

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Dissertação de Mestrado

Otimização das Operações de Compra e
Venda de Energia por parte de Veículos
Elétricos *Plug-in* e Modelagem de Bateria
com Estimação de Estado de Carga via
Filtro de Kalman *Unscented*

Débora de Souza Martins

VITÓRIA – ES

2020

Débora de Souza Martins

**Otimização das Operações de Compra e Venda de
Energia por parte de Veículos Elétricos *Plug-in* e
Modelagem de Bateria com Estimação de Estado de
Carga via Filtro de Kalman *Unscented***

Dissertação de Mestrado apresentada ao
Programa de Pós-Graduação em Engenharia
Elétrica do Centro Tecnológico, da Uni-
versidade Federal do Espírito Santo, como
requisito parcial para a obtenção do Grau de
Mestre em Engenharia Elétrica

Orientador: Profa. Dra. Jussara Farias Fardin
Coorientador: Prof. Dr. Augusto César Rueda
Medina

VITÓRIA – ES

2020

Ficha catalográfica disponibilizada pelo Sistema Integrado de
Bibliotecas - SIBI/UFES e elaborada pelo autor

M379o Martins, Débora de Souza, 1992-
Otimização das operações de compra e venda de energia por
parte de veículos elétricos plug-in e modelagem de baterias com
estimação de estado de carga por filtro de Kalman unscented /
Débora de Souza Martins. - 2020.
90 f. : il.

Orientadora: Jussara Farias Fardin.
Coorientador: Augusto César Rueda Medina.
Dissertação (Mestrado em Engenharia Elétrica) -
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Veículos elétricos. 2. Sistemas de energia elétrica. 3.
Baterias elétricas. 4. Redes elétricas inteligentes. I. Fardin,
Jussara Farias. II. Medina, Augusto César Rueda. III.
Universidade Federal do Espírito Santo. Centro Tecnológico. IV.
Título.

CDU: 621.3

Débora de Souza Martins

Otimização das Operações de Compra e Venda de
Energia por parte de Veículos Elétricos *Plug-in* e
Modelagem de Bateria com Estimação de Estado de
Carga via Filtro de Kalman *Unscented*

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico, da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do Grau de Mestre em Engenharia Elétrica

Aprovada em 1 de Junho de 2020


COMISSÃO EXAMINADORA:



Profª. Dra. Jussara Farias Fardin
Universidade Federal do Espírito Santo
Orientador



Prof. Dr. Augusto César Rueda Medina
Universidade Federal do Espírito Santo
Coorientador



Prof. Dr. José Leandro Félix Salles
Universidade Federal do Espírito Santo
Examinador



Prof. Dr. Joel David Melo Trujillo
Universidade Federal do ABC
Examinador

Dedico este trabalho ao meu afilhado Bernardo e ao meu sobrinho Victor Augusto.

AGRADECIMENTOS

Antes de tudo, agradeço a Deus pela oportunidade da vida e pelo privilégio de poder me dedicar aos estudos e realizar mais essa grande etapa em minha carreira.

Agradeço à Jussara e ao Augusto por acreditarem em meu trabalho, pela amizade construída neste período e pela orientação paciente e cuidadosa com meu processo de aprendizagem.

Agradeço à minha mãe por me inspirar a sempre fazer o meu melhor e ao meu pai, por não medir esforços para me apoiar em todas as fases da elaboração deste trabalho. Eles nunca me deixam esmorecer.

Aos queridos amigos do LEPAC, agradeço por tornarem o período do mestrado mais leve e as manhãs de sexta-feira mais gostosas, com o café compartilhado.

Minha eterna gratidão às minhas amigas Thais, Catherine, Mariana e Fabiana pelas longas conversas sobre a pós-graduação, pelas risadas de doer a barriga e por me ajudarem a lidar com as etapas difíceis (e fáceis) da vida e da área de pesquisa.

Ao Victor, agradeço pelo carinho, apoio e compreensão durante todo esse período e pela parceria na vida.

Agradeço à Lorrane, que dividiu a casa, as angústias e as felicidades durante o período do mestrado e se tornou uma irmã.

Às minhas amigas mais antigas, as amoras, agradeço pela torcida e pela compreensão de minhas ausências nos períodos críticos do projeto.

Aos demais queridos amigos e familiares que sempre estão de braços abertos e vibram a cada boa novidade que a vida nos traz, muito obrigada.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Estamos dando um sinal ao mundo de que, em um futuro bem próximo, o petróleo não será motivo para que haja guerra no mundo ou para que um país consumidor não invada um país produtor.

(Luiz Inácio Lula da Silva)

RESUMO

O aumento na utilização de veículos elétricos fomenta os estudos na área de integração de veículos na rede elétrica onde o objetivo é obter respostas sobre formas de tratar a inserção desta tecnologia na sistema elétrico. Ainda neste contexto, surge um novo paradigma no mercado de energia devido à possibilidade dos usuários de veículos elétricos venderem e comprarem energia do sistema. No presente trabalho, apresenta-se uma metodologia de otimização das operações de compra e venda de energia, com o objetivo de minimizar os custos e maximizar o lucro do ponto de vista dos veículos elétricos em dois cenários. No primeiro cenário, considera-se um único veículo elétrico; no segundo cenário, um grupo de veículos elétricos. Além disso, apresenta-se também uma modelagem de baterias, com obtenção de variáveis de decisão e estimação do estado de carga das baterias via Filtro de Kalman Unscented. O gerenciamento da interação entre os veículos elétricos e a rede elétrica baseia-se, principalmente, no valor do estado de carga da bateria dos veículos elétricos. É importante que o sistema de gerenciamento da bateria forneça informações precisas sobre os estados da bateria do veículo, para que a otimização não submeta as baterias a regimes não adequados de funcionamento. Na presente dissertação a otimização em V2G e a modelagem da bateria não estão integradas. Por isso, as avaliações são feitas separadamente. Os resultados obtidos atendem bem aos objetivos tanto da metodologia de otimização quanto da modelagem de baterias, indicando que estas metodologias são promissoras para a abordagem deste tipo de problema.

ABSTRACT

The increase of the use of electric vehicles encourages studies in the area of integrating these new vehicles in the electric grid: Vehicle to Grid and Grid to Vehicle. The objective is to obtain answers on ways to deal with the insertion of electric vehicles in the electric system. Still in this context, a new paradigm appears in the energy market due to the possibility for electric vehicle users to sell and buy energy from the system. In the present work, a methodology for optimizing energy purchase and sale operations is presented, with the objective of minimizing costs and maximizing profit from the point of view of vehicles in two scenarios. In the first scenario, a single electric vehicle is considered; in the second scenario, a group of electric vehicles. In addition, a battery modeling is also presented, obtaining decision variables and estimating the charge state of the batteries via Unscented Kalman Filter. Decision making within the system that involves the interaction between electric vehicles and the electric grid is based, mainly, on the value of the state of charge of the battery of electric vehicles. It is important that the battery management system provides accurate information about the vehicle's battery status, so that optimization does not subject batteries to improper operating regimes. In this work, the evaluation of the optimization methodology and the battery modeling are not integrated therefore both systems are carried out separately. The results obtained serve well the objectives of both the optimization methodology and battery modeling. Because of that, it's noted that these methodologies are promising to address this type of problem.

Keywords: Electric Vehicle, Vehicle to Grid, Grid to Vehicle, Battery Management System.

LISTA DE ILUSTRAÇÕES

Figura 1 – Fluxograma do Algoritmo para o Cenário 1	41
Figura 2 – Fluxograma do Algoritmo do Cenário 2	44
Figura 3 – Circuito Equivalente da Bateria	47
Figura 4 – Esquemático do Modelo de Bateria	52
Figura 5 – Curva Horária de Preço de Energia - Espanha	55
Figura 6 – Energia em kWh e Custo em € para Hyundai $SoC = 0,55$ e preço fixo de energia	57
Figura 7 – Custo em € para Hyundai $SoC = 0,55$ conforme Preço Horário da Energia	57
Figura 8 – Energia em kWh e Custo em € para Hyundai $SoC = 0,60$ e preço fixo de energia	58
Figura 9 – Custo em € para Hyundai $SoC = 0,60$ conforme Preço Horário da Energia	58
Figura 10 – Energia em kWh e Lucro em € para Hyundai $SoC = 0,90$ e preço fixo de energia	59
Figura 13 – Lucro em € para Hyundai $SoC = 0,98$ conforme Preço Horário da Energia	59
Figura 11 – Lucro em € para Hyundai $SoC = 0,90$ conforme Preço Horário da Energia	60
Figura 12 – Energia em kWh e Lucro em € para Hyundai $SoC = 0,98$ e preço fixo de energia	60
Figura 14 – Lucro - Subgrupo 1	62
Figura 15 – Custo - Subgrupo 2	62
Figura 16 – Corrente de Entrada - FUDS	64
Figura 17 – Corrente de Entrada - US06	65
Figura 18 – Erros de estimação do SoC para testes a $25^{\circ}C$	65
Figura 19 – SoC Real - Base FUDS	67
Figura 20 – SoC Real - Base US06	68
Figura 21 – SoC Real e Estimado com UKF - FUDS	68
Figura 22 – SoC Real e Estimado com UKF - US06	69
Figura 23 – SoC Real e SoC Estimado com UKF no HYSDEL - FUDS	70
Figura 24 – Saídas binárias do modelo HYSDEL - FUDS	71
Figura 25 – SoC Real e SoC Estimado com UKF no HYSDEL - US06	71
Figura 26 – Saídas binárias do modelo HYSDEL - US06	72
Figura 27 – Erro Percentual de Estimação do SoC - FUDS	73

Figura 28 – Erro Percentual de Estimação do SoC - US06	73
--	----

LISTA DE TABELAS

Tabela 1 – Parâmetros da Equação Geral $SoC - OCV$ conforme o tipo de bateria	48
Tabela 2 – Características do Hyundai Cona para vários valores de SoC no Cenário 1	56
Tabela 3 – Características dos EVs Avaliados no Cenário 2	61
Tabela 4 – Parâmetros de Circuito Bateria INR 18650-20R a $25^{\circ}C$	66
Tabela 5 – RMSE e MAE para estimação do SoC utilizando Equação (3.24) . . .	69
Tabela 6 – Valores de SoC para a definição do EG	70
Tabela 7 – RMSE e MAE para estimação do SoC utilizando expressão 3.24 e HYSDEL	72
Tabela 8 – Intervalos de valores de SoC devido ao erro percentual	74
Tabela 9 – Características Peugeot e-2008 SUV	84
Tabela 10 – Características Kia e-Niro	84
Tabela 11 – Características BMW i3	84
Tabela 12 – Características Renault Zoe ZE50	85
Tabela 13 – Características Nissan Leaf	85
Tabela 14 – Características Hyundai Kona	85

LISTA DE ABREVIATURAS E SIGLAS

AMPL	<i>A Mathematical Programming Language</i>
BEV	<i>(Battery Electric Vehicle)</i> Veículo Elétrico a Bateria
BMS	<i>(Battery Management System)</i> Sistema de Gerenciamento de Bateria
BNEF	<i>Bloomberg New Energy Finances</i>
CDS	<i>(Charge and Discharge Stations)</i> Estações de Carga e Descarga
DHA	<i>(Discrete Hybrid Automata)</i> sistemas Autômatos Híbridos Discretos
DoD	<i>(Deep of Discharge)</i> Afundamento de Carga
EEA	<i>(European Environmental Agency)</i> Agência Europeia de Meio Ambiente
EES	<i>(Energy Storage System)</i> Sistema de Armazenamento de Energia
EG	<i>(Event Generator)</i> Gerador de Evento
EP	Erro Percentual
EV	<i>(Electric Vehicle)</i> Veículo Elétrico
FCEV	<i>(Fuel Cell Electric Vehicle)</i> Veículo Elétrico a Célula Combustível
FSM	<i>(Finite State Machine)</i> Máquina de Estado Finita
FUDS	<i>Federal Urban Driving Schedule</i>
G2V	<i>(Grid to Vehicle)</i> Rede para Veículo
HEV	<i>(Hybrid Electric Vehicle)</i> Veículo Elétrico Híbrido
HYSDEL	<i>HYbrid System DEscription Language</i>
IEA	<i>(International Energy Agency)</i> Agência Internacional de Energia
IEC	<i>(International Electrotechnical Commission)</i> Comissão Internacional de Eletrotécnica
MAE	<i>(Mean Absolute Error)</i> Erro Médio Absoluto
MATLAB	<i>MATrix LABoratory</i>

MLD	(<i>Mixed Logical Dynamics</i>) sistemas Dinâmicos de Lógicas Mistas
MS	(<i>Mode Selector</i>) Seletor de Modo
OCV	(<i>Open Circuit Voltage</i>) Tensão de Circuito Aberto
PEV	(<i>Plug-in Electric Vehicle</i>) Veículo Elétrico Plugável
PHEV	(<i>Plug-in Hybrid Electric Vehicle</i>) Veículo Elétrico a Bateria Plugável
PWA	(<i>Piecewise Affine System</i>) Sistema Afim por Partes
RMSE	(<i>Root Mean Square Error</i>) Raiz do Erro Quadrático Médio
SAS	(<i>Switched Affine System</i>) Sistema de Comutação Afim
SoC	(<i>State of Charge</i>) Estado de Carga
SoH	(<i>State of Health</i>) Estado de Saúde
UKF	(<i>Unscented Kalman Filter</i>) Filtro de Kalman Unscented
UT	(<i>Unscented Transform</i>) Transformada Unscented
V2G	(<i>Vehicle to Grid</i>) Veículo para a Rede
V2H	(<i>Vehicle to Home</i>) Veículo para Casa
V2V	(<i>Vehicle to Vehicle</i>) Veículo para Veículo

LISTA DE SÍMBOLOS

Símbolos - Modelagem da Otimização

SoC_V	Valor de estado de carga mínimo para o qual o EV pode vender energia para a rede elétrica
SoC_C	Valor de estado de carga mínimo para o qual o EV deve comprar energia para a rede elétrica
ν	Velocidade do EV
δ_{CDS}	Distância constante entre as CDS
$Custo_D$	Custo de Deslocamento
$Custo_{DoD}$	Custo de Afundamento de Carga
Ω_{EV}	Conjunto de EVs
Ω_{CDS}	Conjunto de CDS
V_ε	Valor de venda da energia
P_ε	Valor de compra da energia
δ_{EV}	Distância de cada EV á cada CDS
L_{DoD}	Número de ciclos de carga e descarga da bateria a partir da taxa de DoD
L_N	Número de ciclos de carga e descarga da bateria em condições nominais
η_{DoD}	Fator de efeito do DoD
ε_S	Energia armazenada na bateria
DoD_{VEN}	Afundamento de carga para a condição de EV vendendo energia
DoD_{COM}	Afundamento de carga para a condição de EV comprando energia
η_{EV}	Consumo do EV no deslocamento
ε_{for}	Energia fornecida pelo EV
ε_{rec}	Energia recebida pelo EV

δ_{max}	Distância máxima que pode ser percorrida pelo EV
ε_{TES}	Capacidade máxima da bateria do EV em (kWh)
SoC_{maxV}	SoC máximo para o cálculo da distância máxima que o EV pode percorrer para vender energia
Qnt_{CDS}	Quantidade de CDS disponíveis
Qnt_{EV}	Quantidade de EVs
SoC_{maxSoH}	Valor máximo de SoC no intervalo ideal para manutenção do SoH das baterias
SoC_{minSoH}	Valor mínimo de SoC no intervalo ideal para manutenção do SoH das baterias

Símbolos - Modelagem da Bateria

R_0	Resistência do circuito da bateria
R_1	Resistência do ramo RC
C_1	Capacitância do ramo RC
V_{RC}	Queda de tensão no ramo RC
Q_R	Capacidade máxima de transferência de energia da bateria em Ah
V_T	Tensão terminal do circuito da bateria
i_L	Corrente do circuito da bateria
μ_x	Média de x
P_x	Covariância de x
$\hat{C}_{xy}^{(k)}$	Covariância estimada entre x e y na $k - esima$ iteração
$E(y^k)$	Momento de ordem k de y
$\mathcal{Y}$	Pontos <i>sigma</i> de y
$\mathcal{X}$	Pontos <i>sigma</i> de x
λ	Parâmetro de escalamento do UKF
κ	Parâmetro secundário de escalamento do UKF
α	Parâmetro de espalhamento dos pontos <i>sigma</i> do UKF

β	Parâmetro para incorporar conhecimento <i>a priori</i> no UKF
$K^{(k)}$	Ganho de Kalman na $k - esima$ iteração
T_S	Tempo de amostragem dos dados
δ_1 a δ_6	Variáveis de decisão do EG
u_1	Entrada discreta do modelo da bateria
e_k	Erro de estimação
E_k	Erro percentual de estimação

SUMÁRIO

1	INTRODUÇÃO	19
1.1	Justificativa e Motivação	19
1.2	Objetivos	23
1.3	Trabalhos Publicados	24
1.4	Organização da Dissertação	24
2	REVISÃO TEÓRICA	25
2.1	Interação Bidirecional de Veículos Elétricos com a Rede Elé- trica: <i>Vehicle to Grid</i> e <i>Grid to Vehicle</i>	25
2.1.1	Veículos Elétricos	26
2.1.2	Tipos de Estações de Carregamento	27
2.2	Otimização	28
2.3	Modelagem de Baterias	30
2.3.1	Filtro de Kalman	30
2.3.2	Filtro de Kalman Unscented	32
2.3.2.1	Transformada Unscented	33
2.3.2.2	Etapas de Funcionamento do UKF	34
3	METODOLOGIA	37
3.1	Otimização da Interação entre EV e Estações de Carga e Des- carga de Energia	37
3.1.1	Considerações gerais	38
3.1.1.1	Definição do Custo de Deslocamento	39
3.1.1.2	Definição do Custo de Afundamento de Carga da Bateria (DoD) .	39
3.1.2	Cenário 1: Um único EV	40
3.1.2.1	Funções Objetivo	41
3.1.2.2	Limitações das Variáveis de Decisão	42
3.1.2.3	Formulação do problema de otimização no Cenário 1	43
3.1.3	Cenário 2: Grupo de EVs	43
3.1.3.1	Funções Objetivo	44
3.1.3.2	Limitações das Variáveis de Decisão	45
3.1.3.3	Formulação do problema de otimização no Cenário 2	45
3.2	Modelagem da Bateria do EV	46
3.2.1	Modelagem de Circuito	46

3.2.2	Relação entre Estado de Carga e Tensão de Circuito Aberto (SoC-OCV)	47
3.2.3	Aplicação do Filtro de Kalman Unscented	49
3.2.4	Modelagem no <i>Software</i> HYSDEL	49
3.2.5	Métricas de Erro de Estimção dos Estados	52
4	RESULTADOS E DISCUSSÕES	53
4.1	Otimização V2G e G2V	53
4.1.1	Definição dos parâmetros	53
4.1.1.1	Definição do valor de compra e venda de energia	54
4.1.1.2	Definição do preço da bateria	55
4.1.1.3	Definição do tipo de CDS	55
4.1.2	Cenário 1	56
4.1.3	Cenário 2	60
4.2	Modelo de Bateria	63
4.2.1	Definição de Parâmetros de Circuito	66
4.2.2	SoC Real	66
4.2.3	Avaliação da Utilização da Equação da Relação SoC-OCV . .	68
4.2.4	Modelo HYSDEL	69
4.2.5	Análise do Erro Percentual e Tomada de Decisão	72
5	CONCLUSÕES E TRABALHOS FUTUROS	75
5.1	Conclusões	75
5.2	Trabalhos Futuros	77
	REFERÊNCIAS	78
	ANEXOS	83
	ANEXO A – MODELOS DE VEÍCULOS ELÉTRICOS	84
	ANEXO B – MATRIZES MLD DO MODELO DA BATERIA	86

1 INTRODUÇÃO

1.1 Justificativa e Motivação

A mobilidade por meio de veículos elétricos está se expandindo rapidamente em todo o mundo. De acordo com o relatório anual de 2019 da Agência Internacional de Energia (*International Energy Agency - IEA*), em 2018 a frota global de veículos elétricos (*Electric Vehicle - EV*) aumentou em cerca de 2 milhões de veículos em relação ao ano anterior, ultrapassando, assim, o valor total de 5,1 milhões de EVs sendo utilizados em todo o mundo. A China continua sendo o maior mercado mundial desses novos veículos, seguido pela Europa e pelos Estados Unidos [1]. Em 2016, a Agência Europeia do Meio Ambiente (*European Environmental Agency - EEA*) estabeleceu metas para expandir o número de EVs no continente europeu, substituindo todos os veículos a combustíveis fósseis por elétricos nas cidades europeias até 2050 [2].

