como função de quantidades físicas, com o SoC e a intensidade das correntes de carga e descarga. Posteriormente, um EKF é aplicado com o objetivo de aumentar a precisão das estimações. É possível verificar através da figura 4.6, os parâmetros estimados neste projeto, e os seus respetivos erros associados.

À exceção do parâmetro C_1 , é notável um claro paralelismo nos resultados quando comparados aos obtidos neste exercício. Em [7], a temperatura não é considerada na estimação destes parâmetros e poderá ser um fator que fundamente os resultados distintos obtidos em C_1 .

Parameter	Error (Root Mean Square)
ΔR_1	1.5%
ΔC_1	2.0%
ΔR_2	1.3%
ΔC_2	2.3%
ΔV_{oc}	1.2%

Figura 4.6: Erros associados à estimação de parâmetros, registados em [7]

4.8 Proposta de Trabalho e Futura Maximização da Precisão de Estimação

Como podemos observar em grande parte da literatura, os parâmetros da bateria são estimados como função do tempo de utilização, SoC, entre outros fatores. O grande entrave destes projetos é a complexidade da modelação do sistema, que provoca taxas de erro relativamente elevadas. A discussão sobre que variáveis considerar ainda é um tópico em nada consensual. De forma a contornar este obstáculo, os parâmetros do circuito equivalente foram estimados sempre em SoC próximos de 100% e enquanto a bateria operava em intervalos de temperatura considerados ideais. Quantificados os parâmetros nestas condições, é possível perceber a evolução da capacidade real da bateria, ao longo do tempo, quando o estado de carga é 100%. Ou seja, conhecido o comportamento do sistema nestas condições, é possível calcular a energia máxima que a bateria é capaz de transferir e estudar a evolução deste indicador ao longo de vários meses.

Como proposta de melhoramento da estimação, seria importante perceber, por exemplo, qual o peso da operação em temperaturas fora dos limites ideais. De momento, essa modelação é inconcebível devido às limitações de amostras adquiridas. Tal como verificado na generalidade da literatura, seria necessário o estudo e monitorização de inúmeros parâmetros durante um longo período, relativamente, de forma a ser possível compreender e quantificar a influência dos mesmos.

Capítulo 5

Estudo da Taxa de Degradação da Bateria e Proposta de Predição com Base em *Machine Learning*

Após o trabalho da base de dados e a estimação dos parâmetros desconhecidos, descrito no capítulo anterior, o presente capítulo está destinado à análise da evolução dos “sinais vitais” da bateria, ou seja, o seu estado de saúde. Com os dados adquiridos já processados, dois algoritmos de *machine learning* são aplicados com o objetivo de compreender a evolução da quantidade de energia disponível na bateria ao longo do tempo. Uma das grandes vantagens da utilização deste tipo de algoritmos é a capacidade de relacionamento de variáveis, como a temperatura, as correntes de carga e o DoD. Ou seja, além da capacidade de estimar e prever a evolução dos melhores indicadores do SoH, a influência de cada variável, (inputs do sistema), tornar-se-á clara.

Neste capítulo é proposta uma alternativa bastante pragmática para a estimação do SoH da bateria e a evolução deste indicador. Inicialmente é descrito o método de cálculo da capacidade atual da bateria transferir energia. De seguida, e já com todos os registos de temperatura, corrente e tensão da bateria completamente organizados ao longo do tempo, os dados são processados por dois algoritmos “inteligentes”, uma rede neuronal artificial (ANN) e uma aplicação contida no *Matlab*, *regression learner* (MRL). Os resultados obtidos são cuidadosamente analisados e é proposta uma previsão futura da evolução do SoH.

Três grandes objetivos são explorados no último capítulo deste projeto:

- Modelação da degradação da bateria em função de diversas variáveis;
- Estimação da restante vida útil da bateria, ou seja, procura do momento onde o curve-knee surgirá;
- Estudo da viabilidade da aplicação da bateria numa segunda vida.

Tal como abordado anteriormente nas secções 1.2 e 1.3.1.1, será extremamente improvável a reutilização de uma bateria quando esta atinge o denominado “joelho” na sua curva de degradação,

e daí conseguir uma boa estimacão desse indicador, poderá constituir um potencial avanço nesta área. Finalmente, os resultados são apresentados e analisados e uma proposta de trabalho futuro é documentada.

