

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE ELETRÔNICA
BACHARELADO EM ENGENHARIA ELÉTRICA**

LENON DINIZ SEIXAS

**OTIMIZAÇÃO DO CONTROLADOR FUZZY PARA
GERENCIAMENTO DE SISTEMAS HÍBRIDOS DE
ARMAZENAMENTO DE ENERGIA**

TRABALHO DE CONCLUSÃO DE CURSO

PONTA GROSSA

2019

LENON DINIZ SEIXAS

**OTIMIZAÇÃO DO CONTROLADOR FUZZY PARA
GERENCIAMENTO DE SISTEMAS HÍBRIDOS DE
ARMAZENAMENTO DE ENERGIA**

Trabalho de Conclusão de Curso apresentado(a) como requisito parcial à obtenção do título de Bacharel(a) em Engenharia Elétrica, do Departamento Acadêmico de Eletrônica, da Universidade Tecnológica Federal do Paraná.

Orientador(a): Prof(a). Dr(a). Fernanda Cristina Correa

PONTA GROSSA

2019



TERMO DE APROVAÇÃO

OTIMIZAÇÃO DO CONTROLADOR FUZZY PARA GERENCIAMENTO DE SISTEMAS HÍBRIDOS DE ARMAZENAMENTO DE ENERGIA

por

LENON DINIZ SEIXAS

Este Trabalho de Conclusão de Curso foi apresentado em 04 de Dezembro de 2019 como requisito parcial para a obtenção do título de Bacharel(a) em Engenharia Elétrica. O(A) candidato(a) foi arguido(a) pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof(a). Dr(a). Fernanda Cristina Correa
Orientador(a)

Prof(a). Dr(a). Hugo Valadares Siqueira
Membro Titular

Prof(a). Dr(a). Max Mauro Dias Santos
Membro Titular

Prof(a). Dr(a). Nome do(a) Responsável
Responsável pelos TCC

Prof(a). Dr(a). Nome do(a) Coordenador(a)
Coordenador(a) do Curso

Dedico este trabalho aos meus entes mais
próximos pelos momentos de ausência.

AGRADECIMENTOS

Este trabalho não seria finalizado sem a ajuda de diversas pessoas e instituições às quais presto minha homenagem. Certamente esses parágrafos não irão atender a todas as pessoas que fizeram parte dessa importante fase de minha vida. Portanto, desde já peço desculpas àquelas que não estão presentes entre estas palavras, mas elas podem estar certas que fazem parte do meu pensamento e de minha gratidão.

A minha família e namorada, pelo carinho, incentivo e total apoio em todos os momentos da minha vida.

A minha orientadora, que me mostrou os caminhos a serem seguidos e pela confiança depositada.

A todos os professores e colegas do departamento, que ajudaram de forma direta ou indireta na conclusão deste trabalho.

A Universidade Tecnológica Federal do Paraná (UTFPR), pela ótima estrutura.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelo apoio financeiro.

Enfim, a todos os que de alguma forma contribuíram para a realização deste trabalho.

É uma grande cena teatral que todos nós
participamos, todos desempenhamos um
papel

Nunca se sabe a pura razão e o seu *grand*
finale

Nos elevamos em emoções e jogamos o
jogo, quer queiramos ou não

(GIRARD, Simon, 2014)

RESUMO

SEIXAS, Lenon Diniz. **Otimização do controlador fuzzy para gerenciamento de sistemas híbridos de armazenamento de energia**. 2019. 92 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica) – Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2019.

A necessidade humana de locomoção e transporte é eterna e inevitável, assim como fazê-la de forma rápida, segura e eficiente. Os interesses e investimentos nesse setor são infindáveis, tendo no último século quebrado barreiras antes nunca imaginadas. Atualmente, associado a consciência ambiental, o desafio é aumentar a eficiência de forma limpa, e para isso, investe-se em veículos elétricos (EV) e híbridos (HEV). Um dos grandes gargalos do desempenho do EV é a autonomia da bateria e, sabendo-se disso, neste trabalho é proposto um controlador fuzzy para realizar o gerenciamento da potência do sistema de armazenamento de energia que objetiva aumentar autonomia de um sistema híbrido de armazenamento, composto por supercapacitor (SC) e bateria. Quando se associa um SC a uma bateria, a complexidade do gerenciamento de potência aumenta consideravelmente, sendo então necessário determinar a correta distribuição de potência entre os dispositivos de armazenamento de forma a ter maior eficiência do sistema, e poupando a bateria de grandes esforços. De forma a obter a máxima eficiência do controlador fuzzy, técnicas de inteligência computacional são comparadas entre si como método de sintonia dos parâmetros fuzzy, sendo estas: algoritmo genético (GA) e otimização por enxame de partículas (PSO). Os controladores encontrados por cada heurística são comparados entre si e com um sistema de distribuição de potência realizado por uma lógica que utiliza limitadores. Os controladores fuzzy mostraram que conseguiram aumentar a autonomia da bateria diante do método proposto, comprovando-se como um método eficiente de controle de gerenciamento de potência. Comparando-se o sistema híbrido de armazenamento de energia composto de SC e bateria proposto a um sistema composto somente por bateria, foi obtido um aumento de autonomia de 14,28%, confirmando que associá-los aumenta a eficiência do sistema, além de aumentar a vida-útil da bateria, reduzir o volume do banco, entre outros ganhos.

Palavras-chave: fuzzy. sistemas de armazenamento de energia. algoritmo genético. enxame de partículas. veículos elétricos.

ABSTRACT

SEIXAS, Lenon Diniz. **Fuzzy controller optimization for hybrid energy storage system management**. 2019. 92 p. Final Coursework (Bachelor's Degree in Electrical Engineering) – Federal University of Technology – Paraná. Ponta Grossa, 2019.

The human need for mobility and transportation is eternal and unavoidable, as is doing so quickly, safely and efficiently. The interests and investments in this sector are endless, over the last century having broken barriers never before imagined. Currently, associated with environmental awareness, the challenge is to increase efficiency in a clean way, and for that, invests in electric (EV) and hybrid (HEV) vehicles. One of the big bottlenecks of EV performance is battery autonomy, and knowing this, this work proposes a fuzzy controller to perform power management of the energy storage system that aims to increase the autonomy of a hybrid storage system, composed of supercapacitor (SC) and battery. When associating an SC with a battery, the complexity of power management increases considerably, so it is necessary to determine the correct power distribution between storage devices for greater system efficiency and to save the battery from strenuous effort. In order to obtain the maximum efficiency of the fuzzy controller, computational intelligence techniques are compared with each other as a fuzzy parameter tuning method, namely: genetic algorithm (GA) and particle swarm optimization (PSO). The controllers found by each heuristic are compared to each other, and also compared to a power distribution system performed by a logic that uses limiters. The fuzzy controllers have shown that they have been able to increase the battery autonomy compared to the proposed method, proving to be an efficient power management control method. Comparing the hybrid SC and battery energy storage system proposed to a battery-only system, an autonomy increase of 14.28 % was obtained, also proving that associating an SC to a battery increases the system efficiency, in addition to extending battery life, reducing bank volume, among other gains.

Keywords: fuzzy. energy storage systems. genetic algorithm. particle swarm optimization. electric vehicles.

LISTA DE ALGORITMOS

Algoritmo 1 – Algoritmo genético	36
Algoritmo 2 – Otimização por enxame de partículas	39

LISTA DE ILUSTRAÇÕES

Figura 1 – Estruturas de HESS de bateria e SC com conversores CC-CC	24
Figura 2 – Modelos de bateria e SC	25
Figura 3 – Comparação lógica binária e fuzzy	28
Figura 4 – Diagrama esquemático controlador fuzzy	30
Figura 5 – Exemplos de seleção	34
Figura 6 – Exemplo de recombinação: crossover de 1 ponto aleatório	34
Figura 7 – Exemplo de mutação: alteração de gene	35
Figura 8 – Cálculo vetorial	38
Figura 9 – Planta elaborada no ambiente Simulink	42
Figura 10 – Típica característica de descarga	44
Figura 11 – Estrutura desacoplada com dois conversores CC-CC	46
Figura 12 – Transitório de potência demandada	47
Figura 13 – Controlador lógico fuzzy	49
Figura 14 – Diagrama de blocos PMC utilizando fuzzy	51
Figura 15 – Diagrama de blocos PMC utilizando limitador	52
Figura 16 – Distribuição de potência com utilização do limitador	53
Figura 17 – Dispersão de <i>fitness</i> proposta GA_126	58
Figura 18 – Resultados proposta GA_126	59
Figura 19 – Dispersão de convergência proposta GA_126	60
Figura 20 – Dispersão de <i>fitness</i> proposta GA_175	60
Figura 21 – Resultados proposta GA_175	61
Figura 22 – Dispersão de convergência proposta GA_175	61
Figura 23 – Comparação 126 e 175 parâmetros	62
Figura 24 – Dispersão de <i>fitness</i> proposta PSO_126	63
Figura 25 – Resultados proposta PSO_126	64
Figura 26 – Dispersão de <i>fitness</i> proposta 175	64
Figura 27 – Resultados proposta PSO_175	65
Figura 28 – <i>Boxplot</i> propostas PSO	65
Figura 29 – Comparação de autonomia entre os controladores encontrados	67
Figura 30 – Distribuição de potência entre os dispositivos	68
Figura 31 – Comparação de autonomia HESS vs ESS	69
Figura 32 – Funções de pertinência GA	70
Figura 33 – Superfícies do conjunto de regras GA	71
Figura 34 – Funções de pertinência PSO	72
Figura 35 – Superfícies do conjunto de regras PSO	73