Com o aumento do uso dessa tecnologia, esperam-se mudanças consideráveis na rede elétrica, desde o aumento de carga causado pelo carregamento massivo de EVs até a possibilidade de utilizar a energia armazenada nas baterias dos veículos para evitar interrupções do fornecimento de energia elétrica. Isso quer dizer que, além de uma carga, os EVs podem ser utilizados como uma fonte complementar de energia do ponto de vista da rede [3]. Entretanto, se a operação deste novo elemento não for controlada, sua inserção como carga ou como fonte pode gerar instabilidade e diminuir a confiabilidade da rede elétrica [4].

Surge então o conceito de *Vehicle to Grid (V2G)*, inicialmente apresentado por Kempton et al. em [5] como a interação bidirecional entre o EV e a rede elétrica. Posteriormente, surgem os termos *Grid to Vehicle (G2V)*, *Vehicle to Home (V2H)*, *Vehicle to Vehicle (V2V)* e se inicia a diferenciação da nomenclatura conforme o fluxo de energia. O objetivo dessas áreas de estudo é a formulação de resoluções para questões em relação à interação entre EVs e o sistema elétrico e EVs [6], [3].

Nesse contexto, alguns trabalhos têm sido desenvolvidos com objetivo de otimizar a utilização de EVs do ponto de vista da rede elétrica visando o aproveitamento para serviços ancilares, como regulação de frequência, filtragem de harmônicos e até mesmo suprimento de energia em momentos de blecaute [7]. Liu et al. apresenta uma estratégia de despacho ótimo para regulação de frequência através da inserção de EVs na rede [8]; e Hemmati et al. propõe uma interação ótima em V2G e V2H para que EVs forneçam energia para a rede elétrica e para uma construção, em momentos em que a carga seja elevada e a geração distribuída forneça pouca energia.

Outra forma de abordar a questão é a otimização do ponto de vista dos EVs. Além das mudanças esperadas na rede elétrica, surge um novo paradigma no mercado de energia. Os proprietários de EVs poderão vender energia para a rede, bem como deverão comprar energia para utilizar na locomoção do seu veículo. Nesse contexto, os custos estão relacionados principalmente ao desgaste da bateria ocasionado pelo afundamento de carga e elevado ritmo de ciclos de carga e descarga que um sistema em V2G pode proporcionar [6].

No presente trabalho, apresenta-se uma proposta de otimização, do ponto de vista dos donos de EV, em dois cenários. O primeiro deles corresponde a um veículo em um trajeto retilíneo, na estrada, com diversas estações de carga e descarga (*Charge and Discharge Stations - CDS*) que podem fornecer e receber energia do EV. O segundo cenário consiste em um grupo de EVs que irá fornecer ou receber energia das CDS. Em ambos os casos, a variável otimizada é a energia, ou seja, obtém-se os valores de energia adequados que serão transferidos do EV ou do grupo de EVs para a rede elétrica ou o inverso, para que se obtenha os valores ótimos de custo ou de lucro do ponto de vista dos donos de EVs. O algoritmo fornece, portanto, a maximização da variável de energia para obter o máximo lucro e a minimização da energia para obter o mínimo custo possível, considerando as limitações das baterias dos EVs. Obtém-se então os valores de custo ou lucro na compra ou venda de energia em cada uma das CDS, respectivamente, além da quantidade ótima de energia a ser transferida em cada um dos casos. No segundo cenário, além das limitações individuais das baterias de cada EV, considera-se as limitações para recebimento e fornecimento de energia das próprias CDS e calcula-se o custo e lucro ótimos para o grupo de veículos em cada uma das estações.

A operação dos processos de otimização é realizada com os *Softwares* MATLAB (*MATrix LABoratory*) e AMPL (*A Mathematical Programming Language*). Os parâmetros de entrada, como as taxas de consumo de energia dos EVs, o tempo de carregamento e o estado percentual de carga da bateria do EV, são definidos no MATLAB e transferidos para o AMPL, que realiza o processamento da otimização baseado no algoritmo MINOS. Esse algoritmo, construído na linguagem Fortran, é utilizado para a resolução ótima de sistemas restritos lineares e não-lineares [9]. Uma vez obtida a solução, os dados de resultado retornam para o MATLAB para a construção de gráficos.

As entradas para a avaliação da otimização dependem do tipo de EV e suas respectivas características, como consumo de energia por quilômetro, capacidade da bateria e a sua autonomia, ou seja, a distância máxima a ser percorrida a partir do quanto de energia se tem na bateria. Optou-se por utilizar dados de EVs reais e já comercializados para priorizar a aproximação com a realidade.

A definição de qual EV deve fornecer ou receber energia na metodologia de otimização apresentada, bem como nas diversas propostas de otimização e controle na literatura,

é feita baseada nos valores do estado de carga (*State of Charge (SoC)*) da bateria dos veículos. Assim, é necessário que esses valores sejam caracterizados adequadamente e representem com exatidão a quantidade de energia armazenada nas baterias, no instante de tempo atual. Isso prevenirá que o sistema de otimização gere tomadas de decisão que submetam as baterias a condições de desgaste que interfiram no tempo de vida útil das mesmas [10], [11].

Considerando isso, no presente trabalho, apresenta-se uma modelagem de bateria com monitoramento do SoC em tempo real [12]. A avaliação dessa modelagem é feita a partir de uma base de dados experimentais disponível no *site* do laboratório de pesquisa em baterias da Universidade de Maryland. Uma bateria de Íon-lítio foi ensaiada sob condições controladas de temperatura, corrente e tensão, para a obtenção dos valores de SoC. Com essas informações é possível avaliar se a modelagem apresentada fornece os valores de SoC adequados.

Entretanto, a bateria referente aos dados experimentais utilizados na avaliação da modelagem não é a mesma presente em todos os modelos de EVs. Por isso, os valores obtidos com o experimento para a validação dessa modelagem não são utilizados como entrada para a otimização. Isso não traz prejuízos para a avaliação da otimização, uma vez que seu comportamento não depende da precisão do SoC. A precisão do SoC é importante para que a bateria responda adequadamente e não tenha seu ciclo de vida afetado. Para a avaliação da otimização foram definidos valores arbitrários de SoC. Portanto, a segunda parte do trabalho é avaliada separadamente da metodologia de otimização em V2G e G2V e consiste em uma modelagem de baterias para o monitoramento do SoC.

O monitoramento do SoC é um desafio atual para os pesquisadores na área de sistemas de armazenamento de energia (*Energy Storage System - ESS*). Não é possível medir diretamente o SoC e, por isso, esse estado deve ser estimado a partir de grandezas do sistema, como tensão e corrente [13]. O SoC de uma bateria depende de fatores externos, como a temperatura sob a qual o sistema está exposto, além do tempo de utilização e do estado de saúde da bateria (*State of Health - SoH*) [14], [15]. Tendo isso em vista, elabora-se um sistema de gerenciamento de baterias (*Battery Management System - BMS*) com o objetivo de indicar o SoC precisamente [12].

Muitas são as possíveis metodologias empregadas para a estimação de estados de um sistema. O método de Contagem de Coulomb combinado com o método da tensão de circuito aberto (*Open Circuit Voltage - OCV*) é uma abordagem consolidada na literatura para a estimação do SoC, além de ser uma forte base para a implementação de métodos mais modernos para estimar os estados importantes das baterias. Entretanto, para que seja possível aplicá-lo, é necessário saber o valor inicial do SoC. Esse valor pode ser modificado por fatores externos, como variação de temperatura, e pelo uso contínuo da bateria. Dessa forma, por não ser um método recursivo, um erro inicial é propagado nas inferências

seguintes [16], [11].

Outra metodologia adotada consiste em considerar a bateria uma “caixa preta” e, por meio de experimentos controlados, obter dados suficiente para reconstruir o comportamento do sistema a partir de aprendizado de máquinas [17], [18]. Neste caso, porém, o grande problema é o custo computacional nos processos de treinamento e teste dos sistemas [19]. Frente a isso, o Filtro de Kalman Unscented (*Unscented Kalman Filter - UKF*) se apresenta como uma forma vantajosa para a resolução desta questão, por ser recursivo, auto ajustável e robusto à não linearidades do sistema [12], [20].

Para a aplicação do UKF é necessário um modelo de circuito do qual se possa extrair equações dos estados a serem estimados e da variável observável do sistema. Com essas equações se obtém o valor de OCV e se realiza a inferência do SoC conforme a curva *SoC-OCV*. Pode-se utilizar uma base de dados experimentais da referida bateria para se obter a curva *SoC-OCV*, como é feito por Zheng et al. em [12]; ou partir de uma expressão matemática que generalize essa relação, como a apresentada por Zhang et al. em [11]. A segunda opção apresenta a vantagem de não ocupar dados de memória do sistema.

Tendo isso em vista, no presente trabalho, apresenta-se um modelo de bateria com estimação de estados por UKF utilizando a expressão matemática que generaliza a relação *SoC - OCV* apresentada por Zhang et al. em [11]. Para a avaliação do modelo, os mesmos dados experimentais apresentados por Zheng et al. em [12] são aplicados no sistema afim de avaliar se a utilização da expressão matemática na relação *SoC - OCV* apresenta desvantagens na estimação dos estados.

Outro importante aspecto analisado para a construção do modelo de bateria é o fato de que implementar um sistema em V2G e G2V requer análises de variáveis contínuas e discretas. A partir das variáveis contínuas é possível definir valores discretos de variáveis de decisão. Por exemplo, a definição se o EV irá se conectar ou não à rede é representada por variáveis discretas. Entretanto, para definir essas condições são analisadas variáveis contínuas como o estado de carga das baterias e a quantidade de energia a ser transferida do EV para o sistema elétrico ou vice-versa. Sistemas que contém variáveis contínuas e discretas são definidos como Sistemas Híbridos [21].

Sistemas híbridos englobam muitas formulações matemáticas diferentes como sistemas Dinâmicos de Lógicas Mistas (*Mixed Logical Dynamics - MLD*), sistemas Afins por Partes (*Piecewise Affine System - PWA*) e sistemas Autômatos Híbridos Discretos (*Discrete Hybrid Automata - DHA*). Essas subclasses são equivalentes sob determinadas condições [21].

O *Software* HYSDEL (*HYbrid System DEscription Language*) é uma ferramenta utilizada para realizar a equivalência matemática entre as diferentes formas de sistemas híbridos [22]. Considerando essa formulação, o modelo de baterias com estimação de

estados por UKF e relação matemática $SoC - OCV$ é implementado no HYSDEL. A implementação é feita no formato de sistema DHA e simulada, com o objetivo de obter variáveis de decisão a partir da análise das variáveis contínuas do sistema.

Este trabalho, portanto, se divide em duas partes que serão avaliadas separadamente: a primeira delas consiste na elaboração de um sistema de otimização do ponto de vista do EV e considerando as restrições das CDS em dois cenários; e a segunda parte consiste em um modelo DHA de bateria para obtenção de respostas contínuas e discretas, e com estimação de estados via UKF e equacionamento matemático para a curva $SoC - OCV$.

Sugere-se que, para a junção de ambas as contribuições, nos próximos trabalhos, seja feita a análise experimental das baterias presentes nos EVs. Assim, poderão ser obtidos os parâmetros a serem inseridos na modelagem de baterias apresentada neste trabalho e o SoC resultante poderá ser adequadamente utilizado como entrada da otimização.

1.2 Objetivos

O objetivo geral do trabalho se divide em duas partes: otimização e modelagem. A primeira consiste na elaboração de uma metodologia de otimização do ponto de vista do EV, considerando as limitações de recebimento e fornecimento de energia das CDS; a segunda parte trata da modelagem de baterias DHA, com variáveis contínuas e de decisão na saída. A estimação dos estados é feita por UKF e a relação $SoC - OCV$ é obtida através de uma equação matemática.

A partir disso, os objetivos específicos são:

- Especificar os cenários e as condições gerais para o sistema de otimização, do ponto de vista do EV;
- Analisar os custos que devem ser considerados para a elaboração da Função Objetivo de compra e de venda de energia em cada um dos cenários;
- Pesquisar os modelos de EVs atuais e selecionar, dentre eles, aqueles que serão utilizados na otimização;
- Construir a modelagem de baterias, desenvolvendo o modelo de circuito equivalente e os valores dos parâmetros;
- Implementar o UKF para a estimação de estados no modelo de circuito da bateria, utilizando uma equação matemática para representar a relação $SoC - OCV$.

1.3 Trabalhos Publicados

Durante o desenvolvimento deste projeto, foi publicado o artigo *Hybrid Model of Electric Vehicle* no 5th IEEE Southern Power Electronics Conference (SPEC) & 15th Brazilian Power Electronics Conference (COBEP). DOI: 10.1109/COBEP/SPEC44138.2019.9065399

1.4 Organização da Dissertação

No Capítulo 2, apresentam-se conceitos essenciais para a compreensão da proposta de otimização no contexto de V2G e G2V e para a modelagem da bateria com estimação do SoC em tempo real. No Capítulo 3, são apresentadas as metodologias de desenvolvimento de ambas as partes do trabalho: na Seção 3.1, verificam-se os cenários, as condições gerais e a definição dos custos utilizados na otimização; e na Seção 3.2, tem-se a apresentação da modelagem da bateria, considerando o circuito equivalente apresentado na literatura, o estimador UKF e a expressão matemática da curva $SoC - OCV$. No Capítulo 4 tem-se a avaliação da proposta de otimização e os resultados da modelagem de baterias, e no Capítulo 5, as conclusões gerais do trabalho, para ambas as partes, e os próximos passos para o desenvolvimento de trabalhos futuros.

2 REVISÃO TEÓRICA

Neste capítulo são apresentadas as teorias de base aplicadas ao presente trabalho. Inicialmente, apresentam-se os conceitos de V2G e G2V e como estão sendo feitas as padronizações sobre o carregamento de EVs. Em seguida, apresentam-se os fundamentos teóricos de otimização, bem como o *Software* utilizado para sua implementação. Apresenta-se, ainda, como é constituída a modelagem para sistemas de bateria e o embasamento matemático do estimador de estados por UKF.

2.1 Interação Bidirecional de Veículos Elétricos com a Rede Elétrica: *Vehicle to Grid* e *Grid to Vehicle*

O aumento na utilização de EVs que se carregam na rede elétrica traz vantagens climáticas em locais cuja matriz energética não depende de combustíveis fósseis. Entretanto, a ampliação na adesão desta tecnologia pode gerar um grande impacto nas redes de energia, que não foram projetadas para suportar esta nova carga. A estabilidade da rede e a qualidade de energia são os principais problemas derivados do processo descontrolado de carregamento das baterias de EVs [23].

Outro aspecto importante dos EVs é que, do ponto de vista do sistema de energia, podem ser entendidos como uma carga ou como um recurso energético para alimentar outras cargas do sistema [7]. Com isso, passa a existir a necessidade de estudar como a interação entre os EVs e a rede pode ser proveitosa do ponto de vista de suprir demandas de energia da rede e da minimização do impacto do crescente volume de carregamento de veículos.

O conceito V2G surgiu com objetivo de formular soluções para os problemas ocasionados pelo aumento na utilização de EVs, além de aproveitar, da melhor forma possível, os recursos que essa nova carga pode trazer [5], [7]. Esse conceito é compreendido como uma tecnologia de Redes Inteligentes (*Smart Grids*), pois envolve a implementação de recursos de comunicação e de otimização dentro do contexto de sistemas elétricos de energia [24].

V2G inicialmente foi compreendido como a interação entre o EV e a rede elétrica de forma bidirecional [5]. Posteriormente, surgiu o conceito de G2V, que indica a conexão através da qual as baterias dos veículos são carregadas a partir da rede elétrica, ou seja, o fluxo de energia é da rede elétrica para o EV [25]. Passa-se, portanto, a fazer a diferenciação

dos termos V2G e G2V para indicar o fluxo de energia na conexão: V2G passa a ser compreendido como a conexão entre o EV e a rede, com fluxo de energia do veículo para a rede elétrica [23].

Os EVs comercializados, nos dias de hoje, possuem diferentes tecnologias para atender aos diversos cenários de mercados mundiais. Na Subseção 2.1.1, apresentam-se os principais tipos de EVs já comercializados no mundo. Com essa comercialização, surgem também as estações de carregamento de diferentes tipos. Elas oferecem serviços e têm capacidades diferentes para cada consumidor comprar energia em livre mercado. Essas estações são explicadas na Subseção 2.1.2.

2.1.1 Veículos Elétricos

Os EVs são categorizados conforme a tecnologia com a qual eles são construídos. Os principais tipos são: Veículos Elétricos Híbridos (*Hybrid Electric Vehicle - HEV*); Veículos Elétricos Plugáveis (*Plug-in Electric Vehicle - PEV*), incluindo Veículos Elétricos a Bateria (*Battery Electric Vehicle - BEV*) e Veículos Elétricos Híbridos Plugáveis (*Plug-in Hybrid Electric Vehicle - PHEV*); e Veículos Elétricos a Célula Combustível (*Fuel Cell Electric Vehicle - FCEV*) [23]. Cada um dos tipos de veículos possui características específicas:

- **HEVs** possuem dois sistemas de acionamento complementares: um motor à gasolina e um motor elétrico. A alimentação é feita exclusivamente a partir da combustão da gasolina e da frenagem regenerativa. Dessa forma, estes veículos não podem ser recarregados pela rede elétrica.
- **BEVs** são acionados somente por motores elétricos. A alimentação das baterias é feita principalmente através de um sistema *plug-in*, conectado a uma fonte externa de eletricidade, geralmente a rede elétrica. Pode haver ainda, de forma complementar, um aproveitamento da energia na frenagem regenerativa.
- **PHEVs**, assim como os HEVs, são equipados com motores à combustão e motores elétricos, que funcionam de forma complementar. A diferença é que o funcionamento principal se dá no sistema bateria-motor. O motor à combustão é utilizado para recarregar a bateria ou substituir o motor elétrico quando a bateria estiver fraca. Além disso, esse tipo de EV possui um sistema *plug-in* e pode ser recarregado pela rede elétrica.
- **FCEVs** utilizam células a combustível para alimentar o motor elétrico. As células a combustível transformam continuamente energia química em energia elétrica e térmica, a partir do fornecimento de um combustível, no caso hidrogênio, e de um oxidante, no caso oxigênio. Estes EVs ainda estão em fase de desenvolvimento e possuem poucos postos de carregamento, quando comparado com os PEVs.

As baterias utilizadas nos PEVs normalmente são do tipo Íon-Lítio, por possuírem autodescarga baixa, alta durabilidade e grande resistência às intempéries do ambiente como altas temperaturas e poeira, além da possibilidade de serem carregadas rapidamente [23] [26] [27].

2.1.2 Tipos de Estações de Carregamento

A Comissão Internacional de Eletrotécnica (*International Electrotechnical Commission*) IEC 61851-1 apresentou regras para sistemas de carregamento de EVs. Foram definidos quatro modos cujas características se diferenciam conforme o tipo de recebimento de energia (se em corrente contínua ou alternada trifásica ou monofásica); o nível de tensão (entre 110V monofásico até 480V trifásico); presença ou ausência de aterramento e de linhas de controle para permitir uma comunicação mono ou bidirecional entre a estação de carregamento e o EV; e presença de proteção obrigatória para a instalação [28].

O primeiro tipo de carregamento é chamado de **Modo 1** e normalmente é realizado em áreas residenciais ou em estacionamentos onde os EVs permaneçam por muito tempo. A instalação neste modo conta com um sistema monofásico com capacidade de corrente de até 16A e tensão de 120V alternada. Este modo de carregamento fornece uma taxa de potência máxima de 3,7kW e não há definição obrigatória quanto a tipo de proteção da instalação [28].

O **Modo 2** é feito com uma taxa de transferência de potência maior que o **Modo 1**, de até 22kW. Isso quer dizer que o tempo de carregamento das baterias neste modo é menor que no **Modo 1**. Além disso, o **Modo 2** normalmente é utilizado em instalações públicas ou privadas e a instalação pode ser monofásica ou trifásica em corrente alternada, com valor máximo de 32A. Neste caso é obrigatória a presença de proteção específica para o cabo [28].

O **Modo 3** é definido como trifásico, em corrente alternada e tem elevada transferência de potência: acima de 22kW. A corrente máxima é acima de 32A e esse sistema é oferecido por entidades públicas, ou seja, controladas por instituições governamentais. Neste caso é obrigatória a instalação de um sistema de controle e de proteção específica para o cabeamento das tomadas [28].

O **Modo 4** consiste no fornecimento em corrente contínua, até 3,225A. A transferência de potência é a cima de 22kW e, assim como no **Modo 3**, o sistema é disponibilizado por entidades públicas. Essa categoria é subdividida em dois grupos: Nível 1 com tensão inferior a 500V, corrente inferior a 80A e potência em 40kW; e Nível 2 com tensão inferior a 500V, corrente inferior a 200A e potência em 100kW [28].

A IEC 61851 ainda definiu os plugs e tomadas para os correspondentes modos de carregamento. Para todos eles, exceto para o **Modo 1**, existem canais de comunicação

bidirecional para transferir informações do EV à estação de carregamento e vice-versa.