5.1 Análise e Pré-processamento da Base de Dados a Considerar nos Algoritmos Inteligentes

Tal como foi anteriormente abordado, o pré-processamento da base de dados é fundamental, não só de forma a possibilitar a correta leitura por parte dos programas inteligentes, mas também permite a automatização deste exercício num futuro projeto. Ou seja, o exercício aqui descrito elimina medições falaciosas, coordena os valores de corrente e tensão e, acima de tudo, facilita o pré-processamento deste tipo de medições em trabalhos futuros.

O primeiro passo de correção de medições consistiu na eliminação de falsos zeros e ruído de medição, através da aplicação de um simples filtro de média. Posteriormente, e durante o cálculo de V_{in} , ao longo de vários meses, tornou-se perceptível um recorrente erro de medição. Foi possível verificar a existência de valores de tensão desfasados em relação a outros parâmetros medidos simultaneamente, ou seja, durante o cálculo de V_{in} , surgiram valores isolados de tensão completamente distantes dos valores esperados. Devido ao reduzido número de valores incoerentes, foi utilizado um método manual de correção das medições. A deteção e correção automática deste tipo de falhas, poderia, eventualmente, constituir um desafio futuro.

Durante o segundo passo deste exercício de pré-processamento foram dispostos e organizados com o apoio da ferramenta Excel as medições recolhidas durante as descargas efetuadas na bateria, ao longo do tempo, e com as devidas correções, previamente efetuadas. Novamente, a evolução do tempo foi exibida em segundos. O objetivo do último capítulo deste projeto é o cálculo de V_{in} durante cada descarga, ao longo dos meses de utilização monitorizados, analisar a sua evolução e relacionar com a energia real transferida.

É possível definir V_{in} como a tensão real que a bateria é capaz de fornecer, ou seja, V_{in} é a tensão medida nos terminais da bateria, mais as perdas registadas, tanto óhmicas como por efeitos termodinâmicos. Resumidamente:

$$V_{in} = V_{out} + (I_{bat} \times R_1 \times e^{-t/\tau_1}) + (I_{bat} \times R_2 \times e^{-t/\tau_2}) + I_{bat} \times R_{int} \quad (5.1)$$

A aplicação desta fórmula nos diferentes meses de operação registada constitui uma estimacão de V_{in} , que se acredita ser relativamente precisa. É de extrema importância salientar o facto de que a estimacão dos parâmetros termodinâmicos foi considerada estática e diferentes condições foram utilizadas para procurar aproximar este fator com menor erro possível. Futuramente, a estimacão destes parâmetros em função de variações na temperatura, humidade, entre outros, constituirá um

desafio bastante importante. Neste projeto, a realização desta modelação verificou-se inconcebível, devido a uma pequena taxa de variação de certos parâmetros, mas em todo o caso, a base de trabalho está criada e com a aquisição de novos dados, será possível resolver esta questão.

Uma análise superficial aos valores de V_{in} obtidos, demonstram uma aparente evolução decrescente, ao longo do tempo como, provavelmente, seria espectável. Como V_{in} está diretamente relacionado com a potência útil da bateria, estes resultados poderão constituir um forte indicador da evolução do SoH da bateria. A aplicação de algoritmos inteligentes, descrito nas secções seguintes, tem como objetivo procurar estas relações e analisar a evolução temporal das mesmas.

5.2 Rede Neuronal Artificial

O estudo e análise dos diversos algoritmos utilizados para estimar o SoH e o SoC, documentado no capítulo 3.1, suportou a ideia de que a aplicação de um método baseado em inteligência computacional na estimação do estado de saúde de uma bateria, seria o processo ideal, tanto pelo tamanho da base de dados considerada, como pela complexa e desconhecida relação que as diferentes variáveis apresentam.