LISTA DE TABELAS

Tabela 1 – Comparação bateria e SC	21
Tabela 2 – Estado de desenvolvimento	23
Tabela 3 – Funções de pertinência	31
Tabela 4 – Funções de pertinência	48
Tabela 5 – Limites de busca para Proposta 126	51
Tabela 6 – Parâmetros das funções de pertinência da Proposta 126	51
Tabela 7 – Comparação dos maiores <i>fitness</i>	66
Tabela 8 – Comparação das maiores medianas	66
Tabela 9 – Mapeamento das possibilidades de regras	89
Tabela 10 – Limites proposta 175 parâmetros	90

LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

SIGLAS

CAES	armazenamento de energia de ar comprimido (do inglês <i>Compressed Air Energy Storage</i>)
CI	inteligência computacional (do inglês <i>Computational Intelligence</i>)
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
EM	motor elétrico (do inglês <i>Electric Motors</i>)
ESS	sistema de armazenamento de energia (do inglês <i>Energy Storage System</i>)
EV	veículo elétrico (do inglês <i>Electric Vehicle</i>)
FC	célula combustível (do inglês <i>Fuel Cell</i>)
FLC	controlador lógico fuzzy (do inglês <i>Fuzzy Logic Controller</i>)
GA	algoritmo genético (do inglês <i>Genetic Algorithm</i>)
HESS	sistema de armazenamento híbrido de energia (do inglês <i>Hybrid Energy Storage System</i>)
HEV	veículo elétrico híbrido (do inglês <i>Hybrid Electric Vehicle</i>)
ICE	motor a combustão interna (do inglês <i>Internal Combustion Engine</i>)
PMC	controle de gestão de potência (do inglês <i>Power Management Control</i>)
PSO	otimização por enxame de partícula (do inglês <i>Particle Swarm Optimization</i>)
SC	supercapacitor
SMES	armazenamento de energia de supercondutores eletromagnéticos (do inglês <i>Superconducting Magnetic Energy Storage</i>)
SOC	estado de carga (do inglês <i>State of Charge</i>)
UTFPR	Universidade Tecnológica Federal do Paraná

SUMÁRIO

1	INTRODUÇÃO	13
1.1	VEÍCULOS ELÉTRICOS	14
1.1.1	Sistemas de armazenamento de energia	15
1.2	OBJETIVOS	17
1.2.1	Objetivos gerais	17
1.2.2	Objetivos específicos	17
1.3	ORGANIZAÇÃO DO TRABALHO	17
2	REVISÃO DA LITERATURA	19
2.1	SISTEMA DE ARMAZENAMENTO DE ENERGIA	19
2.2	GERENCIAMENTO DO SISTEMA HÍBRIDO DE ARMAZENAMENTO DE ENERGIA	27
2.2.1	Fuzzy: Sistemas Nebulosos	27
2.2.1.1	Controlador Fuzzy	29
2.2.2	Meta-heurísticas bioinspiradas	31
2.2.2.1	Algoritmo Genético	32
2.2.2.2	Otimização por enxame de partículas	36
2.2.2.3	Exemplos de aplicações	39
3	DESENVOLVIMENTO	41
3.1	DESENVOLVIMENTO DO MODELO MATEMÁTICO DA PLANTA	41
3.1.1	Configuração dos dispositivos de armazenamento	42
3.1.2	Topologia do sistema de armazenamento híbrido de energia	45
3.2	CONTROLE DO GERENCIAMENTO DE POTÊNCIA	48
3.2.1	Controlador Fuzzy	48
3.2.2	Algoritmo genético	53
3.2.3	Otimização por enxame de partículas	56
4	RESULTADOS E DISCUSSÃO	57
4.1	ALGORITMO GENÉTICO	58
4.2	OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS	63
4.3	ANÁLISE GERAL DE DESEMPENHO	66
4.4	CONTROLADORES FUZZY	69
5	CONCLUSÕES E PERSPECTIVAS	74
	REFERÊNCIAS	77
	APÊNDICES	88
	APÊNDICE A – APÊNDICE A	89
A.1	TABELAS FLC	89

1 INTRODUÇÃO

Nas últimas décadas a preocupação ambiental tornou-se um tópico discutido mundialmente, dado a percepção de que vivemos em um ecossistema frágil e interdependente. Já no início da década de 70, com a criação da UNEP (*United Nations Environment Programme*), é começado a colocar em prática essa responsabilidade social e consciência coletiva sobre o uso saudável e sustentável do planeta e seus recursos (ONUBR, 2019).

O engajamento com esse tema cresceu de forma lenta. O movimento ambiental em si começou séculos atrás em resposta à industrialização e, mesmo com tratados e políticas, as grandes potências mundiais demoram a promover ações. É vista a preocupação com a qualidade do ar aumentar somente na década de 90. Diminuir emissão de gases é o então objetivo assinado pelos países da ONU em Kyoto, 1997. A partir desse momento, inicia-se uma busca por formas de energia limpa e equipamentos com maior eficiência energética, porém, até hoje a Agência Europeia do Ambiente (*European Environment Agency*) pontua a combustão em transporte rodoviário como uma das partes significativas da poluição atmosférica (EEA, 2014).

A indústria automobilística é um dos maiores entre os setores industriais e está relacionado diretamente com o desenvolvimento da sociedade, tal qual a importância da necessidade de mobilidade. Nos EUA, o carro a gasolina começa a dominar esse mercado por volta de 1920, devido ao seu menor custo e incentivo governamental – utilizando as novas reservas de petróleo descobertas (CLIMAINFO, 2019). Porém, quase um século depois, a alta dependência dos recursos originários do petróleo acabou criando uma situação de debilidade, pois sendo um recurso não renovável, gera aumentos de preço e conflitos internacionais (CORRÊA, 2013). Assim, a indústria de veículos elétricos começa a tomar forma e espaço no mercado.

A partir de meados de 1980, diversas leis e normas para controle de emissões começam a ser instauradas devido à grande frota de veículos, mas definitivamente a partir de 2017, países do mundo todo começam a promulgar leis banindo veículos a combustíveis fósseis. Em países como China, França, Noruega e Inglaterra, a partir de 2040, não será permitido venda de veículos a gasolina e diesel.

Apesar das previsões jurídicas, analisando a questão mais a fundo, é notório

que uma alta emissão de poluentes a partir de plantas geradoras pode contrabalançar os lucros em substituir motores a combustão por elétricos. É uma análise importante, visto que poluição por transporte tem escala local, enquanto que por geração energética é regional. Segundo Buekers et al. (2014), países europeus que possuem uma geração menos poluente podem ganhar milhões de Euro/ano evitando custos externos definidos por Euro/tonelada de poluente emitido. Entretanto, países que não a possuem podem realmente não se beneficiar com a troca.

A situação ambiental é motivo de debate mundial, não somente pela razão ambientalista em si, mas também pelo impacto econômico e social que as mudanças geradas por esse movimento podem apresentar. De mesmo modo, o sucesso do veículo elétrico é interdependente também de forças econômicas, como se comprovou historicamente.

Devido a literatura sobre o assunto ser encontrada majoritariamente em língua inglesa, os termos serão tratados utilizando sua sigla original.

1.1 VEÍCULOS ELÉTRICOS

Os primeiros veículos movidos a bateria surgiram no século XIX, sendo que, por volta de 1890, William Morrison construiu o primeiro carro elétrico de sucesso, capaz de alcançar 22 km/h (MCCLELLAN, 1963) (MATULKA, 2014). No início do século XX, um terço de todos os veículos nas ruas dos Estados Unidos eram elétricos, atingindo o auge da sua popularidade. Em 1901, Ferdinand Porsche cria o primeiro veículo elétrico híbrido (HEV - do inglês *hybrid electric vehicle*), alimentado a gasolina e bateria. Muitos inventores da época, como Thomas Edison, percebem a alta demanda e começam a trabalhar no desenvolvimento da tecnologia (MATULKA, 2014).

