

DESENVOLVIMENTO E AVALIAÇÃO DE UMA ESTRATÉGIA DE GESTÃO ENERGÉTICA EM FCHEV

CARLA ALEXANDRA SILVA REISINHO

julho de 2022

DESENVOLVIMENTO E AVALIAÇÃO DE UMA ESTRATÉGIA DE GESTÃO ENERGÉTICA EM FCHEV

Carla Alexandra Silva Reisinho

2022

Instituto Superior de Engenharia do Porto

Departamento de Engenharia Mecânica

isen

P.PORTO

DESENVOLVIMENTO E AVALIAÇÃO DE UMA ESTRATÉGIA DE GESTÃO ENERGÉTICA EM FCHEV

Carla Alexandra Silva Reinho

Estudante n.º 1170771

Dissertação apresentada ao Instituto Superior de Engenharia do Porto para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Engenharia e Gestão Industrial, realizada sob a orientação do Doutor Manuel Joaquim Pereira Lopes

2022

Instituto Superior de Engenharia do Porto

Departamento de Engenharia Mecânica

isen

P.PORTO

AGRADECIMENTOS

Em primeiro lugar, gostaria de agradecer ao meu orientador, Professor Manuel Pereira Lopes, por inicialmente me ter apresentado este projeto desafiador e por todo o apoio disponibilizado ao longo destes meses, dando sugestões e críticas construtivas que permitiram enriquecer todo o trabalho.

Deixo também uma palavra de agradecimento a toda a equipa de Engenharia 1 da CaetanoBus, pelo incrível ambiente de trabalho e entreajuda. Em especial, agradeço aos Engenheiros Tiago Rocha e João Madureira, por me terem dado a oportunidade de abraçar este projeto, por toda a orientação, motivação e conhecimentos partilhados e por terem criado todas as condições para que este estágio tenha sido uma experiência muito positiva.

Toda esta jornada não teria sido a mesma sem o meu grupo de amigos, que estiveram sempre presentes durante estes 5 anos e permitiram que fosse mais fácil ultrapassar todos os desafios. Não seria possível ter melhor companhia nem melhores memórias convosco.

Agradeço também a quem me acompanhou no primeiro ano do ensino superior, um ano especialmente difícil e de escolhas importantes. Foi fundamental ter criado esta amizade, que especialmente agora tem um papel importantíssimo, dando o suporte necessário para me manter sempre motivada e focada. Obrigada, Nuno, por todo o apoio incondicional.

Finalmente, é na família que se encontra a maior base para todo o meu progresso. Acreditaram em mim em todos os momentos e construíram os alicerces para ser a pessoa que sou hoje. A vocês devo o maior agradecimento de todos: Obrigada.

página propositadamente em branco

RESUMO

Devido à crescente preocupação com as alterações climáticas e à consequente mudança de paradigma, gradualmente são utilizados mais veículos elétricos e híbridos, como é o caso dos FCHEV (*Fuel cell Hybrid Electric Vehicle*). Como é característico nos veículos híbridos, a existência de duas fontes de energia faz com que seja crucial otimizar a distribuição de potência, sendo esta a chave para melhorar o desempenho do veículo. Assim, definiu-se como medida principal de desempenho o consumo equivalente em *Gasoline Gallon Equivalent*, que efetua um *tradeoff* entre o consumo de hidrogénio e o consumo ponderado de energia da bateria, em função do seu estado de carga.

Tendo como principais objetivos o aumento do tempo de vida dos componentes e a redução do consumo do veículo, construiu-se uma estratégia de gestão energética em tempo real, baseada em programação dinâmica, com extração de regras de controlo pela *response surface methodology* e implementação de *machine learning* para a identificação dos tipos de ciclo de condução.

A estratégia foi construída e simulada em Matlab, partindo da modelação do sistema e da implementação da função DPM (*Dynamic Programming Matrix*), desenvolvida pelo instituto ETH Zurich para efetuar a programação dinâmica. Seguidamente, foi utilizada a função *stepwiselm* e a app *Regression Learner* para extrair as regras de controlo e, finalmente, recorreu-se à app *Classification Learner* para identificar os ciclos de condução. Toda a estratégia foi complementada com o *Matlab Coder*, para fazer a transição do algoritmo para linguagem C, suportada pela ECU.

Os resultados foram analisados no final de cada fase de implementação, validando a metodologia proposta. Assim, na fase de otimização demonstrou-se que é possível melhorar o consumo equivalente, relativamente ao algoritmo implementado no veículo, obtendo-se uma redução média superior a 15%, sem se demonstrarem alterações significativas no consumo de H_2 . A partir destes resultados, efetuou-se a extração de regras de controlo, utilizando duas estratégias distintas: regressões não lineares e árvores de decisão. No caso da primeira, não foi possível demonstrar que efetivamente o consumo equivalente é menor, apesar da percentagem de redução desse consumo ser em média superior a zero. No caso da segunda, a robustez do modelo de *machine learning* demonstrou que em média o consumo equivalente é menor do que no algoritmo atualmente presente no autocarro, sendo que a percentagem de redução em média ultrapassa os 10%. Com ambas as estratégias, as alterações no consumo de H_2 não se mostraram significativas.

Na fase de reconhecimento do ciclo de condução, utilizou-se uma árvore de decisão que foi analisada para diferentes tempos de decisão, demonstrando-se que com 600 e 300 segundos a identificação apresentou os melhores resultados de *accuracy*, sendo perceptível que para 300 segundos será reduzido o espaço em memória na ECU para armazenamento dos parâmetros de condução, mostrando-se também ser mais preciso em cenários mais semelhantes com a realidade.

Finalmente os testes de estrada demonstraram melhorias de 15.7% no consumo equivalente, 24.4% no consumo de H_2 e 6.8% no rendimento, com a estratégia que utiliza regressões não lineares. No entanto, o algoritmo mais adequado seria o construído com árvores de decisão, que devido à sua complexidade não foi possível de implementar na ECU.

PALAVRAS-CHAVE

FCHEV, Estratégia de Gestão Energética, Programação Dinâmica, Fuel Cell, Consumo Equivalente.

página propositadamente em branco

ABSTRACT

Due to the growing focus on climate change and its influence in the transportation sector, more and more electric and hybrid vehicles are being used, much like FCHEV (*Fuel cell Hybrid Electric Vehicle*). Having a double energy source, it is crucial to optimize power distribution which is the key element to improving the vehicle's performance. As such, for the sake of measuring performance, the Gasoline Gallon Equivalent consumption was used as the main unit of measurement because it jointly considers the energy tradeoff between hydrogen consumption and the estimated battery energy consumption based on its charging status.

Considering the components' effective lifetime and low energy consumption as the main objectives, a live energy management strategy was developed based on dynamic programming, control rules from response surface methodology and the implementation of machine learning which identifies the type of driving cycle.

This strategy was developed and simulated with Matlab, starting with system modeling and DPM (Dynamic Programming Matrix) function implementation, developed by the ETH Zurich institute to incorporate dynamic programming. Afterwards the *stepwiselm* function and the Regression Learner app were used to extract control rules and finally, the Classification Learner app was used to identify the driving cycles. This strategy was complemented with Matlab Coder in order to transition the algorithm to C so as to be supported by the bus' ECU.

The results were analyzed at the end of each implementation phase, validating the proposed methodology. Therefore, in the optimization phase, it was proven that it is possible to improve efficiency, compared to the algorithm already implemented in the vehicle, managing an average improvement of 15%, without causing any significant changes to the H₂ consumption. From these results, the control rules were extracted using two distinct strategies: non-linear regressions and decision trees. For the first one, it wasn't possible to demonstrate a lower equivalent consumption, even though the efficiency percentage was on average above zero. As for the second one, because of the complexity and resulting effectiveness of the machine learning model, it was showed that on average, the equivalent consumption is lower than the currently implemented algorithm, showing an average cut in equivalent consumption above 10%. With both strategies, the changes in H₂ consumption were not significant.

In the driving pattern recognition phase, a decision tree was used and analyzed for different decision response times, showing that with 600 and 300 seconds the presented identification was more accurate, knowing that for 300 seconds the used memory space in the ECU for the driving parameters is reduced, while also being more precise in scenarios closer to reality.

Ultimately the road tests showed 15.7% of improvements in the equivalent consumption, 24.45% in H₂ consumption and 6.8% in efficiency, with the strategy that uses non-linear regressions. However, the most adequate algorithm using the decision tree, due to its complexity, cannot be implemented in the ECU.

KEYWORDS

FCHEV, Energy Management Strategy, Dynamic Programming, Fuel Cell, Equivalent Consumption

página propositadamente em branco

ÍNDICE

ÍNDICE DE FIGURAS	VII
ÍNDICE DE TABELAS	IX
LISTAS DE SIGLAS E SÍMBOLOS	XI
1. INTRODUÇÃO	13
1.1. Enquadramento e Pertinência	13
1.2. Questão e Objetivos de Investigação	14
1.3. Opções Metodológicas	14
1.4. Apresentação da Empresa	15
1.5. Estrutura do Trabalho	16
2. REVISÃO BIBLIOGRÁFICA.....	17
2.1. Paradigma Ambiental	17
2.1.1. Alterações climáticas	17
2.1.2. Políticas Ambientais	19
2.2. Fuel Cell Hybrid Electric Vehicle	20
2.2.1. Classificação dos veículos.....	20
2.2.2. Funcionamento do FCHEV	22
2.2.3. Topologias	23
2.3. Dificuldades na Implementação do Controlo.....	24
2.4. Estratégias de Gestão Energética em Veículos Híbridos	24
2.4.1. Estratégias baseadas em regras.....	25
2.4.2. Estratégias baseadas em otimização	26
2.4.3. Estratégia baseadas em aprendizagem.....	27
2.4.4. Estratégias mistas	29
3. APRESENTAÇÃO DO CASO DE ESTUDO: AUTOCARRO H2.CITY GOLD.....	33
3.1. Características e Funcionamento	33
3.2. Requisitos e Limitações	35
3.3. Ciclos de Condução	36
4. ESTRATÉGIA DE GESTÃO ENERGÉTICA PARA O AUTOCARRO H2 CITY GOLD	37
4.1. Apresentação da Estratégia.....	37
4.1.1. Otimização	37
4.1.2. Extração de regras de controlo	39
4.1.3. Reconhecimento do ciclo de condução	40
4.2. Implementação em Matlab	41
4.2.1. Programação dinâmica	41
4.2.2. Extração de regras de controlo	44
4.2.3. Reconhecimento do ciclo de condução	44
4.3. Validação e Visualização de Resultados	45

4.4. Implementação na ECU	46
5. APRESENTAÇÃO DE RESULTADOS.....	47
5.1. Otimização.....	47
5.1.1. Análise do fator de penalização do SOC	47
5.1.2. Resultados da DP.....	49
5.1.3. Análise de variância	51
5.2. Regras de Controlo	52
5.2.1. Seleção e descrição do modelo de extração.....	52
5.2.2. Resultados da regressão não linear	53
5.2.3. Resultados da árvore de decisão	58
5.3. Reconhecimento do Ciclo de Condução.....	62
5.3.1. Seleção e descrição do modelo.....	62
5.3.2. Análise do tempo de tomada de decisão.....	63
5.3.3. Resultados do reconhecimento em rotas mistas.....	64
5.4. Implementação do Algoritmo Completo.....	66
5.5. Testes de Estrada	67
5.5.1. Avaliação do reconhecimento do ciclo de condução.....	68
5.5.2. Comparação do algoritmo em simulação e em estrada	70
5.5.3. Comparação do algoritmo proposto com o algoritmo atual	71
6. CONCLUSÃO	73
6.1. Conclusões Finais.....	73
6.2. Limitações e Investigação Futura	75
REFERÊNCIAS BIBLIOGRÁFICAS	77
APÊNDICE A	83
APÊNDICE B	85
APÊNDICE C	89
APÊNDICE D.....	93

ÍNDICE DE FIGURAS

Figura 1- Estrutura acionista	15
Figura 2- Emissões de CO ₂ per capita (Ritchie & Roser, 2020).....	18
Figura 3- Emissões setoriais de gases com efeito de estufa na EU, em 2020 (Eurostat, 2022)	18
Figura 4- Emissões sectoriais de CO ₂ equivalente, em Portugal, em 2019 (REA, 2021)	19
Figura 5- Classificação de veículos (Das et al., 2017)	20
Figura 6- Configuração típica de um FCHEV (Ehsani et al., 2018)	22
Figura 7- Esquema de uma FC a hidrogénio (Erjavec, 2013).....	23
Figura 8- Topologias FCHEV (Tazelaar et al., 2013).....	23
Figura 9- Autocarro H2.City Gold	33
Figura 10- Funcionamento H2.City Gold (CaetanoBus, 2021b).....	34
Figura 11- Otimização com intervalos de 3326W	43
Figura 12- Otimização com intervalos de 175W	43
Figura 13- Proposta de Solução.....	46
Figura 14- Redução do consumo equivalente em função do u	47
Figura 15- Redução do consumo de H ₂ em função do u	48
Figura 16- Aumento do rendimento em função do u	48
Figura 17- SOC final em função do u	48
Figura 18- Comparação da <i>PFC</i> entre DP e regressão para ciclos urbanos	54
Figura 19- Comparação da <i>PFC</i> entre DP e regressão para ciclos intercity	54
Figura 20- Comparação da <i>PFC</i> entre DP e regressão para ciclos autoestrada.....	55
Figura 21- Comparação do SOC entre DP e regressão para ciclos urbanos.....	55
Figura 22- Comparação do SOC entre DP e regressão para ciclos intercity	56
Figura 23- Comparação do SOC entre DP e regressão para ciclos autoestrada.....	56
Figura 24- Parametrização <i>Fine Tree</i>	58
Figura 25- Comparação da <i>PFC</i> entre DP e árvore de decisão para ciclos urbanos	58
Figura 26- Comparação da <i>PFC</i> entre DP e árvore de decisão para ciclos intercity.....	59
Figura 27- Comparação da <i>PFC</i> entre DP e árvore de decisão para ciclos autoestrada	59
Figura 28- Comparação do SOC entre DP e árvore de decisão para ciclos urbanos.....	60
Figura 29- Comparação do SOC entre DP e árvore de decisão para ciclos intercity	60
Figura 30- Comparação do SOC entre DP e árvore de decisão para ciclos autoestrada.....	61
Figura 31- Parametrização e resultados da classificação com <i>Medium Tree</i>	63
Figura 32- Rota para testes de estrada	68
Figura 33- Teste de estrada com intervalo de 600 segundos	69
Figura 34- Teste de estrada com intervalo de 300 segundos	69
Figura 35- Comparação da <i>PFC</i> no veículo e na simulação para intervalo de 600 segundos.....	70
Figura 36- Comparação da <i>PFC</i> no veículo e na simulação para intervalo de 300 segundos.....	71
Figura 37- Proposta de solução detalhada.....	83
Figura 38- Comparação do veículo com a simulação, para intervalo de 600 segundos	89
Figura 39- Comparação do veículo com a simulação, para intervalo de 300 segundos	90
Figura 40- Comparação do algoritmo proposto com o atual, para intervalo de 600 segundos	91
Figura 41- Comparação do algoritmo proposto com o atual, para intervalo de 300 segundos	92
Figura 42- Análises de variância	93

página propositadamente em branco

ÍNDICE DE TABELAS

Tabela 1- Características do H2.City Gold (CaetanoBus, 2021b)	33
Tabela 2- Características do motor	34
Tabela 3- Características da bateria	34
Tabela 4- Características dos tanques de hidrogénio	35
Tabela 5- Ciclos de condução e respetivos parâmetros.....	36
Tabela 6- Fatores de <i>Gasoline Gallon Equivalent</i> (U.S. Department of Energy, 2021)	38
Tabela 7- Definição dos parâmetros da função DPM.....	42
Tabela 8- Resultados DP para ciclos urbanos.....	50
Tabela 9- Resultados DP para ciclos intercity.....	50
Tabela 10- Resultados DP para ciclos autoestrada	51
Tabela 11- Resultados da análise da variação do intervalo de tempo.....	63
Tabela 12- Resultados da análise da variação do intervalo de tempo em ciclos misto	65
Tabela 13- Resultados do algoritmo completo com regressão em ciclos misto	66
Tabela 14- Resultados do algoritmo completo com árvore de decisão em ciclos misto	67
Tabela 15- Resultados do algoritmo proposto e do atual, para os dois testes efetuados.....	72
Tabela 16- Comparação do algoritmo proposto com o atual, para os dois testes efetuados	72
Tabela 17- Resultados da regressão para ciclos urbanos	85
Tabela 18- Resultados da regressão para ciclos intercity.....	85
Tabela 19- Resultados da regressão para ciclos autoestrada	86
Tabela 20- Resultados da árvore de decisão para ciclos urbanos.....	86
Tabela 21- Resultados da árvore de decisão para ciclos intercity.....	87
Tabela 22- Resultados da árvore de decisão para ciclos autoestrada	87

página propositadamente em branco

LISTAS DE SIGLAS E SÍMBOLOS

Lista de Siglas

AEV	<i>All Electric Vehicle</i> (Veículo Totalmente Elétrico)
AFC	<i>Alkaline Fuel Cell</i> (Fuel Cell Alcalina)
AP	Acordo de Paris
BEV	<i>Battery Electric Vehicle</i> (Veículo Elétrico a Bateria)
CO ₂	Dióxido de Carbono
DMFC	<i>Direct Methanol Fuel Cell</i> (Fuel Cell de Metanol Direto)
DP	<i>Dynamic Programming</i> (Programação Dinâmica)
DPM	<i>Dynamic Programming Matrix</i> (Matriz de Programação Dinâmica)
ECMS	<i>Equivalent Consumption Minimization Strategy</i> (Estratégia de Minimização do Consumo Equivalente)
EM	<i>Electric Motor</i> (Motor Elétrico)
EMS	<i>Energy Management Strategies</i> (Estratégia de Gestão Energética)
FC	<i>Fuel cell</i> (Célula de Combustível)
FCEV	<i>Fuel cell Electric Vehicle</i> (Veículo Elétrico a Fuel Cell)
FCHEV	<i>Fuel cell Hybrid Electric Vehicle</i> (Veículo Elétrico Híbrido a Fuel Cell)
GGE	<i>Gasoline Gallon Equivalent</i> (Galão Equivalente de Gasolina)
H ₂	Hidrogénio
HEV	<i>Hybrid Electric Vehicle</i> (Veículo Elétrico Híbrido)
HVAC	<i>Heating, Ventilating and Air Conditioning</i> (Aquecimento, Ventilação e Ar Condicionado)
ICE	<i>Internal Combustion Engine</i> (Motor de Combustão Interna)
ICEV	<i>Internal Combustion Engine Vehicle</i> (Veículo com Motor de Combustão Interna)
ISEP	Instituto Superior de Engenharia do Porto
KP	<i>Kioto Protocol</i> (Protocolo de Quioto)
LP	<i>Linear Programming</i> (Programação Linear)
MCFC	<i>Molten Carbonate Fuel Cell</i> (Fuel Cell de Carbonato Fundido)
NN	<i>Neural Network</i> (Rede Neuronal)
P.Porto	Instituto Politécnico do Porto
PAFC	<i>Phosphoric Acid Fuel Cell</i> (Fuel Cell de Ácido Forfórico)
PEMFC	<i>Proton-Exchange Membrane Fuel cell</i> (Fuel Cell de Membrana de Troca de Protões)
PMP	<i>Pontryagin Minimum Principle</i> (Princípio Mínimo de Pontryagin)
PPS	<i>Peaking Power Source</i> (Fonte de Energia de Pico)
RMSE	<i>Root Mean Square Error</i> (Erro Quadrático Médio)
SC	Super Condensador
SOFC	<i>Solid Oxide Fuel Cell</i> (Fuel Cell de Óxido Sólido)
VOC	<i>Open Circuit Voltage</i> (Tensão de circuito aberto)

Lista de Símbolos

C_{bat}	Capacidade da bateria	Ah
I_{bat}	Corrente da bateria	Ah
J_k^*	Cost-to-go ótimo no instante k	GGE
P_{FC}	Potência pedida à FC	kW
P_{FC_ant}	Potência pedida à FC no instante anterior	kW
P_{FC_max}	Potência mínima pedida à FC	kW
P_{FC_min}	Potência máxima pedida à FC	kW
P_{HVAC}	Potência pedida pelo HVAC	kW
P_{bat}	Potência pedida à bateria	kW
P_{bat_max}	Potência máxima pedida à bateria	kW
P_{reqmed}	Potência pedida pelo veículo com alisamento exponencial	W
P_{req}	Potência pedida pelo veículo	kW
Q_{FC}	Consumo equivalente da FC	GGE
Q_{bat}	Consumo equivalente da bateria	GGE
R_{cha}	Resistência de carga	Ω
R_{dis}	Resistência de descarga	Ω
SOC_{max}	Estado de carga da bateria máximo	
SOC_{min}	Estado de carga da bateria mínimo	
SOC_{tar_max}	Estado de carga da bateria máximo desejável	
SOC_{tar_min}	Estado de carga da bateria mínimo desejável	
V_{OC}	Tensão de circuito aberto	V
g_{FC}	Consumo da FC	g/s
s_k	Variável de estado pedido de potência anterior à FC	kW
u_k	Variável de controlo (potência da FC)	kW
x_k	Variável de estado SOC	
η_{FC}	Eficiência da FC	
u	Constante de ajuste	
V	Velocidade	Km/h
L	Função de custos	
$rate$	Rate de subida e descida do pedido de potência à FC	kW
λ	Fator de penalização	
μ	Média	

1. INTRODUÇÃO

Neste capítulo faz-se uma breve descrição do contexto em que se irá realizar o projeto, bem como a pertinência do tema, quer no que diz respeito ao paradigma ambiental, quer relativamente ao desenvolvimento dos autocarros em causa. Seguidamente, enuncia-se a questão de investigação, o objetivo global e os objetivos específicos que se pretendem alcançar ao longo do projeto.

1.1. Enquadramento e Pertinência

Este trabalho é desenvolvido num estágio curricular na CaetanoBus, na área dos veículos híbridos a hidrogénio. A presença da empresa no mercado da mobilidade elétrica, no qual se incluem projetos de utilização da pilha de combustível da Toyota em autocarros urbanos, está alinhada com o compromisso de desenvolvimento de soluções cada vez mais amigas do ambiente (Caetanobus, 2019). Os mais recentes desenvolvimentos na área da sustentabilidade da CaetanoBus são os veículos e.City Gold, autocarro urbano elétrico, e H2.City Gold, autocarro a pilha de combustível, que já se encontram em circulação em diversos países.

Os autocarros híbridos a hidrogénio são a nova aposta de veículos sem emissões de gases poluentes, que permitem garantir a mesma disponibilidade e versatilidade de rotas, com tempos de reabastecimento curtos (FuelCellWorks, 2020). Estes veículos são equipados com células de combustível (*Fuel cell*) permitindo que o veículo seja “Hydrogen in, water out” (Toyota, 2019), apresentando diversas vantagens, nomeadamente a capacidade de utilizar a energia das travagens, zero emissões, baixos custos de manutenção e operação silenciosa (Wang et al., 2020). A implementação de veículos a hidrogénio nos transportes públicos é recente e está a crescer na Europa, como resposta às necessidades ambientais de descarbonização e com o propósito de alcançar uma economia com zero emissões até 2050 (Comissão Europeia, 2018). Deste modo, em diversos países da Europa, os veículos movidos a hidrogénio estão na transição da fase de testes para a fase de trabalho efetivo, sendo expectável que, segundo Yorke (2021), estes sejam capazes de manter o nível de serviço e a capacidade das rotas, comparativamente com os veículos a diesel.

Nos FCHEV, a *fuel cell* (FC) é considerada a fonte primária de energia e o sistema de armazenamento de energia é responsável por auxiliar o fornecimento de potência de forma rápida e dinâmica (Wang et al., 2020). Assim, para melhorar o desempenho de todo o sistema é necessária uma estratégia de gestão energética, capaz de coordenar a potência fornecida pela FC e pelo sistema de armazenamento (Wang et al., 2020), de modo a garantir uma melhor performance em termos energéticos e um aumento do tempo de vida dos principais componentes, reduzindo os custos de manutenção (Sorlei et al., 2021).