2.2 Otimização

Segundo Boyd, em [29], entende-se o problema de otimização como uma abstração do problema de escolher a melhor opção possível dentre um conjunto de candidatos. Pode-se compreender, então, como um processo pelo qual se determina o valor ótimo de uma grandeza, ou seja, o melhor valor possível considerando determinados critérios. A formulação matemática do problema de otimização consiste em:

$$\max(f(x)) \quad (2.1)$$

Sujeito à:

$$g_i(x) \leq b_i \quad (2.2)$$

Onde $i = 1, 2, \dots, m$; o vetor $x = x_1, x_2, \dots, x_n$ é a variável de otimização; a função $f : R^n \rightarrow R$ é a função objetivo; e as funções $g_i : R^n \rightarrow R$ são desigualdades que são chamadas de restrições; e b_i são os limites das restrições.

O vetor x^* é chamado de solução ótima se gerar a maior solução dentre todos os vetores que satisfazem as restrições. Isso quer dizer que: $\forall z$ com $g_1(z) \leq b_1, \dots, g_m(z) \leq b_m$, tem-se $f(z) \leq f(x^*)$.

Os sistemas de otimização podem ser lineares ou não-lineares, dependendo das expressões que caracterizam tanto a função objetivo quanto as restrições. Basta haver uma equação não linear para descrever qualquer destes elementos, que o sistema passa a ser considerado não-linear [29].

A construção das funções objetivo para cada cenário do sistema desenvolvido no presente trabalho, bem como a definição dos parâmetros e das variáveis de decisão são apresentados no Capítulo 3.

A otimização é realizada baseado na comunicação entre os *Softwares* MATLAB e AMPL. No MATLAB são realizados os tratamentos dos dados de entrada em matrizes. Essas informações são enviadas para o AMPL, onde ocorre todo o processo de otimização. Os resultados são recebidos novamente pelo MATLAB para a elaboração de gráficos para a análise.

O AMPL é uma ferramenta de modelagem e resolução de sistemas de otimização. Para utilizá-lo, tem-se uma linguagem específica de alto nível para descrever os dados de otimização, variáveis, objetivos e restrições. Essa linguagem permite que as expressões matemáticas sejam descritas de forma similar à linguagem matemática. Isso facilita a

adaptação do problema real na linguagem computacional, bem como a compreensão de problemas elaborados por outros autores.

O processamento da otimização pelo AMPL pode ser feito por diversos tipos de solucionadores, baseado no tipo de problema a ser tratado. Existem os algoritmos baseados em resoluções quadráticas, lineares e convexas para problemas de variáveis inteiras contínuas e mistas; os algoritmos para tratamentos de problemas não lineares contínuos, que encontram soluções locais e os algoritmos para problemas de números inteiros mistos.

No presente trabalho, utiliza-se o solucionador MINOS para a obtenção dos resultados da otimização. MINOS é um pacote computacional para resolução de problemas de otimização lineares e não lineares desenvolvido pelo Laboratório de Otimização de Sistemas da Universidade de Stanford. Ele foi inicialmente construído na linguagem Fortran 77 e posteriormente foi adaptado ao AMPL, em sua versão 5.1 [30] [9].

O MINOS é capaz de minimizar ou maximizar funções contínuas e diferenciáveis sujeitas a restrições lineares, não-lineares e limites superiores e inferiores simples. Sua utilização é adequada para programação linear e quadrática, e para encontrar algum ponto viável para um conjunto de igualdades e desigualdades. Se a função objetivo é convexa e as restrições são lineares, a solução obtida será um mínimo ou máximo global. Caso contrário, a solução então será um mínimo ou máximo local [9].

Para sistemas lineares, o MINOS resolve a otimização através do método SIMPLEX primal [31]. Neste método, assume-se que os pontos extremos de restrições são conhecidos e, a partir disso, calcula-se a as respostas da função objetivo para esses pontos. Em seguida, calcula-se a função objetivo para os elementos vizinhos dentro dos limites definidos. Se as respostas dos elementos vizinhos forem melhores, ou seja, se forem menores para uma função objetivo de minimização ou maiores para maximização, essas respostas são guardadas e comparadas com as respostas dos próximos elementos a serem calculados. Esse processo é interrompido até que um ponto extremo ideal seja encontrado ou se o caso ilimitado ocorrer [32].

O tratamento de problemas com funções objetivos não lineares e restrições lineares é realizado através do método de gradiente reduzido com aproximações através de quasi-Newton [31]. Assim, utiliza-se um método quasi-Newton para monitorar o gradiente da função objetivo e encontrar o mínimo ou máximo global.

Por fim, para problemas com restrições não lineares, o MINOS usa método Lagrangiano de restrição linear (*Linearly Constrained Lagrangian* - *LCL*) adaptado ao método de Robinson, que lineariza as restrições gerando subproblemas. O método de Robinson é de implementação complexa e torna as resoluções dos problemas um pouco mais restritivas. Entretanto, o MINOS relaxa as restrições linearizadas em etapas. Assim, se as restrições permanecerem inviáveis após cinco procedimentos de relaxamento consecutivos, o problema

original é declarado inviável [33].

2.3 Modelagem de Baterias

Para que seja possível a elaboração de sistemas de otimização envolvendo BEVs e PHEVs, é necessário um sistema de modelagem que forneça informações precisas [11]. Uma das informações mais importantes para a elaboração dos sistemas de otimização, neste caso, é o SoC dos EVs [10].

Filtros Gaussianos correspondem a algumas das principais ferramentas utilizadas na literatura para a estimação dos estados de uma bateria em tempo real, incluindo o SoC. Os métodos que utilizam filtros dessa natureza apresentam alta precisão, capacidade de autocorreção e boa adaptabilidade [12], [34] [27]. Para implementar a estimação dos estados, utiliza-se um modelo de circuito da bateria a partir do qual se obtêm as equações em espaços de estado e da grandeza de saída: a tensão terminal. O modelo de circuito utilizado no presente trabalho é apresentado na Subseção 3.2.1, do Capítulo Metodologia.

O filtro gaussiano utilizado neste trabalho é o UKF, que é amplamente aplicado em trabalhos que realizam estimação de estados de baterias na literatura. Trata-se de uma variação do filtro de Kalman, com aplicação da Transformada Unscented para o tratamento da não linearidade do sistema. Além disso, esse filtro é a mesma ferramenta aplicada no trabalho de Zhang et al. [11], cuja base de dados será utilizada para a validação do modelo no presente trabalho.

Para construir o embasamento teórico necessário para a compreensão do funcionamento do UKF, realiza-se uma breve explicação sobre o Filtro de Kalman linear na Subseção 2.3.1 e, em seguida, apresenta-se a explicação do UKF na Subseção 2.3.2, com a apresentação da Transformada Unscented e do passo-a-passo do algoritmo do UKF com as equações do filtro de Kalman adaptadas.

2.3.1 Filtro de Kalman

O Filtro de Kalman (*Kalman Filter* - *KF*) é aplicado sistemas dinâmicos lineares e, por meio de um conjunto de equações matemática recursivas, permite estimar estados não observáveis deste sistema. Apesar destes estados não serem medidos diretamente, seus valores afetam variáveis de saída do sistema. Com isso, é possível calculá-las com os estados estimados do sistema. O erro quadrático entre os resultados dos cálculos e os valores reais das variáveis observáveis afeta os parâmetros do filtro de Kalman. Estes, então, são ajustados para a estimação correta dos estados. Minimizando o erro quadrático entre as variáveis de observação calculadas e os seus respectivos valores de medição, a estimação dos estados se torna muito precisa [35].

O KF pode ser dividido em duas etapas: a primeira é chamada de etapa de estimação *a priori* e a segunda, chamada de estimação *a posteriori*. Para cada uma dessas etapas existe um grupo de equações a partir das quais são feitas estimativas num instante futuro e um grupo de equações que corrigem estas estimativas [36]. Na etapa de estimação *a priori*, as equações são chamadas de “Equações de previsão”. Estas são responsáveis pelo avanço das variáveis de estado e das covariâncias no tempo para se obter a estimativa no instante futuro, ou seja, são as equações de atualização no tempo para a realização da previsão do estado no instante futuro. Já as chamadas “Equações de correção” atualizam as medições e são responsáveis pela retroalimentação da estimativa, ou seja, essas equações incorporam uma nova informação da variável observável nas previsões e realizam uma correção da estimativa dos estados [35].

Seja um sistema linear, cuja variável observável é a saída y . A Equação (2.3) descreve seu comportamento, onde Z é a matriz que representa a saída baseada nos estados x , k é o contador de tempo, d descreve as constantes do sistema e ε é um sinal de média zero e matriz de covariância H [35].

$$y(k) = Z(k)x(k) + d(k) + \varepsilon(k) \quad (2.3)$$

A estimação por KF se inicia com a suposição inicial dos estados e da covariância dos erros, representados por $\hat{x}_0$ e $\hat{P}_0$, respectivamente. Em seguida, inicia-se a estimação *a priori*: calcula-se os estados no instante futuro e a covariância do erro. Os estados estimados *a priori* são calculados com a equação em espaço de estados que descreve o comportamento do estado x , representada pela Equação (2.4), onde $\hat{x}(k)$ é o estado estimado *a priori* no instante k , $\hat{x}(k-1)$ é o estado estimado no instante $k-1$, T é a matriz que representa o desenvolvimento das variáveis de estado, R é uma matriz de mesma dimensão de T , η é um sinal de média zero e matriz de covariância Q e c representa as constantes do sistema [37]. Os ruídos ε e η não são correlacionados entre si [35].

$$\hat{x}(k) = T(k)\hat{x}(k-1) + c(k) + R(k)\eta(k) \quad (2.4)$$

A covariância *a priori* é representada por $\hat{P}_x(k)$ e calculada conforme a Equação (2.5).

$$\hat{P}_x(k) = T(k)\hat{P}_x(k-1)T(k)' + R(k)Q(k)R(k)' \quad (2.5)$$

Em seguida, calcula-se a estimação *a posteriori*, considerando a saída medida no sistema no instante k . O ganho de Kalman no instante k ($K(k)$) é calculado através da

Equação (2.6), onde $H(k)$ representa o erro da equação de medição.

$$K(k) = P(k-1).Z'(k)(Z(k)P(k-1)Z'(k) + H(k))^{-1} \quad (2.6)$$

Os estados estimados *a posteriori* são calculados conforme a Equação (2.7) e a atualização da covariância é dada pela Equação (2.8).

$$\hat{x}(k) = \hat{x}(k-1) + K(k)(y(k) - Z(k)\hat{x}(k-1) - d(k)) \quad (2.7)$$

$$P(k) = (I - K(k)Z(k))P(k-1) \quad (2.8)$$

O KF não é utilizado em aplicações de sistemas não lineares. Para isso, são utilizadas variações, como o Filtro de Kalman Estendido (*Estented Kalman Filter - EKF*) que permite abordar problemas com não linearidades de, no máximo, ordem 2 [38]. Entretanto, para problemas de natureza significativamente não linear, a linearização proposta no EKF não é suficiente para obter estimações precisas [34]. Para lidar com esses problemas, surgiram os filtros de Partículas e o UKF [38].

O Filtro de Partículas pode ser aplicado em sistemas fortemente não lineares. Entretanto, seu custo computacional é muito elevado. Por isso, o UKF se apresenta como mais vantajoso para a maioria dos casos [38].

2.3.2 Filtro de Kalman Unscented

O UKF faz parte da família de filtros de Kalman que trata sistemas não lineares. Trata-se de um tipo de filtragem ótima cujo objetivo é estimar os estados de um sistema variante no tempo. Os estados não observáveis do sistema são indiretamente observados por meio de um conjunto de medidas com incertezas, ou seja, medidas que não são funções determinísticas dos estados do sistema. Isso quer dizer que para realizar o tratamento da não linearidade, o UKF considera que as funções de cálculo da saída e as funções de cálculo dos estados do sistema possuem características de respostas aleatórias [38]. Considerando a não linearidade do sistema como respostas não determinísticas, utiliza-se a Transformada Unscented (*Unscented Transform - UT*) juntamente com o processo do filtro de Kalman para a estimação dos estados do sistema.

Dessa forma, o UKF segue a mesma construção lógica do KF. Isso quer dizer que nele também existem as duas etapas *a priori* e *a posteriori*, com as mesmas respectivas funções de predição e de correção. A diferença é a presença da UT, que é o elemento central do UKF [38].

2.3.2.1 Transformada Unscented

A UT é utilizada no UKF com o objetivo de realizar o tratamento da não linearidade dos sistemas cujos estados são estimados pelo filtro. Para a aplicação desse tipo de transformada, deve-se partir do pressuposto de que as funções de estados e de saída, que são não lineares, devem possuir respostas com características aleatórias [39]. Considerando a Equação (2.9), onde g é uma transformação não linear; x é uma variável aleatória com distribuição normal, ou seja, $x = \mathcal{N}(\mu_x, P_x)$ onde μ_x é a média de x e P_x é a covariância.

$$y = g(x) \quad (2.9)$$

Para a obtenção dos valores de média e covariância de y , basta calcular o valor de seus dois primeiros momentos [40]. Seja $k = 1, 2, \dots$, o momento de ordem k da variável aleatória y é definido como $E(y^k)$, desde que essa quantidade exista. Os dois primeiros momentos da variável aleatória y serão então: $E(y^1)$ e $E(y^2)$. Sendo que $E(y^1) = \mu_y$, ou seja, o valor esperado de ordem 1 é igual à média de y . Já a covariância de y pode ser calculada como $Var(y) = E(y^2) - (\mu_y)^2$ [40].

Segundo Scardua, “a UT escolhe deterministicamente pontos no espaço de estados do sistema dinâmico que capturam a média e a covariância da distribuição de x . Esses pontos são chamados de *pontos sigma*” [38]. A partir disso, aplica-se a transformação definida na Equação (2.9) para se obter os pontos sigma transformados $\mathcal{Y}_i = g(\mathcal{X}_i)$, ou seja, os pontos sigma de y . Estes são utilizados para estimar os valores de média e covariância de y , além da covariância cruzada de x e y .

Os pontos sigma de x são definidos como $2n_x + 1$ vetores obtidos conforme mostrado na Equação (2.10), onde n_x é o número de elementos de x .

$$\begin{aligned} \mathcal{X}_0 &= \mu_x \\ \mathcal{X}_i &= \mu_x + (\sqrt{(n_x + \lambda)P_x})_i \quad i \in 1 \dots n_x \\ \mathcal{X}_{i+n_x} &= \mu_x - (\sqrt{(n_x + \lambda)P_x})_i \quad i \in 1 \dots n_x \end{aligned} \quad (2.10)$$

Com a aplicação da Equação (2.9) nos pontos sigma x , tem-se os pontos sigma de y , a partir dos quais é possível calcular a média e a covariância como mostra as equações (2.11) e (2.12), respectivamente.

$$\mu_y = w_0^{(m)}\mathcal{Y}_0 + \sum_{i=1}^{2n_x} w_i^{(m)}\mathcal{Y}_i \quad (2.11)$$

$$P_y = w_0^{(c)}(\mathcal{Y}_0 - \mu_y)(\mathcal{Y}_0 - \mu_y)^T + \sum_{i=1}^{2n_x} w_i^{(c)}(\mathcal{Y}_i - \mu_y)(\mathcal{Y}_i - \mu_y)^T \quad (2.12)$$

A covariância entre x e y é calculada conforme a Equação (2.13).

$$P_{xy} = w_0^{(c)}(\mathcal{X}_0 - \mu_x)(\mathcal{Y}_0 - \mu_y)^T + \sum_{i=1}^{2n_x} w_i^{(c)}(\mathcal{X}_i - \mu_x)(\mathcal{Y}_i - \mu_y)^T \quad (2.13)$$

Os parâmetros $w_0^{(m)}$, $w_0^{(c)}$, $w_i^{(m)}$ e $w_i^{(c)}$ são calculados conforme a Equação (2.14). Os indicadores sobrescritos (c) e (m) indicam que o fator é utilizado para o cálculo da variância e da média, respectivamente.

$$\begin{aligned} w_0^{(m)} &= \frac{\lambda}{n_x + \lambda} \\ w_0^{(c)} &= \frac{\lambda}{n_x + \lambda} + (1 - \alpha^2 + \beta) \\ w_i^{(m)} &= \frac{\lambda}{2(n_x + \lambda)}, & i \in 1 \dots 2n_x \\ w_i^{(c)} &= \frac{\lambda}{2(n_x + \lambda)}, & i \in 1 \dots 2n_x \end{aligned} \quad (2.14)$$

Onde λ é um parâmetro de escalamento das variáveis e se calcula da seguinte forma: $\lambda = \alpha^2(n_x + \kappa) - n_x$. Os parâmetros α , β e κ são ajustáveis: α define o espalhamento dos pontos sigma em torno de μ_x ; κ é um parâmetro de escalamento secundário e β pode ser utilizado para incorporar conhecimento *a priori* sobre a distribuição de x , ou seja, pode ser ajustado a partir do conhecimento do usuário da ferramenta [38].

Os cálculos utilizados na UT são incorporados ao KF a cada iteração para o tratamento das não linearidades nas equações de estado e de saída. Neste caso, os estados são representados pela variável x e a saída pela variável y . O funcionamento do UKF é apresentado na Subseção 2.3.2.2.

2.3.2.2 Etapas de Funcionamento do UKF

Nesta subseção, são apresentadas as equações do KF adaptadas para incorporar os elementos da Transformada Unscented. Tendo isso em vista, realizam-se algumas considerações para a compreensão das variáveis do algoritmo: a partir daqui, em cada uma das variáveis relativas aos estados e à saída, o sobrescrito entre parênteses indica o instante de tempo, salvo para os fatores $w_0^{(m)}$, $w_0^{(c)}$, $w_i^{(m)}$ e $w_i^{(c)}$, que são apresentados na Equação 2.14. Já o subscrito x e y indicam, respectivamente, se a variável se refere ao estado ou à saída.

Seja um sistema dinâmico não linear representado pela equação de espaço de estados e pela equação de medidas descritas, respectivamente, na Equação (2.15) e na Equação (2.16). As funções f e h são não lineares e a variável x é um processo estocástico com distribuição conjunta normal, ou seja, $x(k) = \mathcal{N}(\mu_x, P_x)$ onde μ_x é a média de x e P_x é a covariância.

$$x(k) = f(x(k-1)) \quad (2.15)$$

$$y(k) = h(x(k)) \quad (2.16)$$

Scardua (2015), em [38], apresenta as etapas da implementação do UKF que são descritas a seguir. Primeiramente, realiza-se a estimação *a priori* para este sistema, segundo os seguintes passos:

- Passo 1: Nesta etapa realiza-se a obtenção dos pontos sigma para descrever o comportamento da variável x . Utiliza-se a Equação (2.17):

$$\begin{aligned} \mathcal{X}_0^{(k-1)} &= \mu_x^{(k-1)} \\ \mathcal{X}_i^{(k-1)} &= \mu_x^{(k-1)} + (\sqrt{(n_x + \lambda)P_x^{(k-1)}})_i \quad i \in 1 \dots n_x \\ \mathcal{X}_{i+n_x}^{(k-1)} &= \mu_x^{(k-1)} - (\sqrt{(n_x + \lambda)P_x^{(k-1)}})_i \quad i \in 1 \dots n_x \end{aligned} \quad (2.17)$$

- Passo 2: No segundo passo, os pontos sigma são propagados pelo modelo dinâmico, seguindo a Equação (2.15). Obtêm-se então os estados estimados *a priori* ($\widehat{\mathcal{X}}_i^{(k)}$) para o próximo instante, como mostra a Equação (2.18).

$$\widehat{\mathcal{X}}_i^{(k)} = f(\mathcal{X}_i^{(k-1)}) \quad (2.18)$$

- Passo 3: Neste passo, calcula-se a média $\widehat{\mu}_x^{(k)}$ e a covariância $\widehat{P}_x^{(k)}$ para os estados estimados *a priori*, conforme as equações (2.19) e (2.20), respectivamente.

$$\widehat{\mu}_x^{(k)} = \sum_{i=0}^{2n_x} w_i^{(m)} \widehat{\mathcal{X}}_i^{(k)} \quad (2.19)$$

$$\widehat{P}_x^{(k)} = \sum_{i=0}^{2n_x} w_i^{(c)} (\widehat{\mathcal{X}}_i^{(k)} - \widehat{\mu}_x^{(k)}) (\widehat{\mathcal{X}}_i^{(k)} - \widehat{\mu}_x^{(k)})^T \quad (2.20)$$

A partir da estimação *a priori*, realiza-se a etapa de correção da estimação, ou seja, a etapa de estimação *a posteriori*, considerando a medida da saída atual.