Em 1908, Henry Ford lança o Model T, movido a gasolina, simples e barato. Em 1913, esse modelo começa a dominar o mercado devido a implementação da linha de montagem, diminuindo ainda mais o seu custo. Nos anos seguintes, com as novas reservas de petróleo, tem-se a decadência do veículo elétrico, tendo por volta de 1935 completamente desaparecido (MATULKA, 2014).

Na década de 70, o carro elétrico volta a tomar certa popularidade: o preço da gasolina sobe muito; a NASA utiliza EV na lua; Sebring-Vanguard se torna a sexta maior fabricante de carro americana, vendendo mais de 2000 CitiCars - um EV com-

pacto. Mas logo o interesse esvanece devido ao seu baixo desempenho e alcance de autonomia, voltando somente a partir do fim da década de 90, com o lançamento do Toyota Prius - primeiro HEV produzido em massa.

No início do novo milênio foi investido em infraestrutura e tecnologias para tornar o uso do veículo elétrico (do inglês *Electric Vehicle*) (EV), acessível. A pesquisa em torno do desenvolvimento da bateria, um dos principais problemas do EV, trouxe melhor performance com a tecnologia íon-lítio, e investimentos do governo auxiliaram em reduzir o seu custo em 50 por cento. Em termos de infraestrutura, segundo Maltulka (2014), em 2014 existiam mais de 20000 postos de carregamentos em 8000 localidades nos Estados Unidos.

Vendo esse novo cenário, em 2017, montadoras como BMW, General Motors partem definitivamente a investir em EVs. Segundo climainfo (2019), espera-se que EVs tornem-se a tendência de mercado até o início da próxima década. A Tesla Motors, empresa que se destacou neste crescente mercado, apresenta em 2013 o Model S, com carga para mais de 200 milhas e com um supercarregador prometendo carregar em uma hora.

No decorrer da história percebe-se como o tipo de motor e a autonomia trazida pelo sistema de armazenamento de energia (ESS - do inglês *energy storage system*) foram cruciais para o sucesso ou fracasso da experiência elétrica dos automóveis. A autonomia está diretamente ligada ao rendimento e custo-benefício da transição combustão-elétrico, e desse modo, alveja-se a sua máxima eficiência.

Em comparação aos veículos convencionais, EVs apresentam uma fonte de potência mais eficiente, maior torque e maior alcance de velocidade, além de não consumir energia quando estacionado (HANNAN et al., 2017). Para reduzir mais ainda o desperdício de energia fora do processo de aceleração, são utilizados freios regenerativos e geradores termoelétricos (HANNAN et al., 2017) (CROLLA; MASHADI, 2011) (HUSAIN, 2011) (MI; MASRUR; GAO, 2011).

1.1.1 Sistemas de armazenamento de energia

Existem diversos tipos de EVs, comumente definidos pelo tipo de ESS, tais como: veículos elétricos híbridos, veículos elétricos a bateria, veículos elétricos híbridos plug-in, veículos elétricos fotovoltaicos, e veículos elétricos a célula de combustível

(HUSAIN, 2011) (MI; MASRUR; GAO, 2011).

O principal tipo de uso dos automóveis é em ciclos urbanos, onde os veículos desenvolvem repetidamente séries de acelerações e paradas, porém, com baixa velocidade média. Essa condição de alta aceleração e desaceleração constante geram, segundo Eckert et al. (2018), uma alta demanda ao sistema de armazenamento de energia, exigindo muito, principalmente, quando este possui somente um conjunto de bateria, uma vez que elas possuem densidade de potência baixa. Devido a isso, é necessário um maior número de células para fornecer a tração requerida de um motor, aumentando o tamanho da bateria e a massa do veículo.

Uma das formas de resolver esse problema e fazer o gerenciamento da energia com maior eficiência, é associar a bateria a um supercapacitor (SC). Um sistema de armazenamento híbrido de energia (do inglês *Hybrid Energy Storage System*) (HESS), pode combinar diferentes fontes de energias em um sistema, tais como: baterias e células de combustíveis, SCs e baterias (HANNAN et al., 2017). Um HESS com bateria e SC, segundo Eckert et al. (2018), traz as seguintes vantagens:

- Redução de estresse na bateria;
- Aumento da vida-útil da bateria;
- Redução do tamanho e custo da bateria;
- Melhoria do gerenciamento de potência;
- SCs recuperam maior energia regenerativa de frenagem;
- A bateria sustenta transientes lentos, enquanto que o SC rápidos transientes.

Entretanto, o uso de um sistema com bateria e SC aumenta a complexidade do controle de gestão de potência (do inglês *Power Management Control*) (PMC). Para suprir esse propósito, neste trabalho, é proposto um controlador fuzzy que consegue lidar com quantidades imprecisas sem precisar da modelagem matemática da planta (SHAW; SIMÕES, 1999).

Sistemas fuzzy trabalham com uma manipulação condicional de variáveis de entrada e saída e podem ser aperfeiçoados utilizando ferramentas de otimização. Neste trabalho, serão abordadas duas ferramentas de um conjunto de algoritmos de

inteligência computacional chamado meta-heurísticas bio-inspiradas, sendo elas: algoritmo genético (do inglês *Genetic Algorithm*) (GA), e otimização por enxame de partícula (do inglês *Particle Swarm Optimization*) (PSO).

1.2 OBJETIVOS

1.2.1 Objetivos gerais

Elaborar um gerenciamento otimizado do sistema de armazenamento híbrido de energia.

1.2.2 Objetivos específicos

Para que o objetivo geral seja cumprido são necessários que os seguintes objetivos específicos sejam realizados:

- Realizar uma revisão da literatura, denotando os principais pontos de cada tópico;
- Desenvolver o sistema de armazenamento híbrido de energia em ambiente de simulação;
- Desenvolver um controlador fuzzy para o gerenciamento de potência;
- Implementar as meta-heurísticas (GA e PSO) propostas a fim de sintonizar o controlador fuzzy e otimizar o desempenho do sistema de armazenamento de energia;
- Comparar os resultados do controlador fuzzy sintonizado por GA e sintonizado por PSO voltado a um sistema de armazenamento híbrido de energia.

1.3 ORGANIZAÇÃO DO TRABALHO

O presente trabalho está organizado da seguinte forma:

- No segundo capítulo, são apresentados o referencial teórico e a revisão da literatura dos tópicos abordados, sendo estes: ESSs, controladores fuzzy, GA e

PSO. É discutida e justificada a implementação de cada item, apresentando os principais modelos encontrados na literatura, bem como exemplos de aplicações nos quais é vista a eficiência de cada metodologia.

- No terceiro capítulo, os materiais e metodologias utilizadas são apresentados. É esclarecido detalhadamente o desenvolvimento e implementação de cada método, apresentando as diferentes propostas de solução, elaboradas com o intuito de atingir o objetivo geral de forma mais precisa, coesa e consistente possível.
- No quarto capítulo, são apresentados os resultados e discussões em torno das propostas apresentadas. Cada resultado é analisado em termos de eficiência e dispersão, discutindo os prós e contras de cada proposta feita, possibilitando, por fim, perceber o real ganho alinhado ao objetivo geral apresentado.
- No quinto e último capítulo, é feito um apanhado geral do exposto, concluindo se o trabalho atingiu os objetivos e o desempenho esperado, direcionando, então, a trabalhos futuros que poderão ser realizados dentro do âmbito do conteúdo apresentado.

2 REVISÃO DA LITERATURA

Neste capítulo é feita uma revisão da literatura, analisando cada tema deste trabalho. É apresentada a base teórica dos modelos a serem simulados, bem como as técnicas de controle e otimização a serem trabalhadas no respectivo sistema de armazenamento de energia.

2.1 SISTEMA DE ARMAZENAMENTO DE ENERGIA

Sistemas de armazenamento de energia tem importante efeito em sistemas elétricos em geral, pois proporciona fornecimento flexível de potência, preservando e aumentando o uso de potência de acordo com a demanda (HANNAN et al., 2017). Para EVs, são utilizados em associação, de forma a prover alto tempo de descarga com confiabilidade (ECKERT et al., 2018).

Alguns parâmetros específicos e de densidade são importantes para mensurar a eficiência e tipo do sistema de armazenamento, tais como:

- Densidade de potência (W/m^3): Razão da potência armazenada pelo volume;
- Densidade energética (J/m^3): Quantidade de energia armazenada por volume;
- Potência específica (W/kg): Relação de potência produzida por uma massa;
- Energia específica (J/kg): Propriedade intensiva que relaciona energia produzida por uma massa.