A energia fornecida pelo sistema deve ser gerida de tal forma a que seja satisfeita a potência requerida pelo veículo, respeitando as capacidades da FC e do armazenamento, e maximizando a eficiência total (Jeong et al., 2005). Na maioria das estratégias já implementadas, recorre-se a algoritmos cujo objetivo é a otimização do consumo energético (Sorlei et al., 2021). No entanto, a eficiência global do veículo está frequentemente condicionada pelas variações temporais, sendo por isso necessário efetuar um controlo baseado nas alterações das condições ao longo do tempo (Tie & Tan, 2013).

No veículo H2.City Gold, um autocarro elétrico movido a hidrogénio com tecnologia FC da Toyota (CaetanoBus, 2021b), o algoritmo atualmente implementado baseia-se em condições definidas empiricamente ou em função de testes efetuados, visto ter sido a primeira metodologia utilizada sem que existisse informação prévia, havendo margem para alcançar melhores resultados através da utilização de técnicas de otimização. Para tal, é fundamental recorrer a algoritmos que permitam fazer uma gestão sustentável da energia, em função das condições de funcionamento do veículo, sendo possível posteriormente otimizar os parâmetros do respetivo algoritmo para os diversos tipos de operação do autocarro, garantindo uma maior eficiência energética.

A solução preconizada pretende trazer melhorias significativas para o desempenho total do veículo e especificamente, para a redução dos consumos e aumento do tempo de vida da FC, pretendendo-se que os resultados sejam demonstrados em cenários simulados e reais, e comparados com a performance do veículo até ao momento.

1.2. Questão e Objetivos de Investigação

Partindo da descrição do problema anteriormente enunciado, o presente trabalho pretende dar resposta à seguinte questão: de que forma a implementação de um algoritmo de gestão energética de veículos híbridos a hidrogénio, baseada em otimização, contribui para a diminuição dos consumos do veículo e aumento do tempo de vida da FC?

Deste modo, o objetivo geral é conceber e implementar um novo algoritmo para a gestão energética de veículos híbridos a hidrogénio, tendo como objetivos específicos os seguintes:

- Interpretar o algoritmo atual e as circunstâncias em que este se encontra implementado;
- Identificar as necessidades e limitações da gestão energética;
- Conceber o algoritmo e otimizar os seus parâmetros;
- Implementar o algoritmo numa ferramenta de simulação;
- Avaliar os resultados obtidos e comparar com o cenário atual;
- Implementar o algoritmo em veículos de teste;
- Avaliar o desempenho dos veículos com o novo algoritmo.

1.3. Opções Metodológicas

Tendo em conta os objetivos gerais e específicos enunciados, opta-se pelo enquadramento sugerido por Caixeta e Fabricio (2018) para caracterizar as opções metodológicas, e que consiste na sua descrição em três níveis hierárquicos, onde se encontra na base as metodologias, como um sistema de métodos, seguidas pelos métodos, a abordagem particular, e no topo os instrumentos/técnicas, como a ferramenta específica a ser utilizada. Assim, também Coutinho (2011, p. 22) destaca que “a metodologia tem sempre um sentido mais amplo que o método, porque questiona o que está por trás, os fundamentos dos métodos”.

Na investigação, segundo Coutinho (2011), a maioria dos autores distingue a metodologia entre duas perspetivas: a quantitativa, centrada na análise de factos observáveis e na medição de variáveis, e a qualitativa, que trata a investigação de ideias e significados baseada no método indutivo. O presente trabalho enquadra-se na perspetiva quantitativa, por se tratar de um estudo objetivo, baseado em métodos científicos e sistemas de avaliação mensuráveis, cujo objetivo é

prever, explicar e controlar fenómenos (Coutinho, 2011). Deste modo, são estudados algoritmos e modelos matemáticos que pretendem descrever e controlar a gestão energética dos veículos híbridos a hidrogénio.

No que diz respeito aos métodos de investigação, segundo Coutinho (2011), existem diversos conjuntos de estratégias que constituem o plano de investigação, tais como investigação experimental, inquérito, estudo de caso, investigação-ação, entre outros. Neste projeto usa-se a investigação-ação como método, visto que inclui a compreensão em contexto real de uma situação específica, e a respetiva aplicação de mudanças (Coutinho, 2011). Este método parte da teoria e da descrição detalhada do problema em estudo, sendo um processo cíclico que alterna entre a ação e a análise crítica. No presente trabalho, a solução encontrada é testada em simuladores, passando por um processo crítico de revisão, sendo finalmente implementada em veículos de teste para compreender o seu comportamento em cenários reais.

1.4. Apresentação da Empresa

A CaetanoBus é uma empresa do Grupo Salvador Caetano, que produz carroçarias e autocarros, cuja sede se situa em Vila Nova de Gaia. A empresa apresenta como missão “Trabalhamos para proporcionar aos nossos Clientes soluções mais seguras e sustentáveis, através de produtos diferenciados.” (CaetanoBus, 2021c).

Há cerca de três décadas que a CaetanoBus iniciou o estudo e desenvolvimento de alternativas de mobilidade elétrica em Portugal, consolidando rapidamente a sua oferta de veículos para cidades e aeroportos em diversos países da Europa. Entre 2010 e 2015 a empresa investiu direta e indiretamente em projetos de investigação e desenvolvimento relacionados com mobilidade elétrica, sendo que em 2014 lançou o e.COBUS, “o primeiro autocarro do mundo 100% elétrico, exclusivo para aeroportos” (CaetanoBus, 2021a). Em 2018 entrou em circulação a alternativa 100% elétrica para ambientes urbanos, o e.City Gold, e em 2019 o H2.City Gold foi apresentado como o autocarro a pilha de combustível Toyota.

Em 2020 foi reforçada a aliança com a Toyota Caetano Portugal, passando esta a ser acionista direta da CaetanoBus. Em 2021 esta aliança resultou no *co-branding* com a Toyota dos autocarros e.City Gold e H2.City Gold, como resposta ao crescimento da empresa e à expansão da mobilidade zero-emissões. Assim, na Figura 1 apresenta-se a atual estrutura acionista da Caetano Bus.




Figura 1- Estrutura acionista

1.5. Estrutura do Trabalho

O presente trabalho incluiu um capítulo destinado à revisão bibliográfica, onde são contextualizados o paradigma ambiental atual e a pertinência da utilização de veículos elétricos híbridos a FC, bem como as necessidades de controlo do veículo e respetivas estratégias de gestão energética existentes.

Posteriormente, dedica-se um capítulo à apresentação do caso de estudo, nomeadamente o autocarro H2.City Gold da CaetanoBus, descrevendo-se as suas características, requisitos e ciclos de condução.

No capítulo 4, é apresentada a estratégia implementada e respetiva justificação da metodologia seguida, indicando como serão visualizados e validados os resultados obtidos. Seguidamente, no capítulo “Apresentação de Resultados” são descritos os resultados que se obtiveram quer em cenários de simulação, quer em cenários reais, comparando-os com os resultados obtidos pelo algoritmo anteriormente implementado.

Finalmente, são ainda apresentadas as conclusões do projeto, destacando as limitações e sugerindo tópicos de investigação futura.

2. REVISÃO BIBLIOGRÁFICA

Com o intuito de contextualizar a utilização de veículos híbridos a hidrogénio e os respetivos desafios de gestão energética, o presente capítulo começa por apresentar o paradigma ambiental atual e as necessidades de mudança no setor dos transportes, seguindo-se a apresentação do conceito de FCHEV. No que diz respeito à gestão energética, são introduzidas as principais dificuldades da sua implementação e as diversas abordagens que têm vindo a ser utilizadas na área ao longo dos últimos anos.

2.1. Paradigma Ambiental

A atividade humana tem contribuído de forma excessiva para a presença de gases com efeito de estufa na atmosfera, nomeadamente com a combustão de combustíveis fósseis (Corbo et al., 2011). Assim, apresenta-se uma contextualização relativa às alterações climáticas no mundo e, em específico, na Europa e em Portugal, seguindo-se a demonstração das políticas que tem vindo a ser implementadas no sentido de alcançar um planeta mais neutro em carbono.

2.1.1. Alterações climáticas

O aquecimento global é resultado do efeito de estufa provocado pela presença na atmosfera de dióxido de carbono e outros gases, como por exemplo, o metano (Ehsani, 2012). Este fenómeno reflete-se no aumento da temperatura da Terra, resultando em grandes danos nos ecossistemas e catástrofes naturais.

De acordo com a Comissão Europeia (2018), o aquecimento global já ultrapassou 1°C, comparativamente com os níveis pré-industriais, estando continuamente a aumentar, prevendo-se que atinja os 2°C em 2060. Por este motivo, “é essencial uma ação climática imediata e decisiva” (Comissão Europeia, 2018, p. 2).


Segundo Ritchie e Roser (2020), antes da revolução industrial as emissões anuais de CO₂ eram muito baixas, apresentando um crescimento lento até meados do século XX. Desde então, a evolução das emissões de CO₂ tem apresentado um crescimento preocupante, sendo que atualmente são emitidas mais de 34 mil milhões de toneladas por ano. Apesar do abrandamento das emissões nos últimos anos, poderemos ainda não ter atingido o pico.

Relativamente às emissões de CO₂ per capita, na Figura 2, verificamos que na América do Norte, ao longo de várias décadas, foi onde este indicador apresentou valores mais elevados, tendo nos últimos anos se aproximado da Oceânia e da Europa. A Europa apresenta também valores muito acima do indicador mundial e, em particular, Portugal desde 1990 que ultrapassou esse mesmo valor.

Per capita CO₂ emissions

Carbon dioxide (CO₂) emissions from the burning of fossil fuels for energy and cement production. Land use change is not included.

Our World
in Data




Source: Our World in Data based on the Global Carbon Project
OurWorldInData.org/co2-and-other-greenhouse-gas-emissions/ • CC BY
Note: CO₂ emissions are measured on a production basis, meaning they do not adjust for emissions embedded in traded goods.

Figura 2- Emissões de CO₂ per capita (Ritchie & Roser, 2020)

Segundo Eurostat (2022), na União Europeia entre 2008 e 2020 as emissões de gases com efeito de estufa reduziram 24%, sendo o dióxido de carbono o maior componente das emissões, como é visível na Figura 3. Em termos do setor de atividade que mais tem impacto nas emissões de gases com efeito de estufa, verifica-se que a manufatura é o setor mais impactante na EU.

Greenhouse gas emissions by economic activity and by pollutant, EU, 2020 (thousand tonnes of CO₂ equivalents)



Source: Eurostat (online data code: env_ac_ainah_t2)

eurostat

Figura 3- Emissões setoriais de gases com efeito de estufa na EU, em 2020 (Eurostat, 2022)

Em Portugal, como é visível na Figura 4, o setor que mais impacto tem nas emissões de CO₂ é o setor dos transportes, dominado pelo tráfego rodoviário. Deste modo, é relevante a intervenção neste setor, visto que entre 2013 e 2019 as suas emissões de CO₂ aumentaram 12% (REA, 2021).

Emissões sectoriais de dióxido de carbono equivalente, em Portugal, em 2019




Figura 4- Emissões sectoriais de CO₂ equivalente, em Portugal, em 2019 (REA, 2021)

Segundo Ehsani (2012), os transportes urbanos têm-se mostrado insustentáveis devido ao seu consumo excessivo que afeta a saúde pública, apesar dos investimentos crescentes no setor. Os “sustainable transports” são um conceito apresentado pelo mesmo autor como os modos de transporte e respetivo planeamento que têm em conta a sustentabilidade, efetuando uma contribuição positiva para o ambiente, para a sociedade e para a economia.

2.1.2. Políticas Ambientais

O Protocolo de Quioto (KP), adotado em 1997, oficializou o *United Nations Framework Convention on Climate Change* que pretendia criar o compromisso de reduzir as emissões de gases com efeito de estufa nos países industrializados, tendo sido o primeiro tratado jurídico internacional direcionado para as alterações climáticas (United Nations, 2022b).

O Acordo de Paris (AP) em 2015, foi um marco para a mudança de paradigma e reconhecimento da necessidade de intervir de forma generalizada em relação às alterações climáticas (Comissão Europeia, 2019). Foram estabelecidos objetivos a longo prazo para limitar o aumento da temperatura média global a, no máximo, 2°C a cima dos níveis pré-industriais, pretendendo-se que o pico global de emissões seja atingido o mais rápido possível, de modo a alcançar um mundo neutro até meados do presente século (United Nations, 2022a).

Como referido no Plano Nacional Energia e Clima 2021-2030 (Comissão Europeia, 2019), é nesta década que se irão concentrar os maiores esforços para a redução das emissões de gases com efeito de estufa, estabelecendo-se metas ambiciosas mas exequíveis. Assim, Portugal assumiu como visão estratégica para o horizonte de 2030 “Promover a descarbonização da economia e a transição energética visando a neutralidade carbónica em 2050, enquanto oportunidade para o país, assente num modelo democrático e justo de coesão territorial que potencie a geração de riqueza e uso eficiente de recursos” (Comissão Europeia, 2019, p. 5).

Deste modo, segundo a Comissão Europeia (2019), as metas de Portugal para 2030 são:

- Redução das emissões de gases com efeito de estufa em 45%-55%;

- Aumento da eficiência energética em 35%;
- Incorporação de mais 47% de fontes de energia renovável;
- Incorporação de mais 20% de fontes de energia renovável nos transportes;
- Promoção das interligações elétricas em 15%.

Tendo em conta as metas estabelecidas por Portugal no âmbito da Partilha de Esforços Comunitária, o Relatório do Estado do Ambiente (2021) indica que Portugal se encontra em situação de cumprimento, tendo reduzido as emissões em relação às metas fixadas com base no ano de 2005.

Focando no setor dos transportes, a atuação no sentido de proporcionar uma rede de transportes públicos mais sustentáveis, está alinhada com a metas estabelecidas por Portugal, sendo por isso fundamental estudar alternativas aos veículos Diesel.

2.2. Fuel Cell Hybrid Electric Vehicle

Um *Fuel Cell Hybrid Electric Vehicle* (FCHEV) é um tipo de veículo híbrido que utiliza a FC *stack* como principal fonte de energia e um super condensador e/ou bateria como fonte auxiliar de potência para o motor elétrico (Fathabadi, 2018). Este tipo de veículo possui como combustível o hidrogénio e emite apenas vapor de água, podendo ser considerado um veículo com zero emissões (Das et al., 2017). Para melhor contextualizar, são apresentados em síntese os diversos tipos de veículos existentes, bem como o funcionamento e topologias específicas dos FCHEV.

2.2.1. Classificação dos veículos

Segundo Das et al. (2017), podemos classificar os veículos em 3 grandes tipos, que podem também ser considerados como a hibridização das tecnologias anteriores. Assim, na Figura 5 estão enumerados os diferentes tipos de veículos e respetivas classificações.




Figura 5- Classificação de veículos (Das et al., 2017)

Deste modo é possível descrever cada uma das classificações da seguinte forma:

- **Veículos com motor de combustão interna (ICEV):** este tipo de veículo converte a energia química de combustíveis fósseis em calor e trabalho, necessário para o seu funcionamento (Tie & Tan, 2013). Nesta classificação incluem-se os veículos convencionais com motor de combustão (ICE) e os *Micro-Hybrid Electric Vehicles* que possuem também um motor elétrico de baixa tensão. Neste segundo caso, o motor elétrico é apenas utilizado no arranque a frio do veículo e permite que durante a desaceleração e travagem o ICE seja desligado, melhorando a eficiência do veículo (Das et al., 2017). Por outro lado, comparativamente com os veículos elétricos ou híbridos, os ICEV convencionais produzem uma grande quantidade de gases poluentes e com efeito de estufa (Wu & Zhang, 2017).
- **Veículos Elétricos Híbridos (HEV):** possuem um ICE e um EM como fontes de potência para o funcionamento do veículo. No caso do tipo *Mild-Hybrid Electric Vehicle*, este possui a mesma vantagem de eficiência que o *micro-HEV*, no entanto a potência e tensão mais elevada do motor elétrico permite que este seja capaz de funcionar em simultâneo com o ICE, apesar de não ser suficiente para atuar de forma isolada (Tie & Tan, 2013). Devido ao grande incremento na eficiência através da hibridização, a produção de *Full-HEV* é mais vantajosa, visto que nestes veículos é possível que o ICE e o EM trabalhem em conjunto ou individualmente, possuindo sistemas com grande capacidade de armazenamento de energia (bateria ou super condensador) (Das et al., 2017). Adicionalmente, incluem-se neste tipo os Plug-in HEV que apresentam também a vantagem de poderem ser carregados externamente, possuindo sistemas de armazenamento maiores que garantem uma maior autonomia ao veículo.
- **Veículos totalmente elétricos:** são veículos que apenas utilizam a energia elétrica para o seu funcionamento. Nesta classificação encontram-se veículos que utilizam apenas um sistema de armazenamento de energia, apenas a FC ou uma combinação de ambos para garantir o seu funcionamento. No caso dos BEV, estes possuem um sistema de carregamento externo, sendo a sua principal vantagem as reduzidas perdas de conversão da energia elétrica para mecânica. No entanto é necessário que o veículo possua um motor de tração com elevado binário, reduzindo a sua eficiência (Das et al., 2017). Por outro lado, os FCEV são abastecidos com hidrogénio o que permite que os únicos subprodutos sejam água e calor. A FC é idealmente utilizada como fonte de alimentação constante, não sendo adequada em casos de mudanças repentinas da potência necessária. Por este motivo, a utilização adicional de um sistema de armazenamento de energia nos FCHEV, permite suportar picos de potência, mantendo a FC como fonte primária de energia, permitindo aumentar a autonomia comparativamente com os FCEV (Das et al., 2017).

Assim, um FCHEV é um tipo de veículo híbrido com motor elétrico, composto por uma FC, responsável pela geração de energia elétrica a partir da reação química entre o hidrogénio e o oxigénio (Saib et al., 2017), e por um sistema auxiliar de energia.

2.2.2. Funcionamento do FCHEV

De uma forma geral, segundo Gao e Ehsani (2001), um FCHEV é constituído por um sistema FC, um *peaking power source* (PPS), um motor eléctrico e respetivo controlador, o controlador do veículo e a interface eletrónica entre a FC e o PPS. Na Figura 6 é possível verificar a configuração descrita.




Figura 6- Configuração típica de um FCHEV (Ehsani et al., 2018)

Em função dos sinais de controlo como, a tração, a travagem, a velocidade, entre outros, o fluxo de energia e a potência do motor são comandados pelo controlador do veículo, reagindo da forma mais adequada (Y. Gao & Ehsani, 2001). Por exemplo, quando existe um pico no pedido de potência, ambos os sistemas, FC e PPS, fornecem energia ao motor eléctrico. Já no caso das travagens, é possível converter a energia cinética em energia eléctrica, que será armazenada no PPS. Do mesmo modo, quando a potência necessária é inferior à capacidade da FC, o excedente poderá ser armazenado no PPS (Ehsani et al., 2018). Para efetuar esta gestão de forma adequada, é necessário um sistema de controlo energético.

Relativamente à fonte primária de energia, uma FC é um dispositivo eletroquímico que converte a energia química de um combustível em energia eléctrica e calor (Hayes & Goodarzi, 2018). A ideia inicial da FC foi criada por William Robert Grove, em 1839 no entanto apenas em 1959 foi produzida com sucesso a primeira FC (Erjavec, 2013).

Segundo Ubong e Gover (2021), podemos encontrar os seguintes tipos de FC: *Proton-Exchange Membrane Fuel Cell* (PEMFC), *Direct Methanol Fuel Cell* (DMFC), *Alkaline Fuel Cell* (AFC), *Phosphoric Acid Fuel Cell* (PAFC), *Molten Carbonate Fuel Cell* (MCFC) e *Solid Oxide Fuel Cell* (SOFC). Para o presente caso de estudo iremos abordar mais aprofundadamente a *Proton-Exchange Membrane Fuel cell*, visto ser a tecnologia mais frequentemente utilizada em FCEV (Briguglio et al., 2011).

As PEMFC, também designadas por *Polymer Electrolyte Membrane Fuel Cells*, atualmente são desenvolvidas para aplicação em transportes e podem ser utilizadas com hidrogénio ou álcool (por exemplo, etanol ou metanol) (Kendall & Pollet, 2012).

Uma FC a hidrogénio é constituída por dois elétrodos (ânodo e cátodo), posicionados em cada um dos lados de um eletrólito. Com a entrada do hidrogénio na FC, os átomos de hidrogénio libertam

eletrões no ânodo, tornando-se íões de hidrogénio no eletrólito. Através de um circuito externo, os eletrões movem-se do ânodo para o cátodo, podendo ser utilizados para alimentar o motor elétrico. Os íões de hidrogénio quando se combinam com as moléculas de oxigénio no cátodo, produzem água e calor que são libertados para a atmosfera (Erjavec, 2013). Este fenómeno é descrito no esquema da Figura 7.




Figura 7- Esquema de uma FC a hidrogénio (Erjavec, 2013)

As PEMFC são a tecnologia frequentemente escolhida para aplicação em automóveis, visto apresentarem uma baixa temperatura de operação (inferior a 100°C), um tamanho reduzido e uma alta eficiência. Normalmente, as FC são organizadas em *stacks* com centenas de células em série, podendo também ser colocadas diversas *stacks* em paralelo para aumentar a capacidade de produção de energia (Hayes & Goodarzi, 2018).

2.2.3. Topologias

A fonte primária de energia num FCHEV é a FC, existindo também um sistema de armazenamento que pode ser uma bateria e/ou um super condensador (Tazelaar et al., 2013). Tazelaar et al. (2013) considera que existem 6 configurações possíveis, que são apresentadas de forma simplificada na Figura 8. A topologia 2 é a mais utilizada em FCHEV, destacando também que as combinações 5 e 6 apresentam a vantagem de permitir lidar com a potência de uma forma mais flexível, apesar de aumentar a complexidade do sistema.




Figura 8- Topologias FCHEV (Tazelaar et al., 2013)

É também possível classificar as topologias em série e paralelo, tal como refere Yue et al. (2019). Numa configuração em série, a FC está conectada com a bateria através de um conversor DC/DC e funciona como forma de aumentar a autonomia e velocidade máxima do veículo, sendo que a bateria fornece energia diretamente ao sistema de tração.

Já no caso da configuração em paralelo, a FC fornece potência diretamente ao motor e à bateria, que pode ter uma capacidade mais reduzida, fornece a energia em falta ou absorve a energia gerada pela travagem. A topologia em paralelo é aquela que é mais frequentemente utilizada.

2.3. Dificuldades na Implementação do Controlo

Todos os componentes de um FCHEV devem estar devidamente integrados de modo a garantir a maior eficiência de operação e segurança do veículo (Inci et al., 2021). Podemos destacar diversos desafios técnicos e problemas em várias categorias, tais como, integração, durabilidade, otimização do sistema, segurança, diagnóstico, gestão de energia, fornecimento de hidrogénio e tempo de vida da FC (Inci et al., 2021). Neste capítulo são destacados os principais aspetos a ter em conta para o desenvolvimento de uma estratégia de gestão energética.

Num veículo híbrido que contempla múltiplas fontes de energia é fundamental efetuar uma gestão que alcance as expectativas do mercado, minimizando o consumo de hidrogénio e aumentando o tempo de vida da FC (Sulaiman et al., 2015). Diversos estudos foram realizados, onde são apresentadas estratégias diferenciadas que demonstram problemas como a implementação limitada a simulação ou a não consideração da degradação dos componentes (Sulaiman et al., 2018).