- Passo 1: Novos pontos sigma são calculados considerando os valores de média e covariância obtidos com as equações (2.19) e (2.20), respectivamente. Este cálculo é mostrado pela Equação (2.21).

$$\begin{aligned} \mathcal{X}_0^{(k)} &= \widehat{\mu}_x^{(k)} \\ \mathcal{X}_i^{(k)} &= \widehat{\mu}_x^{(k)} + (\sqrt{(n_x + \lambda)\widehat{P}_x^{(k)}})_i \quad i \in 1 \dots n_x \\ \mathcal{X}_{i+n_x}^{(k)} &= \widehat{\mu}_x^{(k)} - (\sqrt{(n_x + \lambda)\widehat{P}_x^{(k)}})_i \quad i \in 1 \dots n_x \end{aligned} \quad (2.21)$$

- Passo 2: Os novos ponto sigma, calculados no passo anterior, são implementados na equação de saída representada pela Equação (2.16). Dessa forma, tem-se:

$$\widehat{y}_i^{(k)} = h(\mathcal{X}_i^{(k)}) \quad (2.22)$$

- Passo 3: Nesta etapa, calculam-se a média $\hat{\mu}_y^{(k)}$ e a covariância $\hat{P}_y^{(k)}$ para os pontos sigma obtidos no Passo 2. Além disso, calcula-se a covariância $\hat{C}_{xy}^{(k)}$ entre os pontos sigma de x e de y , de acordo com as equações (2.23), (2.24) e (2.25).

$$\hat{\mu}_y^{(k)} = \sum_{i=0}^{2n_x} w_i^{(m)} \hat{\mathcal{Y}}_i^{(k)} \quad (2.23)$$

$$\hat{P}_y^{(k)} = \sum_{i=0}^{2n_x} w_i^{(c)} (\hat{\mathcal{Y}}_i^{(k)} - \hat{\mu}_y^{(k)}) (\hat{\mathcal{Y}}_i^{(k)} - \hat{\mu}_y^{(k)})^T \quad (2.24)$$

$$\hat{C}_{xy}^{(k)} = \sum_{i=0}^{2n_x} w_i^{(c)} (\hat{\mathcal{X}}_i^{(k)} - \hat{\mu}_x^{(k)}) (\hat{\mathcal{Y}}_i^{(k)} - \hat{\mu}_y^{(k)})^T \quad (2.25)$$

- Passo 4: Na quarta e última etapa do algoritmo, considera-se o valor de saída medido no instante atual k e, com isso, calculam-se o ganho de Kalman, K , a média e a covariância do estado filtrado.

$$K^{(k)} = \hat{C}_{xy}^{(k)} (\hat{P}_y^{(k)})^{-1} \quad (2.26)$$

$$\mu_x^{(k)} = \hat{\mu}_x^{(k)} + K^{(k)} [y_k - \hat{\mu}_y^{(k)}] \quad (2.27)$$

$$P_x^{(k)} = \hat{P}_x^{(k)} + K^{(k)} \hat{P}_y^{(k)} (K^{(k)})^T \quad (2.28)$$

Os valores de média e covariância, bem como os pesos de Kalman calculados no último passo da etapa de cálculo *a posteriori* retornam para o primeiro passo no instante seguinte. Assim, a cada iteração, o UKF atualiza os pesos e admite correções na estimação conforme o acréscimo de novos valores de medida.

3 METODOLOGIA

Neste capítulo são descritos os métodos utilizados para o resolver os problemas formulados neste projeto. Na Seção 3.1, apresentam-se os cenários, as condições gerais e as definições dos custos utilizados no processo de otimização para V2G e G2V proposto no presente trabalho. Na Seção 3.2, apresenta-se a modelagem da baterias no ambiente HYSDEL, considerando o circuito equivalente apresentado na literatura e o UKF para a estimação do SoC da bateria em tempo real.

3.1 Otimização da Interação entre EV e Estações de Carga e Descarga de Energia

A presente proposta de otimização tem o objetivo de fornecer para usuários de EVs, indicações para o carregamento do veículo ou para a venda de energia. A proposta de resolução é construída de forma a minimizar os custos de carregamento da bateria e maximizar o lucro de venda de energia do ponto de vista do proprietário do EV. Dependendo do SoC da bateria do veículo, ele poderá fornecer energia para a CDS ou comprar energia para seu abastecimento próprio. Considera-se que as CDS estão conectadas à rede elétrica. Para que isso seja possível, considera-se que existe uma comunicação bidirecional sem fio entre os EVs que estão próximos naquele instante e as CDS disponíveis. Além disso, considera-se que para carregamento e descarregamento de energia a taxa de transferência é a definida no **Modo 3**, explicado na Subseção 2.1.2.

Dois cenários são considerados para otimização. No Cenário 1, calculam-se os valores ótimos de energia a ser recebida ou fornecida para se ter custo mínimo ou lucro máximo, respectivamente, em cada CDS. Neste caso, o sistema avalia somente um EV e as CDS que estão disponíveis para ele, conforme a distância máxima que ele pode percorrer. Já o Cenário 2 consiste na otimização de um grupo de EVs que irá fornecer ou receber energia das CDS. Assim, calcula-se, para cada CDS, o valor do custo mínimo ou do lucro máximo do grupo de EVs, considerando as restrições para os EVs e para as CDS em termos de capacidade de recebimento e fornecimento de energia. Nesta seção, são apresentadas as funções objetivo para cálculo de custo mínimo e lucro máximo, além das respectivas restrições.

As considerações gerais da proposta e a definição dos custos considerados nas funções objetivo, que são iguais para ambos os cenários, são apresentadas na Subseção 3.1.1. As especificações de cada cenário, bem como as respectivas funções objetivo são explicadas nas subseções 3.1.2 e 3.1.3.

3.1.1 Considerações gerais

Os EVs considerados para a otimização são do tipo PEV, ou seja, possuem um sistema *plug-in* que permite o recebimento de energia de uma fonte externa como a rede elétrica. Para o presente trabalho, será considerado que os veículos e as CDS têm também estrutura necessária para que o fluxo de energia possa ser, também, do EV para a CDS. Foram utilizados modelos de veículos comercializados, que possuem a possibilidade de carregamento rápido. Os modelos e as respectivas características de todos os EVs considerados no presente trabalho são apresentados no Anexo A e foram retiradas do *site Electric Vehicle Database* [41].

Para verificar se o veículo irá fornecer ou receber energia, o algoritmo avalia o SoC da bateria frente a parâmetros que indicam que o EV pode vender energia para a rede (SoC_V) ou se o EV deve se conectar para comprar energia (SoC_C). Assim, se $SoC \geq SoC_V$, então o EV pode vender energia para a CDS; se $SoC \leq SoC_C$, o EV poderá se carregar em alguma CDS. Os parâmetros SoC_V e SoC_C variam entre 0 e 1 e indicam o percentual de carga da bateria. Para cada uma destas condições e em cada um dos cenários, existe uma função objetivo. Considera-se, ainda, que o EV deve ser estacionado se o SoC da bateria atingir um valor de SoC_{limite} . Este valor representa o percentual mínimo necessário para que o EV continue em movimento, ou seja, o SoC estiver abaixo deste valor, o EV deve ser estacionado.

A otimização será aplicada considerando que os veículos trafegam em uma estrada de percurso retilíneo e velocidade (ν) constante. Considera-se, ainda, que a distância entre as estações de carregamento (δ_{CDS}) é constante e, com esse valor, calcula-se quantas CDS estão disponíveis para o veículo ou o grupo de veículos, baseado na distância máxima que poderá ser percorrida por ele(s). O cálculo da distância máxima é diferente em cada um dos cenários, pois no segundo caso, todos os EVs devem ser capazes de acessar a todas as CDS sem que o seu SoC fique abaixo de SoC_{limite} .

Os valores de compra e venda de energia são definidos baseado em uma curva-horária do preço da energia. Essa curva horária é construída a partir da curva de carga da concessionária de energia. Nos momentos de maior demanda de potência, tem-se um preço mais elevado para a energia. Os valores em €/kWh utilizados nos testes, bem como a definição numérica de todos os parâmetros dos processos de otimização são apresentados no Capítulo 4.

A forma de cálculo da distância máxima, as funções objetivo e as restrições de cada cenário são explicadas nas subseções 3.1.2 e 3.1.3. Os custos considerados nas funções objetivo de ambos os cenários são: custo de deslocamento ($Custo_D$) e custo de afundamento de carga da bateria $Custo_{DoD}$, que serão explicados nas subseções 3.1.1.1 e 3.1.1.2, respectivamente.

3.1.1.1 Definição do Custo de Deslocamento

Seja Ω_{EV} o conjunto de EVs e Ω_{CDS} o conjunto de CDS considerados no problema de otimização. O $Custo_D$ é utilizado somente nas funções objetivo de maximização do lucro. Ele é calculado para cada EV e corresponde ao valor da energia que foi despendida no trajeto e deixou de ser vendida nas respectivas CDS. A contabilização deste custo é feita conforme a Equação (3.1), onde $i \in \Omega_{EV}$, indicando o EV no conjunto de EVs considerado; $j \in \Omega_{CDS}$, indicando a CDS no conjunto considerado; V_ε é o valor de venda da energia em €/kWh, δ_{EV} é a distância de cada EV às CDS; η_{EV} é o consumo do EV no deslocamento em km/kWh.

$$Custo_D(i, j) = V_\varepsilon(j) \cdot \frac{\delta_{EV}(i, j)}{\eta_{EV}(i)} \quad (3.1)$$

3.1.1.2 Definição do Custo de Afundamento de Carga da Bateria (DoD)

Os EVs considerados neste trabalho possuem um banco de baterias cuja vida útil é baseada no número de ciclos completos de carga e descarga que podem ser executados antes que a capacidade nominal de armazenamento caia para valores abaixo de 80%. Quando em um sistema V2G, o veículo não irá realizar ciclos completos de descarga e de carga, ou seja, o descarregamento bem como o carregamento podem ser feitos de forma parcial. Entretanto, esses ciclos parciais podem gerar um elevado desgaste nas propriedades do sistema de bateria e isso afeta a capacidade de carga e descarga da mesma, gerando um custo a ser considerado na otimização do sistema. O descarregamento parcial é chamado de afundamento de carga (*Deep of Discharge - DoD*) [42].

Zhou et al., em [42], apresenta um método para verificar o custo relacionado ao DoD da bateria. Considera-se, primeiramente, que o DoD pode ser obtido a partir do SoC por: $DoD = 1 - SoC$. Como o afundamento de carga gera o desgaste na bateria, Zhou et al. estabeleceu uma relação entre o DoD e os ciclos de carga que representam a vida útil da bateria de lítio a partir de dados experimentais. Essa relação é definida pela Equação (3.2), onde L_{DoD} é o número de ciclos de carga e descarga da bateria a partir da taxa de descarregamento DoD .

$$L_{DoD} = 649 \cdot DoD^{-0.795} \quad (3.2)$$

Com isso, calcula-se η_{DoD} que é o fator de efeito do DoD no ciclo de vida da bateria através da Equação (3.3), onde L_N é o ciclo de vida nas condições ideais para a bateria.

$$\eta_{DoD}(i) = \frac{L_{DoD}(i)}{L_N(i)} \quad (3.3)$$

Então, calcula-se o $Custo_{DoD}$ com a Equação (3.4), onde $Custo_{Bat}$ é o valor da bateria, ε_S é a energia armazenada na bateria em kWh , L_N é o ciclo de vida da bateria em condições ideais e η_{DoD} é o fator de efeito do DoD.

$$Custo_{DoD}(i) = \frac{Custo_{Bat}(i)}{L_N(i) \cdot \varepsilon_S(i) \cdot \eta_{DoD}(i)} \quad (3.4)$$

O cálculo do afundamento de carga para a situação em que o EV vende energia é diferente do cálculo para a situação em que o EV compra energia da rede. Para o primeiro caso, a determinação do DoD é feita segundo a Equação (3.5), apresentada por Zhou et al. em [42], onde DoD_{VEN} é o valor do afundamento de carga para o caso em que o EV vende energia e ε_{for} é o valor de energia a ser fornecida para a CDS.

$$DoD_{VEN}(i, j) = \frac{\left(\frac{\delta_{EV}(i, j)}{\eta_{EV}(i)}\right) + (\varepsilon_{for}(i, j))}{\varepsilon_S(i)} \quad (3.5)$$

A determinação do DoD para a situação em que o EV deve comprar energia (DoD_{COM}), proposta no presente trabalho, é feita conforme a Equação (3.6).

$$DoD_{COM}(i, j) = \frac{\left(\frac{\delta_{EV}(i, j)}{\eta_{EV}(i)}\right)}{\varepsilon_S(i)} \quad (3.6)$$

3.1.2 Cenário 1: Um único EV

Neste primeiro Cenário, a otimização é realizada para um veículo e as CDS que estão disponíveis para o mesmo. O cálculo da distância máxima quando o EV irá receber energia é diferente para quando o EV irá fornecer energia. Para o primeiro caso, considera-se que o EV poderá se deslocar até o momento em que seu SoC atingir o valor de SoC_{limite} . Assim, a distância máxima é obtida conforme a Equação (3.7), onde δ_{max} é a distância máxima e ε_{TES} é a capacidade útil da bateria do EV em kWh . Os valores de eficiência e capacidade útil da bateria são fornecidos pelos fabricantes dos veículos na condição de percurso em estrada (Anexo A).

$$\delta_{max} = (SoC - SoC_{limite}) \cdot \eta_{EV} \cdot \varepsilon_{TES} \quad (3.7)$$

Já para o caso do EV fornecer energia, a distância máxima é calculada considerando que o EV poderá se deslocar até o momento em que seu SoC atingir o valor de SoC_{maxV} . Define-se este valor, pois, se o EV puder se deslocar até atingir SoC_{limite} , não haverá energia disponível em sua bateria para o fornecimento à CDS. Assim, a distância máxima é calculada segundo a Equação (3.8).

$$\delta_{max} = (SoC - SoC_{maxV}) \cdot \eta_{EV} \cdot \varepsilon_{TES} \quad (3.8)$$

Dividindo a a distância máxima a ser percorrida pela distância entre os CDs, chega-se a quantidade de CDS, conforme mostra a Equação (3.9), onde Qnt_{CDS} é a quantidade de CDS.

$$Qnt_{CDS} = \frac{\delta_{max} - 1}{\delta_{CDS}} \quad (3.9)$$

Uma vez obtida a quantidade de CDS disponíveis para cada EV, é resolvido o problema de otimização conforme as funções objetivo apresentadas na Subseção 3.1.2.1.

Na Figura 3.1.2, apresenta-se o fluxograma do algoritmo de otimização no Cenário1.




Figura 1 – Fluxograma do Algoritmo para o Cenário 1

Fonte: Próprio Autor

3.1.2.1 Funções Objetivo

A otimização proposta possui duas funções objetivo que são escolhidas pelo algoritmo baseado no estado de carga atual do EV. Se o EV puder fornecer energia, a função objetivo será representada pela Equação (3.10). Se, por outro lado, o EV tiver de ser carregado, a função objetivo será representada pela Equação (3.11), onde P_ε é o preço de compra da energia em €/kWh, V_ε é o preço de venda da energia em €/kWh e ε_{rec} é a energia recebida pelo EV da CDS em kWh.

$$FO_{VEN} = \max(V_\varepsilon \cdot \varepsilon_{for} - Custo_D - Custo_{DoD}) \quad (3.10)$$

$$FO_{COM} = \min(P_\varepsilon \cdot \varepsilon_{rec} + Custo_{DoD}) \quad (3.11)$$

Na Equação (3.10), calcula-se a quantidade de energia ideal a ser transferida de cada CDS para cada EV para minimizar o custo. Assim, o resultado para cada EV são dois vetores: um vetor contendo o custo mínimo para a compra de energia em cada CDS e outro vetor contendo o valor de energia adequado para se obter o respectivo custo mínimo. De forma similar acontece na Equação (3.11): calcula-se a quantidade de energia ideal a ser transferida de cada EV para cada CDS para maximizar o lucro. Gerando também dois vetores de valores como resposta para cada EV.

3.1.2.2 Limitações das Variáveis de Decisão

Neste Cenário, considera-se a limitação relacionada à quantidade de energia que o EV pode fornecer ou receber. Os valores dependem do SoC, do SoC_{limite} e da capacidade de sua bateria, definida segundo o modelo.

A quantidade de energia que o veículo pode receber é definida como, no máximo, a energia necessária para que a bateria do EV atinja $SoC = 1$, ou seja, a quantidade de energia armazenada na bateria seja igual a capacidade útil total (ε_{TES}).

Na literatura, é possível encontrar algumas recomendações de intervalos ideais de SoC para manter as melhores condições de durabilidade das baterias. Esses valores são baseados no monitoramento do SoH e cada tipo de bateria possui um intervalo adequado [26]. O SoC_{maxSOH} é o valor máximo do intervalo ideal de SoC e SoC_{minSOH} , o valor mínimo deste intervalo. O SoC_{limite} é um valor menor que o valor de SoC_{minSOH} , ou seja, um valor abaixo do SoC mínimo para manter o estado de saúde da bateria.

No carregamento, o valor mínimo de energia que o EV deve receber é a aquele necessário para que a bateria do EV atinja $SoC = SoC_{maxSOH}$, o valor máximo é o necessário para que o SoC atinja 100%. Essas limitações são consideradas tendo em vista que o EV irá se locomover após se carregar, ou seja, haverá gasto de energia da bateria. Assim, mesmo que se carregue com o mínimo de energia necessário, o SoC ainda poderá ficar dentro do intervalo ideal para manter a saúde da bateria. A escolha da quantidade ideal de energia que será enviada para o EV, dentro desse intervalo, é feita no processo de otimização.

Nas equações (3.12) e (3.13), observa-se como é o cálculo do limite superior e inferior de energia que cada EV pode receber de cada CDS, respectivamente, em kWh .

$$\varepsilon_{rec}(i, j) \leq \frac{\delta_{EV}(i, j)}{\eta_{EV}(i)} + (1 - SoC(i)) \cdot \varepsilon_{TES}(i) \quad (3.12)$$

$$\varepsilon_{rec}(i, j) \geq \frac{\delta_{EV}(i, j)}{\eta_{EV}(i)} + (SoC_{maxSOH} - SoC(i)) \cdot \varepsilon_{TES}(i) \quad (3.13)$$

A quantidade de energia que o EV pode fornecer depende do estado de carga mínimo (SoC_{limite}). A expressão que define a quantidade de energia máxima que o EV pode fornecer é apresentada pela Equação (3.14) em kWh . O valor mínimo de energia que o EV pode fornecer é zero.

$$\varepsilon_{for}(i, j) \leq (SoC(i) - SoC_{limite}) \cdot \varepsilon_{TES}(i) - \frac{\delta_{EV}(i, j)}{\eta_{EV}(i)} \quad (3.14)$$

3.1.2.3 Formulação do problema de otimização no Cenário 1

Para a situação em que o EV vende energia, tem-se a Equação (3.15) como Função Objetivo.

$$\max(V_{\varepsilon} \cdot \varepsilon_{for} - Custod - CustodoD) \quad (3.15)$$

Sujeito às equações (3.1), (3.4) e (3.14).

Para a situação em que o EV compra energia, tem-se a Equação (3.16), como Função Objetivo.

$$\min(P_{\varepsilon} \cdot \varepsilon_{rec} + CustodoD) \quad (3.16)$$

Sujeito às equações (3.4), (3.12) e (3.13).

3.1.3 Cenário 2: Grupo de EVs

O Cenário 2 consiste na otimização de um grupo de EVs que interage com as CDS conectadas à rede, para fornecer ou comprar energia, dependendo de seus valores de SoC. O objetivo, neste Cenário, é calcular o custo mínimo e o lucro máximo do grupo de EVs em cada uma das CDS considerando as restrições adequadas.

O algoritmo, neste caso, separa os EVs de um grupo em dois subgrupos: os que podem fornecer energia e os que devem ser carregados. Essa separação é feita conforme o SoC de cada um dos EVs do grupo. A partir disso, calcula-se a distância máxima de cada um dos subgrupos para a obtenção da quantidade de CDS disponíveis para compra e/ou venda de energia.

O cálculo da distância máxima, neste caso, deve ser feito considerando que todos os EVs deverão ter acesso às CDS disponíveis na otimização. Primeiramente, calcula-se a distância máxima que cada EV do grupo pode percorrer. Esse cálculo é feito conforme as equações (3.7) e (3.8). Depois disso, obtém-se a menor distância dentre as distâncias máximas dos EVs do grupo. Esta então será a distância máxima para a obtenção do número

de CDS. Uma vez obtida a quantidade de CDS disponíveis para cada EV, é resolvido o problema de otimização conforme as funções objetivo apresentadas na Subseção 3.1.3.1.

Na Figura 2, apresenta-se o fluxograma do algoritmo de otimização no Cenário 2.