Segundo ESA (2019), os ESSs mais importantes podem ser divididos em seis categorias: Bateria de Estado Sólido (*Solid State Batteries*), Baterias de Fluxo (*Flow Batteries*), *Flywheels*, armazenamento de energia de ar comprimido (do inglês *Compressed Air Energy Storage*) (CAES), Térmica, Hidroelétrica Bombeada (*Pumped Hydro-Power*).

Já Hannan et al. (2017), em sua pesquisa, apresenta uma classificação mais profunda baseada no tipo de energia: Mecânica, Eletroquímica, Química, Elétrica, Térmica e Híbrida.

Os sistemas mecânicos compreendem as categorias Flywheel, Hidroelétrica bombeada, CAES; sendo, o último, o tipo responsável por quase 99% da capacidade de armazenamento elétrico do mundo, o que é 3% da capacidade global de geração (HANNAN et al., 2017).

Os sistemas eletroquímicos de armazenamento de energia compreendem todas as baterias recarregáveis convencionais, sendo subdivididos em Baterias de fluxo e Baterias recarregáveis secundárias. Esse tipo de bateria pode armazenar e prover energia sem emissões prejudiciais, convertendo-a de química para elétrica e vice-versa, porém apresentando redução de vida-útil da célula devido a reação química (HUSAIN, 2011).

Os sistemas químicos de armazenamento liberam e armazenam energia por meio de reações químicas, como faz a célula combustível (do inglês *Fuel Cell*) (FC), que converte a energia química do combustível em energia elétrica continuamente e enquanto o material ativo abastecer, sendo essa a principal vantagem do uso dessa tecnologia (MI; MASRUR; GAO, 2011). Diferencia-se da bateria por ter uma fonte externa de geração de energia, podendo esta ser microbial, ar-metal ou hidrogênio. Essa tecnologia pode oferecer eficiência de 40 a 85 % (HANNAN et al., 2017).

Os sistemas térmicos de armazenamento alojam energia na forma de calor em um depósito isolado, sendo subdividido em três classes: armazenamento de calor latente, armazenamento de calor sensível, e sistemas de armazenamento de sorção termoquímicos.

Os sistemas elétricos armazenam a energia em eletricidade em forma de campo elétrico, separando cargas ou campo magnético por fluxo, em SC ou armazenamento de energia de supercondutores eletromagnéticos (do inglês *Superconducting Magnetic Energy Storage*) (SMES). Além de possuir a vida-útil mais longa dentre os ESSs com cerca de 40 anos, a potência específica do SC é aproximadamente 1000-2000 W/kg com 95% de eficiência energética (HANNAN et al., 2017). Como um capacitor ordinário, o SC armazena energia pela separação física, por meio de um isolador, de cargas positivas e negativas em eletrodos. Isso faz com que os SC possuam maior ciclo de vida e densidade de potência do que as baterias, porém baixa densidade energética, como apresentado na tabela 1 (KHALIGH; Zhihao Li, 2010).

Em EVs, SCs são usados durante frenagem elétrica e como fonte de energia durante picos de aceleração (ECKERT et al., 2018; HANNAN et al., 2017; KHALIGH;

Tabela 1 – Comparação bateria e SC

	Bateria	Supercapacitor
Energia utilizável (kWh)	23,5	0,3
Máxima corrente de descarga (A)	224	400
Energia específica (Wh/kg)	113	4
Potência específica (W/kg)	174	1500
Ciclo de vida (anos)	2,5-5	10-12
Custo (dólares/kW)	400	100
Custo de ciclo de vida (dólares/kW)	1200	100

Fonte: Adaptado de (KHALIGH; Zhihao Li, 2010)

Zhihao Li, 2010). SCs possuem alta densidade de potência, mas baixa energia específica, portanto, são usados associados a baterias, FCs ou outra tecnologia que forneça alta potência (HUSAIN, 2011; MI; MASRUR; GAO, 2011). A energia armazenada no capacitor é apresentada na equação (1):

$$W_c = \frac{1}{2}C \times V^2 = \frac{1}{2}Q \times V \quad (1)$$

Em que C é a capacitância em farads, Q a carga em coulombs e V é volts.

Quando se associa SC a outro sistema, tem-se um HESS, que é a combinação de dois ou mais ESS diferentes, tais como: ESS de alta densidade de potência com alta densidade de energia, ou de resposta rápida com resposta lenta, ou alto custo e baixo custo. HESS são subclassificados em híbridos bateria-bateria, híbridos bateria SC, híbrido FC e bateria, híbrido SMES bateria, híbrido bateria e flywheel, híbrido bateria e CAES, híbrido FC e SC, híbrido FC e flywheel ultrarrápido, híbrido CAES e SC (HANNAN et al., 2017; HUSAIN, 2011).

A bateria é o dispositivo primário de armazenamento de energia de veículos terrestres, mas aumentar 15% da autonomia elétrica com ela quase dobra o custo do sistema, pois este necessita de altos picos de potência mantendo alta densidade energética (KHALIGH; Zhihao Li, 2010). Aumentar o tamanho da bateria pode resolver o problema de possuir baixa densidade de potência, porém aumenta o seu custo (Jian Cao; EMADI, 2012; HUSAIN, 2011; MI; MASRUR; GAO, 2011). No mercado, destacam-se as baterias de chumbo ácido, de hidreto de metal níquel (Nickel-Metal Hydride – NiMH) e Lítio-íon.

Baterias de chumbo ácido são baterias de baixo custo com uma tecnologia madura, tendo sido bastante usada nos últimos 50 anos. O chumbo esponjoso funci-

ona como o negativo ativo, enquanto o óxido de chumbo é o material positivo ativo e ácido sulfúrico diluído é o eletrólito. Segundo Khaligh e Zhihao Li (2010), esse tipo de bateria não é adequado para descargas acima de 20 % de sua capacidade avaliada e, quando operando em taxa profunda de estado de carga estado de carga (do inglês *State of Charge*) (SOC), terá ciclo de vida limitado, além de que, por possuir pesados coletores de chumbo, sua densidade de potência e energia é baixa. É a tecnologia mais difundida no mercado de veículos elétricos.

A bateria de NiMH (Nickel-Metal Hydride) utiliza solução alcalina como eletrólito, eletrodo positivo de hidróxido de níquel e negativo de ligas metálicas, tendo duas vezes a densidade de energia da bateria de chumbo ácido (KHALIGH; Zhihao Li, 2010). Segundo Fetcenko et al. (2007) é uma tecnologia de bateria recarregável importante por possuir grande energia, potência e ainda ser reciclável, inofensiva ao meio ambiente. Possui armazenamento de energia e potência volumétrico, opera bem a altas temperaturas, e tem longo ciclo de vida. Entretanto, se descarregada seguidamente a altas correntes de carga, pode diminuir sua vida-útil em 200 a 300 ciclos, além de que o efeito da memória nessas baterias pode diminuir o SOC utilizável em um veículo elétrico híbrido (do inglês *Hybrid Electric Vehicle*) (HEV) (KHALIGH; Zhihao Li, 2010).

Baterias de NiMH eram a escolha dos EVs e HEVs dos anos '90 e '00 muito devido a sua segurança comprovada, além de serem livres de manutenção quando submetida a leves sobrecargas, pois seu excesso de energia é usado para dividir e recombinar água (VAZQUEZ et al., 2010).

As baterias de Li-íon possuem eletrodo positivo feito de cobalto oxidado, negativo de carbono, e eletrólito de sal de lítio em um solvente orgânico. Segundo Khaligh e Zhihao Li (2010), com o aumento do preço do níquel, as baterias de Li-íon prometem logo substituir as baterias de NiMH em EVs, já que possuem baixo efeito de memória, alta potência e energia específica e um ciclo de vida longo de 1000 ciclos. Apesar do custo alto para algumas aplicações, o Li-íon possui muitas vantagens, sendo bastante presente em aplicações de equipamentos portáteis, e uma tecnologia promissora para EVs (VAZQUEZ et al., 2010).

Na tabela 2 é apresentado um resumo do estado de desenvolvimento atual das tecnologias de componentes de armazenamento de energia em função da densidade energética, energia específica e potência específica. Paralelamente, em relação

aos EVs, vê-se que normalmente picos de aceleração de veículos duram menos que 30 segundos e, portanto, a utilização de SC torna-se viável — visto sua alta potência específica (WU et al., 2012).