Segundo Inci et al. (2021), o tempo de vida da FC é uma das barreiras mais cruciais que a indústria de FCHEV enfrenta. Fatores como o arranque do veículo, a temperatura ambiente, a pressão do oxigénio e a humidade relativa, afetam de forma relevante o tempo de vida da FC. Para além disso a complexidade de operação do veículo, como por exemplo, as situações de *start/stop* e a necessidade de picos de potência, está também relacionada com a degradação da FC. A degradação da membrana na PEMFC é um dos pontos que mais afetam a sua durabilidade, devido à aglutinação de platina. O desenvolvimento de um sistema capaz de lidar com os picos de potência, que inclui um sistema de armazenamento de energia, irá permitir uma melhor gestão dos ciclos *start/stop* da FC, prevenindo a sua degradação e, conseqüentemente, aumentando o seu tempo de vida.

Salienta-se ainda que, quer o comportamento de estrada, quer a necessidade de potência HVAC, afetam também a gestão de energia, visto ser fundamental que a estratégia se consiga adaptar a diferentes comportamentos do veículo, permanecendo de forma otimizada para ciclos de condução arbitrários (Sulaiman et al., 2015).

2.4. Estratégias de Gestão Energética em Veículos Híbridos

Neste tópico são abordadas diferentes estratégias de gestão energética para satisfazer a potência pedida pelo veículo, passíveis de serem implementadas em FCHEV's e estudadas por diversos autores em diferentes tipos de topologias.

2.4.1. Estratégias baseadas em regras

As estratégias baseadas em regras do tipo *If-Then-Else* são constituídas por um conjunto de relações estáticas e não lineares (Tazelaar et al., 2013). Normalmente, apresentam bons resultados apesar de não ser possível garantir o ótimo, visto que são baseadas em conhecimentos empíricos e os parâmetros são afetados pelas condições da condução (Sorlei et al., 2021).

Uma grande parte das estratégias deste tipo são baseadas em *Fuzzy Logic*, uma teoria proposta em 1965 que pretende representar a forma como o raciocínio humano é construído, tendo em conta a existência de incerteza devido à generalização, ambiguidade, mudança ou falta de conhecimento sobre o assunto em estudo (Rajasekaran & Pai, 2004). Esta metodologia baseia-se em 3 fases fundamentais: *fuzzification*, tomada de decisão e *defuzzification* (İnci et al., 2021).

Nas suas diversas aplicações, o *fuzzy logic* apresenta um raciocínio simplificado, robusto e adaptável, com uma boa capacidade de previsão. No entanto, estas estratégias não são as mais adequadas quando se pretende, por exemplo, otimizar os consumos (Sorlei et al., 2021). Salienta-se ainda o facto, de ser possível obter resultados em tempo real utilizando este tipo de algoritmos (Tazelaar et al., 2013).

Gao et al. (2008) implementou uma estratégia baseada em *fuzzy logic* num autocarro equipado com um sistema FC e dois equipamentos de armazenamento de energia, uma bateria e um super condensador. Do mesmo modo, Li et al. (2012), apresentou um método de controlo *fuzzy logic* em veículos híbridos FC /bateria e FC /bateria/super condensador. No caso de Jeong et al. (2005), a estratégia fuzzy logic foi implementada num veículo constituído por FC, bateria e conversor DC/DC. Nestes casos de estudo, os inputs utilizados foram a potência pedida pelo autocarro e o SOC da bateria e/ou do super condensador. Em relação aos outputs, estes dizem respeito à potência que será requerida à FC, à bateria e ao super condensador. Após a aplicação do conjunto de regras definidas, em todos estes casos foram obtidos resultados positivos no que diz respeito à capacidade de satisfazer a potência pedida pelo veículo. No caso do estudo de Gao et al. (2008) ainda é referida a distribuição equilibrada da energia solicitada às 3 fontes, mantendo o SOC e a potência FC em intervalos razoáveis. Jeong et al. (2005), garante também que foi possível aumentar a eficiência do sistema e manter o SOC da bateria dentro de limites aceitáveis para aumentar o respetivo tempo de vida.

Um quarto caso analisado diz respeito ao estudo efetuado por Zhang et al. (2021) que para além de implementar *fuzzy logic* para a gestão energética, aplicou um modelo semelhante para o reconhecimento do ciclo de condução. Assim, utilizando como input a velocidade média e a percentagem de tempo parado é possível identificar se o ciclo de condução é do tipo cidade, suburbano ou autoestrada, resultando como output do *fuzzy controller* o SOC ideal. Posteriormente foram aplicadas as regras que utilizam como input a variação do SOC (diferença entre o SOC real e ideal) e como output a potência pedida à FC. Assim, após ser definido o SOC ideal em função do ciclo de condução mais apropriado, é efetuada a divisão de potência entre a FC e a bateria. Com esta estratégia foi possível manter o SOC na zona de maior eficiência e reduzir ou evitar as situações que degradam a FC.

2.4.2. Estratégias baseadas em otimização

As estratégias de otimização baseiam-se em modelos analíticos e numéricos capazes de minimizar ou maximizar uma função objetivo (Tie & Tan, 2013). Podemos dividir este tipo de estratégia em Otimização Global ou Otimização em Tempo Real (Sorlei et al., 2021).

A otimização global tem por base o conhecimento da potência pedida quer no futuro como no passado para minimizar, por exemplo, o consumo através da eficiência, tendo em conta o ciclo de condução (Tie & Tan, 2013). Podemos incluir neste tipo de otimização a programação linear (LP) e a programação dinâmica (DP). Visto que é necessário conhecer *a priori* todo o mapeamento da potência pedida pelo veículo, este tipo de controlo não pode ser implementado em tempo real (Rodatz et al., 2005). Assim, as estratégias de otimização global apenas podem ser implementadas no modo *offline* para um ciclo de condução específico, sendo útil para compreender os limites que podem ser alcançados na prática (Koot, 2006), para efetuar um *benchmark* para as estratégias em tempo real ou para definir o dimensionamento ótimo dos componentes da *powertrain* (Loenhout, 2007). Para além disso, apesar de ser uma ferramenta poderosa, este tipo de metodologia exige um elevado poder computacional, devido ao grande número de iterações, podendo demorar diversas horas para a sua execução (Musardo et al., 2005).

Por outro lado, a otimização em tempo real utiliza os dados atuais do sistema, o que retorna uma função de custos instantânea (Tie & Tan, 2013). Estas estratégias podem ser baseadas em *Equivalent Consumption Minimization* (ECMS) e *Pontryagin's Minimum Principle* (PMP) (Sorlei et al., 2021). O raciocínio para a transformação de um problema de otimização global num problema de otimização em tempo real é a introdução de uma função de custos que apenas dependa do valor atual das variáveis (Musardo et al., 2005). Assim, pretende-se que a cada instante, para qualquer que seja a velocidade do veículo, a estratégia de controlo seja capaz de determinar a melhor distribuição de potência, garantindo sempre que a potência requisitada pelo veículo é satisfeita (Paganelli et al., 2001). Apesar da principal vantagem deste método ser a possibilidade de encontrar o valor ótimo do problema, é necessário um elevado poder computacional no veículo, o que pode não ser sempre exequível (İnci et al., 2021).

No caso da otimização em tempo real, a principal estratégia utilizada em FCHEV é a ECMS (Sorlei et al., 2021). Rodatz et al (2005) apresentou uma proposta baseada nesta estratégia para um veículo constituído por uma FC e um super condensador. Neste caso, é utilizada uma variável de controlo u descrita como o quociente entre a potência de/para o super condensador e a potência pedida pelo veículo. A função de custos depende da potência pedida à FC e da potência pedida ao super condensador, multiplicada por um fator de conversão $s(t)$, permitindo calcular o consumo equivalente em cada instante. Os autores consideram que o ponto fundamental da sua abordagem é o fator $s(t)$, sendo que por isso este fator foi subdividido em s_{dis} e s_{chg} de modo a melhor se adequar aos momentos em que o super condensador está a fornecer ou a receber energia, respetivamente. Ambos os fatores são computados a priori em função do ciclo de condução em estudo, e o fator $s(t)$ será uma função da probabilidade do super condensador se encontrar em carga ou descarga. Assim, o modelo proposto é implementado em cada instante t da seguinte forma:

- A potência pedida pelo veículo é medida;
- São aplicadas diversas tentativas para o valor de u , dentro do intervalo admissível;

- Para cada tentativa é calculado o respetivo consumo de hidrogénio e consumo equivalente do super condensador;
- A função de custos para cada valor de u é computada;
- O valor de u é escolhido em função da tentativa que apresentou menor valor de custos.

Este modelo foi testado num dinamómetro e em estrada, sendo que na maioria dos casos foi capaz de alcançar a velocidade pretendida, exceto no final da simulação para a velocidade de 12km/h. Os autores justificam este facto pela curva de eficiência da FC ser achatada e pelo facto do SOC no final da simulação se encontrar a um nível muito baixo. No entanto, salienta-se a capacidade do algoritmo de manter o SOC do super condensador entre limites razoáveis de uma forma natural, na maioria do ciclo de condução.

De forma semelhante, Musardo et al. (2005) apresenta um algoritmo adaptável baseado em ECMS, para um veículo híbrido. O fator de equivalência para o consumo da bateria é também o fator chave para a estratégia implementada, no entanto este é computado para diversos ciclos de condução em função de um e de dois coeficientes. Primeiramente, é adotada uma abordagem semelhante à presente em Rodatz et al (2005), com um fator de carga e um fator de descarga e posteriormente, é efetuado um estudo que apresenta resultados igualmente satisfatórios para uma simplificação do problema, utilizando apenas um coeficiente. Para além disso, a adaptabilidade do modelo proposto reside no facto de este periodicamente verificar as condições de condução, alterando o fator para aquele que melhor representa as condições atuais, comparativamente com os ciclos de condução estudados. Com esta estratégia, foi possível manter o SOC sempre dentro dos limites estabelecidos de modo a operar na zona de maior eficiência. Isto deveu-se principalmente à capacidade do modelo se adaptar às mudanças do ciclo de condução, contrariamente ao primeiro estudo apresentado.

Tao et al. (2020) diferencia o seu estudo dos restantes visto que aplica dois métodos diferentes na alocação da potência. Neste caso, a estratégia dirige-se a um veículo constituído por FC, bateria e super condensador, e baseia-se na divisão da potência pedida em “alta frequência” e “baixa frequência”. Para isso é utilizada a transformada Wavelet para separar as duas componentes da potência pedida, de modo a proteger a FC de grandes variações de potência, sendo a potência de alta frequência alocada ao super condensador. Seguidamente, a potência de baixa frequência irá passar pela estratégia ECMS, de modo a minimizar o consumo de hidrogénio, mantendo a carga da bateria dentro de limites pré-estabelecidos. A ECMS neste caso de estudo é aplicada minimizando a soma do consumo da FC e da bateria, multiplicando o último por um fator k que depende do SOC e dos seus limites mínimo e máximo. A estratégia proposta foi testada em simulação, aplicando uma combinação de ciclos de condução. Em suma, foi possível melhorar a eficiência global do veículo e aumentar a sua autonomia, sendo que os picos de potência foram corretamente absorvidos pelo super condensador e o SOC da bateria foi mantido dentro dos limites, operando na sua zona de maior eficiência. Deste modo, garante-se uma melhor eficiência e utilização da FC, com o objetivo de estender o seu tempo de vida.

2.4.3. Estratégia baseadas em aprendizagem

As estratégias baseadas em aprendizagem utilizam grandes grupos de dados históricos e dados em tempo real para a obtenção do controlo ótimo, apresentando como principal vantagem a capacidade de adaptação, sem necessidade de um modelo estático (Sorlei et al., 2021). No entanto,

a grande dificuldade reside na definição do conjunto de dados e respetiva dimensão que permite obter a performance pretendida (Tran et al., 2020).

Segundo Tran et al. (2020), métodos de *data-driven* e *machine learning* são estratégias adaptativas e capazes de gerir grandes quantidades de dados de forma eficiente, podendo ser integradas para atualizar os parâmetros otimizados em diferentes condições de condução. Podemos categorizar os algoritmos baseados em aprendizagem em *reinforcement*, *supervised/unsupervised* e *neural networks* (NN) (İnci et al., 2021).

Reinforcement learning é uma técnica de *machine learning* inspirada na psicologia comportamental, que tem por base a aprendizagem e tomada de decisão humana (Hsu et al., 2016). Tran et al. (2020) descreve esta estratégia como sendo composta por um agente que se encontra constantemente em interação com um ambiente. A cada instante o agente recebe informação do ambiente, tomando a decisão da ação a ser inserida no mesmo. Deste modo, o ambiente efetua as alterações necessárias para o seu novo estado e é calculada a recompensa associada à transição. As recompensas que vão sendo atribuídas irão formar a política de controlo do agente, que consequentemente mapeia os estados de modo a tomar as melhores decisões. O objetivo final do agente é acumular recompensas ao longo do tempo, maximizando-as.

Nos casos de estudo Hsu et al. (2016) e Reddy et al. (2019) é utilizada a abordagem *Q-learning*, que estabelece a política de decisão entre os estados e ações que serão utilizados pelo agente. Ambos os casos, aplicam-se a veículos FC /bateria. Hsu et al. (2016) utiliza como estados o SOC da bateria e a posição do pedal, que indica a potência pedida pelo veículo. O espaço de ação é definido em função do “degree of hybridization”, que irá corresponder ao quociente entre a potência pedida à FC e a potência pedida pelo veículo. No que diz respeito à função de recompensa esta é definida para dois modos distintos, “battery safe mode” e “ECO mode”, e depende do SOC da bateria. Em Reddy et al. (2019) os estados considerados foram a potência pedida à FC, a potência fornecida ou absorvida pela bateria e o SOC da bateria. As ações que podem ser tomadas estão relacionadas apenas com a variação da potência pedida à FC que permite também posteriormente calcular a potência que deverá ser pedida à bateria. Finalmente, a recompensa é atribuída com o objetivo de minimizar a variação do SOC da bateria, de modo que a recompensa seja máxima para valores de SOC de 0,7. De salientar, que todos os estados de espaços, ações e recompensas foram devidamente discretizados.

Em conclusão, ambas as estratégias de *reinforcement learning* apresentaram resultados positivos, sendo que no caso de Hsu et al. (2016) foi efetuada uma comparação com uma estratégia *fuzzy logic*, onde se obteve uma redução de 6% no consumo de H₂, mantendo o SOC mais próximo do valor estabelecido. Por outro lado, Reddy et al. (2019) afirma que o objetivo de minimizar a variação do SOC foi alcançado, no entanto não é possível garantir a minimização do consumo, sendo necessário alterar o algoritmo, direcionando-o para esse objetivo.

No *supervised learning* são utilizadas previsões e correções com base no respetivo erro, de modo que o modelo apresente o nível de desempenho desejado. Assim, é necessário que a fase de treino do modelo seja alimentada com dados conhecidos e devidamente classificados para que seja possível o cálculo e comparação dos parâmetros até ser obtido o comportamento desejado (Tran et al., 2020). Um exemplo da aplicação deste tipo de estratégia num veículo híbrido é descrito em Chin e Jafari (2011) onde é utilizado o erro quadrático médio como medida de performance do algoritmo, com o objetivo de minimizar o consumo de combustível. O modelo é alimentado pelos

dados registado a cada instante que são pré-computados, sendo que a desvantagem do modelo reside no facto de apenas ser aplicável a veículos nas mesmas condições que os dados de treino.

Por outro lado, no *unsupervised learning* o modelo é deduzido dos dados de input, podendo ser extraídas regras gerais, aplicadas regras para reduzir redundâncias ou organizados os dados por semelhanças (Tran et al., 2020). Grelle et al. (2006) apresenta um estudo para um veículo híbrido onde é utilizado o método *c-means clustering* para agrupar os dados de *input* que apresentam um grau de hibridização ideal, classificados por um vetor que contem os parâmetros que descrevem o estado do veículo. Esta estratégia foi implementada juntamente com um algoritmo genético para definir o número ótimo de clusters.

Por último, as estratégias baseadas em NN apresentam uma abordagem robusta que permite lidar com problemas não lineares de elevada complexidade, sendo necessária uma grande quantidade de dados para efetuar o treino da rede (Inci et al., 2021). Cada nó de uma rede apresenta múltiplos *inputs* que são processados, devolvendo os respetivos *outputs* (Tran et al., 2020). Xie et al. (2008) apresenta uma estratégia baseada em NN num veículo híbrido com FC e bateria. Neste caso foi aplicada uma rede de três camadas com otimização através de algoritmos genéticos. Os autores consideraram que a capacidade de convergência para a fase de treino do modelo seria melhorada com a aplicação do algoritmo referido, tornando a estratégia mais rápida e eficaz. Como *input* foi considerada a potência pedida pelo veículo, e respetiva taxa de subida/descida, e o SOC da bateria, sendo o *output* a potência pedida à FC. Para a construção da rede, foi utilizado o índice de economia de H_2 como função de desempenho, sendo aplicadas a cada iteração as técnicas de *crossover* e mutação. Aplicando o modelo obtido no sistema de controlo do veículo, foram efetuadas simulações que destacaram a capacidade de manter o SOC bastante estável e reduzir o consumo do veículo em 7,2 % comparativamente com uma estratégia *fuzzy logic*.

2.4.4. Estratégias mistas

Alguns autores como Lin e Li (2019), Jeon et al. (2002), Wang et al. (2020) e Romano (2021) implementam estratégia mistas onde incluem em conjunto algoritmos *fuzzy logic*, métodos de otimização e/ou modelos de aprendizagem, com o intuito de tornar a estratégia flexível e adaptável a diversos cenários de circulação do veículo, tendo também em consideração a maximização do tempo de vida dos seus principais componentes.

Wang et al. (2020) estudou uma estratégia de controlo para um veículo FC híbrido, onde propõe a otimização da gestão de energia baseada na identificação da zona de maior eficiência. Os autores consideram que a zona de eficiência máxima e o ponto de eficiência máxima do veículo variam em função das condições de operação do mesmo. Por este motivo, a estratégia proposta aplica o método *forgetting factor recursive least square* para a identificação da zona de maior eficiência, atualizando a respetiva restrição de controlo em tempo real. Para a divisão de potência é utilizado o método da minimização dos consumos equivalentes (ECMS), onde são incluídas penalizações para o não funcionamento na zona previamente definida. Os resultados indicaram que a identificação da zona de maior eficiência foi efetuada de forma rápida e precisa, garantindo pequenas variações do SOC e consumos de hidrogénio mais baixos, em comparação com uma estratégia baseada em regras. Ainda foi verificado que as flutuações da potência pedida à FC foram reduzidas, o que apresenta vantagens em relação ao tempo de vida da mesma.

Lin e Li (2019) apresentam uma estratégia aplicada a um veículo híbrido que preconiza a sua adaptabilidade a diversos ciclos de condução. Em primeiro lugar, os autores utilizam programação dinâmica, cuja variável de estado é o SOC da bateria e variável de controlo é a potência pedida à bateria. A função objetivo irá direcionar-se para a minimização do consumo equivalente do veículo, incluindo dois fatores, um que diz respeito ao motor de combustão e outro à bateria. Aplicando a estratégia de otimização offline a rotas já conhecidas e previamente estudadas, é possível obter um mapeamento dos valores ótimos do SOC e da divisão de potência para cada instante. Adicionalmente, o veículo em estudo apresenta a necessidade de efetuar também uma decisão em relação ao seu modo de operação (série, paralelo ou puramente elétrico) que é efetuada utilizando uma estratégia *fuzzy logic*, que tem como *inputs* a velocidade a cada instante, a potência pedida e o SOC, e como output o respetivo modo de operação. Tendo em conta que o estudo prévio efetuado com programação dinâmica apenas faz sentido conhecendo a priori as necessidades de potência de todo o percurso, os autores fazem uma extração de regras de distribuição de potência utilizando uma regressão não linear multivariável. Deste modo, utilizando a minimização do erro quadrático entre a potência ótima calculada e potência computada pelo modelo, para cada instante, obteve-se a equação que descreve o comportamento da divisão de potência, em função da velocidade e potência pedida. Este modelo faz sentido aplicar a diversos ciclos de condução que se pretendam ter em consideração, sendo obtida uma equação para cada caso de estudo. Finalmente, a NN baseada em *learning vector quantization* é construída com base nos 4 ciclos de condução selecionados, tornando o modelo flexível. Na prática, a estratégia proposta irá avaliar de 100 em 100 segundos qual o ciclo de condução que melhor se adequa, em função das características de condução atuais, fazendo a respetiva aplicação da equação que irá calcular a divisão de potência. Assim, os resultados obtidos mostram que a variação do SOC permaneceu bastante suave, sendo também comprovada a minimização do consumo em relação ao modelo anteriormente utilizado, demonstrando uma excelente capacidade de adaptabilidade às condições de condução.

De uma forma muito semelhante, Jeon et al. (2002) apresentou uma estratégia também para um veículo híbrido, que pretende ser capaz de alterar o seu algoritmo em função do modo de condução. Para tal, foram selecionados seis ciclos de condução para os quais foram estudados os respetivos parâmetros que os caracterizam. Tal como em Lin e Li (2019), previamente foram otimizados os parâmetros das equações que descrevem a distribuição ótima de potência, neste caso utilizando o método de Taguchi. Recorrendo ao algoritmo de *hamming network*, os autores treinaram a rede para os seis ciclos de condução e esta foi aplicada no controlo do veículo para a decisão de qual dos padrões melhor se adequa à situação atual, comparando o produto interno dos parâmetros atuais com o produto interno de cada ciclo de condução. Os resultados obtidos demonstram que o SOC da bateria foi mantido dentro dos limites que garantem o seu funcionamento na zona de maior eficiência, existindo também evidências de que a performance global do veículo foi melhorada relativamente a um modelo sem reconhecimento do tipo de condução.

Romano (2021) propõe uma estratégia de gestão energética em FCHEV baseada em programação dinâmica e redes neuronais. O trabalho desenvolvido partiu da modelação do Toyota Mirai, identificando uma função de custos adequada ao problema multiobjectivo. Para tal, estabeleceu uma medida standard de avaliação da performance do veículo, através da comparação com as diferentes alternativas de combustíveis. Foi utilizada a medida *Gasoline Gallon Equivalent* (GGE)

aceite mundialmente, contabilizando as duas fontes de energia de um FCHEV, de modo a minimizar GGE.

A estratégia utilizada partiu da implementação em Matlab de um algoritmo de programação dinâmica para a otimização offline de diferentes ciclos de condução, seguindo-se a aplicação de uma rede neuronal, treinada com os resultados da DP, cujo resultado será implementado em tempo real. Esta metodologia, que se assemelha ao trabalho desenvolvido por Lin e Li (2019), demonstra a aplicabilidade em FCHEV das estratégias já implementadas em HEV, apresentando resultados promissores. Romano (2021) destaca que foi possível manter a bateria e a FC a operar na zona de maior eficiência, sendo que a NN captou de forma adequada o comportamento ótimo devolvido pela DP. Em geral, foi obtida uma melhor performance comparativamente com a estratégia anteriormente implementada no veículo, sendo que efetivamente o consumo de H_2 foi reduzido. Salientam-se ainda vantagens relativamente ao ciclo de vida da bateria e da FC, através da estabilidade da SOC e da redução do número de ciclos de descarga da bateria.

Como trabalhos futuros o autor destaca a melhoria da performance da NN, principalmente para valores de SOC diferentes dos utilizados da programação dinâmica, e o treino de diferentes NN para adaptabilidade a ciclos de condução significativamente diferentes, como por exemplo, urbano e autoestrada. De referir que a estratégia apenas foi testada em simulação, sendo a implementação em veículos reais um passo importante para a validação do método.

3. APRESENTAÇÃO DO CASO DE ESTUDO: AUTOCARRO H2.CITY GOLD

O H2.City Gold é um veículo híbrido a hidrogénio produzido pela CaetanoBus, cuja estratégia de gestão energética é o foco do presente projeto. Por este motivo, apresentam-se as suas características e princípios de funcionamento, destacando os requisitos e limitações para a estratégia de gestão energética. Descreve-se também os ciclos de condução em que o veículo opera, de modo a estudar o seu comportamento nos diferentes cenários.