Na presente secção, é descrita a aplicação de uma ANN de série temporal que é utilizada para modelar o comportamento da bateria, mediante os dados adquiridos, e prever o futuro comportamento dos parâmetros vitais da mesma. A arquitetura da rede, Autorregressiva Não-linear com Inputs Externos (NARX) com uma camada escondida que inclui 8 neurónios, pode ser visualizada na figura 5.1 e é considerada extremamente útil a lidar com séries temporais dinâmicas. Posteriormente, a predição da série $y(t)$ é obtida através de d valores passados de $y(t)$ e outra série $x(t)$.




Figura 5.1: Arquitetura da rede neuronal NARX.

Durante cada semana de operação, foram registados os valores de um dia de: corrente, tensão nos terminais da bateria, estado de carga atual, temperaturas máxima e mínima, definidos como entradas do sistema, e a tensão interna da bateria e a energia total transferida, como saídas do sistema. V_{in} e a potência útil da bateria estão diretamente relacionados e foram calculados e introduzidos na ANN, paralelamente.

5.2.1 Análise dos Resultados Obtidos da Aplicação da ANN de Série Temporal

Na presente secção, são apresentados os resultados obtidos da utilização da *toolbox* de redes neuronais, disponível no *Matlab*. Foi selecionada esta aplicação devido à sua interatividade e

facilidade na visualização de resultados. Na figura 5.2 é visível a resposta da ANN (NARX) após o seu treino e respectivos erros de estimação. É evidente a existência um padrão decrescente, possível indicador da degradação do SoH da bateria.




Figura 5.2: Resultados obtidos do treino da rede neuronal.

A aplicação possibilita também a visualização da performance do treino a que a ANN foi sujeita, figura 5.3. É evidente a manutenção dos erros de validação e teste em valores relativamente elevados. A reduzida dimensão do *dataset* é insuficiente para a aproximação de erros mais aceitáveis. De salientar a importância da continuação deste projeto na construção de um modelo extremamente robusto. Parâmetros relevantes do estado do treino da ANN, como o gradiente, μ e as *validation checks* são apresentados na figura 5.4.

É sempre significativo lembrar que o presente projeto não dispõe de uma base de dados extensa pelo que será difícil contemplar todas as relações existentes entre variáveis, e a taxa de erro poderá revelar-se relativamente alta. Ao invés de procurar a obtenção de um modelo definitivo e absoluto da degradação da bateria, este projeto apresenta uma metodologia de trabalho que facilmente poderá ser utilizada futuramente no desenvolvimento deste tópico.




Figura 5.3: Performance do treino da ANN.

5.3 Regression Learner do Matlab

Na presente secção, são apresentados os resultados obtidos da utilização da *toolbox*, baseada em *machine learning*, o *regression learner*, presente no *Matlab*. Esta aplicação foi seleccionada após apresentar excelentes indicadores na resolução deste tipo de problemas e também como suporte aos resultados apurados pela ANN. Tal como as ANN, este exercício possibilita fazer previsões quanto à evolução futura do SoH da bateria. Na figura 5.5, é possível encontrar os resultados da aplicação deste programa em função do seu tempo de utilização, onde se pode verificar uma tendência decrescente, tal como na ANN. Uma vantagem deste programa é a facilidade da visualização das dependências entre parâmetros. Por exemplo, a figura 5.6 demonstra a evolução de V_{in} em função da temperatura de operação a que a bateria está sujeita. Como seria expectável, V_{in} cresce com a aproximação dos limites ideais de temperatura de operação.

Com objetivo de analisar os erros de medição, encontra-se na figura 5.7 um gráfico que apresenta a comparação entre os valores estimados e reais obtidos neste programa.




Figura 5.4: Estado de treino da rede neuronal.

5.4 Predição do Comportamento do SoH: ANN vs MRL

Apesar de ser relativamente evidente que o número de amostras consideradas poderá ser reduzido para construir um modelo sólido e utilizável foi executado, neste projeto, um exercício de previsão baseado nos diferentes algoritmos inteligentes aplicados. Este exercício proporcionou a construção de uma visão bastante superficial do futuro da bateria.