Figura 2 – Fluxograma do Algoritmo do Cenário 2

Fonte: Próprio Autor

3.1.3.1 Funções Objetivo

Cada subgrupo neste segundo Cenário possui um objetivo diferente: Maximizar o lucro para os EVs que podem fornecer energia para as CDS e minimizar o custo para os que devem receber energia das CDS. Em ambos os casos, a otimização é feita considerando todos os EVs, ou seja, calcula-se o lucro máximo do subgrupo de EVs que fornece energia, para cada CDS, e o custo mínimo do subgrupo de EVs que recebe energia, para cada CDS.

Para o subgrupo que irá fornecer energia, a função objetivo, FO_{VEN} , será representada pela Equação (3.17), que representa o lucro obtido com a venda de energia menos o custo do deslocamento e o custo do afundamento de carga da bateria. Já para o subgrupo de EVs que irá receber energia, a função objetivo, FO_{COM} , será representada pela Equação (3.18), que representa o custo total da compra de energia, considerando o custo do afundamento de carga até o carregamento. Em ambas as equações, j é o contador que percorre a quantidade de CDS.

$$FO_{VEN} = \max \left(\sum_{j=1}^{Qnt_{CDS}} V_{\varepsilon}(j) \cdot \left(\varepsilon_{for} - \frac{\delta_{EV}(j)}{\eta_{EV}} - Custo_{DoD} \right) \right) \quad (3.17)$$

$$FO_{COM} = \min \left(\sum_{j=1}^{Qnt_{CDS}} P_{\varepsilon}(j) \cdot \varepsilon_{rec} + Custo_{DoD} \right) \quad (3.18)$$

3.1.3.2 Limitações das Variáveis de Decisão

No segundo Cenário, calcula-se a quantidade de energia que o subgrupo de EVs deve fornecer para cada CDS com o objetivo de obter o lucro máximo. De forma similar, calcula-se a quantidade de energia que o outro subgrupo deve receber de cada CDS com o objetivo de obter o custo mínimo. Tendo isso em vista, definiu-se os limites de quantidade de energia que cada EV deve receber ou fornecer individualmente. Estes valores são exatamente iguais aos definidos no Cenário 1, na Subseção 3.1.2.2.

Neste cenário, também é necessário considerar a capacidade máxima de recebimento e de fornecimento de energia de cada CDS disponível. Para esta limitação, é necessário estabelecer o tipo de carregamento de cada CDS e, assim, obter a capacidade de fornecimento de cada ponto de conexão em kVA . Deve-se considerar, ainda, o valor de fator de potência e o tempo necessário para a transferência de energia na CDS. Com esses valores, calcula-se a quantidade máxima de energia a ser fornecida ou recebida pela CDS conforme a Equação (3.19), onde ε é a energia fornecida ou recebida pela CDS em kWh de cada EV i do grupo; Qnt_{EV} é o número de EVs do subgrupo; N é o número de pontos de carga ou descarga de energia; P_{max}^{CDS} é a potência aparente transferida em cada ponto de recarga máxima; fp é o fator de potência; e t_{max} é o tempo máximo para carregamento dentre os modelos de EVs selecionados. Considera-se, neste trabalho, os mesmos valores de fp e de t_{max} para fornecimento ou recebimento de energia.

$$\sum_{i=1}^{Qnt_{EV}} \varepsilon(i, j) \leq N(j) \cdot P_{max}^{CDS}(j) \cdot fp \cdot t_{max} \quad (3.19)$$

3.1.3.3 Formulação do problema de otimização no Cenário 2

Para o subgrupo de EVs que vende energia, tem-se a Equação (3.20) como Função Objetivo.

$$\max \left(\sum_{j=1}^{Qnt_{CDS}} V_{\varepsilon}(j) \cdot (\varepsilon_{for} - Custo_D - Custo_{DoD}) \right) \quad (3.20)$$

Sujeito às equações (3.1), (3.4), (3.14) e (3.19).

Para o subgrupo de EVs que compra energia, tem-se a Equação (3.21), como Função Objetivo.

$$\min \left(\sum_{j=1}^{Qnt_{CDS}} P_{\varepsilon}(j) \cdot \varepsilon_{rec} + Custo_{DoD} \right) \quad (3.21)$$

Sujeito às equações (3.4), (3.12), (3.13) e (3.19).

3.2 Modelagem da Bateria do EV

Como foi explicado na Seção 2.3, define-se um sistema de gerenciamento dos dados das baterias (BMS) para obter, de forma precisa, os valores dos estados da bateria, como o SoC.

O UKF é o método utilizado para a estimação dos estados da bateria. Para que sua aplicação seja possível, é necessária a definição do modelo de circuito da bateria. O circuito equivalente utilizado para a modelagem da bateria é apresentado na Subseção 3.2.1, e a definição dos parâmetros de circuito para a aplicação do algoritmo de estimação de estados são apresentadas na Subseção 4.2.1. A partir do modelo de circuito, é possível obter as equações em espaços de estados e a equação da saída do sistema. Essas equações são importantes para a implementação do UKF, apresentada na Subseção 3.2.3.

A grandeza que pode ser medida no sistema e que é utilizada na implementação do UKF, neste caso, é a tensão terminal da bateria (V_T). Em uma das etapas da implementação do UKF, é necessária uma comparação entre a tensão terminal medida e o valor de tensão terminal calculado a partir dos estados estimados. Para esse cálculo, é necessário ter a relação entre o SoC e a OCV da bateria. Essa relação está apresentada na Subseção 3.2.2.

3.2.1 Modelagem de Circuito

Na literatura, são apresentados muitos circuitos para a modelagem de baterias. Segundo Mysiris [43], apesar de o circuito equivalente de Thévenin, como o mostrado na Figura 3, ser o mais utilizado para a estimação do SoC em tempo real, ele não é o mais preciso, pois os elementos de circuito variam com a temperatura e o desgaste da bateria. Para melhorar a precisão, deve-se adicionar mais ramos RC ao circuito. Isto, entretanto, aumenta a complexidade do circuito e a determinação dos valores dos parâmetros. Segundo Mysiris, os ganhos na precisão não compensam as perdas com a alta complexidade para a determinação dos parâmetros. Por isso, adota-se o circuito equivalente que possui um ramo RC, como o mostrado na Figura 3 [43]. Além disso, para avaliar a modelagem será feita a comparação com as respostas obtidas por Zheng et al. [12], adota-se a mesma modelagem de circuito e os mesmos parâmetros que foram determinados no artigo [12].

Neste circuito, R_0 representa as perdas por Efeito Joule internas à bateria; R_1 e C_1 representam o efeito transiente de relaxamento na corrente da bateria. A queda de tensão no ramo R_1C_1 é chamada de V_{RC} e Q_R é a capacidade da bateria. Os valores dos parâmetros estão definidos na Subseção 4.2.1. A saída medida do sistema é a tensão terminal: V_T ; a entrada do sistema é a corrente i_L .

A partir do circuito, obtém-se as equações de espaços de estados e a equação da tensão terminal que descrevem a dinâmica do modelo de bateria, mostradas nas equações




Figura 3 – Circuito Equivalente da Bateria

Fonte: Próprio Autor

(3.22) e (3.23), respectivamente, onde T_S é o tempo de amostragem dos dados [12].

$$\begin{bmatrix} SoC[k+1] \\ V_{RC}[k+1] \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & e^{-\frac{T_S}{R_1 C_1}} \end{bmatrix} \begin{bmatrix} SoC[k] \\ V_{RC}[k] \end{bmatrix} + \begin{bmatrix} \frac{T_S}{Q_R} \\ R_1 \left(1 - e^{-\frac{T_S}{R_1 C_1}} \right) \end{bmatrix} i_L \quad (3.22)$$

$$V_T[k] = OCV(SoC[k]) + V_{RC}[k] + R_0 i_L[k] \quad (3.23)$$

A relação SoC-OCV representa o comportamento da bateria, ou seja, os processos eletroquímicos e termodinâmicos que se refletem na tensão de circuito aberto para vários valores de estado de carga da bateria [12].

3.2.2 Relação entre Estado de Carga e Tensão de Circuito Aberto (SoC-OCV)

A estimação do estado de carga baseado nos circuitos equivalentes de Thévenin, de primeira e segunda ordem juntamente com o UKF é dependente da relação SoC-OCV [44]. Normalmente a curva SoC-OCV é obtida a partir do tratamento de dados obtidos com ensaios das baterias a diferentes temperaturas [44]. Os experimentos para a obtenção desses dados são realizados com controle de temperatura, ou seja, define-se uma temperatura sob a qual a bateria ensaiada estará exposta. Além disso, define-se ainda o método de ensaio que pode ser *Incremental OCV* ou *Low Current OCV*. O método experimental que gera uma curva que torna a estimação dos dados mais próxima da variação real do SoC é o *Incremental OCV* [12], [44]. Uma vez que se tem a curva SoC-OCV, esses dados são consultados para a estimação do SoC. Isso quer dizer que uma base de dados é necessária para armazenar os dados que representam a dinâmica da bateria para cada valor de seu estado de carga. Tendo em vista a necessidade de preservar a memória de dados num sistema que possa receber rotinas para a estimação de SoC de baterias, torna-se

interessante utilizar uma função matemática que descreva a relação SoC-OCV [12]. Zhang et al. então apresenta, em [11], equações matemáticas que representam a relação entre as grandezas SoC e OCV conforme o tipo de bateria.

Os tipos de bateria são definidos conforme os elementos químicos presentes no Anodo e no Catodo, ou seja, os elementos que são ionizados e geram uma diferença de potencial elétrico entre os polos da bateria. Os tipos de bateria que foram testados e modelados matematicamente por Zheng et al. são: LMO/Grafite Íon-lítio; LNMCO/Grafite Íon-lítio; LNMCO&LMO/Grafite Íon-lítio; LFP/Grafite Íon-lítio; LTO/LNMCO+LMO. Para cada um dos tipos de bateria, foram realizados testes, com temperatura controlada a 25°C , para verificar o fluxo de íons no decorrer do tempo, conforme a corrente elétrica aplicada no sistema. Nos testes, as baterias foram primeiro completamente descarregadas com uma corrente constante, até chegarem na tensão mínima, descrita no *datasheet*. Assim, ficaram em repouso por duas horas. Após isso, as baterias foram carregadas até chegarem na tensão máxima, também definida no *datasheet*, e ficaram em repouso por duas horas. A carga e a descarga foram feitas com corrente constante de $1/20\text{ C}$. Durante os processos de carga e descarga, a tensão terminal (V_T) das baterias foi medida e registrada para a construção das curvas $\text{SoC} - V_T$ para cada uma das baterias. Com isso e estimando os parâmetros de circuito para cada uma das baterias, foi possível calcular os valores OCV e construir as curvas $\text{SoC} - \text{OCV}$ [11].

A partir das curvas $\text{SoC} - \text{OCV}$ e das taxas de transferência de carga entre catodo e anodo das baterias na carga e na descarga, Zhang et al. determinaram uma expressão matemática que generaliza a relação $\text{SoC} - \text{OCV}$ para os tipos de bateria ensaiados à temperatura de 25°C [11]. Essa expressão é definida segundo a Equação (3.24).

$$\text{OCV} = a + b.(-\ln(\text{SoC}))^m + c.\text{SoC} + d.e^{n(\text{SoC}-1)} \quad (3.24)$$

onde os fatores a, b, c, d, m e n são os valores estimados a partir das características de transferência de carga de cada tipo de bateria ensaiada por Zhang et al. [11]. A Tabela 1 mostra os valores de cada parâmetro conforme o tipo de bateria.

Tabela 1 – Parâmetros da Equação Geral $\text{SoC} - \text{OCV}$ conforme o tipo de bateria

Tipo de Bateria	<i>Parâmetros da Equação</i>					
	a	b	c	d	m	n
LMO/Grafite	3.875	-0.335	- 0.5332	0.8315	0.653	0.6
LNMCO/Grafite	3.5	-0.0334	-0.106	0.7399	1.403	2
LNMCO&LMO	3.6	-0.111	-0.5	1.113	1.093	1.9
LFP/Grafite	3.135	-0.685	-1.342	1.734	0.478	0.4
LTO/LNMCO&LMO	2.235	-0.00132	-0.3503	0.6851	2.964	1.6

Fonte: Zhang et al. em [11]

3.2.3 Aplicação do Filtro de Kalman Unscented

A aplicação do UKF é feita conforme o passo-a-passo descrito na Subseção 2.3.2.2. A equação de estados e de medidas são, respectivamente, as equações (3.22) e (3.23). Os parâmetros α , β e κ foram definidos após diversos ensaios, seguindo recomendações de [35] para sintonia de parâmetros do UKF. Assim, os valores utilizados, bem como os estados iniciais são apresentados no Capítulo 4.

3.2.4 Modelagem no *Software* HYSDEL

O HYSDEL é um *software* que permite a transição entre as diversas formas de representar sistemas híbridos. Essa ferramenta é utilizada para calcular matrizes que descrevem um sistema MLD computacionalmente, que são adequadas para otimizar, controlar e simular sistemas dinâmico [45]. No presente trabalho, utiliza-se o HYSDEL no intuito de transformar o modelo de baterias em um sistema matricial onde seja possível gerar variáveis de decisão para a implementação em V2G e G2V. Primeiramente, o modelo é definido como um sistema DHA e, com a utilização do HYSDEL, é transformado em um formato MLD para ser simulado.

A subclasse de sistemas híbridos de DHA é o resultado da relação entre um sistema de comutação afim (*Switched Affine System - SAS*) e uma máquina de estados finitos (*Finite State Machine - FSM*). Portanto, um sistema DHA abrange variáveis contínuas do SAS e variáveis discretas de decisão da FSM [46]. Esta relação é possível devido aos elementos de conexão: Gerador de Eventos (*Event Generator - EG*) e o Seletor de Modos (*Mode Selector - MS*).

A operação do DHA acontece da seguinte forma: o EG extrai sinais lógicos das variáveis contínuas a partir das definições de condições de contorno e suas decisões geram uma transição de estados na FSM. O MS combina então as variáveis lógicas para selecionar o modo de cálculo das variáveis contínuas no SAS. Dessa forma, o modelo DHA é uma forma de generalizar modelos orientados para ferramentas computacionais para sistemas híbridos e também representa o ponto de partida para solução de análises complexas e problemas de síntese de sistemas híbridos. No entanto, os procedimentos de verificação e simulação do DHA têm um alto custo computacional [46].

A MLD, por outro lado, é uma estrutura de modelagem baseada em expressões matemáticas matriciais que possuem um custo computacional menor para ser executado, além de possuir desigualdades matriciais que são adequadas para formulação do problema de otimização. Ela permite a descrição de várias classes de sistemas, como DHA, modelos com saídas qualitativas e sistemas PWA. Assim, com um modelo DHA é possível obter um sistema MLD a partir da aplicação de um conjunto de regras [47]. Dessas regras surge o *software* HYSDEL, que faz a transformação a partir de rotinas computacionais.

A descrição da implementação do modelo do presente trabalho será apresentada no formato DHA, que é mais adequada para a compreensão. O fragmento do código gerado pelo HYSDEL que contém as matrizes MLD é apresentado no Anexo B.

As variáveis contínuas de entrada do modelo são:

- $SoC[k - 1]$: Estado de Carga do EV no instante anterior ao instante atual k ;
- $V_{RC}[k - 1]$: Queda de tensão no ramo RC no instante anterior ao instante atual k ;
- $i_{bat}[k]$: Corrente elétrica no instante atual.

A variável binária de entrada é representada por u_1 . Quando o valor de u_1 for 1, o EV está conectado à rede. Se por outro lado $u_1 = 0$ o EV está desconectado da rede.

O EG é definido por variáveis auxiliares que recebem valores binários dependendo dos valores das variáveis contínuas. No presente trabalho, tem-se um vetor com seis variáveis auxiliares binárias que são descritas na Equação (3.25). A variável δ_1 tem valor unitário se o SoC é maior ou igual a SoC_{maxSoH} e valor zero, se So é menor que SoC_{maxSoH} . De forma similar, a variável δ_2 tem valor unitário se o SoC é maior ou igual a SoC_{minSoH} ; δ_3 tem valor zero se o SoC atingiu o mínimo SoC_{limite} e valor unitário se o SoC ainda é superior a este valor limite. As demais variáveis representam operações entre as três primeiras: δ_4 indica que o valor de SoC está abaixo do valor SoC_{maxSoH} ; δ_5 indica se o SoC está no intervalo menor que SoC_{maxSoH} e maior que SoC_{minSoH} ; e a variável δ_6 indica com valor unitário que o SoC ainda não atingiu o valor limite.

$$EG : \begin{cases} [\delta_1 = 1] & \leftrightarrow [SoC[k - 1] \geq SoC_{maxSoH}] \\ [\delta_2 = 1] & \leftrightarrow [SoC[k - 1] \geq SoC_{minSoH}] \\ [\delta_3 = 1] & \leftrightarrow [SoC[k - 1] \geq SoC_{limite}] \\ [\delta_4 = 1] & \leftrightarrow [\delta_1] \\ [\delta_5 = 1] & \leftrightarrow [\neg \delta_1 \wedge \delta_2] \\ [\delta_6 = 1] & \leftrightarrow [\neg \delta_3] \end{cases} \quad (3.25)$$

As saídas contínuas do modelo são os estados SoC e V_{RC} calculados segundo a Equação (3.22) que descreve a dinâmica do sistema. As saídas discretas indicam se o veículo pode fornecer energia à rede, se deve se carregar ou se deve parar no caso de uma condição de emergência:

- $EV_{Fornece} = \delta_4$;
- $EV_{Recebe} = \delta_5$;

- $Parar = \delta_6$

Existem duas possibilidades de situações para o EV: ou ele está conectado à rede ou ele está desconectado e deve tomar a decisão de se conectar e para qual finalidade (carregar ou fornecer energia). Essas situações são definidas pelo MS, mostrado na Equação (3.26). A partir do MS, será definido o SAS, mostrado nas equações (3.27) e (3.28), onde I_1 é a corrente de entrada do sistema quando o mesmo está conectado fornecendo ou recebendo energia e I_2 é a corrente do sistema quando o EV está em movimento.

$$MS : m_p(k) = \begin{cases} 1 & \text{if } u_1 \\ 2 & \text{if } \neg u_1 \end{cases} \quad (3.26)$$

$$SAS : SoC[k+1] = \begin{cases} SoC[k] + I_1 \frac{T_S}{Q_R} & \text{if } u_1[k] = 1 \\ SoC[k] + I_2 \frac{T_S}{Q_R} & \text{if } u_1[k] = 0 \end{cases} \quad (3.27)$$

$$SAS : V_{RC}[k+1] = \begin{cases} V_{RC}[k].e^{\frac{-T_S}{R_1 C_1}} + I_1.R_1(1 - e^{\frac{-T_S}{R_1 C_1}}) & \text{if } u_1[k] = 1 \\ V_{RC}[k].e^{\frac{-T_S}{R_1 C_1}} + I_2.R_1(1 - e^{\frac{-T_S}{R_1 C_1}}) & \text{if } u_1[k] = 0 \end{cases} \quad (3.28)$$

A implementação do UKF no modelo híbrido construído no HYSDEL pode ser melhor compreendida através da Figura 4. A corrente elétrica no instante atual e os estados estimados no instante anterior são as entradas do modelo híbrido, além dos parâmetros constantes de circuito e de características da bateria. A saída do modelo HYSDEL são as variáveis de decisão e os estados calculados com as equações que descrevem seu comportamento. As saídas contínuas do modelo HYSDEL bem como a tensão nos terminais da bateria são inseridas no UKF. O filtro então realiza o cálculo da variável medida com os estados estimados no instante anterior e, conforme o passo-a-passo indicado na Subseção 2.3.2.2, realiza-se o ajuste dos parâmetros de filtragem e dos estados estimados *a posteriori*. Esses estados são inseridos novamente no HYSDEL, juntamente com a nova corrente atual e o ciclo se repete.

A avaliação do modelo de bateria com estimação de estados implementado no HYSDEL é feita na Seção 4.2, do Capítulo 4. Utilizam-se métricas para o cálculo do erro da estimação dos estados, explicadas na Subseção 3.2.5. O erro de estimação é calculado como a diferença entre o valor estimado e o valor real.




Figura 4 – Esquemático do Modelo de Bateria

Fonte: Próprio autor

3.2.5 Métricas de Erro de Estimação dos Estados

Os índices estatísticos utilizados para avaliar a modelagem da bateria são a Raiz do Erro Quadrático Médio (*Root Mean Square Error - RMSE*) e o Erro Médio Absoluto (*Mean Absolute Error - MAE*). Essas métricas foram as mesmas utilizadas no trabalho de Zheng et al., em [12], cujos resultados são aqueles aos quais é desejável que o modelo se aproxime. As fórmulas para o cálculo do RMSE e do MAE são apresentadas nas equações (3.29) e (3.30), onde n é o número de amostras, e_k é o erro de estimação.