3.1. Características e Funcionamento

O autocarro H2.City Gold, é um veículo elétrico movido a hidrogénio, produzido na CaetanoBus desde 2019. É uma solução inovadora e flexível para ambiente urbano, que está associada à mobilidade com zero emissões de gases nocivos para o ambiente. Na Tabela 1 apresentam-se as principais características deste veículo, ilustrado pela Figura 9.



Figura 9- Autocarro H2.City Gold

Tabela 1- Características do H2.City Gold (CaetanoBus, 2021b)

Carroçaria	Caetano
Comprimento	10,740 m ou 11,995 m
Largura	2,5 m
Altura	3,458 m
Portas	2 ou 3
Lotação	Até 64 (10,7m) ou até 87 (12m) passageiros
Motor	Siemens síncrono de ímanes permanentes (180kW)
Sistema de célula de combustível	Tanques de hidrogénio - Tipo 4 em compósito: 5x 312l (máx. 37.5kg: 350 bars) - Tempo de abastecimento: <9 min (estimado) - Potência nominal da pilha de combustível: 60kW (Toyota FC Stack)
Baterias	LTO
Carregamento	CCS Tipo 2 – AC/DC
Autonomia	Até 400 km
Consumo	Desde 6 kg/100 km

Este veículo classifica-se como FCHEV com topologia do tipo 2, como referido na Figura 8, do subcapítulo 2.2.3 Topologias, ou seja, é constituído por bateria, FC e conversor DC/DC, conversor DC/AC e motor. A FC utilizada é do tipo PEMFC, sendo que o veículo possui tanques de armazenamento de hidrogénio que a irão alimentar, juntamente com o oxigénio presente no ar. Através da reação do hidrogénio com o oxigénio é produzida energia e libertada água e calor para a atmosfera. Na Figura 10 é apresentado um esquema que sintetiza o funcionamento do H2.City Gold.




Figura 10- Funcionamento H2.City Gold (CaetanoBus, 2021b)

Relativamente ao motor presente no H2.City Gold, este é produzido pela Siemens e as suas principais características encontram-se descritas na Tabela 2.

Tabela 2- Características do motor

Motor de Tração	SIEMENS
Tipo	Motor síncrono de ímanes permanentes
Potência Máxima	180 kW
Tensão Nominal	625 V – 740 V
Binário Máximo	2 500 Nm
Líquido de Refrigeração	Água Refrigerante ¹

¹ 50% anticongelante (e.g. Antifrogen N) e 50% água até -35°C

O sistema de armazenamento de energia é composto por 3 módulos em paralelo que por sua vez são constituídos por 276 células cada. Deste modo destaca-se na Tabela 3 as características da bateria presente no H2.City Gold.

Tabela 3- Características da bateria

Tipo de Baterias	FORSEE POWER Pulse 15 battery packs
Química das células	LTO
Número de packs	3 packs (de 15 kWh cada), conectados em paralelo
Capacidade	45 kWh
Tensão Nominal	635 V
Método de carga	Plug-in/CCS tipo 2, 200A
Potência de carga (DC)	150 kW (máximo)
Carregador OnBoard (AC)	22 kW (opcional)

Relativamente ao armazenamento de hidrogénio, na Tabela 4 são descritas as características dos tanques, ou seja, a sua capacidade e parâmetros de operação. Destaca-se ainda que o hidrogénio irá alimentar a FC Stack da Toyota, que apresenta uma potência nominal de 60kW.

Tabela 4- Características dos tanques de hidrogénio

Sistema	AGILITY CHG Type 4
Número de tanques	5 (7,5 Kg cada)
Capacidade	5 x 7,5 = 37,5 Kg
Volume de Água	312,5 Litros
Pressão de trabalho	350 bar @ 15°C
Gama de Temperaturas	De -40 a +85°C
Certificação	EC-79

Para descrever o comportamento do veículo é fundamental identificar a eficiência da FC, visto que esta varia com a potência que lhe é solicitada. Por este motivo, o consumo de hidrogénio estará também dependente da potência, sendo que os valores indicados pelo fornecedor são confidenciais.

Para além disso, é ainda necessário modelar a variação do SOC em função da potência que entra e sai da bateria, sendo por isso indispensável conhecer a tensão de circuito aberto, a resistência de descarga e a resistência de carga. O fornecedor apresenta estas variáveis em função do estado de carga da bateria, sendo também estes dados confidenciais. No caso da resistência, esta deve ser multiplicada por 276, visto que cada módulo possui 276 células, e dividida pelos 3 módulos em paralelo. A tensão apenas necessita de ser multiplicada pelas 276 células.

3.2. Requisitos e Limitações

Para efetuar a gestão energética do veículo apresentado, existe um conjunto de requisitos que são impostos, nomeadamente no que diz respeito à avaliação da performance e à redução da degradação dos componentes. O principal objetivo da estratégia a ser implementada é a redução do consumo global do veículo, garantindo que é também reduzido o consumo e a degradação da FC e o SOC é mantido em níveis desejáveis. Para isso, será necessário limitar os picos no pedido de potência à FC, utilizando a capacidade de armazenamento da bateria.

Destaca-se ainda a necessidade de adaptação e flexibilidade da estratégia a diferentes cenários, nomeadamente a tipos de operação diversificados, de modo a ser possível implementar a estratégia de forma generalizada aos diversos clientes da CaetanoBus.

No entanto, é necessário também ter em conta algumas limitações e dificuldades, como é o caso dos ciclos *start/stop* da FC, que serão cenários a evitar de modo a reduzir os picos de potência. Outra variável que apresenta uma influência muito significativa no pedido total de potência do veículo é a necessidade de HVAC, sendo que este pode variar em função do local de operação do autocarro e da época do ano.

Em suma, os requisitos e limitações apresentados pretendem dar resposta à necessidade de aplicar a estratégia em veículos reais, que circulem em diferentes condições, sendo por isso fundamental uma elevada capacidade de adaptação.

3.3. Ciclos de Condução

Os ciclos de condução a serem estudados devem ser previamente definidos para que sejam representativos das necessidades dos clientes e descrevam os diferentes tipos de rotas possíveis. Assim, serão estudados os seguintes ciclos de condução, considerados relevantes pela CaetanoBus:

- Urbano;
- Intercidades;
- Autoestrada.

De modo a identificar os tipos de rotas que se pretendem estudar, é fundamental caracterizar os ciclos de condução através dos seus principais parâmetros, sendo que estes foram selecionados em função da experiência dos especialistas da CaetanoBus e das variáveis utilizada por Lin e Li (2019):

- Velocidade média;
- Desvio padrão da velocidade;
- Velocidade média excluindo tempos de paragem;
- Aceleração média;
- Desaceleração média;
- Percentagem de tempo parado;
- Número médio de paragens por hora.

Para o cálculo dos parâmetros, foi analisada uma amostra de 45 ciclos de condução (15 urbanos, 15 intercity e 15 autoestrada) e calculada a respetiva média dos parâmetros por tipo de ciclo, sendo os resultados apresentados na Tabela 5.

Tabela 5- Ciclos de condução e respetivos parâmetros

Parâmetro / Ciclo	Urbano	Intercidades	Autoestrada
Velocidade média (km/h)	16.60	35.62	60.52
Desvio padrão da velocidade	14.67	20.03	16.65
Velocidade média excluindo tempos de paragem (km/h)	24.83	40.49	61.09
Aceleração média (m/s²)	0.50	0.34	0.19
Desaceleração média (m/s²)	-0.43	-0.36	-0.21
Percentagem de tempo parado (%)	34	12	1
Número médio de paragens por hora	54.87	22.36	4.74

Relativamente a cada ciclo de condução foram recolhidos os dados reais do veículo, em intervalos de tempo de um segundo, sendo que foram analisados os seguintes dados: velocidade do veículo, potência total pedida, potência fornecida pela bateria e pela FC, potência de HVAC e SOC.

Salienta-se que os dados obtidos dizem respeito ao comportamento do veículo com o algoritmo originalmente implementado, sendo esta a base de comparação para os resultados que serão obtidos.

4. ESTRATÉGIA DE GESTÃO ENERGÉTICA PARA O AUTOCARRO H2 CITY GOLD

Partindo da revisão bibliográfica efetuada, no presente capítulo expõe-se a estratégia que resulta das necessidades apresentadas pela CaetanoBus e da viabilidade das estratégias apresentadas por diversos autores. São ainda demonstradas as etapas para a sua implementação, mencionando todas as ferramentas necessárias.

4.1. Apresentação da Estratégia

A proposta de solução apresentada tem por base o estudo de uma estratégia de gestão energética em tempo real, desenvolvida por Lin e Li (2019), aplicada a um veículo elétrico híbrido, que preconiza um controlo adaptável com reconhecimento do tipo de ciclo de condução. A lógica implementada parte da aplicação da programação dinâmica para a otimização da divisão de potência entre a bateria e o motor de combustão, que posteriormente irá permitir a extração de regras que descrevem esse controlo. Por outro lado, Romano (2021) apresentou uma estratégia semelhante aplicada a um FCHEV, nomeadamente o Toyota Mirai, que demonstrou a possibilidade de obter resultados promissores em veículos FC, utilizando programação dinâmica e redes neuronais.

Devido à grande semelhança entre o autocarro H2.City Gold e o Toyota Mirai, a estratégia de Romano (2021) irá constituir a ponte entre a estratégia de Lin e Li (2019) e a estratégia que se preconiza, sendo que o valor que se irá acrescentar reside na flexibilidade e adaptabilidade do algoritmo a diferentes ciclos de condução em tempo real.

A estratégia irá ser implementada em três fases: otimização com programação dinâmica, extração de regras de controlo e reconhecimento do ciclo de condução.

4.1.1. Otimização

A implementação de programação dinâmica no caso em estudo só é possível se existir conhecimento prévio de todo o ciclo de condução, servindo como base para a compreensão do comportamento ideal da gestão energética entre a bateria e a FC.

Partindo dos dados obtidos a priori, relativamente ao pedido total de potência de um veículo a percorrer cada uma das rotas em estudo, será aplicado um modelo de otimização para a distribuição de potência, utilizando programação dinâmica.

Inicialmente são definidas duas variáveis de estado x_k e s_k , que dizem respeito ao SOC e à potência pedida à FC no instante anterior, respetivamente, e uma variável de controlo u_k , que representa a potência que será pedida à FC.

Analisando todo o percurso do veículo, o objetivo é encontrar a distribuição de potência ótima entre a FC e a bateria de modo a minimizar o consumo equivalente. O consumo da FC (g_{FC}) em g/s será calculado utilizando a regressão linear obtida a partir dos dados indicados pelo fornecedor.

De modo a tornar o consumo da FC e da bateria equivalentes, é necessário encontrar um fator de conversão. Segundo U.S. *Department of Energy* (2021), é possível calcular uma conversão das diferentes alternativas de combustíveis para GGE utilizando os valores da Tabela 6.

Tabela 6- Fatores de *Gasoline Gallon Equivalent* (U.S. Department of Energy, 2021)

Combustível	Unidades	Conversão
B100	Gallons	GGE = B100 gal x 1.066
CNG @ 2400 psi	Gallons @ 2400 psi	GGE = CNG gal @ 2400 psi x 0.191
CNG @ 3600 psi	Gallons @ 3600 psi	GGE = CNG gal @ 3600 psi x 0.287
CNG @ 3000 psi	Gallons @ 3000 psi	GGE = CNG gal @ 3000 psi x 0.239
CNG	Hundred cubic feet	GGE = CNG ccf x 0.877
Diesel	Gallons	GGE = Diesel gal x 1.155
E85	Gallons	GGE = E85 gal x 0.734
Elettricidade	kWh	GGE = Elettricidade kWh x 0.031
Gasolina	Gallons	GGE = Gasolina gal
Hidrogénio	Kg	GGE = H ₂ Kg x 1.019
Hidrogénio	Gallons	GGE = H ₂ gal x 0.256
LNG	Gallons @ 14.7 psi and -234°F	GGE = LNG gal x 0.666
LPG	Gallons	GGE = LPG gal x 0.758

Assim, é possível obter, a partir da potência pedida à bateria (kW) e do consumo de hidrogénio (g), o consumo equivalente de todo o sistema em GGE, tendo em conta que o tempo será discretizado em segundos. Na Equação 1 e na Equação 2 encontra-se representada esta conversão para cada instante do problema.

$$Q_{bat} = 0.031 \frac{1}{3600} P_{bat} \quad \text{Equação 1}$$

$$Q_{FC} = 1.019 \frac{1}{1000} g_{FC} \quad \text{Equação 2}$$

Para além disso, é ainda aplicado ao consumo equivalente da bateria uma penalização para o desvio do SOC dos limites desejados (He & Yang, 2006), de modo a garantir o seu funcionamento na zona de maior eficiência na maioria do ciclo e evitando situações de carga demasiado baixa ou demasiado alta. No presente caso de estudo considerou-se que o SOC ideal é de 72.5%, mais ou menos 2.5%. A Equação 3, descreve essa penalização, onde SOC_{tar_max} e SOC_{tar_min} representam os limites superior e inferior do SOC desejável (SOC_{tar}), respetivamente, e u é uma constante para ajuste das características da bateria (os autores Torreglosa et al. (2011) e He e Yang (2006) optaram pelo valor de 0.6). Destaca-se ainda que quando existe regeneração de energia ($P_{bat} < 0$) e o SOC se encontra entre os limites desejáveis, a penalização irá atuar de tal forma que este seja o cenário mais beneficiado, sendo que pelo contrário, quanto maior o afastamento ao SOC ideal e quanto maior a P_{bat} , maior será a penalização dada ao custo equivalente da bateria.

$$\lambda = \begin{cases} \left| 1 - 2u \frac{SOC - 0.5(SOC_{tar_max} + SOC_{tar_min})}{SOC_{tar_max} - SOC_{tar_min}} \right|, & P_{bat} \geq 0 \\ 1 - \left| 1 - 2u \frac{SOC - 0.5(SOC_{tar_max} + SOC_{tar_min})}{SOC_{tar_max} - SOC_{tar_min}} \right|, & P_{bat} < 0 \end{cases} \quad \text{Equação 3}$$

Deste modo, define-se a função de custo do problema como a soma do consumo equivalente da FC e do consumo equivalente da bateria em GGE, em função das variáveis de estado e controlo.

$$L = Q_{FC}[x_k, u_k] + \lambda Q_{bat}[x_k, u_k] \quad \text{Equação 4}$$

Assim, é possível descrever a função de controlo na Equação 5, utilizando a discretização do problema em N períodos de tempo.

$$J = \sum_{k=0}^{N-1} L[x_k, u_k] \quad \text{Equação 5}$$

Utilizando o princípio de Bellman com uma abordagem *backward*, define-se a função objetivo do problema de forma recursiva:

$$J_k^*(x_k) = J_{k+1}^*(x_{k+1}) + \min_{u(k)} (L[x_k, u_k]) \quad \text{Equação 6}$$

O problema está ainda sujeito a um conjunto de restrições que dizem respeito aos limites de SOC, de potência da FC e de potência da bateria:

$$P_{bat_min} \leq P_{bat} \leq P_{bat_max} \quad \text{Equação 7}$$

$$P_{FC_min} \leq P_{FC} \leq P_{FC_max} \quad \text{Equação 8}$$

$$SOC_{min} \leq SOC(t) \leq SOC_{max} \quad \text{Equação 9}$$

$$P_{Req} = P_{FC} + P_{bat} \quad \text{Equação 10}$$

$$|P_{FC} - P_{FC_ant}| \leq rate \quad \text{Equação 11}$$

É necessário também definir as funções de transição de estado que irão permitir a atualização das variáveis de estado em cada iteração. A Equação 12 e a Equação 13 descrevem a transição de estado do SOC e a Equação 14 descreve a transição de estado para a potência pedida à FC no instante anterior. A variável de estado que diz respeito à potência pedida à FC na iteração anterior irá permitir que seja verificada a restrição da Equação 11, que garante que não é ultrapassado o rate de pedido de potência que a FC pode alcançar, ou seja 175W/s.

$$x_{k+1} = SOC_k - \frac{I_{bat(k+1)}}{3600C_{bat}} \quad \text{Equação 12}$$

$$I_{bat} = \frac{V_{OC} - \sqrt{V_{OC}^2 - 4RP_{bat}}}{2R} \quad \text{Equação 13}$$

$$s_{k+1} = P_{FC} \quad \text{Equação 14}$$

4.1.2. Extração de regras de controlo

Com o objetivo de extrair as regras de distribuição de potência a partir dos resultados obtidos com a programação dinâmica, tal como em Lin e Li (2019), é aplicada a *Response Surface Methodology*, com a qual são obtidas as expressões que descrevem o comportamento ótimo da potência pedida

à FC para os ciclos de condução em estudo. Com esta metodologia pretende-se obter a relação entre as variáveis que descrevem a rota e a potência pedida à FC.

As variáveis de interesse definidas por Lin e Li (2019) foram a potência pedida pelo veículo e a sua velocidade, sendo a variável de resposta a potência pedida à bateria. Tendo em conta que o veículo em estudo circula em rotas reais, considera-se relevante utilizar como variáveis de interesse a potência total pedida, a velocidade, o SOC e a potência do HVAC, de modo a melhor descrever o comportamento do mesmo. Salienta-se ainda que no caso da potência total, devido à grande variabilidade dos valores, e de acordo com a experiência da empresa em testes anteriores, aplicou-se um amortecimento exponencial com o objetivo de favorecer o reconhecimento do ciclo.

Esta estratégia permite obter um modelo matemático, cujo grau será previamente definido, que devolve a potência pedida à FC em função das variáveis de interesse anteriormente descritas, sendo o seu modelo compacto para uma equação de grau 2, o apresentado na Equação 15. Nesta equação, A_i são os coeficientes a obter pelo método *nonlinear least square*, x_i e x_j são as variáveis de interesse, e n é o número total de variáveis, que neste caso serão utilizadas 4.

$$y = A_0 + \sum_{i=1}^n A_i x_i + \sum_{i=1}^n A_{ii} x_i^2 + \sum_{i=1}^{n-1} \sum_{j=i+1}^n A_{ij} x_i x_j \quad \text{Equação 15}$$

Assim, é utilizado o método *nonlinear least square* descrito na Equação 16, onde Y_i é o valor da potência ótima pedida à FC, obtida por DP, e y_i é a potência pedida à FC prevista pelo modelo.

$$\min \sum_{i=1}^N [Y_i - y_i]^2 \quad \text{Equação 16}$$

Deste modo, pretende-se encontrar o valor ótimo dos coeficientes A_i que minimizam a diferença acumulada entre o valor ótimo e o valor previsto da potência pedida à FC, ao longo dos N segundos do ciclo de condução.

Em alternativa, recorrendo a modelos de *supervised machine learning* é possível utilizar também métodos de regressão que utilizam o mesmo conjunto de parâmetros para prever a potência que deverá ser solicitada à FC. Romano (2021) utilizou redes neurais que permitiram absorver o comportamento da otimização, treinando, validando e testando a mesma com os dados obtidos na DP.

Assim, é possível avaliar os diversos modelos em simultâneo, comparando o erro quadrático médio (RMSE) para compreender a estratégia que melhor se adequa aos dados em estudo. O RMSE é a medida normalmente utilizada para avaliar o desempenho de modelos, estando o seu significado diretamente relacionado com as unidades em estudo. Por este motivo deve ser utilizado apenas para comparação de modelos que se aplicam ao mesmo tipo de dados/problema (Chai & Draxler, 2014).

4.1.3. Reconhecimento do ciclo de condução

Para identificação do tipo de ciclo de condução Lin e Li (2019) utilizaram a NN *Learning Vector Quantization*, onde os ciclos de condução em estudo irão constituir a fase de treino da rede. Deste

modo é construída uma rede para a tomada de decisão do tipo de condução que mais se assemelha às condições reais de condução do veículo. A rede é treinada em modo offline, para posteriormente poder ser implementada na ECU.

É possível utilizar a mesma lógica de treino e teste em diversos modelos de *supervised machine learning*, que são capazes de utilizar um conjunto de dados para aprender o comportamento do modelo, avaliando a sua performance com novos dados de teste. Assim, através da introdução dos parâmetros que descrevem o ciclo de condução, é possível que o modelo apresente como resposta a previsão do ciclo de condução mais adequado.

Deste modo, torna-se possível avaliar diversos modelos, comparando a sua performance com a utilização da *accuracy* para efetuar uma tomada de decisão mais precisa, em relação à classificação de cada ciclo de condução. A *accuracy* é a medida utilizada para a avaliação do desempenho de modelos de previsão e é definida como o rácio entre o número de classificações corretas e o número total de classificações efetuadas (Mehdiyev et al., 2016).

4.2. Implementação em Matlab

O Matlab é o software atualmente utilizado pela empresa para modelação e simulação dos veículos, sendo por isso fundamental a integração do presente projeto com os trabalhos já desenvolvidos. Por esse motivo, seguidamente apresenta-se a estratégia de implementação em Matlab para cada uma das fases anteriormente descritas.

4.2.1. Programação dinâmica

Para a implementação do problema de programação dinâmica é utilizada a metodologia proposta por Sundstrom e Guzzella (2009b), que aborda a função DPM para a aplicação genérica de DP em Matlab. Esta função resolve problemas discretos de controlo, utilizando o princípio de Bellman através da introdução da função objetivo e das equações que descrevem o modelo (Sundstrom & Guzzella, 2009b). Destacam-se as vantagens ao nível da redução do tempo de computação e da precisão do algoritmo, sendo que, segundo Guzzella e Sciarretta (2010), um problema de gestão energética num veículo híbrido pode ser resolvido com estes algoritmos em menos de um minuto. Para além disso, esta ferramenta não é exclusiva para a resolução de problemas de gestão energética em veículos híbridos, sendo que também já foi implementada com sucesso em problemas de estacionamento de veículos, problemas de controlo inteligente e problemas de controlo de emissões do motor (Sundstrom, 2009).

A função DPM é normalmente chamada como descrito na Equação 17, onde *res* é a estrutura que contém o resultado, *dyn* está associada ao controlo ótimo do algoritmo (*cost-to-go* e *input map*), *fun* é a função do modelo, *par* são os parâmetros que se pretendem introduzir no modelo, *grd* é a estrutura do espaço de controlo e estados, *prb* é a estrutura do problema e *options* diz respeito a definições adicionais que se podem introduzir no modelo.

$$[\text{res } \text{dyn}] = \text{dpm}(\text{fun}, \text{par}, \text{grd}, \text{prb}, \text{options}); \quad \text{Equação 17}$$

Esta função implementada em Matlab foi disponibilizada para *download* por Sundstrom e Guzzella (2009a) no *Institute for Dynamic Systems and Control*, para estudantes e investigadores.

Relativamente aos inputs necessários para a implementação da função DPM, estes dividem-se em:

- *prb*, que inclui o tamanho e número de períodos de tempo, e o vetor que inclui os dados relevantes para o problema em função do tempo, nomeadamente, a potência total pedida pelo veículo;
- *grd*, que contém a informação relativa à discretização das variáveis de estado e controlo, apresentando-se esses parâmetros na Tabela 7;
- *options*, que define a forma como o algoritmo será implementado, nomeadamente a seleção de minimização ou maximização da função objetivo, o tipo de inputs e o armazenamento do mapa de custos.