Foram, então, construídos dois perfis sintéticos, com aproximadamente cinco meses de uma possível utilização futura da bateria. O primeiro, denominado **Perfil A**, contempla uma simulação em condições semelhantes às registadas de utilização de um EV, com altas correntes e DoD. O segundo, **Perfil B**, tem como principal objetivo o de simular a utilização da bateria numa segunda vida, com condições de utilização muito menos exigentes. As temperaturas de utilização consideradas foram baseadas nas temperaturas médias semanais, registadas no ano transato. Os resultados deste exercício de previsão consolida, em parte, os modelos obtido e cria um *workflow* simples e eficaz, utilizável futuramente no desenvolvimento deste tópico.

Através da análise do anexo C é possível compreender os resultados da predição, relativamente coerentes com os valores esperados. Ambos os métodos são capazes de prever uma maior degradação da bateria, seguindo condições de operação de EV. Porém, é difícil considerar estes resultados completamente validados. Além de uma menor degradação, aparenta existir um ligeiro abrandamento da taxa de degradação, facto que poderá ser validado brevemente em projetos semelhantes.




Figura 5.5: Resultados obtidos pelo MRL ao longo do tempo.




Figura 5.6: Evolução de Vin mediante a variação de temperatura.




Figura 5.7: Gráfico que relaciona os valores reais e estimados.

Capítulo 6

Conclusões e Trabalho Futuro

6.1 Conclusões

A realização deste projeto permitiu aprofundar o estudo e conhecimento relativamente ao ainda desconhecido mundo da estimação de parâmetros vitais da bateria. Após a recolha, análise e pré-processamento da base de dados considerada nesta dissertação, foram propostos dois métodos de estimação do SoH da bateria envolvida. O estudo prévio dos parâmetros mais relevantes da bateria e dos diferentes métodos de estimação do SoH possibilitou a criação de uma orientação de trabalho que poderá ser utilizada futuramente.

No que diz respeito aos trabalhos anteriormente realizados neste âmbito, foram encontradas inúmeras adversidades documentadas que resultaram em estimações pouco precisas. Foi selecionado um modelo, que apresentou um fluxo de trabalho relativamente semelhante a este projeto e que demonstrou resultados relativamente satisfatórios. Estes projetos poderão ser aliados numa proposta de trabalho futuro.

Quanto aos resultados obtidos da aplicação de algoritmos inteligentes, foi possível encontrar um padrão evidente de degradação ao longo do tempo. A forte influência da temperatura na degradação da bateria foi comprovada. A ação da profundidade dos ciclos de carga/descarga é difícil de estimar devido ao paralelismo encontrado nas amostras recolhidas, apesar de se acreditar ser relevante. As correntes altas registadas são, obviamente, um fator que aumenta a taxa de degradação. A determinação do “joelho” de degradação não foi atingida na plenitude, apesar dos esforços realizados nessa direção. Tanto na modelação como na previsão futura foram encontrados alguns picos associados a erros, pelo que pode ser impreciso definir em algum desses pontos o “*curve knee*”.

Relativamente aos exercícios de previsão, mediante diferentes perfis de utilização, apresentaram resultados entusiasmantes. Os resultados podem ser observados em [C](#). A redução da taxa de degradação, utilizando perfis mais suaves, constitui um forte indicador de que a aplicação de baterias, provenientes dos EV, poderá ser um conceito viável.

6.2 Proposta de Melhoria e Trabalho Futuro

Os exercícios realizados de estimação dos parâmetros do circuito equivalente da bateria, pré-processamento de dados, modelação e estimação da taxa de degradação da bateria demonstraram resultados extremamente satisfatórios, dentro das limitações existentes. Serve a presente secção para propor uma melhoria deste projeto num contexto onde existam condições ideais de trabalho, algo que é possível encontrar ao longo de certas secções do documento, nas quais foram expostas as limitações encontradas e algumas melhorias foram propostas.

Como já referido anteriormente, o presente documento procurou a modelação da evolução do estado de saúde de uma bateria com o objetivo de estimar a sua viabilidade numa segunda aplicação e alguns aspetos destes exercícios poderão ser conseguidos com mais precisão e qualidade. Durante a estimação dos componentes do circuito equivalente de *Thevenin*, estes foram considerados estáticos, com o objetivo de aumentar a precisão de estimação utilizando as medições efetuadas na bateria. Futuramente, e com muitos mais semanas, meses de dados adquiridos, será possível estimar estas parâmetros com mais exatidão e eventualmente variantes no tempo. Outra questão importante é o tamanho da base de dados utilizada na ANN e MRL. Caso seja possível recolher muitos mais tempo de dados de diferentes baterias, em diferentes condições de utilização, principalmente a temperatura e a DoD, o treino deste tipo de algoritmos será muito mais eficaz e traduzirá resultados mais satisfatórios.