Tabela 2 – Estado de desenvolvimento

Componente	Energia específica (Wh/kg)	Densidade energética (Wh/lit)	Potência específica (W/kg)
Chumbo ácido	40	80	100
NiMH	80	200	700
Li-íon	150	500	900
Supercapacitor	5.6	6.4	11000

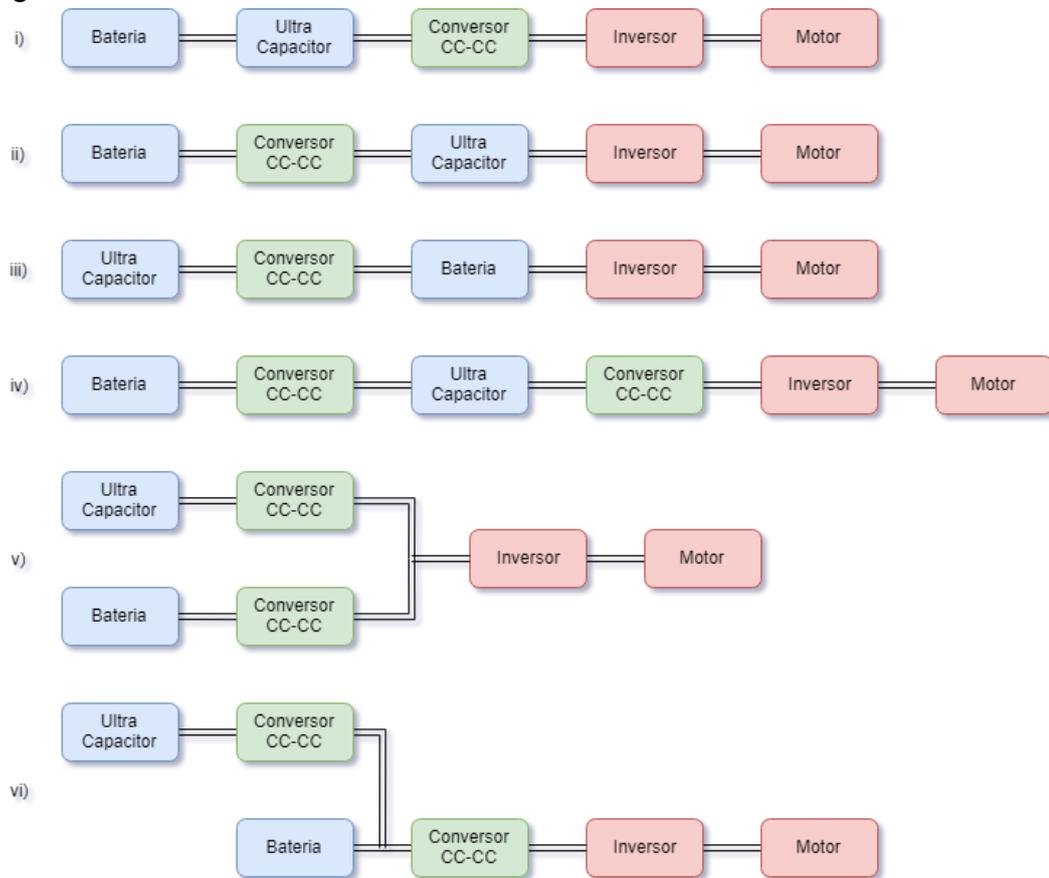
Fonte: Adaptado de Wu et al. (2012)

Um HESS de SC e bateria, sistema a ser estudado neste trabalho, pode otimizar a resposta a alta demanda de potência e de energia, além de poder absorver a oscilação de alta frequência do SC e de baixa frequência da bateria (HANNAN et al., 2017; MI; MASRUR; GAO, 2011). Na figura 1 é apresentado os tipos possíveis de configurações para um sistema híbrido a bateria e SC. A primeira estrutura, em paralelo passivo com o mesmo terminal de tensão, é relativamente simples e eficiente. As estruturas (ii), (iii) e (iv) apresentam diferentes configurações com conversores CC-CC bidirecionais, sendo que (iii) é mais eficiente que (ii) pela tensão fixa do SC mantido pelo conversor. As estruturas (v) e (vi) apresentam uma configuração desacoplada com dois conversores CC-CC bidirecionais em paralelo, que proporcionam alta flexibilidade, estabilidade, e eficiência para fornecer um HESS compacto e redundante a falhas de uma fonte; entretanto, nessa estrutura a vida-útil da bateria é reduzida devido à alta corrente de saída (HANNAN et al., 2017).

Segundo Geetha e Subramani (2017), o objetivo principal quando implementado um HESS é diminuir o estresse da bateria de forma a aumentar o seu tempo de vida. A redução do tamanho da bateria e do SC é também muito benéfico à eficiência. Para otimizar a bateria, é tido como variável a distância percorrida, e a otimização do SC depende do perfil da potência demandada (GEETHA; SUBRAMANI, 2017).

Jian Cao e Emadi (2012), considerando a maioria dos ciclos urbanos, propõem em projeto manter a tensão do SC em um valor maior do que a tensão da bateria. Dessa forma, esta só irá prover potência quando a tensão do SC for abaixo de sua tensão, utilizando ao máximo a capacidade de potência do SC e um perfil de carga mais suave para o sistema da bateria, aumentando sua vida-útil. O esquema

Figura 1 – Estruturas de HESS de bateria e SC com conversores CC-CC



Fonte: Adaptado de: Hannan et al. (2017).

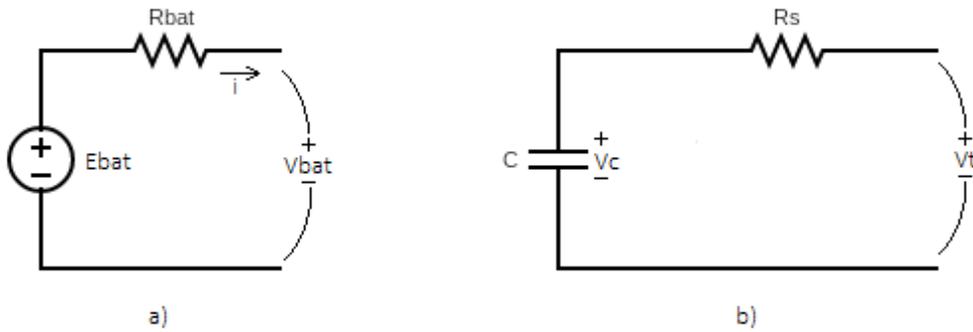
proposto exige um conversor CC-CC menor, utilizando acima de 75% da energia do SC. Como mencionado, ciclos urbanos são caracterizados por diversas sequências de altas acelerações seguidas de paradas, exigindo então de todo o sistema de armazenamento.

De acordo com Song et al. (2014), EV puros estressam a bateria mais do que HEV por usarem uma maior parte de sua energia disponível, sendo algo em torno de 80% para EV e 10% para HEV. Sabendo-se que a potência demandada exige frequentemente picos de potência, principalmente considerando-se ciclos urbanos, a bateria tende a executar muitas operações de carga e descarga, trazendo danos a vida útil da bateria, mesmo que análises estatísticas indiquem que ciclos de direção rápida degradem mais do que uma direção lenta (SONG et al., 2014; KHALIGH; Zhihao Li, 2010; PETERSON; APT; WHITACRE, 2010). Nesse sentido, o trabalho de Song et al. (2014) apresenta que um HESS consegue diminuir o custo de ciclo de vida da bateria em 23% quando comparado com uma configuração utilizando somente a bateria.

Os modelos básicos de bateria e SC mais utilizados na literatura são com

resistência interna, apresentados na figura 2 (SONG et al., 2014; KHALIGH; Zhihao Li, 2010). E_{bat} é a tensão de circuito aberto do módulo da bateria, R_{bat} a sua resistência interna, i a corrente que flui pelo circuito e V_{bat} a tensão de circuito aberto do modelo, enquanto que para o modelo do SC, C é a capacitância do módulo, V_c sua tensão em circuito aberto e R_s a resistência interna.

Figura 2 – Modelos de bateria e SC



Fonte: Autoria própria

Na figura 2a é possível calcular o SOC a partir da tensão de circuito aberto V_{bat} , que é obtido a partir de uma fonte de tensão controlada em série com o resistor interno, como apresentado nas equações 2 a 5 (WANG et al., 2015).

$$V_{bat} = E_{bat} - iR_{bat} \quad (2)$$

$$P_{bat} = V_{bat}i \quad (3)$$

$$i = \frac{E_{bat} - \sqrt{E_{bat}^2 - 4R_{bat}P_{bat}}}{2R_{bat}} \quad (4)$$

$$SOC_{bat} = SOC_0 + \frac{k_t \int_0^t i dt}{C_t} \quad (5)$$

em que k_t é o coeficiente de temperatura e C_t a capacitância da bateria.