Tabela 7- Definição dos parâmetros da função DPM

Variável	Valor
Tempo	
Dimensão dos intervalos	1 segundo
Variável de estado - SOC	
Dimensão dos intervalos	1%
Número de intervalos ($grd.Nx\{1\}$)	101 $(=(100-0)/1 + 1)$
Limite superior final ($grd.Xn\{1\}.hi$)	100%
Limite inferior final ($grd.Xn\{1\}.lo$)	0%
Variável de estado - P_{FC_ant}	
Dimensão dos intervalos	3326W
Número de intervalos ($grd.Nx\{2\}$)	17 $(=(60000-6784)/3326 + 1)$
Limite superior final ($grd.Xn\{2\}.hi$)	60000W
Limite inferior final ($grd.Xn\{2\}.lo$)	6784W
Variável de controlo - P_{FC}	
Dimensão dos intervalos	175W (aproximadamente)
Número de intervalos ($grd.Nu\{2\}$)	306 $(\geq(60000-6784)/175 + 1)$
Limite superior final ($grd.Un\{2\}.hi$)	60000W
Limite inferior final ($grd.Un\{2\}.lo$)	6784W
P_{bat}	
Limite superior	186000W
Limite inferior	-225000W

De notar que, no caso da variável de controlo P_{FC} é necessário que a discretização seja sensível à variação de 175W para que seja possível efetuar o cálculo da taxa de subida/descida. No entanto, para a variável de estado P_{FC_ant} foi considerado um valor inferior para reduzir o tempo de simulação, sendo que a discretização desta variável em intervalos maiores não invalida a sensibilidade para o cálculo do rate. Pelo mesmo motivo, para a discretização do SOC foram considerados intervalos de 1%.

A título de exemplo da exigência computacional necessária, uma rota com aproximadamente uma hora de duração, para a discretização da P_{FC_ant} em intervalos de 175W, seriam necessárias cerca de 4 horas e 45 minutos para efetuar a otimização. Utilizando intervalos de 3326W, o tempo para otimização seria cerca de 20 minutos. Na Figura 11 e na Figura 12 são apresentados os resultados das otimizações para os dois cenários, sendo possível visualizar um comportamento idêntico e uma reduzida diferença entre os diversos indicadores. Calculando o erro percentual médio entre a potência pedida à FC da situação com intervalos de 175W e da situação com intervalos de 3326W,

obteve-se um erro de 1,6%, sendo que se verificou que o rate máximo de 175W foi garantido em ambos os casos.




Figura 11- Otimização com intervalos de 3326W




Figura 12- Otimização com intervalos de 175W

Visto que todo o estudo irá incluir uma amostra de 45 rotas, e a diferença entre os resultados obtidos não é significativa, optou-se por utilizar um menor número de intervalos, reduzindo assim a exigência computacional.

Os outputs da função incluídos na estrutura *res* dizem respeito à trajetória das variáveis de estado e do respetivo custo e os sinais que são guardados no algoritmo, nomeadamente a potência pedida à bateria. A estrutura *dyn* armazena os mapas de *cost-to-go* e controlo ótimos.

Dentro do modelo, são ainda utilizadas as seguintes estruturas:

- *inp*, onde *inp.X{.}*, *inp.U{.}* e *inp.W{.}* dizem respeito ao estado atual das variáveis de estado, da variável de controlo e dos dados de input (P_{req}), respetivamente;
- *par*, outros parâmetros definidos pelo utilizador, necessários para o modelo;
- *X{.}* e *C{.}*, que correspondem aos resultados e custos obtidos depois de aplicar os estados e controlo *inp.X{.}*, *inp.U{.}*
- *I*, que representa o conjunto de combinações impossíveis para o sistema;
- *Signals*, a estrutura com as variáveis extra, que o utilizar pretende armazenar.

4.2.2. Extração de regras de controlo

Primeiramente, é necessário calcular o amortecimento exponencial para a potência total pedida, sendo isto possível utilizando a função *dsp.MovingAverage(Name, Value)*, cujo “Method” é “Exponential weighting” e “Forgetting Factor” é 0.99995. Um fator elevado dá mais peso aos dados antigos, sendo a média menos sensível às variações no presente. Este valor foi mantido de acordo com o já utilizado na estratégia anteriormente implementada no veículo.

Para identificar as variáveis de interesse e respetivas interações que apresentam efeito significativo na variável de resposta, deverá efetuar-se uma análise da variância que pode ser executada com a função *stepwiselm* em Matlab. A função *stepwiselm* cria um modelo do grau definido com as variáveis que se pretendem estudar e respetivas interações, permitindo adicionar ou remover variáveis ao modelo em função do seu *p_value*.

Deste modo, apenas as variáveis e interações cuja relação com a variável de resposta é significativa é que serão utilizadas para a aplicação do modelo *nonlinear least square*, ou seja, quando o respetivo *p-value* for inferior a 0,05. É ainda devolvida a estimativa do coeficiente para cada termo do modelo, sendo assim possível obter a equação que caracteriza o comportamento da potência pedida à FC.

Utilizando a app *Regression Learner* é possível treinar e testar diversos modelos de *machine learning*. Para tal, deverão ser importados os dados que dizem respeito aos mesmos 4 parâmetros (potência total pedida, SOC, velocidade e potência do HVAC) e selecionar o método *5 fold cross validation* para evitar as situações de *overfitting*. A aplicação de *cross validation* é utilizada para dividir repetidamente os dados em dois grupos, um para treino e o outro para teste do modelo, aumentando a confiabilidade da previsão (Roberts et al., 2017). Todos os modelos disponibilizados pelo Matlab são treinados e testados, sendo devolvido o respetivo RMSE para comparação da performance.

O Matlab disponibiliza ainda a hipótese de exportar somente o modelo compacto, que omite os dados de treino para apenas fazer previsões com novos dados. Assim, é possível obter uma função simplificada e mais adequada para posteriormente ser implementada na ECU.

4.2.3. Reconhecimento do ciclo de condução

Para implementar os modelos de classificação, é necessário utilizar em Matlab a app *Classification Learner*, importando uma amostra de ciclos constituída por rotas urbanas, intercity e

autoestrada, com as respetivas características, que dizem respeito ao valor dos 7 parâmetros que caracterizam cada ciclo.

Para evitar *overfitting*, é utilizado o método *cross validation* para a fase de teste com 5 *folds*, sendo a variável de resposta o tipo de ciclo. Utilizam-se todos os modelos disponibilizados pela ferramenta, comparando-os através da *accuracy* obtida, de modo a selecionar aquele cuja performance seja mais satisfatória. Exportando o modelo compacto, será possível posteriormente implementar o respetivo código em linguagem C na ECU.

4.3. Validação e Visualização de Resultados

Antes da realização deste projeto, o desempenho do veículo era avaliado em função do consumo de hidrogénio por cada 100km. No entanto, verificou-se que, tendo em conta os requisitos da empresa e a pesquisa efetuada, existem medidas mais robustas que efetuam a ponderação de diversos fatores. Assim, a principal medida de desempenho foi definida como o consumo equivalente em GGE, sendo este o alvo da otimização que engloba não só o consumo de H₂, mas também o consumo da bateria ajustado em função da distância do SOC atual ao SOC ideal.

Os resultados do consumo equivalente são apresentados graficamente pelo respetivo valor acumulado ao longo do tempo, sendo ainda indicada a redução em percentagem deste consumo relativamente aos dados reais recolhidos do veículo com o algoritmo anterior.

Adicionalmente, considerou-se importante avaliar também o consumo de hidrogénio isoladamente, visto ser uma medida de elevado interesse para a empresa e para os clientes. Assim, para além do cálculo do consumo de hidrogénio por cada 100 km conseguido pelo algoritmo atual e pelo novo algoritmo, é ainda apresentada a redução conseguida pela presente estratégia, em percentagem.

No que diz respeito à FC, no subcapítulo 3.2 Requisitos e Limitações foi referida a necessidade de reduzir os picos no seu pedido de potência, de modo a evitar a degradação da FC, aumentando o seu tempo de vida. Tendo em conta as dificuldades encontradas para a quantificação numérica desta degradação, considerou-se que o desvio padrão seria capaz de refletir as variações existentes no pedido de potência, servindo de comparação em relação ao algoritmo atualmente implementado nos veículos. Espera-se que valores reduzidos no desvio padrão indiquem pedidos de potência mais homogêneos e, portanto, menos degradação da FC.

Como forma de avaliar a capacidade que o algoritmo tem de manter a FC a funcionar na zona de maior eficiência, utilizou-se a energia produzida por quilograma de H₂ consumido. Este indicador apresentado em forma de percentagem para a comparação dos dois algoritmos revela que quanto maior for a energia produzida pela FC, maior será a eficiência global da mesma, sendo uma medida de rendimento.

Para além disso, todo o comportamento do veículo é descrito pelo gráfico do SOC para ambos os algoritmos e pelos gráficos de potência, com a potência total, potência da FC e potência da bateria em cada instante.

4.4. Implementação na ECU

Após as fases de extração das regras de controlo e criação do algoritmo de reconhecimento do ciclo de condução, é possível exportar as respetivas funções em Matlab. No entanto para que estas sejam passíveis de ser implementadas no autocarro é necessário obter as mesmas em linguagem de programação C. Por este motivo, recorreu-se à app Matlab *Coder* que gera o código em linguagem C de cada função, sendo este compatível com a ECU.

Do mesmo modo, programou-se uma função capaz de calcular os 7 parâmetros de caracterização de um ciclo, que irá receber como input o valor instantâneo da velocidade e o sinal que indica que o veículo está parado ou em movimento. Esta irá armazenar num vetor os valores de cada segundo para que ao fim do tempo definido sejam efetuados os cálculos necessários e devolvido como output o valor de cada parâmetro atualizado. Assim, estaremos a disponibilizar à função de classificação os dados necessários para que esta seja capaz de tomar a decisão do tipo de ciclo.

A tomada de decisão é fundamental para que seja aplicada a regra que descreve a divisão de potência, em função do ciclo de condução que melhor se adequa ao tipo de condução em que o veículo se encontra. Este processo deverá ser efetuado em intervalos de tempo dimensionados de forma a obter o ajuste adequado dos parâmetros, mantendo um equilíbrio com as exigências computacionais. Assim, após a identificação do ciclo de condução adequado às condições de condução atuais, será aplicada a respetiva regra de controlo da potência pedida à FC.

Na Figura 13 é apresentado um resumo da proposta de solução, partindo da implementação *offline* até à implementação *online* na ECU (para mais detalhe, consultar o Apêndice A). O processo é apresentado da seguinte forma:

- 1) Definir os ciclos de condução e respetivos parâmetros;
- 2) Partindo dos registos *a priori* de cada ciclo de condução, aplicar o modelo de DP para cada rota;
- 3) Utilizar a solução ótima de cada ciclo de condução para extrair as regras de controlo que descrevem o comportamento do pedido ótimo de potência à FC;
- 4) Treinar e testar os diversos modelos de *machine learning* com uma amostra de rotas dos ciclos de condução definidos, obtendo a função capaz de efetuar a classificação dos ciclos;
- 5) Gerar código em linguagem C das funções criadas;
- 6) Executar na ECU a função de reconhecimento do ciclo de condução e aplicar a respetiva regra de pedido de potência à FC.




Figura 13- Proposta de Solução

5. APRESENTAÇÃO DE RESULTADOS

Neste capítulo apresentam-se os resultados obtidos por etapas, bem como análises auxiliares efetuadas para a parametrização e seleção dos modelos a utilizar em Matlab e na ECU do veículo.

5.1. Otimização

5.1.1. Análise do fator de penalização do SOC

No subcapítulo 4.1.1 Otimização, apresentou-se o consumo equivalente como medida de performance, que se descreve como a soma do consumo equivalente da FC com o consumo equivalente da bateria em GGE. Para além disso, é ainda contemplado um fator de penalização para o desvio do SOC atual em relação ao SOC desejável, sendo este fator dependente de uma constante u que descreve a capacidade de carga e descarga da bateria.

Visto que o valor adotado para esta constante pelos diversos autores (Torreglosa et al. (2011) e He e Yang (2006)), não se encontra devidamente justificado para um veículo com as características do autocarro em estudo, efetuou-se uma análise de sensibilidade para melhor entender o seu comportamento, utilizando uma amostra de 3 ciclos urbanos (U), 3 ciclos intercity (I) e 3 ciclos autoestrada (A).

Assim, fez-se variar o u entre 0.1 e 0.9 (em intervalos de 0.1) para todas as rotas da amostra. Com isto pretende-se identificar o valor de u que permite obter uma melhor performance global, tendo em conta o consumo equivalente, o consumo de H_2 , o rendimento da FC e o SOC final. Na Figura 14, Figura 15, Figura 16 e Figura 17 apresentam-se os resultados de cada indicador para os diferentes valores de u .




Figura 14- Redução do consumo equivalente em função do u




Figura 15- Redução do consumo de H₂ em função do u




Figura 16- Aumento do rendimento em função do u




Figura 17- SOC final em função do u

Assim, verifica-se que entre u igual a 0.1 e 0.2 é onde o SOC final sofre a maior variação, sendo que para 0.1 este indicador, na maioria das rotas analisadas, atinge um nível demasiado baixo e pouco desejável. Este facto é compreensível, tendo em conta que no caso da constante u ser 0.1, o fator de penalização será pouco acentuado, desvalorizando os momentos em que o SOC se encontra afastado do seu valor ideal, o que resulta num SOC final reduzido.

Consequentemente, para valores de u acima de 0.2, a variação do SOC final não é tão acentuada e portanto, a redução no consumo de H_2 também não é tão notória. Assim, apesar do cenário com u igual a 0.1 ser aquele cujas poupanças no consumo de hidrogénio seriam mais elevadas, de modo a privilegiar um estado da carga da bateria mais próximo do ideal, considera-se que a melhor opção é a adoção do valor 0.2 para a contante u .

Relativamente ao consumo equivalente, verificou-se que na maioria dos casos o aumento do u está diretamente relacionado com a melhoria nos consumos equivalentes. Para o rendimento, este apenas mostrou melhorias significativas quando u apresenta o valor de 0.1. Porém, não sendo este fator alvo de otimização, compreende-se que não apresente resultados otimizados.

Em suma, tendo em conta a necessidade de efetuar um *tradeoff* entre os diversos indicadores e tendo por base uma estratégia que privilegia a redução do consumo de hidrogénio, mantendo o SOC próximo do nível desejado, optou-se por prosseguir com a otimização utilizando um u de 0.2 que para além de manter bons resultados no consumo equivalente, também previne gastos excessivos no consumo de H_2 .

5.1.2. Resultados da DP

Como já foi referido no subcapítulo 4.3 Validação e Visualização de Resultados, foram utilizados o consumo equivalente, o consumo de H_2 , o rendimento e o desvio padrão da potência pedida à FC para avaliar a performance da otimização comparativamente ao cenário atualmente implementado no veículo. Adicionalmente, incluiu-se o valor inicial e final do SOC de modo a verificar se este não se afastou em demasia do SOC ideal definido.

Os resultados obtidos na programação dinâmica são os apresentados na Tabela 8, Tabela 9 e Tabela 10. Como seria de esperar em todas as rotas existe uma melhoria do consumo equivalente, visto ser este o alvo da otimização. No entanto, por vezes esta melhoria tem como consequência um aumento no consumo de H_2 de modo a aproximar o SOC do valor ideal, sendo este comportamento desejável principalmente quando o SOC inicial se encontra muito baixo. Este facto é possível de verificar comparando o SOC inicial com o SOC final que, sempre que é possível, tende a aproximar-se de 72.5%.

Salienta-se ainda que os resultados obtidos para o rendimento são apenas um indicador da utilização da zona de maior eficiência da FC, não sendo este o alvo da otimização. Assim, os valores negativos neste indicador mostram que apesar do rendimento alcançado não ser melhor do que o obtido com o algoritmo anterior, a performance global foi beneficiada.

Tabela 8- Resultados DP para ciclos urbanos

Ciclos Urbanos	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
U1	23.58	-17.98	-2.63	9.54	68.4	72.12
U2	19.07	5.23	-1.36	11.45	73.2	69.83
U3	18.27	-5.60	-1.10	6.66	74.4	71.92
U4	29.10	-11.35	-1.32	7.13	73.2	71.32
U5	10.39	-27.19	-2.60	9.71	72.8	64.83
U6	17.63	7.71	-0.54	10.40	68.8	73.85
U7	21.07	4.58	-0.45	9.01	74.8	71.31
U8	25.91	-2.47	-0.67	8.09	74.4	72.21
U9	15.02	-161.39	-10.57	16.51	50	71.08
U10	28.17	2.58	-2.46	15.87	74	74.44
U11	14.55	4.57	-0.70	12.32	77	69.63
U12	14.50	12.51	0.09	9.10	74	70.70
U13	27.73	-16.26	-1.96	9.00	70.8	76.65
U14	8.26	14.16	0.04	4.22	74.8	73.38
U15	25.46	-17.30	-2.76	8.47	74	74.15

Tabela 9- Resultados DP para ciclos intercidades

Ciclos Intercidades	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
I1	12.90	25.33	-0.25	22.32	66%	58.84
I2	24.46	1.62	-1.16	18.42	70%	65.09
I3	37.37	2.28	-2.38	19.35	70%	72.28
I4	60.91	-11.24	-2.40	15.37	71%	72.41
I5	31.80	-8.00	-3.94	17.94	72%	68.66
I6	7.69	0.69	-1.23	14.17	62%	37.92
I7	41.41	-11.58	-1.92	14.60	80%	69.91
I8	31.28	-19.45	-8.08	21.96	71%	76.37
I9	45.49	-65.60	-6.11	17.38	82%	72.99
I10	43.21	-54.85	-5.36	16.24	77%	68.60
I11	9.80	15.46	-0.93	23.16	77%	64.08
I12	34.19	-6.49	-5.92	20.57	76%	73.03
I13	44.81	-5.57	-3.86	19.10	70%	72.35
I14	22.78	0.20	-4.25	22.84	69%	65.19
I15	4.08	16.47	-0.25	20.38	34%	47.54

Tabela 10- Resultados DP para ciclos autoestrada

Ciclos Autoestrada	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
A1	3.74	-0.88	-0.62	8.91	66%	50.46
A2	5.71	6.46	0.46	13.62	71%	54.98
A3	7.59	-7.95	-1.35	11.33	73%	51.98
A4	7.57	15.90	0.15	19.94	70%	53.03
A5	6.10	11.22	1.19	14.07	61%	46.27
A6	47.58	-0.18	-0.73	19.06	78%	71.66
A7	10.88	54.73	7.28	17.15	66%	52.20
A8	14.01	22.77	2.13	21.38	83%	56.67
A9	6.11	20.00	1.48	18.21	44%	37.91
A10	9.05	16.85	1.51	14.80	52%	39.34
A11	10.30	41.45	4.36	19.00	57%	45.47
A12	12.28	34.20	3.03	16.36	68%	53.05
A13	11.89	-6.47	-4.05	18.97	67%	59.26
A14	10.85	57.25	4.40	9.21	70%	61.14
A15	16.19	39.96	2.49	16.53	74%	59.63

5.1.3. Análise de variância

Com o intuito de perceber a diferença entre o consumo equivalente do algoritmo atualmente implementado no veículo (dados recolhidos inicialmente) e o consumo equivalente obtido pela DP, procedeu-se com um teste de hipóteses. Primeiramente, avaliaram-se as amostras relativamente à sua relação, concluindo-se que estas são emparelhadas visto que foram recolhidas das mesmas unidades experimentais, ou seja, foram avaliadas os mesmo ciclos de condução em dois momentos distintos, com o algoritmo antigo (dados reais) e com a DP (dados simulados).

Os testes de hipóteses em amostras emparelhadas partem de uma amostra $D = X - Y$, onde X e Y são duas amostras aleatórias emparelhadas. Assim, a média em estudo é igual à diferença entre as médias de ambas as amostras ($\mu_D = \mu_X - \mu_Y$), sendo as hipóteses nula e alternativa descritas na Equação 18 e Equação 19, respetivamente.

$$H_0: \mu_D = \mu_0 \quad \text{Equação 18}$$

$$H_1: \mu_D < \mu_0 \text{ ou } H_1: \mu_D > \mu_0 \text{ ou } H_1: \mu_D \neq \mu_0 \quad \text{Equação 19}$$

Deste modo, é necessário verificar se a amostra de dimensão 45 segue ou não uma distribuição normal. Para tal, efetuou-se um teste de Shapiro-Wilk, cuja hipótese nula é os dados da amostra D serem provenientes de uma distribuição normal. Assim, para um nível de significância de 5%, obteve-se um p_value inferior a 0.05 (1.1065×10^{-7}), sendo rejeitada a hipótese nula e concluindo-se que os dados não seguem uma distribuição normal.

Tendo falhado a suposição de normalidade e sendo a dimensão da amostra superior a 30, irá prosseguir-se com um teste Z para amostras emparelhadas. Pretende-se estudar, para um nível de confiança de 5%, se o consumo equivalente médio do algoritmo anterior é superior ao consumo equivalente médio da DP. Assim, iremos considerar um teste unidirecional com as seguintes hipóteses:

$$H_0: \mu_D = 0 \quad \text{Equação 20}$$

$$H_1: \mu_D > 0 \quad \text{Equação 21}$$

Os resultados obtidos, permitem rejeitar a hipótese nula com um p_value inferior a 0.05 (3.0859×10^{-8}), concluindo que a média do consumo equivalente para o algoritmo antigo é superior à média do consumo equivalente para a DP.

Analisando também a variância da percentagem de redução do consumo equivalente, tendo sido rejeitada a normalidade desta amostra para um intervalo de significância de 5%, efetuou-se um teste Z para as seguintes hipóteses.

$$H_0: \mu = 15 \quad \text{Equação 22}$$

$$H_1: \mu > 15 \quad \text{Equação 23}$$

Assim, para uma significância de 5% obteve-se um p_value de 0.0028 o que permite concluir que a redução do consumo com a DP é em média superior a 15%.

Do mesmo modo analisou-se a normalidade da amostra constituída pela redução do consumo de H_2 , sendo também rejeitada essa hipótese, e aplicado um teste Z para verificar se existe ou não redução desse consumo com a DP. As hipóteses utilizadas estão descritas na Equação 24 e na Equação 25.

$$H_0: \mu = 0 \quad \text{Equação 24}$$

$$H_1: \mu \neq 0 \quad \text{Equação 25}$$

Com um nível de significância de 5%, não foi possível rejeitar a hipótese nula para um p_value de 0.9167, não se podendo afirmar que em média existe aumento ou redução de consumo de H_2 com a DP.

Neste sentido, a solução apresentada mostra que é possível melhorar o estado de carga da bateria, mantendo-o em níveis mais próximos do desejado, sem que seja consumida uma quantidade de hidrogénio significativamente diferente. Assim, o objetivo de melhorar o consumo equivalente é alcançado, estando os resultados validados para avançar para etapa seguinte de extração das regras que modelam o pedido ótimo de potência à FC.

5.2. Regras de Controlo

5.2.1. Seleção e descrição do modelo de extração

Partindo do pedido ótimo de potência à FC em cada instante obtido pela programação dinâmica, pretende-se definir as regras de controlo para cada tipo de ciclo que refletem o comportamento da otimização e que sejam passíveis de aplicar em tempo real no veículo.