Este projeto procura a modelação de uma bateria utilizada num contexto urbano num clima moderado como o português, completamente distinto de climas equatoriais ou polares. Neste sentido, este documento servirá como uma base de trabalho extremamente completa no estudo e desenvolvimento deste tópico, que tão importante será, caso a utilização de baterias nos automóveis se venha a consolidar como o futuro.

Anexo A

Cells considered	FL Test Conditions**	FL-EOL Cap [%]	FL-EOL DC Resistance [%]	FL-EOL FEC	SL-BOL Cap [%]	SL-BOL DC Resistance [%]	SL condition	SL cycling test profile
C1	0.5C-1C – 50% – 80% – 35°C	95.00	115	800	96.41	114	Homogeneous S1	Power smoothing
C2	0.5C-1C – 50% – 80% – 35°C	93.56	97	800	95.77	93		
C3	0.5C-1C – 50% – 80% – 35°C	94.11	118	800	96.00	104		
C4	C/3-C/3 – 50% – 80% – 35°C	97.88	105	500	96.8	112	Heterogeneous S2	Power smoothing
C5	C/3-1C – 50% – 80% – 25°C	95.22	111	1900	96.28	116		
C6	C/3-1C – 50% – 80% – 25°C	95.51	107	1900	96.80	113		
C7	C/3-1C – 50% – 65% – 45°C	88.08	267	900	89.05	308	Heterogeneous S3	Power smoothing
C8	2C-1C – 50% – 80% – 35°C	NA	NA	800	74.16	226		
C9 [†]	NA – 80% – NA – 45°C	84.35	167	NA	86.93	183		
C10	C/3-1C – 50% – 35% – 35°C	100.11	108	800	100.98	101	Homogeneous S4	Power smoothing
C11	C/3-1C – 50% – 35% – 35°C	99.22	107	800	100.38	96		
C12	C/3-1C – 50% – 35% – 35°C	99.33	114	800	100.31	103		
C13	C/3-1C – 50% – 35% – 45°C	96.93	180	900	96.10	153	Cell level	Power smoothing
C14	C/3-1C – 50% – 35% – 45°C	96.88	151	900	96.07	138	Cell level	Residential
C15	C/3-2C – 50% – 80% – 35°C	74.73	359	2100	74.59	361	Cell level	Residential

Figura A.1: Perfil de corrente sintetizado de um mês, da aplicação de *power smoothing* (azul) e da aplicação residencial (laranja) [3]

Anexo B

Diagrama Temporal	Semana 1-3	Semana 3-7	Semana 7-14	Semana 12-17	Semana 17-19	Semana 19-21
Análise do modelo a adotar e planeamento de testes de validação						
Análise do método computacional para processamento do estado de saúde						
Realização de testes e avaliação dos resultados						
Escrita da dissertação						
Verificação global de resultados da dissertação finalização de todos os detalhes						
Preparação da apresentação final						

Figura B.1: Diagrama Temporal de Gantt

Anexo C

A apresentação dos resultados de predição obtidos encontra-se exposta na presente secção. A exposição deste exercício em anexo deve-se principalmente ao facto dos modelos utilizados na predição, ainda não estarem completamente validados. Num futuro próximo, e com a entrada de mais medições de diferentes baterias em diferentes condições, este workflow poderá ser retomado, o respetivo modelo poderá ser validado e consequentemente, será possível tecer previsões bastante mais fundamentadas.

O exercício de predição procurou estimar a evolução de V_{in} nas seguintes 21 semanas de uma possível utilização.

C.1 NARX ANN

Nas figuras C.1 e C.2 é possível verificar os resultados do exercício de previsão utilizando a rede neuronal artificial já treinada.