O modelo de SC é apresentado na figura 2b. Para obter o SOC é utilizado a equação 6, em que V_C é a tensão em circuito aberto do módulo e $V_{C,max}$ a sua tensão máxima (SONG et al., 2014).

$$SOC_C = \frac{V_C}{V_{C,max}} \quad (6)$$

A frenagem é uma grande responsável pelo consumo de energia do veículo. Em trechos urbanos típicos ela pode consumir mais que 25% do total da energia de tração, enquanto que em cidades grandes, esse valor pode chegar a 70% (EHSANI, 2005). Uma característica de destaque dos EVs é a possibilidade de recuperar essas energias, já que o motor elétrico (do inglês *Electric Motors*) (EM) pode operar como gerador, convertendo energia cinética ou potencial da massa do veículo em energia elétrica (YOONG et al., 2010; GAO; CHEN; EHSANI, 1999). Incluir a frenagem regenerativa pode diminuir significativamente o consumo de combustível, mas também aumentar a complexidade do sistema de freio, levantando questões sobre como distribuir a força de freio total entre frenagem regenerativa e fricção mecânica de forma a recuperar o máximo possível de energia cinética, e a distribuição de forças no eixo frontal e traseiro. Veículos convencionais consomem nas rodas frontais cerca de 65% da energia de frenagem, sendo então mais efetivo aplicar frenagem regenerativa somente neste eixo (EHSANI, 2005). Além disso, outro ganho inerente da frenagem regenerativa é poder funcionar como ABS (*Antilock Brake System*).

A recuperação de energias regenerativas é uma realidade em sistemas ferroviários elétricos, linhas de metrô eletrificadas e, principalmente, HEVs (Nasri; Moghadam; Mokhtari, 2010; Adinolfi et al., 1998; Cikanek; Bailey, 2002). Neste último, a energia proveniente da frenagem regenerativa além de poder ser armazenada para recarregar a bateria, pode ser utilizada para fornecer calor ao líquido de arrefecimento que pré-aquece o motor a combustão interna (do inglês *Internal Combustion Engine*) (ICE) antes da partida do motor (BRANDENBURG; KING, 1994).

Para armazenar a energia proveniente da frenagem regenerativa é necessária uma alta potência específica. González-Gil, Palacin e Batty (2013) identificam que capacitores eletroquímicos de camada dupla são uma tecnologia adequada, enquanto que Yoong et al. (2010) utilizam *flywheel* e SC com um conversor CC-CC para aumentar a performance regenerativa.

Em geral, nota-se que é mais eficiente utilizar capacitores para executar essa tarefa, pois estes possuem maior potência específica. Isolar a bateria de ser recarregada diretamente durante a frenagem regenerativa, e deixar os SCs com a prioridade de reciclagem de energia, faz com que sua vida-útil seja aumentada (WANG et al., 2015).

2.2 GERENCIAMENTO DO SISTEMA HÍBRIDO DE ARMAZENAMENTO DE ENERGIA

Um bom gerenciamento de potência deve não só minimizar o consumo energético do HESS e estender sua autonomia, mas também regular a distribuição de potência entre as fontes para que evite o impacto de corrente no conjunto de baterias (ZHANG; XIONG; CAO, 2016). Esse gerenciamento pode ser feito com controladores a base de regras, como os Fuzzy (HU et al., 2018).

O desempenho do sistema de gerenciamento depende diretamente de três aspectos, listados abaixo, sendo que grande parte das pesquisas na área não conseguem lidar bem com todos os itens ao mesmo tempo (ZHANG; XIONG; CAO, 2016):

1. Método efetivo de análise para otimização;
2. Aplicação em tempo real do gerenciamento de potência;
3. Garantir performance excelente em condições diversas.

2.2.1 Fuzzy: Sistemas Nebulosos

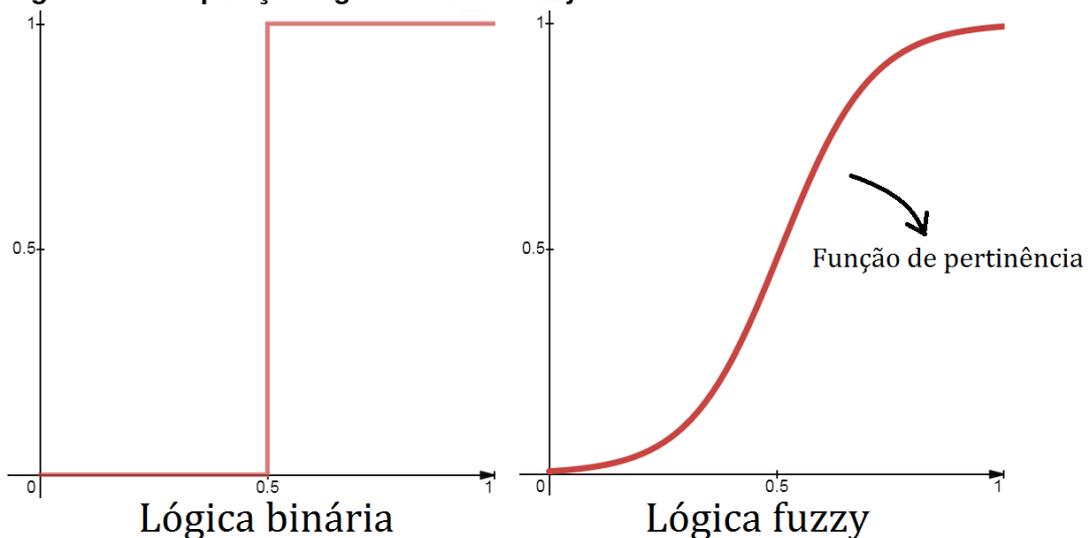
Sistemas inteligentes como o fuzzy fornecem soluções para problemas de forma única, com operações inspiradas em sistemas biológicos. Um sistema dedutivo, por exemplo, é o processo que se utiliza para inferir conclusões baseadas em informações que já são conhecidas, enquanto que em um sistema indutivo, é o processo de aprendizado e a generalização através de um exemplo particular proveniente da observação do comportamento do mesmo em uma situação dinâmica (SHAW; SIMÕES, 1999).

Analisando os aspectos vagos da informação, a lógica fuzzy foi introduzida no meio científico por Zadeh (1968), mas seus princípios foram desenvolvidos por Jan Lukasiewicz, em 1920 (CHENCI; LUCAS, 2011). A lógica difusa é multivalente e capaz de capturar informações vagas, converter de uma linguagem natural para formato numérico, sendo possível a manipulação por computadores. Inspirada no raciocínio humano, a lógica fuzzy é útil em tarefas de tomadas de decisão, em que as variáveis individuais não são definidas em termos exatos (YAGER; ZADEH, 2012).

O advento da lógica fuzzy foi causado pela necessidade de um método capaz de expressar de maneira sistemática quantidades imprecisas, vagas ou mal-definidas (KOSKO; ISAKA, 1993). Modelos matemáticos são precisos para sistemas lineares, porém apresentam dificuldades para modelos não-lineares. Controladores fuzzy podem ser investidos com o conhecimento experimental de operadores humanos treinados, obtendo uma ação de controle consistente em sistemas não-lineares utilizando a modelagem de um conhecimento empírico (SHAW; SIMÕES, 1999).

Na clássica lógica binária, tem-se em um conjunto a possibilidade de valores nulos ou unitários. Já em um conjunto fuzzy existem valores entre o 0 e o 1 que são quantificados a partir da função de pertinência, como apresentado na figura 3. Essa função representa os graus de pertinência dos termos imprecisos estudados pela lógica fuzzy.

Figura 3 – Comparação lógica binária e fuzzy



Fonte: Autoria própria

A lógica fuzzy como ferramenta de otimização também pode apresentar severas melhorias para os resultados de um controlador, como apresenta Castanho et al. (2018), utilizando-a para otimizar um controlador PID. Com um controlador PID com lógica fuzzy, Wu et al. (2012) conseguem uma resposta de saída de corrente mais rápida do que de um PID puro em um conversor CC-CC aplicado a um HESS. A otimização do PID pela lógica fuzzy torna-se possível pois é feito um ajuste variável dos ganhos k_p , k_i , k_d .

Na obra de Hu et al. (2018), os autores conduzem um trabalho comparando controladores baseados em regras utilizados em EVs com HESS que consistem de ba-

teria e SC. É proposto um controlador extenso — composto de um controlador adaptativo baseado em regras auxiliado por um controlador de lógica fuzzy —, comparando-o com um controlador tradicional baseado em regras e um controlador adaptativo baseado em regras. Os resultados apresentados por Hu et al. (2018) mostram que o controlador extenso, que utiliza um controle fuzzy auxiliar, obteve a melhor performance. O controlador fuzzy aplicado atua na correção da alocação de potência para o controlador adaptativo baseado em regras e, portanto, os autores concluem que uma regra geral existe para a alocação de potência de um HESS e que controladores baseados em regras conseguem alcançar boa performance.

2.2.1.1 Controlador Fuzzy

Controladores, ou também chamado compensadores, são subsistemas que controlam uma planta, ou seja, atuam sobre um sistema de modo a atingir resultados pré-estabelecidos. Podem funcionar em malha aberta, em que a saída não tem efeito sobre o controle, ou em malha fechada, que com a realimentação objetivam reduzir o erro do sistema iterativamente (OGATA, 2011).