Deste modo, utilizou-se a potência total pedida (com alisamento exponencial), a velocidade, o SOC e a potência do HVAC como variáveis de interesse, sendo a variável de resposta a potência pedida à FC. A função *stepwiselm* foi implementada para um polinómio de grau 2, sendo devolvido o conjunto de termos e respetivas interações que apresentaram significância no modelo (p_value inferior a 0.05). O grau do polinómio foi selecionado em função do RMSE, que não melhorou

significativamente quando se aumentou o grau, optando-se assim por simplificar a equação obtida. Utilizando o método *nonlinear least square*, a função é também capaz de calcular o valor dos coeficientes dos termos selecionados. Assim, a Equação 26, Equação 27 e Equação 28 descrevem o comportamento do pedido de potência à FC para ciclos urbanos, intercity e autoestrada, respetivamente.

$$\begin{aligned}
 P_{FC} = & 395717.7336 - 3.3344 * P_{reqmed} - 952742.7766 * SOC + 19.4004 * V \\
 & + 4693.9982 * P_{HVAC} + 4.4763 * P_{reqmed} * SOC \\
 & + 600197.7404 * SOC^2 + 0.0068265 * P_{reqmed} * V \\
 & - 208.2569 * SOC * V + 0.026366 * P_{reqmed} * P_{HVAC} \\
 & - 6108.9794 * SOC * P_{HVAC} - 6.1723 * V * P_{HVAC} \\
 & - 10.3647 * P_{HVAC}^2
 \end{aligned}
 \tag{Equação 26}$$

$$\begin{aligned}
 P_{FC} = & 93805.4045 - 0.093332 * P_{reqmed} - 197191.7448 * SOC \\
 & - 937.4005 * V + 3260.4008 * P_{HVAC} \\
 & + 0.44291 * P_{reqmed} * SOC + 139528.4706 * SOC^2 \\
 & + 0.0084468 * P_{reqmed} * V + 624.4528 * SOC * V + 2.872 * V^2 \\
 & - 0.0090737 * P_{reqmed} * P_{HVAC} - 2703.359 * SOC * P_{HVAC} \\
 & - 8.0528 * V * P_{HVAC} - 13.8584 * P_{HVAC}^2
 \end{aligned}
 \tag{Equação 27}$$

$$\begin{aligned}
 P_{FC} = & 32794.5553 - 1.4006 * P_{reqmed} - 3730.4821 * SOC - 206.9257 * V \\
 & + 7665.8532 * P_{HVAC} + 1.4875 * P_{reqmed} * SOC \\
 & + 33608.6897 * SOC^2 + 0.012461 * P_{reqmed} * V \\
 & - 319.6735 * SOC * V - 0.8711 * V^2 \\
 & - 0.021875 * P_{reqmed} * P_{HVAC} - 9294.5044 * SOC * P_{HVAC} \\
 & + 16.8048 * V * P_{HVAC} - 59.1978 * P_{HVAC}^2
 \end{aligned}
 \tag{Equação 28}$$

5.2.2. Resultados da regressão não linear

Para cada uma das regressões dos ciclos urbano, intercity e autoestrada foi obtido um RMSE de 11785, 18569 e 16530, respetivamente. Os resultados de todos os indicadores para cada ciclo encontram-se presentes na Tabela 17, Tabela 18 e Tabela 19 do Apêndice B.

De forma a comparar visualmente o comportamento da potência pedida à FC na programação dinâmica e com a regressão, efetuaram-se os gráficos da Figura 18, Figura 19 e Figura 20, onde se encontram os dados relativos a todos os ciclos urbanos, intercity e autoestrada, respetivamente. Relativamente ao erro percentual médio, este foi de 57%, 65% e 48% para os ciclos urbanos, intercity e autoestrada, respetivamente, o que indica um mau ajuste ao controlo ótimo obtido.




Figura 18- Comparação da P_{FC} entre DP e regressão para ciclos urbanos




Figura 19- Comparação da P_{FC} entre DP e regressão para ciclos intercedidos




Figura 20- Comparação da P_{FC} entre DP e regressão para ciclos autoestrada

Para melhor compreender o efeito dos pedidos de potência no estado de carga da bateria, criaram-se os gráficos que comparam o SOC obtido com a programação dinâmica e com a regressão para cada ciclo, estando estes representados na Figura 21, Figura 22 e Figura 23. Destaca-se que com a regressão, o algoritmo não é capaz de manter o SOC tão próximo do SOC ideal, piorando em média o consumo equivalente do veículo. Consequentemente, o consumo de H_2 é mais reduzido visto que este não é utilizado para manter o SOC em níveis mais altos.




Figura 21- Comparação do SOC entre DP e regressão para ciclos urbanos




Figura 22- Comparação do SOC entre DP e regressão para ciclos intercity




Figura 23- Comparação do SOC entre DP e regressão para ciclos autoestrada

Tal como na análise de variância efetuada para os resultados da otimização, neste caso para averiguar se existe diferença entre o consumo equivalente do algoritmo antigo e do algoritmo com a regressão, considera-se um teste de hipóteses para amostras emparelhadas.

Deste modo, é necessário verificar se a amostra segue ou não uma distribuição normal, efetuando-se um teste de Shapiro-Wilk, cuja hipótese nula foi rejeitada com um p_value de 4.22×10^{-9} que é

inferior ao nível de confiança de 5%. Assim, é rejeitada a hipótese nula, concluindo-se que os dados não seguem uma distribuição normal.

Prossegue-se então com o teste Z para amostras emparelhadas de dimensão superior a 30, sendo estudado se o consumo equivalente médio do algoritmo anterior é superior ao consumo equivalente médio da regressão, para um nível de confiança de 5%. As hipóteses do teste são as consideradas na Equação 29 e Equação 30.

$$H_0: \mu_D = 0 \quad \text{Equação 29}$$

$$H_1: \mu_D > 0 \quad \text{Equação 30}$$

Assim, não foi possível rejeitar a hipótese nula, sendo o *p_value* superior a 0.05 (0.2652), concluindo que, para um nível de significância de 5%, não é possível afirmar que a média do consumo equivalente do algoritmo antigo é superior à média do consumo equivalente da regressão.

Analisando a variância na redução do consumo equivalente, rejeitou-se a normalidade desta amostra para um intervalo de significância de 5%, efetuando-se um teste Z para as hipóteses da Equação 31 e da Equação 32 .

$$H_0: \mu = 0 \quad \text{Equação 31}$$

$$H_1: \mu > 0 \quad \text{Equação 32}$$

Assim, com um *p_value* de 0.0106 inferior ao nível de significância de 0.05 conclui-se que a redução do consumo com regressões é superior a 0%.

Analisou-se também a normalidade da redução do consumo de H_2 , sendo também rejeitada essa hipótese. Assim, aplicou-se um teste Z para verificar a existência de redução de consumo de H_2 com as regressões, tendo como hipóteses as descritas na Equação 33 e na Equação 34.

$$H_0: \mu = 0 \quad \text{Equação 33}$$

$$H_1: \mu \neq 0 \quad \text{Equação 34}$$

Deste modo, não foi possível rejeitar a hipótese nula para um *p_value* de 0.8527, não sendo possível afirmar que existe um aumento ou redução de consumo de H_2 com as regressões, para um nível de significância de 5%.

Os testes de hipóteses efetuados encontram-se presentes de forma mais detalhada no Apêndice D, tendo sido também analisada a variância por tipo de ciclo, mostrando-se que excepcionalmente, a regressão dos ciclos urbanos, também demonstrou que o consumo equivalente em média é inferior ao consumo equivalente do algoritmo anterior, para um nível de significância de 5%.

Em suma, salienta-se que a regressão apresenta dificuldade em absorver o comportamento ótimo da FC, principalmente nas zonas de pedidos de potência mínimos e máximos, podendo ser uma situação problemática principalmente em ciclos mais exigentes, como é o caso da autoestrada. Para além disso não é possível garantir que o algoritmo antigo tem um consumo equivalente significativamente maior do que o obtido com as regressões, apesar da percentagem de redução ser considerada superior a zero.

5.2.3. Resultados da árvore de decisão

Utilizando a aplicação *Regression Learner* para treinar e validar modelos de *machine learning*, com os dados obtidos na DP, aquele que obteve melhores resultados em termos de RMSE foi a *Fine Tree*, uma árvore de decisão disponibilizada pela aplicação, cuja parametrização se encontra descrita na Figura 24.




Figura 24- Parametrização *Fine Tree*

O RMSE calculado para cada um dos tipos de ciclo, utilizando a árvore de decisão apresentada, mostraram-se muito mais satisfatórios do que as regressões não lineares descritas, sendo neste caso de 3745, 6295 e 4109.9, para ciclos urbanos, intercity e autoestrada, respetivamente. Os resultados mais detalhados de cada indicador encontram-se presentes na Tabela 20, Tabela 21 e Tabela 22 do Apêndice B.

Do mesmo modo que na análise das regressões, calculou-se o erro percentual médio relativo ao pedido de potência à FC, sendo este de 51%, 36% e 4%, para ciclos urbanos, intercity e autoestrada, respetivamente. Na Figura 25, Figura 26 e Figura 27 é visível a comparação dessa potência para cada um dos ciclos dos três tipos, sendo notória uma melhor aproximação, comparativamente com os resultados da regressão não linear.




Figura 25- Comparação da P_{FC} entre DP e árvore de decisão para ciclos urbanos




Figura 26- Comparação da P_{FC} entre DP e árvore de decisão para ciclos intercidade




Figura 27- Comparação da P_{FC} entre DP e árvore de decisão para ciclos autoestrada

Como forma de melhor compreender visualmente o efeito destes pedidos de potência à FC no SOC de cada rota, a Figura 28, Figura 29 e Figura 30 mostram também a comparação do estado de carga da bateria obtido com DP e com o controlo efetuado pela árvore de decisão.




Figura 28- Comparação do SOC entre DP e árvore de decisão para ciclos urbanos




Figura 29- Comparação do SOC entre DP e árvore de decisão para ciclos intercity




Figura 30- Comparação do SOC entre DP e árvore de decisão para ciclos autoestrada

Para averiguar se existe diferença entre o consumo equivalente do algoritmo antigo e do algoritmo com a árvore de decisão, considera-se um teste de hipóteses para amostras emparelhadas. Assim, é necessário verificar se a amostra segue uma distribuição normal, efetuando-se um teste de Shapiro-Wilk, que obteve um p_value de 3.8679×10^{-8} , inferior ao nível de confiança de 5%, sendo rejeitada a hipótese nula e concluindo-se que os dados não seguem uma distribuição normal.

O teste Z para amostras emparelhadas de dimensão superior a 30 será efetuado para estudar se o consumo equivalente médio do algoritmo anterior é superior ao consumo equivalente médio da árvore de decisão, para um nível de confiança de 5%. Consideram-se as hipóteses de teste da Equação 35 e da Equação 36.

$$H_0: \mu_D = 0 \quad \text{Equação 35}$$

$$H_1: \mu_D > 0 \quad \text{Equação 36}$$

Deste modo, o teste obteve um p_value de 2.4235×10^{-7} que por ser inferior ao nível de confiança de 0.05, é possível rejeitar a hipótese nula, considerando-se que a média do consumo equivalente do algoritmo antigo é superior à média do consumo equivalente da árvore de decisão.

Estudou-se também a variância na redução do consumo equivalente, que mostrou não seguir uma distribuição normal para um intervalo de significância de 5%, podendo ser efetuado um teste Z, cujas hipóteses se encontram descritas na Equação 37 e na Equação 38, analisar a existência de variação.

$$H_0: \mu = 10 \quad \text{Equação 37}$$

$$H_1: \mu > 10 \quad \text{Equação 38}$$

Obtendo-se o p_value de 0.000463, inferior ao nível de significância de 0.05, foi rejeitada a hipótese nula e é possível concluir que a redução do consumo com as árvores de decisão é superior a 10%.

Prosseguindo com uma análise da normalidade da redução do consumo de H_2 , a hipótese nula foi rejeitada, aplicando-se em seguida um teste Z para verificar a existência de redução de consumo de H_2 com as árvores de decisão. As hipóteses de teste estão descritas na Equação 39 e na Equação 40.

$$H_0: \mu = 0 \quad \text{Equação 39}$$

$$H_1: \mu \neq 0 \quad \text{Equação 40}$$

Assim, a hipótese nula foi rejeitada para um p_value de 0.671, o que não permite afirmar que existe um aumento ou redução de consumo de H_2 com as árvores de decisão, para um nível de significância de 5%.

Em suma, a estratégia que utiliza árvores de decisão mostra ser muito mais adequada para a extração das regras de controlo a partir da otimização efetuada, apresentando um bom desempenho principalmente em ciclos de autoestrada, sendo comprovado que em média é possível alcançar uma redução superior a 10% no consumo equivalente, sem que seja afetado o consumo de H_2 .

No entanto, tendo em conta a complexidade dos diversos modelos disponibilizados pela app *Regression Learner* do Matlab, foi efetuada uma análise prévia, de modo a compreender a exequibilidade da implementação deste modelo na ECU. Assim, verificou-se que devido a limitações de hardware, ainda não é possível processar a exigência computacional dos modelos de *supervised machine learning*, sendo que por isso, os testes de estrada apenas são possíveis de executar com a estratégia que utiliza as regressões não lineares.

5.3. Reconhecimento do Ciclo de Condução

5.3.1. Seleção e descrição do modelo

Os autores Lin e Li (2019) utilizaram na sua estratégia uma rede neuronal para efetuar o reconhecimento do ciclo de condução em tempo real. No entanto, pelo mesmo motivo referido na secção anterior, a exigência computacional de uma rede neuronal e as limitações de hardware do veículo, impossibilitaram a sua implementação na ECU. Em contrapartida, foi possível implementar uma árvore de decisão cuja reposta é 1, 2 ou 3, que significa, respetivamente, ciclo urbano, intercity e autoestrada.

A árvore foi construída utilizando a app *Classification Learner* do Matlab que após testar diversos modelos de *machine learning*, devolve a respetiva *accuracy*, possibilitando a seleção do modelo com melhor performance. Para a *Medium Tree* disponibilizada pela aplicação com os parâmetros apresentados na Figura 31, foi obtida uma *accuracy* de 97.8%, sendo a amostra de treino constituída por 15 ciclos urbanos, 15 ciclos intercity e 15 ciclos autoestrada.

Training Results
 Accuracy (Validation) 97.8%
 Total cost (Validation) 1
 Prediction speed ~1700 obs/sec
 Training time 1.162 sec

Model Type
 Preset: Medium Tree
 Maximum number of splits: 20
 Split criterion: Gini's diversity index
 Surrogate decision splits: Off

Figura 31- Parametrização e resultados da classificação com *Medium Tree*

5.3.2. Análise do tempo de tomada de decisão

A tomada de decisão relativa ao tipo de ciclo em que o veículo se encontra deverá ser efetuada em intervalos de tempo contantes que permitam refletir as características do ciclo, mantendo um equilíbrio com as exigências computacionais. O tamanho deste intervalo está diretamente relacionado com o espaço em memória que é necessário reservar na ECU para armazenar o histórico de valores da velocidade, sendo por isso fundamental estudar o seu dimensionamento e respetiva relação com os resultados obtidos em simulação.

Por este motivo, foram estudados os intervalos de 60, 120, 300 e 600 segundos na amostra constituída por nove ciclos (3 urbanos, 3 intercity e 3 autoestrada), com o objetivo de avaliar se a identificação do tipo de ciclo é efetuada de forma rápida e eficaz. Na Tabela 11 é apresentado para cada intervalo de tempo e para cada um dos ciclos em análise, a percentagem do ciclo que foi classificada como urbano, intercity ou autoestrada.

Tabela 11- Resultados da análise da variação do intervalo de tempo

Ciclo	Intervalo (s)	Resposta		
		% U	% I	% A
U1	600	100%	0%	0%
	300	100%	0%	0%
	120	100%	0%	0%
	60	91%	4%	5%
U2	600	100%	0%	0%
	300	100%	0%	0%
	120	84%	9%	7%
	60	73%	9%	18%
U3	600	100%	0%	0%
	300	100%	0%	0%
	120	95%	5%	0%
	60	87%	5%	8%
I1	600	0%	76%	24%
	300	0%	43%	57%
	120	0%	47%	53%
	60	8%	27%	66%

I2	600	37%	37%	27%
	300	18%	37%	45%
	120	22%	22%	56%
	60	26%	7%	67%
I3	600	0%	100%	0%
	300	14%	86%	0%
	120	28%	50%	22%
	60	41%	22%	36%
A1	600	0%	0%	100%
	300	0%	0%	100%
	120	0%	9%	91%
	60	0%	5%	95%
A2	600	0%	0%	100%
	300	0%	0%	100%
	120	0%	10%	90%
	60	0%	5%	95%
A3	600	0%	0%	100%
	300	0%	0%	100%
	120	0%	10%	90%
	60	0%	5%	95%

Para o caso dos ciclos urbanos e autoestrada, verificou-se que a *accuracy* da árvore de decisão é bastante elevada, sendo esta sempre superior a 70%. No entanto, de notar que para os intervalos de 600 e 300 segundos, essa classificação foi sempre 100% correta.

Os ciclos intercity, mostraram-se mais exigentes na sua classificação visto que a sua definição não é clara. É de esperar que um ciclo intercity apresente uma mistura entre as características de urbano e autoestrada, sendo por isso aceitável que a *accuracy* da sua classificação como intercity seja mais baixa.

Assim, visto que globalmente a *accuracy* para um intervalo de 300 segundos não é significativamente menor relativamente ao intervalo de 600 segundos e, tendo em conta a necessidade de reduzir o espaço em memória a ser utilizado na ECU, privilegia-se a estratégia que irá efetuar o reconhecimento do tipo de ciclo de 300 em 300 segundos. Para além disso, prevê-se que um intervalo mais reduzido irá prevenir situações de atraso na tomada de decisão em ciclos mais complexos.

5.3.3. Resultados do reconhecimento em rotas mistas

De modo a estudar o comportamento de todo o algoritmo, selecionaram-se 10 rotas onde o veículo efetuou um tipo de condução misto, classificou-se manualmente todos os ciclos e aplicou-se o algoritmo completo de tomada de decisão e pedido de potência. Desta forma, pretende-se analisar o comportamento do algoritmo em cenários mais complexos e semelhantes a uma situação real, avaliando o respetivo desempenho segundo a *accuracy*, que compara os tipos de ciclo identificados com a classificação manual. Os resultados são apresentados na Tabela 12.

Tabela 12- Resultados da análise da variação do intervalo de tempo em ciclos misto

Ciclo	Intervalo (s)	Accuracy
mix1	600	60%
	300	79%
	120	76%
	60	61%
mix2	600	53%
	300	55%
	120	54%
	60	53%
mix3	600	51%
	300	73%
	120	75%
	60	71%
mix4	600	54%
	300	62%
	120	55%
	60	51%
mix5	600	45%
	300	71%
	120	67%
	60	63%
mix6	600	62%
	300	82%
	120	63%
	60	56%
mix7	600	64%
	300	76%
	120	77%
	60	71%
mix8	600	53%
	300	79%
	120	70%
	60	66%
mix9	600	52%
	300	70%
	120	56%
	60	44%
mix10	600	67%
	300	60%
	120	47%
	60	41%

Assim, verificou-se que em ciclos mistos o intervalo de tempo de 300 segundos é aquele que apresenta melhor *accuracy* na maioria das rotas.

5.4. Implementação do Algoritmo Completo

De modo a compreender o efeito de toda a estratégia em rotas mais longas e semelhantes com a realidade, utilizaram-se os mesmos 10 ciclos mistos, analisando os indicadores que permitem a avaliação e validação do algoritmo, e relacionando-os também com o intervalo de tempo para a tomada de decisão, nomeadamente 600 e 300 segundos. Na Tabela 13 apresentam-se os resultados obtidos com as regressões não lineares definidas.

Tabela 13- Resultados do algoritmo completo com regressão em ciclos misto

Ciclo	Intervalo (s)	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
mix1	600	36.43	-11.03	-1.40	11.36	74.80	75.49
mix1	300	34.89	-11.35	-1.37	11.07	74.80	76.03
mix2	600	-69.56	12.03	2.15	8.40	70.40	45.20
mix2	300	-69.01	12.45	2.21	8.28	70.40	43.87
mix3	600	-18.12	9.63	1.49	7.67	72.00	67.07
mix3	300	-27.41	13.44	2.16	6.50	72.00	62.40
mix4	600	-69.87	12.62	2.26	9.69	80.00	37.01
mix4	300	-76.65	11.83	1.74	11.46	80.00	38.03
mix5	600	26.80	-10.44	-0.65	8.12	76.40	73.23
mix5	300	28.48	-11.89	-1.05	9.51	76.40	74.63
mix6	600	7.23	0.35	0.21	3.27	77.20	67.06
mix6	300	6.80	-0.75	0.12	3.51	77.20	67.83
mix7	600	5.90	3.49	0.24	3.24	72.80	70.60
mix7	300	7.58	2.61	0.08	4.14	72.80	71.31
mix8	600	47.66	-11.78	-0.29	3.60	78.40	77.98
mix8	300	53.43	-30.49	-2.09	8.00	78.40	91.25
mix9	600	-51.00	17.76	2.92	7.87	70.80	51.46
mix9	300	-56.14	20.59	2.54	10.48	70.80	47.13
mix10	600	-87.04	27.84	4.38	9.39	74.00	24.23
mix10	300	-81.50	28.05	3.51	12.73	74.00	22.20

Devido à dimensão reduzida da amostra, efetuou-se uma análise de variância com o teste não paramétrico de Wilcoxon, verificando-se que para um nível de significância de 5%, em nenhum dos intervalos é possível afirmar que existe uma redução de consumo equivalente superior a zero.

Tendo como abordagem para a extração de regras a árvore de decisão, é esperado que os resultados globalmente sejam melhores tendo em conta a maior capacidade deste modelo de absorver o comportamento da programação dinâmica. Na Tabela 14 são apresentados os resultados desta estratégia.

Tabela 14- Resultados do algoritmo completo com árvore de decisão em ciclos misto

Ciclo	Intervalo (s)	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
mix1	600	26.50	-20.21	-3.37	14.51	74.80	85.15
mix1	300	34.54	-16.48	-2.50	13.04	74.80	81.53
mix2	600	18.58	-3.17	-1.01	13.96	70.40	86.90
mix2	300	3.70	-3.31	-1.11	14.12	70.40	86.84
mix3	600	-23.43	-5.42	-2.59	16.53	72.00	82.53
mix3	300	-17.99	3.49	-1.65	16.13	72.00	71.54
mix4	600	-23.45	4.48	-1.27	18.15	80.00	54.71
mix4	300	-16.97	4.32	-0.96	17.28	80.00	56.56
mix5	600	25.97	-9.59	-2.68	14.37	76.40	69.09
mix5	300	29.53	-15.92	-3.51	15.25	76.40	76.24
mix6	600	30.74	-31.78	-2.85	10.15	77.20	88.83
mix6	300	29.74	-32.98	-3.29	11.24	77.20	89.22
mix7	600	48.00	-20.75	-3.40	12.98	72.80	90.56
mix7	300	48.18	-20.07	-2.86	11.75	72.80	90.54
mix8	600	57.73	-30.69	-3.39	12.75	78.40	90.16
mix8	300	60.44	-30.64	-3.33	12.58	78.40	90.21
mix9	600	-47.57	-7.69	-3.30	19.23	70.80	76.32
mix9	300	-105.52	16.02	-1.92	19.84	70.80	47.74
mix10	600	-95.29	14.13	-1.70	21.83	74.00	41.78
mix10	300	-55.52	25.16	0.10	20.61	74.00	22.74

No entanto, do mesmo modo que para a regressão, a análise de variância com o teste de Wilcoxon indicou que não existem evidências para afirmar que a redução do consumo é superior a zero, para um nível de significância de 5%.

5.5. Testes de Estrada

Com o objetivo de verificar o comportamento do veículo em situações reais com o algoritmo constituído pelas regressões não lineares, definiu-se uma rota mista na área metropolitana do Porto, que permitisse avaliar o desempenho do autocarro em diferentes cenários. Estes testes apenas foram efetuados com a estratégia da regressão não linear devido à impossibilidade de implementação da árvore de decisão na ECU, como referido no subcapítulo 5.2.3 Resultados da árvore de decisão.

Assim, partindo da CaetanoBus em Vila Nova de Gaia, o veículo efetuou a rota presente na Figura 32, sendo esperado que o algoritmo identifique os tipos de ciclo representados. No caso da parte do circuito entre a Ponte Infante Dom Henrique e o Castelo do Queijo, o autocarro efetuou todas as paragens sinalizadas na estrada, simulando a abertura e fecho de portas para entrada e saída de passageiros, como num ciclo tipicamente urbano.

De notar que as condições meteorológicas e de trânsito durante os testes de estrada não foram significativas para afetar a identificação do tipo de ciclo de condução esperado.




Figura 32- Rota para testes de estrada

O algoritmo foi testado em estrada duas vezes, tendo sido alterado o intervalo de tempo para a tomada de decisão entre 600 e 300 segundos. Desta forma, foi efetivamente possível avaliar quer a eficácia e eficiência da identificação do tipo de ciclo, quer os principais indicadores de avaliação da performance do algoritmo.