Figura C.1: Predição da evolução do SoH com uma rede neuronal, aplicando um perfil de utilização idêntico a um EV.




Figura C.2: Predição da evolução do SoH com uma rede neuronal, aplicando um perfil de utilização idêntico a um conjunto de casas.

C.2 *Regression Learner do Matlab*

Nas figuras C.3 e C.4 é possível verificar os resultados do exercício de previsão utilizando o MRL.




Figura C.3: Predição da evolução do SoH com o aplicação de regressão inteligente do *Matlab*, aplicando um perfil de utilização idêntico a um EV.




Figura C.4: Predição da evolução do SoH com o aplicação de regressão inteligente do *Matlab*, aplicando um perfil de utilização idêntico a um conjunto de casas.

Referências

- [1] A. Keeli and R. K. Sharma, “Optimal use of second life battery for peak load management and improving the life of the battery,” in *2012 IEEE International Electric Vehicle Conference*, March 2012, pp. 1–6.
- [2] M. Ecker, J. B. Gerschler, J. Vogel, S. Käbitz, F. Hust, P. Dechent, and D. U. Sauer, “Development of a lifetime prediction model for lithium-ion batteries based on extended accelerated aging test data,” *Journal of Power Sources*, vol. 215, pp. 248 – 257, oct 2012. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0378775312008671>
- [3] E. Martinez-Laserna, E. Sarasketa-Zabala, I. V. Sarria, D. I. Stroe, M. Swierczynski, A. Warnecke, J. M. Timmermans, S. Goutam, N. Omar, and P. Rodriguez, “Technical viability of battery second life: A study from the ageing perspective,” *IEEE Transactions on Industry Applications*, vol. 54, no. 3, pp. 2703–2713, May 2018.
- [4] A. Eddahech, O. Briat, N. Bertrand, J.-Y. DelÃ©tage, and J.-M. Vinassa, “Behavior and state-of-health monitoring of li-ion batteries using impedance spectroscopy and recurrent neural networks,” *International Journal of Electrical Power Energy Systems*, vol. 42, no. 1, pp. 487 – 494, 2012. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0142061512001779>
- [5] G. L. Plett, “Extended kalman filtering for battery management systems of lipb-based hev battery packs: Part 3. state and parameter estimation,” *Journal of Power Sources*, vol. 134, no. 2, pp. 277 – 292, 2004. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0378775304003611>
- [6] K. S. Ng, C.-S. Moo, Y.-P. Chen, and Y.-C. Hsieh, “Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries,” *Applied Energy*, vol. 86, no. 9, pp. 1506 – 1511, 2009. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0306261908003061>
- [7] Y. Diab, F. Auger, E. Schaeffer, and M. Wahbeh, “Estimating lithium-ion battery state of charge and parameters using a continuous-discrete extended kalman filter,” *Energies*, vol. 1075, p. 1, 07 2017.
- [8] M. K. Kandler Smith, Aron Saxon and B. Lundstrom, “Life prediction model for gridconnected li-ion battery energy storage system,” 2017, presented at the 2017 American Control Conference.
- [9] M. Team *et al.*, “A guide to understanding battery specifications,” 2008, consultado em Novembro, 2018.