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (e_k)^2} \quad (3.29)$$

$$MAE = \frac{1}{n} \sum_{k=1}^n |e_k| \quad (3.30)$$

Além disso, foi utilizada ainda a avaliação do Erro Percentual (EP), que é obtido a partir do cálculo da Equação (3.31), onde EP_k é o erro percentual, $\widehat{SoC}_k$ é o SoC estimado e SoC_k é o SoC real para a amostra k .

$$EP_k = \frac{100(|\widehat{SoC}_k - SoC_k|)}{SoC_k} \quad (3.31)$$

4 RESULTADOS E DISCUSSÕES

Nesse Capítulo, apresenta-se a avaliação das metodologias de resolução dos problemas apresentados. Inicialmente, na Seção 4.1, verifica-se o funcionamento da metodologia de otimização em V2G e G2V, do ponto de vista do EV. Os dados utilizados para essa avaliação, como consumo de energia por quilômetro e distância máxima percorrida pelo veículo, foram obtidos a partir de informações fornecidas pelos fabricantes de EVs já comercializados na Europa. Além disso, levou-se em consideração essa mesma localidade para a definição de preço da energia e informações específicas de modos de carregamento.

A avaliação da modelagem de baterias é mostrada em seguida, na Seção 4.2. Para essa avaliação, foi utilizada uma base de dados experimentais disponível na *Internet*, em um *site* do centro de pesquisa da Universidade de Maryland. Com essa base de dados, é possível observar a variação do SoC a partir da corrente de entrada e, assim, verificar se o estimador está funcionando de forma adequada. A bateria ensaiada para obtenção da base de dados são do tipo íon-lítio. Apesar de a maioria dos EVs utilizar baterias desse mesmo tipo, as informações fornecidas pelos fabricantes não são suficientes para a avaliação da estimação dos estados. Para isso, são necessários dados provenientes de ensaios das baterias, que não são rotineiramente realizados. Tendo isso em vista, optou-se por avaliar a otimização e a modelagem da bateria separadamente.

4.1 Otimização V2G e G2V

Na Subseção 4.1.1, são apresentados os parâmetros e o correspondente contexto considerados para a avaliação da modelagem de otimização. Em seguida, nas subseções 4.1.2 e 4.1.3, são apresentados os resultados obtidos para o primeiro e segundo cenários, respectivamente. Para o Cenário 1, foram avaliados veículos com *SoC* inicial de 0,55, 0,60, 0,90 e 0,98 e são apresentados os gráficos de custo e lucro para cada uma das opções de CDS. Já no Cenário 2, foram analisados 3 grupos de EVs com *SoC* inicial definido aleatoriamente. Neste segundo caso, são apresentados os gráficos de custo e lucro para cada EV, considerando ainda a variação da hora atual.

4.1.1 Definição dos parâmetros

Como foi mencionado no Capítulo 3, considera-se que os EVs trafegam em uma estrada retilínea a uma velocidade constante. A essa velocidade, definiu-se o valor de $\nu = 80km/h$. Além disso, tendo em vista a disponibilidade dos dados sobre preços de EVs, preços de baterias; e as informações sobre implementação de estações de carregamentos de

EVs [48], [2], considerou-se o contexto e as informações do mercado Europeu. Conforme os estudos apresentados no livro *E-Mobility (2015)*, a distância ideal entre estações de carregamento de EVs na zona rural é em torno de $\delta_{CDS} = 5km$ [48]. Esse será, portanto o valor considerado neste trabalho. Considerando, ainda, a localização da estrada, todas as informações de preços e valores dos parâmetros da otimização são obtidos na unidades monetárias €.

Conforme as recomendações para manutenção da saúde da bateria (SoH), feitas por Eider et al. em [26], o ideal é que as baterias de Íon-lítio permaneçam com estados de carga entre 60% e 80% para a preservação do SoH. Após a análise de diversas condições de operação, foi possível observar que quanto maior o *SoC* do EV, mais provável é a obtenção de lucro com a venda de energia. Por isso, para este trabalho definiu-se: $SoC_{maxSoH} = 0,8$. O valor que indica que o EV deve receber energia é igual ao valor mínimo para a preservação do estado de saúde da bateria: $SoC_{minSoH} = 0,6$; e o valor que indica que o EV deve ser estacionado para não comprometer a saúde da bateria é a baixo do valor mínimo: $SoC_{limite} = 0,5$.

Para a situação em que o EV vende energia, a distância máxima é calculada considerando que parte da energia deve ser preservada para a venda. Isso quer dizer que a distância máxima percorrida deve ser aquela em que, ao final do percurso, o EV ainda possa vender parte da energia sem prejudicar o ciclo de vida da bateria. Então, define-se que o EV poderá vender energia se $SoC \geq 0,90$ e a distância máxima é calculada considerando $SoC_{maxSoH} = 0,8$.

Por outro lado, considera-se que o EV pode comprar energia se o $SoC \leq 0,70$, pois apesar de ainda estar dentro do intervalo ideal de estado de carga da bateria, 0,70 é um valor abaixo das condições nominais de DoD. Além disso, considera-se que o EV irá percorrer uma distância máxima até o SoC_{limite} , que é mais baixo que o valor de SoC_{minSoH} . Permitir a busca pelas CDS a partir de $SoC = 0,7$ aumenta as possibilidades de a mais vantajosa não estar a uma distância em que o SoC se aproxime do SoC_{limite} .

Nas subseções 4.1.1.1, 4.1.1.2 e 4.1.1.3 são apresentadas outras definições utilizadas para a avaliação da modelagem de otimização em ambos os cenários.

4.1.1.1 Definição do valor de compra e venda de energia

Os valores de custo e compra de energia foram definidos baseados em dados fornecidos pela União Europeia para a Espanha, em €/kWh, pagos por consumidores domésticos [49]. Em ambos os cenários, foi utilizado um vetor de preços de energia conforme o horário do dia. Essa curva horária é mostrada na Figura 5.

Considera-se que o valor de venda é equivalente ao valor de compra de energia para consumidores comuns. No primeiro cenário, as primeiras simulações foram feitas

considerado o valor correspondente às 18h. Para as simulações seguintes foi considerada a curva horária completa. Já para o Cenário 2, considerou-se a curva completa desde o início. Entretanto, os valores horários de energia são somados a um percentual que pode variar aleatoriamente entre mais ou menos 5%. Essa variação foi adicionada com o objetivo de simular uma possível variação de preço entre as CDS na estrada.




Figura 5 – Curva Horária de Preço de Energia - Espanha

Fonte: Holaluz, Espanha (2019) [49]

4.1.1.2 Definição do preço da bateria

Para a determinação do valor de $Custo_{Bat}$, verificou-se que, segundo a empresa de pesquisa em finanças Bloomberg New Energy Finances (BNEF)¹, a previsão é que em 2026 o custo das baterias seja estimado em 100,00\$/kWh [50]. Entretanto, já em 2019, o custo estimado das baterias é menor do que o previsto em 2017. Segundo artigos da mesma empresa de pesquisa em finanças, em 2019 o custo das baterias de Ion-lítio de veículos elétricos é em torno de 156,00\$/kWh [51]. Por ser o valor estimado mais próximo da presente data, será utilizado para a otimização. Na conversão do dia 09 de Fevereiro de 2020, tem-se, em euros, o valor de 141,17€/kWh.

O valor do número de ciclos de vida da bateria em condições ideais adotado no presente trabalho é o mesmo que foi adotado por Zhou et al. para baterias de Íon-lítio: $L_N = 2200$ ciclos [42].

4.1.1.3 Definição do tipo de CDS

Como no Cenário 2 são avaliados grupos de EVs que se conectam às CDS, é necessário considerar a capacidade máxima de recebimento e de fornecimento de energia

¹ BNEF é o principal serviço de pesquisa da Bloomberg abrangendo as áreas de energia limpa, transporte avançado, indústria digital, materiais e mercadorias inovadores.

de cada CDS disponível. Para esta limitação, considera-se que todas as CDS no presente trabalho são do Modo 3, de carregamento rápido. Com isso, foi definido que cada ponto de energia da CDS tem capacidade de fornecimento de potência de 43 *kVA*, conforme a documentação da Central de Regulação Energética da França (2018) [52].

Segundo Nikita et al., a qualidade da energia de uma estação de carregamento é afetada pela quantidade de veículos que estão conectados a ela. Quando há 6 EVs conectados, o fator de potência atinge o valor de 0,96 [53]. No presente trabalho, consideram-se CDS, com 4, 5 ou 6 pontos de carregamento e descarregamento para os EVs. O fator de potência considerado é o apresentado na pior condição testada por Nikita et al.: 0,96. Com esses valores, calcula-se a quantidade máxima de energia a ser fornecida ou recebida pela CDS conforme a Equação (3.19).

4.1.2 Cenário 1

Para o Cenário 1, foi avaliado um modelo de veículos com SoC inicial de 0,55, 0,60, 0,90 e 0,98. O objetivo é verificar a obtenção da distância máxima, da quantidade de CDS, bem como a relação do fornecimento e recebimento de energia para cada situação de estado de carga inicial. Primeiramente a análise foi feita para um preço fixo e, em seguida, foi feita para a curva horária de tarifa de energia.

O modelo avaliado foi o Hyundai Cona 64*kWh*. A partir dos valores de estado de carga e das características do modelo, é possível obter a distância máxima e definir se o EV irá fornecer (Lucro) ou receber (Custo) energia. Essas informações são mostradas na Tabela 2.

Tabela 2 – Características do Hyundai Cona para vários valores de *SoC* no Cenário 1

<i>SoC</i>	Distância Máxima [<i>km</i>]	Núm. CDS	Custo/Lucro
0,55	18,30	3	Custo
0,60	36,57	6	Custo
0,90	18,28	3	Lucro
0,98	47,54	9	Lucro

Fonte: Próprio Autor

Na Figura 6, *SoC* = 0,55 e preço fixo de energia, é possível observar os valores ótimos de energia para a obtenção do custo mínimo em cada uma das CDS disponíveis para o EV. Observa-se, na Figura 6, que com o distanciamento da CDS, a quantidade de energia fornecida ao EV e o respectivo custo aumenta. Entretanto, o custo aumenta em uma taxa maior que a energia fornecida. Isso acontece, pois o afundamento de carga aumenta conforme o EV consome energia no percurso até a CDS, aumentando, assim o custo mínimo. Observa-se, na Figura 7, a variação do custo de carregamento da energia com o preço variando conforme a curva horária apresentada na Figura 5. É possível observar

que nos horários em que os preços são mais elevados, o custo para o abastecimento em todas as CDS é superior. Além disso, verifica-se que, nos horários em que o preço é mais elevado, a inclinação da linha de custo por CDS é maior. Isso quer dizer que o custo, nesses horários, aumenta a uma taxa maior do que em horários de preço menos elevado.




Figura 6 – Energia em kWh e Custo em € para Hyundai $SoC = 0,55$ e preço fixo de energia

Fonte: Próprio autor




Figura 7 – Custo em € para Hyundai $SoC = 0,55$ conforme Preço Horário da Energia

Fonte: Próprio autor

Na Figura 8, $SoC = 0,60$ e preço fixo de energia, tem-se uma elevação de custo quase paralela à elevação de energia recebida pelo EV. Isso acontece, pois o afundamento de carga nesta faixa de valores de SoC gera um custo menor que na situação anterior. Assim, o custo ótimo não ganha uma parcela elevada de custo por afundamento de carga. Na Figura 9, mostra-se a variação do custo de carregamento da energia com o preço

variando conforme a curva horária apresentada na Figura 5. Assim como no caso anterior, a taxa de aumento do custo é maior nos horários em que o preço é mais elevado.




Figura 8 – Energia em kWh e Custo em € para Hyundai $SoC = 0,60$ e preço fixo de energia

Fonte: Próprio autor




Figura 9 – Custo em € para Hyundai $SoC = 0,60$ conforme Preço Horário da Energia

Fonte: Próprio autor

Na Figuras 10, $SoC = 0,90$ e preço fixo de energia e na Figura 12, $SoC = 0,98$ e preço fixo de energia observa-se o valor ótimo de energia fornecida para cada CDS para a obtenção do lucro máximo. Em ambas as situações, somente a primeira estação apresenta lucro positivo. Para todas as outras, a perda de energia no deslocamento e o afundamento de carga impedem que a arrecadação seja superior ao custo. Assim, o lucro é negativo.

Na Figura 11, $SoC = 0,90$ e na Figura 13, $SoC = 0,98$, têm-se a variação do lucro de carregamento da energia com o preço variando conforme a curva horária apresentada na Figura 5. Em ambas as figuras, é possível observar que nos horários em que o valor da energia é maior, o lucro de venda de energia na CDS mais próxima é maior. Entretanto, nas CDS seguintes, mais distantes, o custo fica muito superior à arrecadação, tornando, assim, o lucro mais negativo. Isso acontece devido ao custo de deslocamento. Como o valor da energia é maior nesses horários, o $Custo_D$, que contabiliza o quanto se deixa de arrecadar com a energia consumida no deslocamento, também fica mais elevado. Assim, o custo aumenta a uma taxa maior do que a arrecadação, com o aumento da distância das CDS.




Figura 10 – Energia em kWh e Lucro em € para Hyundai $SoC = 0,90$ e preço fixo de energia

Fonte: Próprio autor




Figura 13 – Lucro em € para Hyundai $SoC = 0,98$ conforme Preço Horário da Energia

Fonte: Próprio autor




Figura 11 – Lucro em € para Hyundai $SoC = 0,90$ conforme Preço Horário da Energia

Fonte: Próprio autor




Figura 12 – Energia em kWh e Lucro em € para Hyundai $SoC = 0,98$ e preço fixo de energia

Fonte: Próprio autor

4.1.3 Cenário 2

A avaliação da otimização para o Cenário 2 foi realizada considerando um grupo de 10 EVs dividido em dois subgrupos de 5 veículos, cujas características são mostradas na Tabela 3. O Subgrupo 1 fornece energia para a CDS, ou seja, deseja-se maximizar o lucro; o Subgrupo 2 é formado por EVs aptos a receberem energia das CDS e então, o objetivo é minimizar o custo. Neste cenário, portanto, o objetivo é calcular o lucro máximo e o custo mínimo total de todos os EVs para cada CDS, considerando as restrições definidas.

A partir dos valores de distância máxima para cada EV, mostrados na última coluna da Tabela 3, foi definida a distância máxima de cada subgrupo, como foi explicado

na Subseção 3.1.3. Para o Subgrupo 1 foi definida a distância máxima é de 32 *km*. Considerando que as CDS estão distanciadas de 5 *km* entre si, o número de CDS é 5. Para o Subgrupo 2, a distância máxima é 30 *km* e, conseqüentemente, o número de CDS é 5.

Tabela 3 – Características dos EVs Avaliados no Cenário 2

Subgrupo 1		
Modelo	SoC	Dist. Máxima [km]
Nissan Leaf	0,96	32,00
Peugeot e-2008 SUV	0,95	37,50
Renault Zoe ZE50	0,98	52,29
BMW i3	0,95	32,30
Peugeot e-2008 SUV	0,98	45,00
Subgrupo 2		
Modelo	SoC	Dist. Máxima [km]
Hyundai Kona	0,62	47,54
Nissan Leaf	0,64	30,00
BMW i3	0,63	30,14
Peugeot e-2008 SUV	0,61	30,00
Renault Zoe ZE50	0,64	43,57

Fonte: Próprio Autor

Diferentemente do Cenário 1, no Cenário 2 definiu-se uma pequena variação aleatória no preço horário da energia. A partir do perfil horário de base apresentado na Subseção 4.1.1.1, foi definida uma variação aleatória de mais ou menos 5% do valor da energia para cada CDS, a cada hora.

Na Figura 14, apresenta-se o perfil de valores ótimos de lucro para cada CDS, conforme a hora de fornecimento de energia. Observa-se que, mesmo com valores aleatórios de tarifa de energia e as restrições de fornecimento, a CDS 1 é a mais vantajosa para receber energia dos EVs. Isso ocorre, pois na primeira estação não há perdas por deslocamento nem por afundamento de carga que sejam consideráveis como nas outras CDS. Além disso, a quantidade de energia fornecida pelos EVs ainda é baixa diante das restrições definidas para o recebimento de energia nas estações. Assim como no Cenário 1, observa-se que o lucro fica mais negativo nos horários em que o valor da energia é maior, nas CDS mais distantes. Isso acontece devido ao $Custo_D$ que aumenta a uma taxa maior do que a arrecadação nesses horários, com o aumento da distância das CDS.




Figura 14 – Lucro em € do Subgrupo 1 para cada CDS conforme Preço Horário da Energia

Fonte: Próprio autor

Na Figura 15, apresenta-se o perfil de Custo ótimo para cada CDS, conforme a hora. Observa-se as CDS 2 e 3 são as que apresentam o menor custo para o carregamento dos EVs para as tarifas de todas as horas. Diferentemente da avaliação do lucro, neste caso as restrições das CDS afetam consideravelmente a determinação do custo mínimo para todos os EVs, pois o volume de energia fornecido para o carregamento é maior. Assim, nem todos os EVs poderão se carregar na primeira estação mesmo que, à primeira vista, esta seja a mais vantajosa. Dessa forma, o maior custo não é necessariamente a CDS mais longe e o menor custo não é a CDS mais próxima.




Figura 15 – Custo em € do Subgrupo 2 para cada CDS conforme Preço Horário da Energia

Fonte: Próprio autor

Observa-se que as limitações de energia das CDS influenciam mais os resultados do

segundo cenário quando os EVs compram energia do que quando fornecem energia às CDS, pois, em geral, a quantidade de energia entregue aos EVs é maior do que a quantidade de energia que os EVs podem fornecer às CDS. Isso acontece por que foi definido que os EVs deveriam se carregar até atingir, pelo menos, $SoC = 80\%$. Nas CDS mais distantes, o SoC inicial é menor devido ao consumo de energia no trajeto e, por isso, os EVs deverão se receber mais energia. Por outro lado, o fornecimento de energia deve ser feito até atingir $SoC = 50\%$. Com o distanciamento das CDS, o SoC inicial diminui e o volume de energia disponível para a venda se torna menor. Isso quer dizer que, considerando o grupo de EVs, a quantidade de energia entregue tende a ser menor que a quantidade de energia necessária para o carregamento dos EVs, conforme o distanciamento das CDS. Por isso, as restrições para fornecimento de energia não atuaram tanto quanto as restrições para recebimento de energia nas CDS.

4.2 Modelo de Bateria

O modelo de bateria proposto no presente trabalho é construído como um sistema Autômato Híbrido Discreto, onde variáveis de decisão são obtidas a partir de valores contínuos e binários. O sistema é modelado utilizando o aplicativo HYSDEL, no *Software* MATLAB, e sua dinâmica é descrita com um circuito equivalente de Thévenin. A partir disso, se obtém as equações matemáticas de modelagem do sistema, como as que descrevem a evolução dos estados no decorrer do tempo conforme os valores de corrente de entrada.

A avaliação do modelo proposto é feita a partir de dados experimentais de baterias do tipo Íon-lítio, disponibilizados no *site* do grupo de pesquisa em baterias da Universidade de Maryland - *CALCE Battery Research Group* [54]. Esses dados foram utilizados em diversos trabalhos que envolvem a modelagem de baterias e a obtenção precisa de seus estados. Muitos destes fazem parte do embasamento teórico da presente dissertação, como o artigo produzido por Zheng et al., em [12], onde foi apresentada a avaliação dos seguintes métodos experimentais para a obtenção das curvas SoC-OCV: *Incremental OCV* e *Low Current OCV*. A bateria foi submetida a ensaios sob as temperaturas de $0^{\circ}C$, $25^{\circ}C$ e $45^{\circ}C$ para a determinação de parâmetros de circuito e para a verificação de qual método é o mais adequado para a estimação dos estados utilizando o UKF.

Foi utilizado um perfil de corrente denominado *Dynamic Stress Test (DST)* para a determinação dos parâmetros de circuito. Esse perfil de valores foi desenvolvido pelo *US Advanced Battery Consortium (USABC)* para simular um regime de descarga dinâmico. Os dados de corrente utilizados para avaliar a estimação dos estados são baseados na variação das velocidades médias dos veículos em vias monitoradas pelo governo norte-americano. São eles: *Federal Urban Driving Schedule (FUDS)* e *US06*. Essas bases de dados estão disponíveis no *site* do grupo de pesquisa em baterias da Universidade de Maryland -

CALCE Battery Research Group [54] para acesso livre. E são utilizadas em diversos testes de baterias, principalmente os que visam avaliar baterias de lítio - normalmente utilizadas em veículos elétricos [12], [34], [19], [55], [56].