5.5.1. Avaliação do reconhecimento do ciclo de condução

O primeiro teste, efetuado com o intervalo de tomada de decisão de 600 segundos, encontra-se representado na Figura 33, sendo visível um claro atraso na tomada de decisão, que apresenta maior gravidade durante o percurso em autoestrada. Tendo em conta que o autocarro circulou em autoestrada cerca de 12 minutos, e visto que no início da mesma o percurso tinha sido identificado como intercedências com base nos 10 minutos anteriores, o ciclo só foi identificado como autoestrada apenas quando o veículo saiu da A20. Com isto, é espetável que a potência pedida à FC esteja subdimensionada durante todo o tempo que o veículo circulou em autoestrada.

Desta forma, verificou-se claramente a necessidade de tomada de decisão com mais frequência, de modo que o algoritmo consiga reagir mais rapidamente às mudanças no ciclo de condução. Assim, quantificando a capacidade de reconhecimento do tipo de ciclo de condução para o cenário descrito, verificou-se uma *accuracy* de 58%.




Figura 33- Teste de estrada com intervalo de 600 segundos

Posteriormente, foi testado o intervalo de 300 segundos, que já tinha sido identificado no capítulo 5.3.2 Análise do tempo de tomada de decisão como aquele cujos resultados se demonstraram mais adequados. Neste cenário verifica-se um atraso na identificação do tipo de ciclo muito mais reduzido, cujo impacto é menos significativo na *accuracy* final de 68%. Assim, a maior consequência está na utilização do tipo autoestrada mesmo após o veículo já ter saído desse tipo de ciclo. No entanto, seria de esperar que se o autocarro continuasse a rota durante mais alguns minutos, essa situação se alterasse para um ciclo mais adequado, em pouco tempo.




Figura 34- Teste de estrada com intervalo de 300 segundos

5.5.2. Comparação do algoritmo em simulação e em estrada

Com o objetivo de compreender o erro existente entre as simulações efetuadas na ferramenta criada para o efeito e o comportamento real do veículo, utilizaram-se os dados reais de potência total requerida, velocidade e potência de HVAC dos dois testes efetuados para simular o veículo com o algoritmo proposto, constituído pelas regressões não lineares.

Na Figura 35 e Figura 36 são apresentadas as comparações da potência pedida à FC no veículo e na simulação, para o intervalo de 600 e 300 segundos, respetivamente (para maior detalhe na comparação pode ser consultada a Figura 38 e a Figura 39 do Apêndice C). Nestes casos, é visível um maior desfasamento entre a potência real e simulada no início do ciclo, visto que o veículo já se encontrava ligado há alguns minutos quando se deu início à gravação da rota, sendo que a simulação considera que o início da rota coincide com o momento em que o veículo é ligado. Este facto irá ter impacto nos instantes em que a tomada de decisão do tipo de ciclo é efetuada, podendo assim estar ligeiramente desfasada devido ao momento em que o intervalo de tempo iniciou a contagem (isto é, quando o veículo foi ligado, para a situação real, ou no instante zero dos dados em estudo, para a simulação).

Para além disso, quando o veículo é ligado a potência pedida à FC é gradualmente incrementada até atingir o valor necessário, sendo isto visível no valor inicial da potência, que para o caso do veículo real já se encontra num nível mais elevado (visto que o autocarro foi ligado antes) e para o caso da simulação encontra-se no seu valor mínimo.




Figura 35- Comparação da P_{FC} no veículo e na simulação para intervalo de 600 segundos




Figura 36- Comparação da P_{FC} no veículo e na simulação para intervalo de 300 segundos

Adicionalmente, destaca-se também as diferenças visíveis devido ao desfasamento do momento em que o algoritmo identifica a entrada do veículo na autoestrada. Com o aumento da velocidade em autoestrada espera-se que os pedidos de potência à FC sofram um aumento mais acentuado, que irá ocorrer também desfasadamente (nos instantes 3600s e 3800s da Figura 35 e nos instantes 3300s e 3600s da Figura 36, aproximadamente).

Relativamente ao erro percentual médio no pedido de potência à FC, para o cenário com 600 segundos, este foi de 2.27% e para o cenário com 300 segundos foi de 2.31%.

5.5.3. Comparação do algoritmo proposto com o algoritmo atual

Tendo sido implementado no veículo de teste o algoritmo proposto, utilizou-se a ferramenta de simulação-ADVISOR utilizada pela empresa para simular o veículo com o algoritmo atual. Assim, será possível comparar o comportamento que foi obtido com o que seria de esperar pelo algoritmo atualmente utilizado pela CaetanoBus. Na Figura 40 e na Figura 41 do Apêndice C encontra-se o resultado da comparação dos dois algoritmos para os dois cenários testados.

Na Tabela 15 são apresentados os resultados dos principais indicadores para ambos os algoritmos, sendo na Tabela 16 efetuada a comparação dos mesmos. Conclui-se assim, que para ambos os testes de estrada efetuados, o algoritmo proposto foi capaz de reduzir o consumo equivalente juntamente com o consumo de H_2 , sem que o nível do SOC descesse para valores preocupantes, sendo possível obter uma melhor solução de distribuição de potência para a rota em causa.

Tabela 15- Resultados do algoritmo proposto e do atual, para os dois testes efetuados

Intervalo (s)	Algoritmo	Consumo equivalente (GGE)	Consumo de H ₂ (Kg/100km)	Rendimento (kWh/kg)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
600	Atual	3.55	6.54	17.14	21.30	76.00	66.42
	Proposto	3.21	4.57	18.68	4.32	76.00	47.97
300	Atual	4.10	5.94	17.45	19.24	63.2	64.33
	Proposto	3.46	4.49	18.72	3.53	63.2	50.61

Tabela 16- Comparação do algoritmo proposto com o atual, para os dois testes efetuados

Intervalo (s)	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)
600	9.7303	30.1442	8.2459
300	15.736	24.3614	6.7568

Em suma, tendo sido analisada e justificada a escolha do intervalo de 300 segundos para identificação do ciclo de condução, por ser aquela que apresenta resultados mais eficientes e eficazes, considera-se que foram obtidas melhorias significativas, quer ao nível do consumo equivalente, quer ao nível do consumo de H₂, sendo ainda alcançada uma melhoria no rendimento da FC. Destaca-se também uma grande diferença no desvio padrão da potência pedida à FC, que dá uma boa indicação de uma redução na degradação da mesma, visto que quanto menor é este indicador, mais homogênea é a dispersão dos valores.

No entanto, tendo em conta as análises de variância efetuadas, salienta-se que não é possível garantir sempre a existência de resultados positivos com o algoritmo que utiliza as regressões não lineares, visto que não foi comprovada a existência de diferenças significativas relativamente ao algoritmo anterior. Assim, seria fundamental efetuar testes de estrada num maior número de rotas para que a análise do algoritmo em veículos reais seja mais robusta.

6. CONCLUSÃO

Neste capítulo apresenta-se de forma sucinta todas as etapas do projeto e respetivos resultados, resumizando as principais conclusões obtidas. Destacam-se ainda as limitações do trabalho e respetivas sugestões de melhoria, para que se possa prosseguir com uma investigação futura.

6.1. Conclusões Finais

O trabalho desenvolvido enquadra-se com a mudança de paradigma ambiental, nomeadamente na utilização de veículos movidos a hidrogénio, tendo sido por isso fundamental contextualizar a sua pertinência e funcionamento. Partindo de uma análise técnica das características e topologias dos FCHEV, identificaram-se as necessidades de gestão do controlo do veículo ao nível das suas fontes de energia (bateria e FC), destacando as principais dificuldades, sendo este o foco de todo o projeto.

A revisão bibliográfica trata diversas estratégias já estudadas ao longo dos anos, que apresentam abordagens distintas para cenários que abrangem veículos elétricos e híbridos, cujo paradigma de gestão energética pode ser extrapolado para o caso específico dos FCHEV.

Assim, após a descrição do veículo em estudo e da análise dos requisitos e limitações enfrentadas, construiu-se a estratégia a implementar, baseando-a numa otimização com programação dinâmica, que se seguiu da respetiva extração de regras de controlo e posteriormente o reconhecimento do tipo de ciclo de condução com técnicas de *machine learning*. Todo o algoritmo foi estudado e implementado em Matlab, utilizando a função DPM do instituto ETH Zurich, as ferramentas de *machine learning* e o Matlab Coder, para fazer a transição do algoritmo para linguagem C, suportada pela ECU.

De modo a avaliar a performance do algoritmo, foram tidos em conta alguns indicadores que permitem analisar os consumos do veículo e a degradação da FC. Assim, considerou-se o consumo equivalente como a medida principal de desempenho, que avalia não só o consumo de H_2 , mas também o estado de carga da bateria. Para além disso, foi utilizado também o consumo de H_2 isoladamente, o rendimento da FC, o desvio padrão da potência pedida à FC e o SOC final da rota. O algoritmo foi avaliado e validado no final da implementação de cada fase, utilizando estes indicadores.

A programação dinâmica foi implementada utilizando a função DPM, cuja variável de controlo é a potência pedida à FC, as variáveis de estado são o SOC e a potência pedida à FC no instante anterior e a função objetivo é a minimização do consumo equivalente. Após a análise efetuada à variação da constante u , verificou-se que o controlo ótimo é mais adequado quando esta é igual a 0.2, para que a distancia do SOC ao valor desejável seja suficientemente penalizada, sem que seja perdida performance. Para tal, utilizaram-se 15 ciclos do tipo urbano, 15 ciclos do tipo intercity e 15 ciclos do tipo autoestrada, concluindo-se com uma análise de variância que, para um nível de significância de 5%, o consumo equivalente médio do algoritmo anterior é superior ao consumo equivalente médio da otimização, podendo-se também afirmar que a percentagem de redução conseguida pela DP é em média superior a 15%. Em contrapartida, não foi possível rejeitar a hipótese de que a redução do consumo de H_2 em média é igual a 0.

A partir do controlo ótimo obtido nos 45 ciclos em estudo, a extração das regras foi efetuada utilizando a *response surface methodology* com regressões não lineares e com os modelos de *machine learning* disponibilizados no Matlab, nomeadamente árvores de decisão. Ambas as estratégias foram testadas, sendo obtido o erro percentual médio para ciclos urbanos, intercity e autoestrada. No caso das regressões não lineares esses erros foram de 57%, 65% e 48%, e no caso da árvore de decisão os erros foram de 51%, 36% e 4%. Utilizando a representação gráfica dos pedidos de potência à FC é visível que as regressões apresentam maior dificuldade em absorver o comportamento ótimo, principalmente nas situações de pedidos de potência máximos e mínimos. Esta situação poderá implicar maiores problemas em cenários de maior exigência para o veículo, sendo que a potência pedida à FC será subdimensionada, levando a uma maior descarga da bateria. Para além disso, através das análises de variância efetuadas com 5% de significância, compreendeu-se que para o algoritmo com regressões, não é possível rejeitar a hipótese de que o consumo equivalente do novo algoritmo é em média igual ao consumo equivalente do algoritmo anterior. Pelo contrário, com as árvores de decisão, para 5% de significância é válida a conclusão de que a média do consumo equivalente da solução proposta é mais baixa do que no algoritmo anterior.

Analisando a variância da percentagem de redução do consumo equivalente, para um nível de significância de 5%, concluiu-se que, no caso das regressões em média essa redução é superior a 0, e no caso das árvores de decisão, em média a redução é superior a 10%. Por outro lado, em ambos os casos, a redução do consumo de H_2 não se mostrou significativamente diferente. No entanto, nesta fase foi possível compreender que a complexidade dos modelos de *machine learning* iriam impossibilitar a sua implementação na ECU, apesar de ser visível uma maior capacidade de aproximação da árvore de decisão. Esta situação poderá ser estudada futuramente para averiguar metodologias de simplificação do modelo.

Para o reconhecimento do tipo de ciclo de condução, do mesmo modo que foi referido anteriormente, não foi possível seguir a metodologia proposta por outros autores, devido à complexidade apresentada pelas redes neurais, no entanto prosseguiu-se com a estratégia, utilizando uma árvore de decisão para a classificação dos ciclos em urbano, intercity ou autoestrada. O ponto inicial desta abordagem exige que seja definido o intervalo de tempo no qual serão armazenados os dados para posteriormente tomar a decisão, sendo que para isso foi efetuado um estudo que avaliou a respetiva *accuracy* para intervalos de 600, 300, 120 e 60 segundos. Concluiu-se assim, que para 600 e 300 segundos os resultados eram muito precisos para ciclos urbanos e autoestrada, sendo os ciclos intercity aqueles que apresentam maior dificuldade por serem um misto dos vários tipos.

Com o intuito de testar a estratégia completa, utilizaram-se 10 ciclos com as características mistas, sendo primeiramente testado o reconhecimento do ciclo de condução para diferentes intervalos de tempo, obtendo-se também melhor *accuracy* para o intervalo de 300 segundos. Para além disso, avaliou-se também os diferentes indicadores quer para as regressões quer para a árvore de decisão, demonstrando-se que não existem evidências de que efetivamente em média existe redução do consumo equivalente.

Finalmente, definiu-se uma rota na área metropolitana do Porto, simulando-se os diferentes tipos de ciclos. Este teste de estrada foi realizado duas vezes, alterando o intervalo de tempo para 600 e 300 segundos. Com estes testes foi possível, não só testar a estratégia em cenários reais,

comparando-a com o algoritmo anterior, mas também validar a ferramenta de simulação desenvolvida para o efeito.

Em termos de reconhecimento dos ciclos de condução, o intervalo mais curto apresentou 68% de *accuracy*, contra os 58% do intervalo mais longo, concluindo-se novamente que um intervalo de 300 segundos é mais preciso. Relativamente à comparação dos resultados simulados e reais da rota em estudo, verificou-se um erro de simulação de aproximadamente 2.3% em ambos os testes, sendo este justificado principalmente pelo desfasamento entre o momento em que o veículo é ligado e o momento em que é iniciada a simulação, demonstrando-se que a ferramenta desenvolvida apresenta um desempenho muito satisfatório.

No que diz respeito à comparação com o algoritmo que atualmente se encontra nos veículos, foi possível realizar uma simulação no ADVISOR com os dados de velocidade e potência reais, de modo a comparar ambas as estratégias nas mesmas rotas. Assim, verificou-se que o algoritmo proposto com a decisão de 300 em 300 segundos, apresentou uma redução de 15.7% no consumo equivalente e 24.4% no consumo de H_2 , destacando-se ainda um aumento de 6.8% no rendimento. No entanto, não se pode afirmar com clareza que irão ser encontrados resultados sempre melhores em futuros testes, visto que a estratégia construída a partir das regressões não lineares não permite afirmar que os resultados são significativamente diferentes da estratégia anteriormente implementada no veículo.

Relativamente às estratégias já presentes na literatura, destaca-se que as principais contribuições deste projeto são no sentido de tornar os algoritmos mais flexíveis e adaptáveis a ciclos de condução em tempo real, sendo efetivamente testado em estrada, demonstrando a sua exequibilidade e dificuldades de implementação em veículos reais.

Em suma, a estratégia inicialmente proposta foi cumprida, tendo sido executadas todas as fases da mesma. Porém, destaca-se a extração de regras de controlo como a fase mais exigente de todo o processo, tendo se demonstrado que a utilização de regressões não lineares não permite garantir uma melhoria significativa e a utilização de árvores de decisão não é suportada pela ECU do veículo. Assim, salienta-se que o maior desafio do projeto está relacionado com o facto de estarem a ser utilizados dados de veículos reais, cuja diversidade é bastante elevada, exigindo ao algoritmo uma grande capacidade de adaptação, que deverá conseguir responder em tempo real na ECU do veículo.

6.2. Limitações e Investigação Futura

Devido à limitação do espaço temporal em que se realizou o presente projeto, existe um conjunto de fatores que poderiam ser aprofundados no estudo, de modo a tornar a estratégia mais robusta. Seguidamente apresentam-se as limitações do algoritmo, tendo em conta as necessidades da empresa e dos respetivos clientes, podendo estes fatores serem alvo de investigação futura:

- Não foi incluído como fator diferenciador entre rotas a elevação das mesmas, sendo este um parâmetro que irá influenciar o pedido total de potência do veículo;
- Do mesmo modo que no ponto anterior, e tendo em conta as diferenças climáticas entre os diversos países onde os autocarros operam, seria pertinente diferenciar entre ciclos com utilização intensiva de HVAC e com utilização residual, sendo este um dos fatores que mais peso apresenta no pedido de potência total do veículo;

- O cálculo do rendimento não está presente de forma direta na função objetivo da otimização, sendo que por isso este fator não está a ser alvo de melhorias, apesar da performance global do veículo estar a ser melhorada. Assim, sugere-se o estudo de uma nova função objetivo que dê também prioridade à otimização deste indicador;
- Relativamente à otimização e à necessidade de discretização das variáveis, optou-se por reduzir os intervalos, nomeadamente na variável de estado do pedido de potência à FC no instante anterior, de modo a reduzir as exigências computacionais, sendo que poderia ser efetuada uma análise mais exaustiva para perceber o impacto desta discretização;
- No conceito de consumo equivalente, tendo em conta que o fator de penalização mostrou ser um fator decisivo para determinar o comportamento da otimização devido à constante u , seria relevante um estudo mais intensivo da interação desta variável com os diversos tipos de ciclo e com o SOC inicial do veículo;
- Tendo em conta a dificuldade de quantificação da degradação da FC e sendo este um dos fatores mais importantes para a empresa, sugere-se a realização de um estudo para avaliar o efeito das variações do pedido de potência à FC no tempo de vida da mesma, sendo o desvio padrão um ponto de partida para este estudo;
- Devido à complexidade dos modelos de *machine learning*, não foi possível implementar a extração de regras com árvores de decisão e redes neurais na ECU, no entanto existe a possibilidade de estudar métodos de simplificação dos modelos, alterando por exemplo o tipo de dados, de modo a reduzir a memória necessária para os processar.

REFERÊNCIAS BIBLIOGRÁFICAS

- Briguglio, N., Andaloro, L., Ferraro, M., & Antonucci, V. (2011). Fuel Cell Hybrid Electric Vehicles. Em S. Soylu (Ed.), *Electric Vehicles - The Benefits and Barriers* (pp. 93–118). InTech.
- Caetanobus. (2019). *Está aí o H2.City Gold: o novo autocarro Caetano a hidrogénio*. Notícias. <https://caetanobus.pt/pt/esta-ai-o-h2-city-gold-o-novo-autocarro-caetano-a-hidrogenio/>
- CaetanoBus. (2021a). *e.Cobus*. Buses. <https://caetanobus.pt/pt/buses/e-cobus/>
- CaetanoBus. (2021b). *H2.City Gold*. Buses. <https://caetanobus.pt/pt/buses/h2-city-gold/>
- CaetanoBus. (2021c). *Quem Somos*. Apresentação. <https://caetanobus.pt/pt/company/who-we-are/>
- Caixeta, M. C. B. F., & Fabricio, M. M. (2018). Métodos e instrumentos de apoio ao codesign no processo de projeto de edifícios. *Ambiente Construído*, 18(1), 111–131. <https://doi.org/10.1590/s1678-86212018000100212>
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?- Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7, 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Chin, H. H., & Jafari, A. A. (2011). A selection algorithm for power controller unit of hybrid vehicles. *2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 324–328. <https://doi.org/10.1109/ITSC.2011.6082910>
- Comissão Europeia. (2018, Novembro 28). *Um Planeta Limpo para todos - Estratégia a longo prazo da UE para uma economia próspera, moderna, competitiva e com impacto neutro no clima*. <https://eur-lex.europa.eu/legal-content/PT/TXT/PDF/?uri=CELEX:52018DC0773&from=EN>
- Comissão Europeia. (2019, Dezembro). *Plano Nacional Energia e CLima (PNEC 2030)*. <https://www.portugalenergia.pt/setor-energetico/bloco-3/>
- Corbo, P., Migliardini, F., & Veneri, O. (2011). *Hydrogen Fuel Cells for Road Vehicles* (1st ed.). Springer London. <https://doi.org/10.1007/978-0-85729-136-3>
- Coutinho, C. P. (2011). *Metodologia de Investigação em Ciências Sociais e Humanas: Teoria e Prática*. Edições Almedina.
- Das, H. S., Tan, C. W., & Yatim, A. H. M. (2017). Fuel cell hybrid electric vehicles: A review on power conditioning units and topologies. *Renewable and Sustainable Energy Reviews*, 76(January 2016), 268–291. <https://doi.org/10.1016/j.rser.2017.03.056>
- Ehsani, M. (2012). Sustainable Transportation. Em *Electric, Hybrid, and Fuel Cell Vehicles* (pp. 5–25). Springer New York. https://doi.org/10.1007/978-1-0716-1492-1_795
- Ehsani, M., Gao, Y., Longo, S., & Ebrahimi, K. (2018). *Modern Electric, Hybrid Electric, and Fuel Cell Vehicles* (3rd ed.). CRC Press.
- Erjavec, J. (2013). *Hybrid, Electric & Fuel-Cell Vehicles* (2nd ed.). Delmar, Cengage Learning.
- Eurostat. (2022). *Greenhouse gas emission statistics - air emissions accounts*. Eurostat Statistics Explained. https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Greenhouse_gas_emission_statistics_-_air_emissions_accounts
- Fathabadi, H. (2018). Fuel cell hybrid electric vehicle (FCHEV): Novel fuel cell/SC hybrid power generation system. *Energy Conversion and Management*, 156(May 2017), 192–201. <https://doi.org/10.1016/j.enconman.2017.11.001>

- FuelCellWorks. (2020). Europe's Largest Hybrid Fuel Cell Bus Fleet and First Hydrogen Infrastructure for Public Transport Unveiled. *FuelCellsWorks*. <https://fuelcellworks.com/news/europes-largest-hybrid-fuel-cell-bus-fleet-and-first-hydrogen-infrastructure-for-public-transport-unveiled/>
- Gao, D., Jin, Z., & Lu, Q. (2008). Energy management strategy based on fuzzy logic for a fuel cell hybrid bus. *Journal of Power Sources*, 185(1), 311–317. <https://doi.org/10.1016/j.jpowsour.2008.06.083>
- Gao, Y., & Ehsani, M. (2001). Systematic Design of Fuel Cell Powered Hybrid Vehicle Drive Train. *SAE Technical Papers*, 724. <https://doi.org/10.4271/2001-01-2532>
- Grelle, C., Ippolito, L., Loia, V., & Siano, P. (2006). Agent-based architecture for designing hybrid control systems. *Information Sciences*, 176(9), 1103–1130. <https://doi.org/10.1016/j.ins.2005.07.018>
- Guzzella, L., & Sciarretta, A. (2010). Model-Based Supervisory Control for Energy Optimization of Hybrid-Electric Vehicles. Em W. S. Levine (Ed.), *The Control Handbook: Control System Applications* (2^aed, pp. 141–158). CRC Press.
- Hayes, J. G., & Goodarzi, G. A. (2018). *Electric Powertrain: Energy Systems, Power Electronics and Drives for Hybrid, Electric and Fuel Cell Vehicles* (1st ed.). John Wiley & Sons Ltd.
- He, B., & Yang, M. (2006). Optimisation-based energy management of series hybrid vehicles considering transient behaviour. *International Journal of Alternative Propulsion*, 1(1), 79. <https://doi.org/10.1504/IJAP.2006.010759>
- Hsu, R. C., Chen, S.-M., Chen, W.-Y., & Liu, C.-T. (2016). A Reinforcement Learning Based Dynamic Power Management for Fuel Cell Hybrid Electric Vehicle. *2016 Joint 8th International Conference on Soft Computing and Intelligent Systems (SCIS) and 17th International Symposium on Advanced Intelligent Systems (ISIS)*, 460–464. <https://doi.org/10.1109/SCIS-ISIS.2016.0104>
- Inci, M., Büyük, M., Demir, M. H., & İlbey, G. (2021). A review and research on fuel cell electric vehicles: Topologies, power electronic converters, energy management methods, technical challenges, marketing and future aspects. *Renewable and Sustainable Energy Reviews*, 137(March 2020), 110648. <https://doi.org/10.1016/j.rser.2020.110648>
- Jeon, S., Jo, S., Park, Y., & Lee, J. (2002). Multi-Mode Driving Control of a Parallel Hybrid Electric Vehicle Using Driving Pattern Recognition. *Journal of Dynamic Systems, Measurement, and Control*, 124(1), 141–149. <https://doi.org/10.1115/1.1434264>
- Jeong, K. S., Lee, W. Y., & Kim, C. S. (2005). Energy management strategies of a fuel cell/battery hybrid system using fuzzy logics. *Journal of Power Sources*, 145(2), 319–326. <https://doi.org/10.1016/j.jpowsour.2005.01.076>
- Kendall, K., & Pollet, B. G. (2012). Hydrogen and Fuel Cells in Transport. *Comprehensive Renewable Energy*, 4, 301–313. <https://doi.org/10.1016/B978-0-08-087872-0.00419-4>
- Koot, M. (2006). *Energy Management Strategies for Vehicular Electric Power Systems* [Phd Thesis, Technische Universiteit Eindhoven]. Eindhoven University of Technology research portal. <https://research.tue.nl/en/publications/energy-management-for-vehicular-electric-power-systems>.
- Li, Q., Chen, W., Li, Y., Liu, S., & Huang, J. (2012). Energy management strategy for fuel cell/battery/ultracapacitor hybrid vehicle based on fuzzy logic. *International Journal of Electrical Power and Energy Systems*, 43(1), 514–525. <https://doi.org/10.1016/j.ijepes.2012.06.026>