- [10] E. Martinez-Laserna, E. Sarasketa-Zabala, D. I. Stroe, M. Swierczynski, A. Warnecke, J. M. Timmermans, S. Goutam, and P. Rodriguez, "Evaluation of lithium-ion battery second life performance and degradation," in *2016 IEEE Energy Conversion Congress and Exposition (ECCE)*, Sept 2016, pp. 1–7.
- [11] "How to Prolong Lithium-based Batteries", 2010, consultado em Outubro, 2018.
- [12] S. S. Choi and H. S. Lim, "Factors that affect cycle-life and possible degradation mechanisms of a li-ion cell based on licoo2," *Journal of Power Sources*, vol. 111, no. 1, pp. 130 – 136, sep 2002. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0378775302003051>
- [13] P. Gyan, "Mobicus project: Battery testing, ageing modeling and simulation of durability strategies," *IQPC 4TH International Conference Automotive Battery Managment Systems*, 2017.
- [14] J. Vetter, P. Novák, M. Wagner, C. Veit, K.-C. Möller, J. Besenhard, M. Winter, M. Wohlfahrt-Mehrens, C. Vogler, and A. Hammouche, "Ageing mechanisms in lithium-ion batteries," *Journal of Power Sources*, vol. 147, no. 1, pp. 269 – 281, 2005. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0378775305000832>
- [15] M. Ecker, N. Nieto, S. Käbitz, J. Schmalstieg, H. Blanke, A. Warnecke, and D. U. Sauer, "Calendar and cycle life study of li(nimnco)o2-based 18650 lithium-ion batteries," *Journal of Power Sources*, vol. 248, pp. 839 – 851, 2014. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0378775313016510>
- [16] J. M. Timmermans, A. Nikolian, J. D. Hoog, R. Gopalakrishnan, S. Goutam, N. Omar, T. Coosemans, J. V. Mierlo, A. Warnecke, D. U. Sauer, M. Swierczynski, D. I. Stroe, E. Martinez-Laserna, E. Sarasketa-Zabala, J. Gastelurrutia, and N. Nerea, "Batteries 2020 x2014; lithium-ion battery first and second life ageing, validated battery models, lifetime modelling and ageing assessment of thermal parameters," in *2016 18th European Conference on Power Electronics and Applications (EPE'16 ECCE Europe)*, Sept 2016, pp. 1–23.
- [17] P. J. Hart, P. J. Kollmeyer, L. W. Juang, R. H. Lasseter, and T. M. Jahns, "Modeling of second-life batteries for use in a certs microgrid," in *2014 Power and Energy Conference at Illinois (PECI)*, Feb 2014, pp. 1–8.
- [18] H. Ambrose, D. Gershenson, A. Gershenson, and D. Kammen, "Driving rural energy access: a second-life application for electric-vehicle batteries," *Environmental Research Letters*, vol. 9, no. 9, p. 094004, 2014. [Online]. Available: <http://stacks.iop.org/1748-9326/9/i=9/a=094004>
- [19] K. Smith, A. Saxon, M. Keyser, B. Lundstrom, Z. Cao, and A. Roc, "Life prediction model for grid-connected li-ion battery energy storage system," in *2017 American Control Conference (ACC)*, May 2017, pp. 4062–4068.
- [20] "What is wltp and how does it work?"
- [21] A. Bandyopadhyay, L. Wang, V. K. Devabhaktuni, R. Yang, and R. C. Green, "Assessing the effect of fast charging on the battery health of plug-in hybrid electric vehicles," in *2012 IEEE Power and Energy Society General Meeting*, July 2012, pp. 1–8.