No trabalho apresentado por Zheng et al., foi utilizado o método Mínimos Quadrados e as métricas RMSE e MAE, que serão explicadas nos itens 3.29 e 3.30 respectivamente, para verificar o erro na estimação dos estados. A conclusão foi a de que o método de *Incremental OCV*² é mais adequado pois gerou um menor erro RMSE e MAE nos testes de estimação do SoC. A partir dessa conclusão, para avaliar o modelo proposto nesta dissertação, comparou-se os resultados da estimação do SoC com os resultados do método *Incremental OCV* em [12], verificando-se assim, a utilização da expressão matemática que modela a curva SoC-OCV, obtida por Zhang et al. em [11], e a utilização do HYSDEL na modelagem. Para que a comparação seja válida, os mesmos dados de entrada, parâmetros de circuito e tensões terminal utilizados para a avaliação dos modelos no artigo de Zheng et al [12] são utilizados para a avaliação do modelo apresentado neste trabalho e apresentados na Subseção 4.2.1.

Para os perfis de corrente US06 e FUDS, considera-se SoC inicial de 0,8 para a definição do SoC Real, que será explicada na Subseção 4.2.2, e para a avaliação do modelo. Os perfis de corrente inseridos no sistema, bem como a respectiva tensão terminal medida em cada experimento estão apresentados nas figuras 16 e 17, respectivamente.




Figura 16 – Corrente de Entrada FUDS para SoC inicial de 80% e Tensão Terminal Medida

Fonte: Próprio autor

² O método *Incremental OCV* consiste em inserir pulsos de corrente positivos e negativos para o carregamento e descarregamento da bateria, respectivamente, em intervalos de tempo para estabilizar a tensão OCV medida [12].




Figura 17 – Corrente de Entrada US06 para SoC inicial de 80% e Tensão Terminal Medida

Fonte: Próprio autor

A Figura 18 apresenta a comparação dos erros RMSE e MAE obtidos para os dois métodos analisados por Zheng et al. e para as duas bases de dados que também são utilizadas no presente trabalho. Observa-se que os erros MAE e RMSE estão abaixo de 0,5 para a base de dados FUDS e próximas do mesmo valor para a base de dados US06.




Figura 18 – Erros de estimação do SoC para testes a 25°C

Fonte: Zheng et al. em [12] modificado

A avaliação é feita em três etapas. Na primeira etapa, a estimação do SoC foi feita pelo UKF utilizando a relação SoC-OCV obtida experimentalmente com o método

Incremental OCV em [12] e depois utilizando a expressão matemática que define a relação SoC-OCV apresentada por Zhang et al. em [11], que é a utilizada no presente modelo.

Na segunda etapa da avaliação, o modelo com a estimação do SoC por UKF e com a expressão matemática de SoC-OCV foi implementado no HYSDEL para a obtenção das variáveis de decisão. De modo similar, os erros RMSE e MAE do SoC estimado pelo UKF foram calculados e comparados aos valores obtidos por Zheng et al. em [12] com o método *Incremental OCV* para obtenção da curva SoC-OCV.

Por fim, na terceira etapa da avaliação, foi analisado se os erros de estimação obtidos com o presente modelo podem afetar as variáveis de decisão obtidas no HYSDEL e, conseqüentemente, afetar a otimização em V2G e G2V.

4.2.1 Definição de Parâmetros de Circuito

Os parâmetros de circuito são sempre obtidos experimentalmente para cada bateria, baseados no tratamento de dados. Tendo isso em vista, Zheng et al. em [12] estimaram parâmetros de circuito para o modelo de bateria INR 18650-20R, com o objetivo de avaliar duas metodologias experimentais para a obtenção da curva SoC-OCV.

Considerando a disponibilidade dos dados e visando o aproveitamento para a validação do modelo, neste trabalho considera-se que a bateria de lítio modelada será da categoria INR 18650-20R e a temperatura definida é de $25^{\circ}C$. Os valores de parâmetros de circuito para esta bateria a essa temperatura, obtidos por Zheng et al. em [12], são apresentados Tabela 4.

Tabela 4 – Parâmetros de Circuito Bateria INR 18650-20R a $25^{\circ}C$

Grandeza	Valor	Unidade
R_0	0.0710	Ω
R_1	0.0222	Ω
C_1	1201.4	F

Fonte: Zheng et al. em [12]

4.2.2 SoC Real

O SoC da bateria é um estado não observável, que não pode ser diretamente medido no sistema [57], [34], [12] e [11]. Considera-se que a sua real variação depende da quantidade de carga (em Coulombs) transferida da bateria para o sistema conectado a ela. Isso quer dizer que o SoC atual depende do SoC no instante anterior ($SoC[k-1]$), da corrente de entrada do sistema ($I[k]$), da capacidade máxima da bateria (Q_{max}) e da taxa

de amostragem da corrente inserida no sistema (t_S), conforme descrito na Equação (4.1). Esse é o chamado método de Contagem de Coulomb [58].

$$SoC[k] = SoC[k - 1] + \frac{I \cdot t_S}{Q_{max}} \quad (4.1)$$

O método de Contagem de Coulomb é tradicional para estimar o SoC de baterias. Entretanto, ele possui a limitação de que, se o estado inicial não for conhecido, haverá um erro na estimação do SoC que não será ajustado [12], [58]. Para considerá-lo como SoC real, portanto, é preciso saber o SoC inicial do sistema.

Zheng et al. nos experimentos definiram o SoC inicial pelas seguintes etapas: primeiro, a bateria de teste foi totalmente carregada por meio do carregamento padrão definido no *datasheet*; em seguida, a bateria foi deixada em repouso por duas horas para eliminar os efeitos de polarização; por fim, a bateria foi descarregada a uma taxa de corrente constante de 1/2C por 24 minutos para atingir o ponto SoC desejado (80%) conforme a curva SoC-OCV [12].

Com o valor inicial definido, foram realizados os testes com as bases de dados *FUDS* e *US06*. Todas as bases de dados possuem taxa de amostragem de $t_S = 5$ s. e os testes foram realizados para a bateria INR 18650-20R, cuja capacidade máxima é de $Q_{max} = 2000mAh$. Utilizando as unidades de tempo e corrente elétrica como segundos [s.] e Ampères [A], respectivamente, o valor da capacidade máxima da bateria é $Q_{max} = 7200$ As..

O SoC Real obtido com cada uma das bases de dados, conforme a Equação (4.1) é mostrado nas figuras 19 e 20.




Figura 19 – Soc Real da Base de Dados FUDS com SoC inicial de 0,8

Fonte: Próprio autor




Figura 20 – Soc Real da Base de Dados US06 com SoC inicial de 0,8

Fonte: Próprio autor

4.2.3 Avaliação da Utilização da Equação da Relação SoC-OCV

A presente etapa de avaliação da modelagem consiste em verificar a utilização da equação que relaciona SoC-OCV, apresentada Subseção 3.2.2 e obtida por Zhang et al. em [11].

Na Figura 21, é possível observar o SoC estimado com o UKF e a Equação 3.24), que relaciona SoC-OCV, para a base de dados FUDS, e SoC real para essa mesma base de dados. Na Figura 22, observa-se o SoC estimado e o SoC Real para a base de dados US06.

A partir da análise destas figuras, observa-se que os valores de SoC estimados pelo UKF estão muito próximos do SoC real, principalmente para as primeiras amostras. Ocorre uma divergência maior, entretanto, para as amostras finais do teste. Essas características também foram observadas por Zheng et al., em [12], que explicou que as divergências podem ser devido à não linearidade da relação SoC-OCV para valores de SoC próximos de 1 e próximos de zero.




Figura 21 – SoC Real e Estimado com UKF - FUDS

Fonte: Próprio autor




Figura 22 – SoC Real e Estimado com UKF - US06

Fonte: Próprio autor

Na Tabela 5 apresentam-se os valores de erro calculados para a estimação do SoC utilizando a expressão que relaciona SoC e OCV. Observa-se que os valores de erro RMSE e MAE obtidos neste teste estão próximos dos valores apresentados por Zheng et al. em [12] e mostrados na Figura 18.

Tabela 5 – RMSE e MAE para estimação do SoC utilizando Equação (3.24)

Base de Dados	RMSE	MAE
FUDS	0.4217	0.3690
US06	0.4797	0.4260

Fonte: Próprio Autor

4.2.4 Modelo HYSDEL

O objetivo da avaliação dos resultados da estimação do SoC para o modelo implementado no ambiente HYSDEL é verificar se o aplicativo pode inserir erros numéricos, como arredondamentos, que prejudiquem a estimação do SoC da bateria. Para tanto, calculou-se o RMSE e o MAE que são as mesmas métricas de erro utilizadas por Zheng et al. para avaliar a estimação do SoC com as curvas experimentais SoC-OCV [12]. Os valores obtidos foram comparados com os do artigo e também com os valores obtidos no modelo feito fora do HYSDEL.

As saídas binárias obtidas neste modelo também são verificadas. Essas variáveis são definidas a partir do EG, onde os valores contínuos definem as variáveis binárias. Os critérios para isso estão definidos conforme é mostrado na Tabela 6. O valor de SoC superior a 0,78 indica que o EV pode fornecer energia e habilita a variável de decisão δ_1 ; o valor de SoC abaixo de 0,60 indica que o EV deve se carregar e habilita a variável de

decisão δ_2 . Abaixo de 0,2, o EV deve parar e habilita a variável δ_3 . Esses valores foram definidos de forma diferente da otimização pois, como dados experimentais utilizados na avaliação indicam SoC inicial de 0,8, as indicações que o EV pode fornecer energia, por exemplo, não seriam visíveis. Então, optou-se por definir valores diferentes da otimização para que todas as saídas binárias possam ser verificadas.

Tabela 6 – Valores de SoC para a definição do EG

Evento	Parâmetro
$[\delta_1 = 1]$	$SoC[k-1] \geq 0,78$
$[\delta_2 = 1]$	$SoC[k-1] \geq 0,60$
$[\delta_3 = 1]$	$SoC[k-1] \geq 0,20$

Fonte: Próprio Autor

Na Figura 23, observa-se o resultado da estimação do SoC utilizando a Equação (3.24) no modelo HYSDEL para a base de dados FUDS. Já na Figura 25, apresentam-se os resultados para a base de dados US06. Os resultados das variáveis de decisão, para cada um dos testes, são apresentados nas figuras 24 e 26, respectivamente.




Figura 23 – SoC Real e SoC Estimado com UKF no HYSDEL - FUDS

Fonte: Próprio autor




Figura 24 – Saídas binárias do modelo HYSDEL - FUDS

Fonte: Próprio autor




Figura 25 – SoC Real e SoC Estimado com UKF no HYSDEL - US06

Fonte: Próprio autor




Figura 26 – Saídas binárias do modelo HYSDEL - US06

Fonte: Próprio autor

Na Tabela 7, apresentam-se os valores de erro calculados para a estimação do SoC no modelo HYSDEL, utilizando a Equação (3.24). Observa-se que nenhum dos valores de erro obtidos neste teste diferem até a quarta casa decimal dos valores do teste anterior apresentados na Tabela 5. Assim, o modelo aplicado em ambiente HYSDEL não apresenta prejuízos para a estimação do SoC.

Tabela 7 – RMSE e MAE para estimação do SoC utilizando expressão 3.24 e HYSDEL

Base de Dados	RMSE	MAE
FUDS	0.4217	0.3690
US06	0.4797	0.4260

Fonte: Próprio Autor

4.2.5 Análise do Erro Percentual e Tomada de Decisão

Nas figuras 27 e 28, observam-se os valores de erro percentual de estimação do SoC para as bases de dados FUDS e US06, respectivamente. Esses erros foram calculados conforme mostra a Equação (3.31). Observa-se que para a estimação dos estados de carga com valores muito próximos de zero, o erro percentual aumenta exponencialmente. Isso mostra uma fragilidade na utilização da Equação (3.24), que generaliza matematicamente a relação SoC-OCV, para a estimação de estados de carga muito próximos de zero. Nesse contexto, o máximo erro percentual obtido para a base de dados FUDS foi de 10% e para a base de dados US06 foi de 19,6%. Esses valores são superiores aos obtidos por Zheng et al. em [12], como é mostrado na última coluna dos gráficos apresentados na Figura 18.




Figura 27 – Erro Percentual de Estimação do SoC - FUDS

Fonte: Próprio autor




Figura 28 – Erro Percentual de Estimação do SoC - US06

Fonte: Próprio autor

Para avaliar se as limitações da utilização da Equação (3.24) comprometem a confiabilidade da tomada de decisão do modelo, verifica-se o quanto os erros percentuais afetam os valores de SoC, que definem cada decisão. O modelo do HYSDEL toma as decisões quando o SoC atinge os valores de 0,78, 0,60 e 0,20, definindo que o veículo pode fornecer energia, deve receber energia e deve parar, respectivamente. Na Tabela 8, mostra-se, para cada um desses valores de SoC, o intervalo obtido com o respectivo erro percentual. Os valores que definem o intervalo são calculados conforme as equações (4.2) e (4.3), onde I^+ é o valor máximo do intervalo, I^- é o valor mínimo do intervalo e EP é o

erro percentual.

$$I^+ = SoC + SoC \times EP \quad (4.2)$$

$$I^- = SoC - SoC \times EP \quad (4.3)$$

Observa-se, pela Tabela 8, que nenhum dos intervalos de valores se interceptam, portanto, os erros de estimação do SoC não alteram as variáveis de decisão obtidas no modelo. Isso quer dizer que, apesar do erro de estimação do SoC, não há possibilidade de habilitar o veículo para receber ou fornecer energia em uma situação em que sua bateria não esteja com quantidade de carga adequada para cada um dos casos.

Tabela 8 – Intervalos de valores de SoC devido ao erro percentual

FUDS		
SoC de Decisão	Erro Percentual	Intervalos
0,78	0,080	0,7794 a 0,7806
0,60	0,387	0,5976 a 0,6023
0,20	3,100	0,1938 a 0,2062
US06		
SoC de Decisão	Erro Percentual	Intervalos
0,78	0,04000	0,7768 a 0,7831
0,60	0,04073	0,5975 a 0,6024
0,20	0,32200	0,1935 a 0,2064

Fonte: Próprio Autor

5 CONCLUSÕES E TRABALHOS FUTUROS

Neste Capítulo são apresentadas as conclusões finais do trabalho. Além disso, apresentam-se propostas para trabalhos futuros que podem complementar as conclusões obtidas nesta dissertação.

5.1 Conclusões

No presente trabalho foi apresentada uma modelagem de otimização para a interação entre EVs e a rede elétrica, utilizando como interface CDS conectadas à rede. A otimização é feita a partir do ponto de vista dos EVs, mas também considera as limitações de fornecimento e recebimento de energia que podem estar presentes nas CDS. As avaliações da metodologia de otimização foram feitas considerando dados europeus, como mercado ideal de CDS, preços de EVs e preço de energia. A escolha da localidade está estritamente relacionada à disponibilidade de informações, ou seja, se as mesmas informações referentes a outros lugares forem disponibilizadas, a metodologia de otimização pode ser implementada.

No Cenário 1, foram apresentadas as opções de estações de carregamento e descarregamento de energia, conforme a distância máxima que o EV pode percorrer. Caso a bateria do EV esteja com o SoC elevado, são apresentadas as estações disponíveis para receber energia, os respectivos valores de lucro e quantidade ideal de energia a ser fornecida pelo EV à CDS. Se por outro lado o SoC da bateria estiver baixo, as estações apresentadas são aquelas disponíveis para fornecimento de energia, os respectivos valores de custo e quantidade ideal de energia a ser recebida pelo EV a partir da CDS.

No Cenário 2, a avaliação foi feita para o grupo de EVs e, neste caso, é possível observar que nem todos os EVs poderiam se carregar na estação mais próxima devido à limitação para fornecimento de energia, que foi considerada nas CDS. Por isso, a curva de Custo se apresenta com um valor mais elevado para a primeira estação, que receberia uma demanda maior de carregamento; os valores de custo para a segunda e terceira estações são mais baixos pois o carregamento nestas seria menor que na primeira; e a última estação teria o custo mais elevado, pois, por ser a mais longe do ponto inicial, teria um custo maior de carregamento.

As limitações para recebimento de energia não são tão significativas para a obtenção do lucro, pois, em geral, a quantidade de energia entregue aos EVs é maior do que a quantidade de energia que os EVs podem fornecer às CDS. Na análise do máximo lucro,

para todos os veículos a maior vantagem lucrativa se apresenta para o fornecimento de energia na primeira estação. Neste caso, quanto mais longe a CDS, mais energia que poderia ser vendida é perdida no trajeto.

Nos resultados apresentados, é possível observar que o algoritmo de otimização consegue atender às restrições impostas, considerando as funções objetivo definidas. As respostas informam a quantidade de energia adequada para se ter o lucro máximo e o custo mínimo do ponto de vista do EV, atendendo aos objetivos iniciais do projeto.

É importante lembrar que a definição de que o EV pode fornecer energia ou deve se carregar é feita pelo código, a partir da avaliação do SoC do veículo. O usuário recebe somente as indicações dos resultados para tomar a decisão de continuar o trajeto ou parar para vender ou comprar energia.

Na segunda parte desta dissertação, foi apresentada uma modelagem de baterias para obtenção de variáveis de decisão e estimação do SoC em tempo real, utilizando UKF e relação matemática da curva $SoC - OCV$. A modelagem da bateria foi construída com o formato DHA, capaz de obter variáveis de decisão a partir da avaliação de variáveis contínuas. Utilizou-se o *Software* HYSDEL para a simulação e obtenção de matrizes que descrevem o comportamento do modelo no formato MLD, para uma futura integração desta estimativa no problema de otimização.

As saídas do modelo de estimação do SoC de bateria não foram utilizadas como entrada para a otimização, uma vez que seria necessário obter dados das baterias utilizadas em todos os EVs considerados na otimização, além de avaliar a variação do SoC considerando toda a estrutura do EV para obter os valores que são utilizados na otimização em V2G-G2V, como consumo em km/kW e etc. Esta, portanto, é uma avaliação sugerida na parte de Trabalhos Futuros, na Seção 5.2, tendo em vista que a obtenção de valores mais precisos de SoC é essencial para a modelagem de otimização em V2G.

A avaliação da modelagem de baterias foi feita por partes, considerando a base de dados de ensaios de uma bateria de Íon-Lítio, disponível gratuitamente por uma instituição de pesquisa norte-americana. Primeiramente, avaliou-se se a expressão matemática utilizada para a relação $SoC - OCV$ aumentaria o erro na estimação dos estados por UKF. Em seguida, o modelo foi implementado no HYSDEL para a obtenção das variáveis de decisão e a estimação dos estados por UKF foi avaliada novamente.

Os resultados mostram que a utilização da expressão matemática $SoC - OCV$ gera o aumento do erro médio para a estimação de estados próximos de zero. Apesar disso, os valores obtidos não provocam interseção entre os intervalos que definem quando o EV deve se carregar, quando pode vender energia e quando precisa ser estacionado. Dessa forma, pode-se concluir que a utilização da expressão matemática não provoca erros prejudiciais à obtenção de variáveis de decisão do sistema.

Na simulação do modelo observa-se, ainda, que na implementação do HYSDEL não há prejuízos para a estimação dos estados. Além disso, os resultados das variáveis de decisão foram obtidos conforme o esperado.

5.2 Trabalhos Futuros

Diante dos resultados obtidos, é possível propor os seguintes trabalhos futuros:

- Obter os parâmetros de circuito e os valores de corrente e tensão nos terminais da bateria de um EV na estrada. Com isso, utilizar a modelagem de baterias como entrada para a modelagem de otimização apresentadas neste trabalho;
- Implementar a otimização onde os dois processos, tanto para venda quanto para compra, são modelados em conjunto resolvendo um único problema de otimização.
- Implementar a metodologia de otimização contextualizada na cidade, adaptando o cálculo da distância a uma variação não-linear entre o EV e as CDS;
- Contextualizar e implementar a modelagem de otimização no Brasil, utilizando as informações necessárias quando as mesmas estiverem disponíveis.