- Lin, X., & Li, H. (2019). Adaptive Control Strategy Extracted from Dynamic Programming and Combined with Driving Pattern Recognition for SPHEB. *International Journal of Automotive Technology*, 20(5), 1009–1022. <https://doi.org/10.1007/s12239-019-0095-7>
- Loenhout, S. A. K. (2007). *Real-time control for a Fuel Cell Hybrid Vehicle with the Equivalent Consumption Minimization Strategy* [Master Thesis, Technische Universiteit Eindhoven (TU/e)]. Eindhoven University of Technology research portal. <https://research.tue.nl/en/studentTheses/real-time-control-for-a-fuel-cell-hybrid-vehicle-with-the-equival>.
- Mehdiyev, N., Enke, D., Fettke, P., & Loos, P. (2016). Evaluating Forecasting Methods by Considering Different Accuracy Measures. *Procedia Computer Science*, 95, 264–271. <https://doi.org/10.1016/J.PROCS.2016.09.332>
- Musardo, C., Rizzoni, G., & Staccia, B. (2005). A-ECMS: An Adaptive Algorithm for Hybrid Electric Vehicle Energy Management. *Proceedings of the 44th IEEE Conference on Decision and Control*, 2005, 1816–1823. <https://doi.org/10.1109/CDC.2005.1582424>
- Paganelli, G., Ercole, G., Brahma, A., Guezennec, Y., & Rizzoni, G. (2001). General supervisory control policy for the energy optimization of charge-sustaining hybrid electric vehicles. *JSAE Review*, 22(4), 511–518. [https://doi.org/10.1016/S0389-4304\(01\)00138-2](https://doi.org/10.1016/S0389-4304(01)00138-2)
- Rajasekaran, S., & Pai, G. (2004). *Neural Networks, Fuzzy Logic and Genetic Algorithm: Synthesis and Applications*. PHI Learning Pvt. Ltd.
- REA. (2021). *Energia e Clima: Emissões de gases com efeito de estufa*. Agência Portuguesa do Ambiente. <https://rea.apambiente.pt/content/emissões-de-gases-com-efeito-de-estufa>
- Reddy, N. P., Padeloup, D., Zadeh, M. K., & Skjetne, R. (2019). An Intelligent Power and Energy Management System for Fuel Cell/Battery Hybrid Electric Vehicle Using Reinforcement Learning. *2019 IEEE Transportation Electrification Conference and Expo (ITEC)*, 1–6. <https://doi.org/10.1109/ITEC.2019.8790451>
- Ritchie, H., & Roser, M. (2020). *CO₂ and Greenhouse Gas Emissions*. OurWorldInData.org. <https://ourworldindata.org/co2-and-other-greenhouse-gas-emissions>
- Roberts, D. R., Bahn, V., Ciuti, S., Boyce, M. S., Elith, J., Guillera-Aroita, G., Hauenstein, S., Lahoz-Monfort, J. J., Schröder, B., Thuiller, W., Warton, D. I., Wintle, B. A., Hartig, F., & Dormann, C. F. (2017). Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure. *Ecography*, 40(8), 913–929. <https://doi.org/10.1111/ECOG.02881>
- Rodatz, P., Paganelli, G., Sciarretta, A., & Guzzella, L. (2005). Optimal power management of an experimental fuel cell/supercapacitor-powered hybrid vehicle. *Control Engineering Practice*, 13(1), 41–53. <https://doi.org/10.1016/j.conengprac.2003.12.016>
- Romano, G. (2021). *Energy Management Strategy of Fuel Cell Hybrid Electric Vehicles based on Dynamic Programming and Neural Networks* [Tese de mestrado, Politecnico di Torino]. Webthesis Libraries. <https://webthesis.biblio.polito.it/21130/>.
- Saib, S., Hamouda, Z., & Marouani, K. (2017). Energy management in a fuel cell hybrid electric vehicle using a fuzzy logic approach. *2017 5th International Conference on Electrical Engineering - Boumerdes (ICEE-B)*, 2017-Janua(1), 1–4. <https://doi.org/10.1109/ICEE-B.2017.8192197>
- Sorlei, I., Bizon, N., Thounthong, P., Varlam, M., Carcadea, E., Culcer, M., Iliescu, M., & Raceanu, M. (2021). Fuel cell electric vehicles: A Brief Review of Current Topologies and Energy Management Strategies. *Energies* 2021, 252(14). <https://doi.org/10.1088/1755-1315/785/1/012011>

- Sulaiman, N., Hannan, M. A., Mohamed, A., Ker, P. J., Majlan, E. H., & Wan Daud, W. R. (2018). Optimization of energy management system for fuel-cell hybrid electric vehicles: Issues and recommendations. *Applied Energy*, 228(July), 2061–2079. <https://doi.org/10.1016/j.apenergy.2018.07.087>
- Sulaiman, N., Hannan, M. A., Mohamed, A., Majlan, E. H., & Wan Daud, W. R. (2015). A review on energy management system for fuel cell hybrid electric vehicle: Issues and challenges. *Renewable and Sustainable Energy Reviews*, 52, 802–814. <https://doi.org/10.1016/j.rser.2015.07.132>
- Sundstrom, O. (2009). *Optimal control and design of hybrid-electric vehicles* [Tese de doutoramento, Chalmers University of Technology]. Research Collection ETH Zurich. <https://www.research-collection.ethz.ch/handle/20.500.11850/16642>.
- Sundstrom, O., & Guzzella, L. (2009a). Downloads: DPM Function. ETH Zurich. <https://idsc.ethz.ch/research-guzzella-onder/downloads.html>
- Sundstrom, O., & Guzzella, L. (2009b). A generic dynamic programming Matlab function. *18th IEEE International Conference on Control Applications*, 7, 1625–1630. <https://doi.org/10.1109/CCA.2009.5281131>
- Tao, F., Zhu, L., Ji, B., Si, P., & Fu, Z. (2020). Energy Management Strategy Using Equivalent Consumption Minimization Strategy for Hybrid Electric Vehicles. *Security and Communication Networks*, 1–8. <https://doi.org/10.1155/2020/6642304>
- Tazelaar, E., Veenhuizen, B., Jagerman, J., & Faassen, T. (2013). Energy Management Strategies for fuel cell hybrid vehicles; an overview. *2013 World Electric Vehicle Symposium and Exhibition (EVS27)*, 1–12. <https://doi.org/10.1109/EVS.2013.6915039>
- Tie, S. F., & Tan, C. W. (2013). A review of energy sources and energy management system in electric vehicles. *Renewable and Sustainable Energy Reviews*, 20, 82–102. <https://doi.org/10.1016/j.rser.2012.11.077>
- Torreglosa, J. P., Jurado, F., García, P., & Fernández, L. M. (2011). Hybrid fuel cell and battery tramway control based on an equivalent consumption minimization strategy. *Control Engineering Practice*, 19(10), 1182–1194. <https://doi.org/10.1016/j.conengprac.2011.06.008>
- Toyota. (2019). *CaetanoBus SA Lança H2.City Gold, o Autocarro Caetano a Hidrogénio com Tecnologia de Pilha de Combustível Toyota*. <https://www.toyota.pt/world-of-toyota/articles-news-events/2019/Autocarro-Caetano-a-hidrogenio-estreia-com-sistema-Toyota.json>
- Tran, D.-D., Vafaeipour, M., El Baghdadi, M., Barrero, R., Van Mierlo, J., & Hegazy, O. (2020). Thorough state-of-the-art analysis of electric and hybrid vehicle powertrains: Topologies and integrated energy management strategies. *Renewable and Sustainable Energy Reviews*, 119, 109596. <https://doi.org/10.1016/j.rser.2019.109596>
- U.S. Department of Energy. (2021). *Fuel Conversion Factors to Gasoline Gallon Equivalents*. <https://epact.energy.gov/fuel-conversion-factors>
- Ubong, E., & Gover, J. (2021). Fuel Cell-Powered HEV Design and Control. Em A. Elgowainy (Ed.), *Electric, Hybrid, and Fuel Cell Vehicles* (2nd ed., pp. 191–200). Springer New York. https://doi.org/10.1007/978-1-0716-1492-1_819
- United Nations. (2022a). *The Paris Agreement*. UNFCCC Sites and platforms. <https://unfccc.int/process-and-meetings/the-paris-agreement/the-paris-agreement>
- United Nations. (2022b). *What is the Kyoto Protocol?* UNFCCC Sites and platforms. https://unfccc.int/kyoto_protocol
- Wang, T., Li, Q., Wang, X., Qiu, Y., Liu, M., Meng, X., Li, J., & Chen, W. (2020). An optimized energy

- management strategy for fuel cell hybrid power system based on maximum efficiency range identification. *Journal of Power Sources*, 445(April 2019). <https://doi.org/10.1016/j.jpowsour.2019.227333>
- Wu, Y., & Zhang, L. (2017). Can the development of electric vehicles reduce the emission of air pollutants and greenhouse gases in developing countries? *Transportation Research Part D: Transport and Environment*, 51(2017), 129–145. <https://doi.org/10.1016/j.trd.2016.12.007>
- Xie, C., Quan, S., & Chen, Q. (2008). Control strategy of hybrid power system for Fuel Cell Electric Vehicle based on neural network optimization. *2008 IEEE International Conference on Automation and Logistics, September*, 753–757. <https://doi.org/10.1109/ICAL.2008.4636250>
- Yorke, D. (2021). *Hydrogen Fuel Cell Buses Scale Up in Europe*. Ballard. <https://blog.ballard.com/fuel-cell-buses-in-europe>
- Yue, M., Jemei, S., Gouriveau, R., & Zerhouni, N. (2019). Review on health-conscious energy management strategies for fuel cell hybrid electric vehicles: Degradation models and strategies. *International Journal of Hydrogen Energy*, 44(13), 6844–6861. <https://doi.org/10.1016/j.ijhydene.2019.01.190>
- Zhang, Y., Hao, D., Meng, X., & Wang, R. (2021). Control Strategy of Plug-in Fuel Cell Hybrid Vehicle Based on Drive Cycle Recognition. *IOP Conference Series: Earth and Environmental Science*, 772(1), 012015. <https://doi.org/10.1088/1755-1315/772/1/012015>

APÊNDICE A




Figura 37- Proposta de solução detalhada

APÊNDICE B

Tabela 17- Resultados da regressão para ciclos urbanos

Ciclos urbano	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
U1	9.27	-20.70	-1.58	2.79	68.4	73.35
U2	3.13	2.20	-0.02	3.48	73.2	72.46
U3	9.60	-25.82	-1.93	2.08	74.4	77.58
U4	15.02	-8.90	-0.69	2.34	73.2	70.62
U5	2.31	-0.48	0.22	3.39	72.8	60.14
U6	-1.44	1.30	0.14	3.01	68.8	76.13
U7	3.97	7.26	0.50	2.42	74.8	70.62
U8	16.91	-7.76	-0.51	1.70	74.4	75.22
U9	9.04	-121.42	-6.61	9.15	50.0	65.22
U10	1.55	6.78	1.06	1.96	74.0	74.02
U11	-5.36	15.58	1.67	5.60	77.0	66.21
U12	0.55	-3.48	-0.23	1.11	74.0	75.01
U13	18.59	-35.91	-1.99	1.85	70.8	82.47
U14	-10.59	-49.44	-3.39	1.69	74.8	78.00
U15	12.52	-44.58	-3.23	1.29	74.0	79.67

Tabela 18- Resultados da regressão para ciclos intercidades

Ciclos intercidades	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
I1	0.70	37.37	6.96	3.10	66.0	55.23
I2	-6.14	30.26	6.47	4.06	70.0	44.36
I3	-49.75	29.36	5.24	4.07	69.6	42.50
I4	2.22	21.17	3.47	2.35	71.2	51.11
I5	-6.55	21.03	3.16	2.32	72.0	48.09
I6	0.64	1.42	0.11	5.43	62.4	38.60
I7	26.35	-3.40	1.14	2.68	79.6	65.87
I8	4.54	-8.85	-0.61	3.08	71.2	75.58
I9	35.08	-91.04	-3.38	2.68	82.4	78.09
I10	25.96	-58.27	-1.97	2.11	76.8	70.42
I11	4.71	9.20	2.38	8.02	77.2	71.60
I12	17.46	-28.09	-2.45	5.40	75.6	85.65
I13	-3.09	12.16	2.03	2.92	70.0	60.95
I14	3.89	11.22	2.46	2.54	68.8	63.04
I15	-2.28	19.95	3.86	5.76	34.0	47.60

Tabela 19- Resultados da regressão para ciclos autoestrada

Ciclos autoestrada	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
A1	-2.80	24.08	4.49	5.95	66.0	41.00
A2	3.10	-3.89	0.14	3.14	70.8	58.41
A3	-18.45	45.39	7.57	11.08	73.2	20.36
A4	-5.21	45.44	8.58	6.84	70.0	41.02
A5	3.76	26.85	4.86	9.60	60.8	43.59
A6	20.20	24.79	5.63	7.56	78.0	50.68
A7	10.43	39.75	7.62	7.75	66.0	56.46
A8	13.85	-14.01	0.43	7.28	82.8	69.58
A9	0.54	23.62	4.34	7.89	44.4	37.27
A10	5.03	22.31	3.58	10.10	52.0	37.85
A11	5.86	47.18	8.30	9.32	57.2	44.57
A12	10.44	-3.38	0.39	8.08	68.0	59.02
A13	6.62	-8.24	-0.33	5.45	67.2	60.13
A14	-0.23	-41.86	-4.01	5.05	70.4	70.89
A15	9.77	10.86	2.61	4.43	74.4	65.02

Tabela 20- Resultados da árvore de decisão para ciclos urbanos

Ciclos urbanos	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
U1	22.51	-26.36	-2.51	7.78	68.4	74.74
U2	15.92	-0.92	-1.22	8.31	73.2	73.66
U3	10.41	-42.70	-2.87	5.54	74.4	82.06
U4	13.83	-15.00	-1.66	8.00	73.2	72.44
U5	7.64	-9.89	-1.08	7.89	72.8	61.72
U6	13.89	-1.27	-0.63	8.63	68.8	76.77
U7	15.23	4.22	-0.12	8.15	74.8	71.54
U8	24.20	-25.16	-1.85	6.68	74.4	84.06
U9	10.90	-158.84	-9.86	14.27	50.0	70.94
U10	-2.79	17.40	1.14	9.88	74.0	70.03
U11	14.51	3.83	-0.68	12.08	77.0	69.91
U12	10.95	10.04	-0.07	8.85	74.0	71.36
U13	24.21	-36.66	-2.37	6.79	70.8	82.58
U14	7.84	13.35	0.08	4.04	74.8	73.45
U15	19.38	-56.64	-3.88	5.03	74.0	81.93

Tabela 21- Resultados da árvore de decisão para ciclos intercidades

Ciclos intercidades	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
I1	12.89	24.37	-0.21	21.95	66.0%	59.34
I2	21.70	0.19	-0.50	15.00	70.0%	66.99
I3	26.08	3.25	-1.60	17.48	69.6%	71.87
I4	39.13	-11.69	-1.40	11.50	71.2%	73.44
I5	26.62	-9.94	-3.10	14.98	72.0%	71.14
I6	6.31	2.13	-0.94	14.08	62.4%	36.58
I7	21.61	14.57	-0.04	16.52	79.6%	49.53
I8	16.26	-61.17	-7.48	15.84	71.2%	89.54
I9	21.05	-7.23	-0.38	10.45	82.4%	64.12
I10	32.36	-86.22	-5.54	13.15	76.8%	74.74
I11	3.18	-9.17	-1.54	12.91	77.2%	82.98
I12	21.26	-10.53	-3.74	15.51	75.6%	76.10
I13	44.62	-6.97	-3.67	17.89	70.0%	73.80
I14	7.46	41.69	1.32	19.47	68.8%	47.65
I15	3.89	14.86	-0.12	19.25	34.0%	48.75

Tabela 22- Resultados da árvore de decisão para ciclos autoestrada

Ciclos autoestrada	Redução consumo equivalente (%)	Redução consumo de H ₂ (%)	Aumento Rendimento (%)	Desvio padrão P_{FC}	SOC inicial (%)	SOC final (%)
A1	2.03	5.85	0.69	8.83	66.0%	47.98
A2	5.48	4.61	0.39	12.61	70.8%	55.60
A3	4.31	1.66	0.51	9.96	73.2%	47.01
A4	7.08	17.09	0.54	19.40	70.0%	52.62
A5	5.82	11.38	1.27	13.93	60.8%	46.25
A6	40.45	9.59	1.06	17.22	78.0%	63.14
A7	10.99	52.69	7.10	17.01	66.0%	52.75
A8	13.49	24.10	2.43	21.02	82.8%	56.25
A9	6.03	17.90	1.59	16.29	44.4%	38.95
A10	8.86	15.35	1.51	13.56	52.0%	39.90
A11	9.89	41.22	4.52	18.65	57.2%	45.55
A12	12.47	31.08	2.68	16.40	68.0%	53.55
A13	11.73	-5.44	-3.61	18.30	67.2%	59.18
A14	11.10	54.72	4.08	9.41	70.4%	61.41
A15	16.18	39.52	2.63	16.17	74.4%	59.73

APÊNDICE C




Figura 38- Comparação do veículo com a simulação, para intervalo de 600 segundos




Figura 39- Comparação do veículo com a simulação, para intervalo de 300 segundos




Figura 40- Comparação do algoritmo proposto com o atual, para intervalo de 600 segundos




Figura 41- Comparação do algoritmo proposto com o atual, para intervalo de 300 segundos

APÊNDICE D

Análise de Variância - Significância de 5%											
Ciclo	Avaliação	Amostras	Dimensão	Shapiro test: p_value	Resposta	Normalidade	Teste	Hipóteses	p_value	Resposta	Decisão
Todos (consumo equivalente)	anterior vs DP	Emparelhadas	45	1.1065E-07	Rejeitar H0	Não	Z-test	H0: média_d=0 H1: média_d>0	3.0859E-08	Rejeitar H0	Consumo do anterior é em média superior à DP
	anterior vs regressão	Emparelhadas	45	4.22E-09	Rejeitar H0	Não	Z-test	H0: média_d=0 H1: média_d>0	0.2652	Não rejeitar H0	Consumo do anterior em média não é significativamente diferente da regressão
	anterior vs árvore	Emparelhadas	45	3.8679E-08	Rejeitar H0	Não	Z-test	H0: média_d=0 H1: média_d>0	2.4235E-07	Rejeitar H0	Consumo do anterior é em média superior à árvore
Redução consumo equivalente	DP	Isolada	45	0.003	Rejeitar H0	Não	Z-test	H0: média_d=15 H1: média_d>15	0.0028	Rejeitar H0	A redução do consumo com DP é em média superior a 15%
	regressão	Isolada	45	2.43E-04	Rejeitar H0	Não	Z-test	H0: média_d=0 H1: média_d>0	0.0106	Rejeitar H0	A redução do consumo com regressão é em média superior a 0%
	árvore	Isolada	45	0.0068	Rejeitar H0	Não	Z-test	H0: média_d=10 H1: média_d>10	4.63E-04	Rejeitar H0	A redução do consumo com árvore é em média superior a 10%
Redução consumo de H2	DP	Isolada	45	2.03E-06	Rejeitar H0	Não	Z-test	H0: média_d=0 H1: média_d>0	0.9167	Não rejeitar H0	Não se pode afirmar que existe diferença no consumo médio de H2
	regressão	Isolada	45	1.30E-03	Rejeitar H0	Não	Z-test	H0: média_d=0 H1: média_d>0	0.8527	Não rejeitar H0	Não se pode afirmar que existe diferença no consumo médio de H2
	árvore	Isolada	45	3.45E-05	Rejeitar H0	Não	Z-test	H0: média_d=0 H1: média_d>0	6.71E-01	Não rejeitar H0	Não se pode afirmar que existe diferença no consumo médio de H2
Urbanos (consumo equivalente)	anterior vs DP	Emparelhadas	15	0.9981	Não rejeitar H0	Sim	t-test	H0: média_d=0 H1: média_d>0	3.0859E-08	Rejeitar H0	Consumo do anterior é em média superior à DP
	anterior vs regressão	Emparelhadas	15	0.4438	Não rejeitar H0	Sim	t-test	H0: média_d=0 H1: média_d>0	0.0039	Rejeitar H0	Consumo do anterior é em média superior à regressão
	anterior vs árvore	Emparelhadas	15	0.5578	Não rejeitar H0	Sim	t-test	H0: média_d=0 H1: média_d>0	0.000047527	Rejeitar H0	Consumo do anterior é em média superior à árvore
Interdidades (consumo equivalente)	anterior vs DP	Emparelhadas	15	0.0299	Rejeitar H0	Não	Wilcoxon	H0: mediana=0 H1: mediana>0	0.000030518	Rejeitar H0	A mediana do consumo anterior é superior à mediana do consumo na DP
	anterior vs regressão	Emparelhadas	15	0.00010362	Rejeitar H0	Não	Wilcoxon	H0: mediana=0 H1: mediana>0	0.2106	Não rejeitar H0	A mediana do consumo anterior não é significativamente diferente da mediana do consumo da DP
	anterior vs árvore	Emparelhadas	15	0.0186	Rejeitar H0	Não	Wilcoxon	H0: mediana=0 H1: mediana>0	0.000030518	Rejeitar H0	A mediana do consumo anterior é superior à mediana do consumo da árvore
Autoestrada (consumo equivalente)	anterior vs DP	Emparelhadas	15	1.0874E-06	Rejeitar H0	Não	Wilcoxon	H0: mediana=0 H1: mediana>0	0.000030518	Rejeitar H0	A mediana do consumo anterior é superior à mediana do consumo na DP
	anterior vs regressão	Emparelhadas	15	0.0002436	Rejeitar H0	Não	Wilcoxon	H0: mediana=0 H1: mediana>0	0.0535	Não rejeitar H0	A mediana do consumo anterior não é significativamente diferente da mediana do consumo da DP
	anterior vs árvore	Emparelhadas	15	1.2244E-06	Rejeitar H0	Não	Wilcoxon	H0: mediana=0 H1: mediana>0	0.000030518	Rejeitar H0	A mediana do consumo anterior é superior à mediana do consumo da árvore

Figura 42- Análises de variância