- [22] D. T. Gladwin, C. R. Gould, D. A. Stone, and M. P. Foster, "Viability of second-life use of electric and hybrid electric vehicle battery packs," in *IECON 2013 - 39th Annual Conference of the IEEE Industrial Electronics Society*, Nov 2013, pp. 1922–1927.
- [23] M. Murnane and A. Ghazel, "A closer look at state of charge (soc) and state of health (soh) estimation techniques for batteries," 2017.
- [24] E. Hosseinzadeh, R. Genieser, D. Worwood, A. Barai, J. Marco, and P. Jennings, "A systematic approach for electrochemical-thermal modelling of a large format lithium-ion battery for electric vehicle application," *Journal of Power Sources*, vol. 382, pp. 77 – 94, 2018. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0378775318301411>
- [25] H. Chaoui, N. Golbon, I. Hmouz, R. Souissi, and S. Tahar, "Lyapunov-based adaptive state of charge and state of health estimation for lithium-ion batteries," *IEEE Transactions on Industrial Electronics*, vol. 62, no. 3, pp. 1610–1618, March 2015.
- [26] Y. K. Tan, J. C. Mao, and K. J. Tseng, "Modelling of battery temperature effect on electrical characteristics of li-ion battery in hybrid electric vehicle," in *2011 IEEE Ninth International Conference on Power Electronics and Drive Systems*, Dec 2011, pp. 637–642.
- [27] D. Whitley, "A genetic algorithm tutorial," *Statistics and Computing*, vol. 4, no. 2, pp. 65–85, Jun 1994. [Online]. Available: <https://doi.org/10.1007/BF00175354>
- [28] J. Chen, Q. Ouyang, C. Xu, and H. Su, "Neural network-based state of charge observer design for lithium-ion batteries," *IEEE Transactions on Control Systems Technology*, vol. 26, no. 1, pp. 313–320, Jan 2018.
- [29] G. May and A. El-Shahat, "Battery-degradation model based on the ann regression function for ev applications," in *2017 IEEE Global Humanitarian Technology Conference (GHTC)*, Oct 2017, pp. 1–3.
- [30] M. Ismail, R. Dlyma, A. Elrakaybi, R. Ahmed, and S. Habibi, "Battery state of charge estimation using an artificial neural network," in *2017 IEEE Transportation Electrification Conference and Expo (ITEC)*, June 2017, pp. 342–349.
- [31] M. M. Ismail and M. A. M. Hassan, "The state of charge estimation for rechargeable batteries based on artificial neural network techniques," in *2013 International Conference on Control, Decision and Information Technologies (CoDIT)*, May 2013, pp. 733–739.
- [32] V. Novak, I. Perfiljeva, and J. Mockor, *Mathematical Principles of Fuzzy Logic*, 01 1999.
- [33] D. Jiani, L. Zhitao, W. Youyi, and W. Changyun, "A fuzzy logic-based model for li-ion battery with soc and temperature effect," in *11th IEEE International Conference on Control Automation (ICCA)*, June 2014, pp. 1333–1338.
- [34] A. Zenati, P. Desprez, and H. Razik, "Estimation of the soc and the soh of li-ion batteries, by combining impedance measurements with the fuzzy logic inference," in *IECON 2010 - 36th Annual Conference on IEEE Industrial Electronics Society*, Nov 2010, pp. 1773–1778.
- [35] F. Codeca, S. M. Savaresi, and G. Rizzoni, "On battery state of charge estimation: A new mixed algorithm," in *2008 IEEE International Conference on Control Applications*, Sep. 2008, pp. 102–107.

- [36] F. N. Dişçi, Y. El-Kahlout, and A. Balıkcı, “Li-ion battery modeling and soc estimation using extended kalman filter,” in *2017 10th International Conference on Electrical and Electronics Engineering (ELECO)*, Nov 2017, pp. 166–169.
- [37] Z. Cheng, J. Lv, Y. Liu, and Z. Yan, “Estimation of state of charge for lithium-ion battery based on finite difference extended kalman filter,” *Journal of Applied Mathematics*, vol. 2014, 03 2014.
- [38] D. Stroe, M. Swierczynski, A. Stroe, V. Knap, R. Teodorescu, and S. J. Andreassen, “Evaluation of different methods for measuring the impedance of lithium-ion batteries during ageing,” in *2015 Tenth International Conference on Ecological Vehicles and Renewable Energies (EVER)*, March 2015, pp. 1–8.
- [39] “*Measuring Battery State-of-charge*”, 2017, consultado em Outubro, 2018, disponível em: “https://batteryuniversity.com/learn/article/how_to_measure_state_of_charge”,.
- [40] “*Battery and Energy Technologies*”, 2005, consultado em Dezembro, 2018, disponível em: “<https://www.mpoweruk.com/testing.htm>”,.
- [41] G. Fathoni, S. A. Widayat, P. A. Topan, A. Jalil, A. I. Cahyadi, and O. Wahyunggoro, “Comparison of state-of-charge (soc) estimation performance based on three popular methods: Coulomb counting, open circuit voltage, and kalman filter,” in *2017 2nd International Conference on Automation, Cognitive Science, Optics, Micro Electro-Mechanical System, and Information Technology (ICA-COMIT)*, Oct 2017, pp. 70–74.
- [42] “*The Solver Add-in in Excel*”, 2015, disponível em: “<https://support.office.com/en-us/article/load-the-solver-add-in>”,.
- [43] T. Huria, M. Ceraolo, J. Gazzarri, and R. Jackey, “High fidelity electrical model with thermal dependence for characterization and simulation of high power lithium battery cells,” in *2012 IEEE International Electric Vehicle Conference*, March 2012, pp. 1–8.