REFERÊNCIAS

- [1] International Energy Agency. *Global EV Outlook 2019*. 2019. Disponível em: www.iea.org/publications/reports/globalevoutlook2019. Citado na página 19.
- [2] European Environmental Agency. *Electric Vehicles in Europe*. 2016. Disponível em: <https://www.eea.europa.eu/publications/electric-vehicles-in-europe>. Citado 2 vezes nas páginas 19 e 54.
- [3] Hosseini, S. S.; Badri, A.; Parvania, M. The plug-in electric vehicles for power system applications: The vehicle to grid (v2g) concept. In: *2012 IEEE International Energy Conference and Exhibition (ENERGYCON)*. [S.l.: s.n.], 2012. p. 1101–1106. Citado na página 19.
- [4] Karfopoulos, E. L. et al. Introducing electric vehicles in the microgrids concept. In: *2011 16th International Conference on Intelligent System Applications to Power Systems*. [S.l.: s.n.], 2011. p. 1–6. Citado na página 19.
- [5] Kempton, W.; Letendre, S. E. Electric vehicles as a new power source for electric utilities. *Transportation Research Part D: Transport and Environment*, v. 2, n. 3, p. 157 – 175, 1997. ISSN 1361-9209. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1361920997000011>. Citado 2 vezes nas páginas 19 e 25.
- [6] Yilmaz, M.; Krein, P. T. Review of the impact of vehicle-to-grid technologies on distribution systems and utility interfaces. *IEEE Transactions on Power Electronics*, v. 28, n. 12, p. 5673–5689, 2013. Citado 2 vezes nas páginas 19 e 20.
- [7] Tan, K. M.; Ramachandramurthy, V. K.; Yong, J. Y. Integration of electric vehicles in smart grid: A review on vehicle to grid technologies and optimization techniques. *Renewable and Sustainable Energy Reviews*, v. 53, p. 720 – 732, 2016. ISSN 1364-0321. Disponível em: <http://www.sciencedirect.com/science/article/pii/S136403211500982X>. Citado 2 vezes nas páginas 19 e 25.
- [8] Liu, H. et al. Optimal dispatch for participation of electric vehicles in frequency regulation based on area control error and area regulation requirement. *Applied Energy*, v. 240, p. 46 – 55, 2019. ISSN 0306-2619. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0306261919303411>. Citado na página 19.
- [9] Systems Optimization Laboratory - Stanford University. *User guide for MINOS 5.5: Fortran package for large-scale optimization*. Disponível em: <https://web.stanford.edu/group/SOL/minos.htm>. Citado 2 vezes nas páginas 20 e 29.
- [10] Piller, S.; Perrin, M.; Jossen, A. Methods for state-of-charge determination and their applications. *Journal of Power Sources*, v. 96, n. 1, p. 113 – 120, 2001. ISSN 0378-7753. Proceedings of the 22nd International Power Sources Symposium. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0378775301005602>. Citado 2 vezes nas páginas 21 e 30.

- [11] Zhang, C. et al. A generalized soc-ocv model for lithium-ion batteries and the soc estimation for Inmco battery. *Energies*, v. 9, p. 900, 11 2016. Citado 7 vezes nas páginas 21, 22, 30, 48, 64, 66 e 68.
- [12] Zheng, F. et al. Influence of different open circuit voltage tests on state of charge online estimation for lithium-ion batteries. *Applied Energy*, v. 183, p. 513 – 525, 12 2016. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0306261916313125>>. Citado 15 vezes nas páginas 21, 22, 30, 46, 47, 48, 52, 63, 64, 65, 66, 67, 68, 69 e 72.
- [13] AN online SOC and capacity estimation method for aged lithium-ion battery pack considering cell inconsistency. *Journal of Energy Storage*, v. 29, p. 101250, 2020. ISSN 2352-152X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S2352152X19311028>>. Citado na página 21.
- [14] Liu, S. et al. Deep-discharging li-ion battery state of charge estimation using a partial adaptive forgetting factors least square method. *IEEE Access*, v. 7, p. 47339–47352, 2019. Citado na página 21.
- [15] Azis, N. A.; Joelianto, E.; Widyotriatmo, A. State of charge (soc) and state of health (soh) estimation of lithium-ion battery using dual extended kalman filter based on polynomial battery model. In: *2019 6th International Conference on Instrumentation, Control, and Automation (ICA)*. [S.l.: s.n.], 2019. p. 88–93. Citado na página 21.
- [16] Aylor, J. H.; Thieme, A.; Johnso, B. W. A battery state-of-charge indicator for electric wheelchairs. *IEEE Transactions on Industrial Electronics*, v. 39, n. 5, p. 398–409, 1992. ISSN 1557-9948. Citado na página 22.
- [17] Salkind, A. J. et al. Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology. *Journal of Power Sources*, v. 80, n. 1, p. 293 – 300, 1999. ISSN 0378-7753. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378775399000798>>. Citado na página 22.
- [18] Shen, Y. Adaptive online state-of-charge determination based on neuro-controller and neural network. *Energy Conversion and Management*, v. 51, n. 5, p. 1093 – 1098, 2010. ISSN 0196-8904. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0196890409005214>>. Citado na página 22.
- [19] Xing, Y. et al. State of charge estimation of lithium-ion batteries using the open-circuit voltage at various ambient temperatures. *Applied Energy*, v. 113, p. 106–115, 01 2014. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0306261913005746>>. Citado 2 vezes nas páginas 22 e 64.
- [20] Xiao, T. et al. Comparative study of ekf and ukf for soc estimation of lithium-ion batteries. In: *2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia)*. [S.l.: s.n.], 2019. p. 1570–1575. Citado na página 22.
- [21] Heemels, W.; De Schutter, B.; Bemporad, A. Equivalence of hybrid dynamical models. *Automatica*, v. 37, n. 7, p. 1085 – 1091, 2001. ISSN 0005-1098. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0005109801000590>>. Citado na página 22.

- [22] Bemporad, A.; Morari, M. Control of systems integrating logic, dynamics, and constraints. *Automatica*, v. 35, n. 3, p. 407 – 427, 1999. ISSN 0005-1098. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0005109898001782>. Citado na página 22.
- [23] Gago, R. G.; Pinto, S. F.; Silva, J. F. G2v and v2g electric vehicle charger for smart grids. In: *2016 IEEE International Smart Cities Conference (ISC2)*. [S.l.: s.n.], 2016. p. 1–6. Citado 3 vezes nas páginas 25, 26 e 27.
- [24] Zhou, Y.; Li, X. Vehicle to grid technology: A review. In: . [S.l.: s.n.], 2015. Citado na página 25.
- [25] Monteiro, V.; Pinto, J. G.; Afonso, J. L. Operation modes for the electric vehicle in smart grids and smart homes: Present and proposed modes. *IEEE Transactions on Vehicular Technology*, v. 65, n. 3, p. 1007–1020, 2016. Citado na página 25.
- [26] Eider, M.; Berl, A. Dynamic generation of recommendations for ev battery health. In: *2018 International Conference of Electrical and Electronic Technologies for Automotive*. [S.l.: s.n.], 2018. p. 1–6. Citado 3 vezes nas páginas 27, 42 e 54.
- [27] Lu, L. et al. A review on the key issues for lithium-ion battery management in electric vehicles. *Journal of Power Sources*, v. 226, p. 272–288, 03 2013. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0378775312016163>. Citado 2 vezes nas páginas 27 e 30.
- [28] M.Falvo et al. Ev charging stations and modes: International standards. In: . [S.l.: s.n.], 2014. p. 1134–1139. ISBN 978-1-4799-4749-2. Citado na página 27.
- [29] Boyd, S. P.; Vandenberghe, L. *Convex Optimization*. Cambridge, USA: Cambridge University Press, 2004. Citado na página 28.
- [30] AMPL. *MINOS for AMPL*. Disponível em: <https://ampl.com/products/solvers/solvers-we-sell/minos/>. Citado na página 29.
- [31] Stanford Business Software Inc. *MINOS 5.5 - Description*. Disponível em: http://www.sbsi-sol-optimize.com/asp/sol_products_minos_desc.htm. Citado na página 29.
- [32] Yang, X. Chapter 22 - linear programming. In: *Engineering Mathematics with Examples and Applications*. Academic Press, 2017. p. 259 – 265. ISBN 978-0-12-809730-4. Disponível em: <http://www.sciencedirect.com/science/article/pii/B9780128097304000306>. Citado na página 29.
- [33] Saunders, M. *Large-Scale Numerical Optimization - Notes 12 - MINOS Part 2: LCL Methods*. 2018. Disponível em: <https://web.stanford.edu/class/msande318/notes.html>. Citado na página 30.
- [34] He, W. et al. State of charge estimation for electric vehicle batteries using unscented kalman filtering. *Microelectronics Reliability*, v. 53, n. 6, p. 840 – 847, 2013. ISSN 0026-2714. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0026271412005185>. Citado 4 vezes nas páginas 30, 32, 64 e 66.

- [35] Aiube, F. A. L. *Modelagem dos Preços Futuros de Commodities: Abordagem pelo Filtro de Partículas*. Tese (Doutorado) — Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio), Programa de Pós Graduação em Engenharia de Produção, Rio de Janeiro, 2005. Citado 3 vezes nas páginas 30, 31 e 49.
- [36] Hargrave, P. J. A tutorial introduction to kalman filtering. In: *IEEE Colloquium on Kalman Filters: Introduction, Applications and Future Developments*. [S.l.: s.n.], 1989. p. 1/1–1/6. Citado na página 31.
- [37] Ferraz, R. S. B. *Estimativa de Preços de Contratos Futuros Sobre Petróleo Utilizando o Método do Filtro de Kalman*. Tese (Doutorado) — Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio), Programa de Pós Graduação em Engenharia de Produção, Rio de Janeiro, 2009. Citado na página 31.
- [38] Scardua, L. A. *Sintonia Automática do Filtro de Kalman Unscented*. Tese (Doutorado) — Universidade de São Paulo, Escola Politécnica, Programa de Pós Graduação em Engenharia de Sistemas, São Paulo, 2015. Citado 4 vezes nas páginas 32, 33, 34 e 35.
- [39] Zandt, J. V. A more robust unscented transform. In: . [S.l.: s.n.], 2001. v. 4473, p. 371–380. Citado na página 33.
- [40] Magalhães, M. N. *Probabilidade e Variáveis Aleatórias*. São Paulo: Editora da Universidade de São Paulo (Edusp), 2015. Citado na página 33.
- [41] EV Database Organisation. *Electric Vehicle Database*. Disponível em: <<https://ev-database.org/>>. Citado 2 vezes nas páginas 38 e 84.
- [42] Zhou, C. et al. Modeling of the cost of ev battery wear due to v2g application in power systems. *IEEE Transactions on Energy Conversion*, v. 26, n. 4, p. 1041–1050, 2011. ISSN 1558-0059. Citado 3 vezes nas páginas 39, 40 e 55.
- [43] Misyris, G. S. et al. Battery energy storage systems modeling for online applications. In: *2017 IEEE Manchester PowerTech*. [S.l.: s.n.], 2017. p. 1–6. Citado na página 46.
- [44] Xiong, R.; Yu, Q.; Sun, F. A study on the inflence of two ocv tests on state of charge estimation of lithium ion battery. In: *2017 12th IEEE Conference on Industrial Electronics and Applications (ICIEA)*. [S.l.: s.n.], 2017. p. 608–612. ISSN 2158-2297. Citado na página 47.
- [45] Mignone, D.; Bemporad, A.; Morari, M. A framework for control, fault detection, state estimation, and verification of hybrid systems. In: *Proceedings of the 1999 American Control Conference (Cat. No. 99CH36251)*. [S.l.: s.n.], 1999. v. 1, p. 134–138 vol.1. ISSN 0743-1619. Citado na página 49.
- [46] e Silva, D. P. et al. Hybrid modeling of energy storage system and electrical loads in a pilot-microgrid. In: *2018 13th IEEE International Conference on Industry Applications (INDUSCON)*. [S.l.: s.n.], 2018. p. 433–438. Citado na página 49.
- [47] Bemporad, A.; Ferrari-Trecate, G.; Morari, M. Observability and controllability of piecewise affine and hybrid systems. *IEEE Transactions on Automatic Control*, v. 45, n. 10, p. 1864–1876, Oct 2000. ISSN 0018-9286. Citado na página 49.

- [48] Fornahl, D.; Werner, N. *E-Mobility in Europe*. [S.l.]: Springer International Publishing Switzerland, 2015. ISBN 978-3-319-13194-8. Citado na página 54.
- [49] Holaluz - Espanha. *Tarifa Coche Eléctrico*. Disponível em: <<https://www.holaluz.com/coche-electrico/>>. Citado 2 vezes nas páginas 54 e 55.
- [50] Bloomberg New Energy Finances. *Lithium-ion Battery Costs and Market*. 2017. Disponível em: <<https://data.bloomberglp.com/bnef/sites/14/2017/07/BNEF-Lithium-ion-battery-costs-and-market.pdf>>. Citado na página 55.
- [51] Bloomberg New Energy Finances. *Battery Pack Prices Fall As Market Ramps Up With Market Average At 156/kWh In 2019*. 2019. Disponível em: <<https://about.bnef.com/blog/battery-pack-prices-fall-as-market-ramps-up-with-market-average-at-156-kwh-in-2019/>>. Citado 2 vezes nas páginas 55 e 84.
- [52] CRE Commission de la Régulation de l'Énergie en France. *Les Réseaux Électriques au Service des Véhicules Électriques*. 2018. Document de Réflexion et de Proposition. Citado na página 56.
- [53] Nikitha, L. et al. Effect of electrical vehicle charging on power quality. In: *2017 International Conference on Circuit ,Power and Computing Technologies (ICCPCT)*. [S.l.: s.n.], 2017. p. 1–6. Citado na página 56.
- [54] INR 18650-20R Battery Database. Disponível em: <<https://web.calce.umd.edu/batteries/data.htm>>. Citado 2 vezes nas páginas 63 e 64.
- [55] Chen, N. et al. Estimation of li-ion battery state of charging and state of healthy based on unscented kalman filtering. In: *The 26th Chinese Control and Decision Conference (2014 CCDC)*. [S.l.: s.n.], 2014. p. 4725–4729. ISSN 1948-9439. Citado na página 64.
- [56] He, W. et al. State of charge estimation for li-ion batteries using neural network modeling and unscented kalman filter-based error cancellation. *International Journal of Electrical Power and Energy Systems*, v. 62, p. 783–791, 11 2014. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0142061514002646>>. Citado na página 64.
- [57] Hu, X.; Li, S.; Peng, H. A comparative study of equivalent circuit models for li-ion batteries. *Journal of Power Sources*, v. 198, p. 359–367, 01 2012. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378775311019628>>. Citado na página 66.
- [58] Fathoni, G. et al. 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 (ICACOMIT)*. [S.l.: s.n.], 2017. p. 70–74. Citado na página 67.

Anexos

ANEXO A – MODELOS DE VEÍCULOS ELÉTRICOS

As informações sobre os modelos de veículos elétricos apresentadas nas tabelas a seguir foram obtidas no *site: Electric Vehicle Database* [41]. Com exceção do preço da bateria, que foi estimado considerando o valor de 141,17€ [51].

Tabela 9 – Características Peugeot e-2008 SUV

Parâmetros	Valor
Preço do EV [€]	35.250,00
Eficiência [km/kWh]	5,2632
Alcance na Estrada em temperatura média [km]	250
Capacidade total da bateria [kWh]	50
Capacidade útil da bateria [kWh]	47.5
Permite recarga rápida	Sim
Tempo para carregamento rápido de 10 a 80% [$minutos$]	28
Preço da Bateria [€]	7.058,00

Tabela 10 – Características Kia e-Niro

Parâmetros	Valor
Preço do EV [€]	39.090,00
Eficiência [km/kWh]	5,3763
Alcance na Estrada em temperatura média [km]	345
Capacidade total da bateria [kWh]	67.1
Capacidade útil da bateria [kWh]	64
Permite recarga rápida	Sim
Tempo para carregamento rápido de 10 a 80% [$minutos$]	44
Preço da Bateria [€]	9.472,50

Tabela 11 – Características BMW i3

Parâmetros	Valor
Preço do EV [€]	38.000,00
Eficiência [km/kWh]	5,6818
Alcance na Estrada em temperatura média [km]	215
Capacidade total da bateria [kWh]	42.2
Capacidade útil da bateria [kWh]	37.9
Permite recarga rápida	Sim
Tempo para carregamento rápido de 10 a 80% [$minutos$]	36
Preço da Bateria [€]	5.957,40

Tabela 12 – Características Renault Zoe ZE50

Parâmetros	Valor
Preço do EV [€]	31.990,00
Eficiência [km/kWh]	5,5866
Alcance na Estrada em temperatura média [km]	290
Capacidade total da bateria [kWh]	55
Capacidade útil da bateria [kWh]	52
Permite recarga rápida	Sim
Tempo para carregamento rápido de 10 a 80% [$minutos$]	56
Preço da Bateria [€]	7.764,30

Tabela 13 – Características Nissan Leaf

Parâmetros	Valor
Preço do EV [€]	36.800,00
Eficiência [km/kWh]	5,5556
Alcance na Estrada em temperatura média [km]	200
Capacidade total da bateria [kWh]	40
Capacidade útil da bateria [kWh]	36
Permite recarga rápida	Sim
Tempo para carregamento rápido de 10 a 80% [$minutos$]	40
Preço da Bateria [€]	5.646,80

Tabela 14 – Características Hyundai Kona

Parâmetros	Valor
Preço do EV [€]	41.400,00
Eficiência [km/kWh]	5,7143
Alcance na Estrada em temperatura média [km]	365
Capacidade total da bateria [kWh]	67.1
Capacidade útil da bateria [kWh]	64
Permite recarga rápida	Sim
Tempo para carregamento rápido de 10 a 80% [$minutos$]	44
Preço da Bateria [€]	9.472,50

ANEXO B – MATRIZES MLD DO MODELO DA BATERIA

```

S.name = 'bateria';
S.MLDisvalid = 1;
S.MLDstructver = 2;
S.MLDsymtable = 1;
S.MLDrowinfo = 1;
S.Arr = zeros(2, 2);
S.Arb = zeros(2, 0);
S.Abr = zeros(0, 2);
S.Abb = zeros(0, 0);

S.B1rr = [
1 0 0 0 ;
0 (params.auxcap) * (1) 0 0 ;
];
S.B1rb = zeros(2, 1);
S.B1br = zeros(0, 4);
S.B1bb = zeros(0, 1);

S.B2rb = zeros(2, 6);
S.B2bb = zeros(0, 6);

S.B3rr = [
((params.Ts) * (100)) / (params.qbat) ;
((params.r1) * ((1) - (params.auxcap))) * (1) ;
];
S.B3br = zeros(0, 1);

S.Crr = [
1 0 ;
0 1 ;
];
S.Crb = zeros(2, 0);
S.Cbr = zeros(3, 2);

```

```
S.Cbb = zeros(3, 0);
```

```
S.D1rr = zeros(2, 4);
```

```
S.D1rb = zeros(2, 1);
```

```
S.D1br = zeros(3, 4);
```

```
S.D1bb = zeros(3, 1);
```

```
S.D2rb = zeros(2, 6);
```

```
S.D2bb = [
```

```
0 0 0 1 0 0 ;
```

```
0 0 0 0 1 0 ;
```

```
0 0 0 0 0 1 ;
```

```
];
```

```
S.D3rr = zeros(2, 1);
```

```
S.D3br = zeros(3, 1);
```

```
S.E1 = [
```

```
-1 0 0 0 0 ;
```

```
1 0 0 0 0 ;
```

```
1 0 0 0 0 ;
```

```
-1 0 0 0 0 ;
```

```
-1 0 0 0 0 ;
```

```
1 0 0 0 0 ;
```

```
0 0 -1 0 -200 ;
```

```
0 0 1 0 -200 ;
```

```
0 0 0 -1 200 ;
```

```
0 0 0 1 200 ;
```

```
0 0 0 0 0 ;
```

```
0 0 0 0 0 ;
```

```
0 0 0 0 0 ;
```

```
0 0 0 0 0 ;
```

```
0 0 0 0 0 ;
```

```
0 0 0 0 0 ;
```

```
0 0 0 0 0 ;
```

```
];
```

```
S.E2 = [
```

```
-1422.000001 0 0 0 0 0 ;
```

```
1578 0 0 0 0 0 ;
```

```

0 -1562.0000001 0 0 0 0 ;
0 1438 0 0 0 0 ;
0 0 -1480.0000001 0 0 0 ;
0 0 1520 0 0 0 ;
0 0 0 0 0 0 ;
0 0 0 0 0 0 ;
0 0 0 0 0 0 ;
0 0 0 0 0 0 ;
1 0 0 -1 0 0 ;
-1 0 0 1 0 0 ;
-1 1 0 0 -1 0 ;
1 0 0 0 1 0 ;
0 -1 0 0 1 0 ;
0 0 -1 0 0 -1 ;
0 0 1 0 0 1 ;
];
S.E3 = [
0 ;
0 ;
0 ;
0 ;
0 ;
0 ;
0 ;
-1 ;
1 ;
-1 ;
1 ;
0 ;
0 ;
0 ;
0 ;
0 ;
0 ;
0 ;
0 ;
];
S.E4 = zeros(17, 2);
S.E5 = [
77.999999 ;
1500 ;

```

```

-62.000001 ;
1500 ;
19.999999 ;
1500 ;
200 ;
200 ;
0 ;
0 ;
0 ;
0 ;
0 ;
1 ;
0 ;
-1 ;
1 ;
];
S.A = [S.Arr, S.Arb; S.Abr, S.Abb];
S.B1 = [S.B1rr, S.B1rb; S.B1br, S.B1bb];
S.B2 = [S.B2rb; S.B2bb];
S.B3 = [S.B3rr; S.B3br];

S.C = [S.Crr, S.Crb; S.Cbr, S.Cbb];
S.D1 = [S.D1rr, S.D1rb; S.D1br, S.D1bb];
S.D2 = [S.D2rb; S.D2bb];
S.D3 = [S.D3rr; S.D3br];

```