Se um sistema for corretamente dimensionado e controlado, é possível aumentar sua eficiência geral (Jian Cao; EMADI, 2012). Lopes (2008) comprova que a estratégia de gerenciamento de potência fundamentada em sistemas fuzzy permite maior economia de combustível em uma unidade propulsora híbrido elétrica composta de banco de baterias e um ICE com gerador. Essa economia acontece uma vez que o ICE fornece menos potência, apresentando a possibilidade de redimensionamento do motor sem comprometimento do desempenho do veículo.

A lógica fuzzy aplicada a um controlador traz como vantagem a possibilidade de modelar um controlador sem conhecer o modelo matemático da planta (SHAW; SIMÕES, 1999). É necessário conhecer apenas o comportamento do sistema. Funcionalmente um controlador lógico fuzzy (do inglês *Fuzzy Logic Controller*) (FLC) consegue ser muito preciso no esforço de controle, já que consegue tratar especificamente cada tipo de entrada.

No FLC, os níveis lógicos são representados por funções de pertinência e variáveis linguísticas por meio de um processo chamado fuzzificação. Este processo obtém os valores das variáveis de entrada e escalona para condicionar os univer-

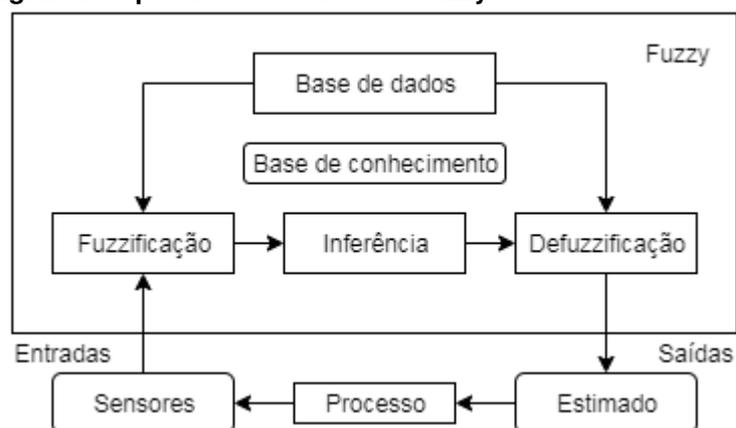
tos de discurso de forma a transformar números em conjuntos fuzzy (ROSS, 2000). De mesmo modo, decodificar as ações de saída fuzzy inferidas para um valor real de saída chama-se defuzzificar, um processo que nada mais é do que um escalonamento de compatibilização entre os valores normalizados pelo mesmo método de fuzzificação com os valores reais dos universos de discurso das variáveis (RONDEAU et al., 1997).

A forma como as variáveis linguísticas de entrada e de saída se relacionam é definido por meio das regras de inferência. O processo de inferência é a etapa de processamento de dados fuzzificados de entrada que, utilizando a base de conhecimento, inferem ações de saída (JANTZEN, 1998). A base de conhecimento consiste de uma relação de regras que definem a estratégia de objetivos, normalmente baseadas na lógica se-então, com pesos e operadores “ou” ou “e”, conforme exemplo:

Se (Erro é Negativo) e (Derivada do erro é Negativo), então (Tensão é Pouco Positivo).

O diagrama esquemático de um controlador fuzzy, segundo Pedrycz e Gomide (1998), pode ser representado conforme figura 4. Todas as informações e definições necessárias para discretização, definição de funções de pertinência, etc; são armazenadas na base de dados.

Figura 4 – Diagrama esquemático controlador fuzzy



Fonte: Autoria própria

No quadro 3 é apresentado um exemplo de controlador contendo as variáveis linguísticas e funções de pertinência. No exemplo em questão, as variáveis de entrada são erro e derivada do erro, divididas em 5 e 3 funções respectivamente. A saída seria somente a tensão, variando em 4 funções classificadas de zero a muito positivo.

Tabela 3 – Funções de pertinência

Entradas	Funções de pertinência
Erro	Negativo / Pouco negativo / Zero / Pouco positivo / Positivo
Derivada do erro	Negativo / Zero / Positivo
Saída	Funções de pertinência
Tensão	Zero / Pouco positivo / Positivo / Muito positivo

Fonte: Autoria própria.

As regras para esse exemplo podem ser construídas combinando todas as possibilidades das entradas *Erro* e *Derivada do erro*, gerando um tipo de saída - o objeto de análise. Essa combinação geraria 15 regras diferentes, bastaria então investigar qual é a melhor função de pertinência de saída para cada regra. Essa investigação é feita de forma empírica, baseando-se na experiência do especialista, no entendimento do problema, e na percepção das respostas geradas.

Para retirar parte do empirismo e obter resultados satisfatórios, sugere-se utilizar algoritmos otimizadores (HOMAIFAR; MCCORMICK, 1995). Neste trabalho, serão abordadas duas meta-heurísticas bioinspiradas como propostas de otimização para sintonia dos parâmetros fuzzy.

2.2.2 Meta-heurísticas bioinspiradas

Meta-heurísticas bioinspiradas, da etimologia de seu nome, significa conjuntos superiores e generalizados de métodos descobridores inspirados na natureza, ou seja, são métodos genéricos de busca e otimização estimulados pelas ciências naturais. Esses métodos fazem parte da área inteligência computacional (do inglês *Computational Intelligence*) (CI) também comumente cunhada pelo termo computação natural, que pode ser definida, mais amplamente, por um estudo adaptativo de mecanismos para permitir ou facilitar comportamentos inteligentes em ambientes complexos e em constante mudança (WANG; LIU, 2006). A CI possui três grandes áreas de inspiração, abaixo listadas, enquanto que os campos de aplicações concentram-se em quatro importantes tipos: problemas de controle, problemas de classificação, problemas de regressão, e problemas de otimização (ECK; WALTMAN, 2007).

- Sistemas difusos/fuzzy: lida com imprecisão semântica; inspirado no raciocínio humano.

- Redes neurais artificiais: fornecem capacidade de processamento distribuídas e cognitivas de aprendizado; inspirada no funcionamento do sistema nervoso de organismos superiores.
- Meta-heurísticas bioinspiradas: derivação de métodos computacionais a partir de princípios evolutivos, sistemas imunológicos artificiais e inteligência de enxame.

Com o desenvolvimento do processamento computacional, a CI tornou-se uma ferramenta importante para soluções de problemas complexos de engenharia (CASTRO, 2006). Entretanto, no primórdio de seu desenvolvimento, havia apenas a computação evolutiva e idealizações de processos evolutivos iterativos.

O início da computação evolutiva deu-se em meados da década de 60 com Friedberg (1958) e Friedberg, Dunham e North (1959) que fez uso de processos evolutivos para resolver problemas computacionais; Box (1957), que usou operações evolutivas para design e análise de equipamentos industriais; e Bremermann (1962) que aplicou a evolução em problemas numéricos. À época, as propostas sofreram com o ceticismo da comunidade científica, devido à falta de embasamento teórico, e com a precariedade do desempenho computacional (JONG; FOGEL; SCHWEFEL, 1997). A computação evolutiva é a subdivisão que deu origem a heurística mais conhecida da área: algoritmo genético.

2.2.2.1 Algoritmo Genético

O algoritmo genético (GA, do inglês *genetic algorithm*) foi proposto por Holland (1975). Inspira-se no trabalho de Darwin (1859), "A Origem das Espécies", que postula que a evolução dos seres vivos e sua complexidade é devido ao Princípio da Seleção Natural, em que indivíduos mais adaptados têm maior chance de sobrevivência e assim, conseguem perdurar sua carga genética.

O GA utiliza uma população inicial para realizar a busca pelo ótimo, que passará por um processo de seleção e evolução. Cada indivíduo dessa população carregará em seus genes uma possível solução para o problema em questão (GOLDBERG; HOLLAND, 1988). A população é gerada atribuindo valores aleatórios para cada indivíduo dentro de um alcance pré-determinado (HOLLAND, 1984).

A representação dos indivíduos é feita por meio do conceito de genótipo e

fenótipo. Genótipo representa o conjunto de genes (informações) que o definem, e fenótipo é a manifestação do genótipo como um produto de sua interação e comportamento com o ambiente que está sujeito (HOLLAND, 1975). Esse entendimento é importante para que se cumpra os critérios necessários para que haja evolução, uma vez que o genótipo será responsável por carregar a carga genética que gerará a variedade e a herança reprodutiva. Da mesma forma o fenótipo, na inteligência computacional chamado de *fitness*, é responsável por identificar o nível de adaptação do indivíduo no processo seletivo.

O processo de seleção é probabilístico e tenta beneficiar àqueles indivíduos mais adaptados, sendo determinante para a evolução da população. A seleção natural, reprodução com herança e variação são os três processos mais importantes para que haja evolução, segundo Darwin (1859).

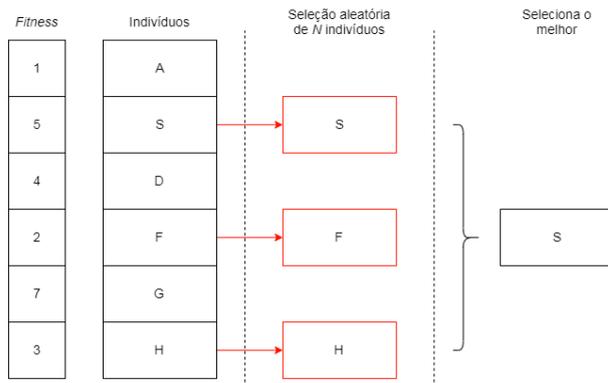
Os métodos mais difundidos que emulam a seleção natural são torneios e roletas. Torneios são métodos que selecionam dois ou mais indivíduos aleatoriamente do *pool* de seleção e os fazem “competir” entre si — comparação de adaptabilidade — vencendo o mais apto. Roletas distribuem em áreas o *fitness* de sua população proporcionalmente a se somar 100%, para então gerar um número aleatório de 0 a 1, e verificar a área de qual indivíduo esse valor pertence — sendo este indivíduo o selecionado. Para efetuar a reprodução é necessário selecionar duas vezes, percebendo que, sem um devido tratamento, o mesmo indivíduo pode ser escolhido ambas as vezes, reproduzindo filhos iguais a ele.

A seleção torneio possui uma pressão seletiva menor, enquanto que roletas favorecem mais os melhores indivíduos da geração. Cada método possui suas características, prós e contras, sendo a roleta o mais didático. Na figura 5a é demonstrado a seleção por torneio, em que são selecionados N indivíduos e, destes, o melhor é escolhido para ser um dos pais. Na figura 5b é apresentado um exemplo de roleta, no qual cada área corresponde a um *fitness*, calculado a partir da equação 7.

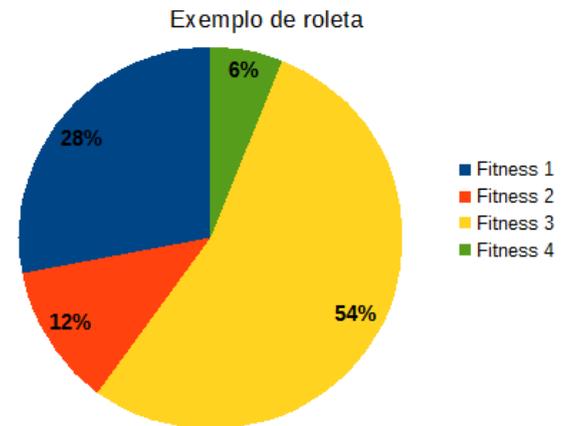
$$A_{\%} = \frac{f}{\sum f_i} \cdot 100 \quad (7)$$

Ordenamento linear, ordenamento uniforme, amostragem estocástica universal, amostragem estocástica sem reposição, seleção por truncamento, normalização linear e normalização exponencial são outros métodos de seleção encontrados na

Figura 5 – Exemplos de seleção
(a) Torneio



(b) Roleta

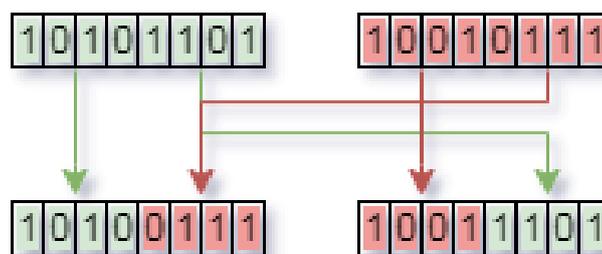


Fonte: Autoria própria.

literatura (PACHECO et al., 1999).

Após a seleção, os indivíduos escolhidos passam por um processo de recombinação, chamado *crossover*. Ele é responsável pela troca genética dos indivíduos pais selecionados ao gerar um indivíduo filho, dando origem a uma nova população, uma nova geração. Após o processo seletivo, dois pais são selecionados para gerar N filhos, que herdarão seu material genético. Esses filhos são gerados a partir da soma genética deferida a partir de um corte em cada pai, podendo este corte ser realizado de diversas formas, tais como: *crossover* binário, *crossover* de K pontos, *crossover* uniforme, *crossover* aritmético, entre outros (ZUBEN, 2000). Na figura 6 é ilustrado um *crossover* de 1 ponto aleatório em codificação binária, no qual os pais sofrem um corte em um ponto aleatório de seus cromossomos e geram dois filhos diferentes a partir de sua carga genética.

Figura 6 – Exemplo de recombinação: crossover de 1 ponto aleatório



Fonte: Autoria própria

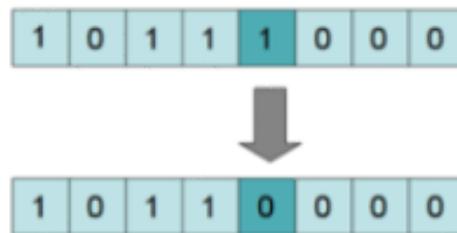
Com o *crossover* o algoritmo realiza exploração, afinando a solução com uma

busca local. No algoritmo genético, é o fator principal de convergência.

Uma vez gerada a população de filhos, o próximo passo é a mutação. A mutação é uma consequência inexorável e inerente da evolução e existência de sistemas reprodutivos tomados em um contexto de um universo de diferencial entrópico positivo, em que a diversidade é um dos mecanismos mais importantes da progressão evolutiva. Projetando-a na computação natural, percebe-se um operador valioso na exploração global de máximos ou mínimos, principalmente quando se tem total controle sobre sua taxa. Essa probabilidade de mutação, segundo (JONG; FOGEL; SCHWEFEL, 1997), deve ser inversamente proporcional ao tamanho da população.

A mutação no GA é usada como um operador adicional ao *crossover* — que é o principal atuador de recombinação —, sendo responsável somente pela manutenção de diversidade da população. Na figura 7 é apresentado um exemplo simples de mutação binária, em que um indivíduo sofre alteração de um gene. Em uma mutação no conjunto real, a modificação pode ser a reinicialização da respectiva variável.

Figura 7 – Exemplo de mutação: alteração de gene



Fonte: Autoria própria

A mutação no algoritmo genético é um operador de divergência, sendo um importante fator de busca global, realizando a exploração do espaço de busca.

Todo esse processo evolutivo passa por diversas iterações até que algum critério de parada seja atingido. Os critérios de paradas normalmente estabelecidos são: limite de gerações pré-determinada (limite de custo de cálculo), todos os indivíduos são iguais ou possuem o mesmo *fitness* (convergência populacional), algum indivíduo atinge o máximo *fitness* (solução áurea). Abaixo, Algoritmo 1 apresenta um resumo em pseudocódigo do funcionamento dessa heurística (FERENTINOS; ARVANITIS; SIGRIMIS, 2002).

Algoritmo 1 – Algoritmo genético

```

1: Inicialização
2: enquanto pop < numero de individuos faça
3:    $pop \leftarrow individuo_i[variavel_k(limiteInferior_k, limiteSuperior_k)]$ 
4: finaliza enquanto
5:  $gbest \leftarrow 0$ 
6: enquanto critérios de parada não são atendidos faça
7:   Avaliacao
8:   Selecao
9:   Crossover
10:   $pop \leftarrow filhos$ 
11:  Mutacao
12:   $best \leftarrow melhor\ individuo$ 
13:  se  $best \geq gbest$  então
14:     $gbest \leftarrow best$ 
15:  finaliza se
16: finaliza enquanto
17:  $Retorna \leftarrow gbest$ 

```

Fonte: Autoria própria.

2.2.2.2 Otimização por enxame de partículas

Outra área computacional de otimização de sistemas que nos últimos anos ganhou destaque é a inteligência de enxame. Esta possui duas linhas diferentes de inspiração: algoritmos inspirados no comportamento social de grupos de animais e algoritmos inspirados nas culturas ou sociocognição (CASTRO, 2007).

O PSO é um algoritmo de inteligência de enxame que foi criado por Eberhart e Kennedy (1995), inspirado pelo trabalho de Reynolds (1987). Este último notou que certos grupos de animais (bandos de pássaros, peixes e animais terrestres) possuem um comportamento sincronizado, com um controle central, e criou um modelo de simulação seguindo quatro regras: separação, alinhamento, coesão, desvio. A partir disso, Eberhart e Kennedy (1995) utilizaram as regras de alinhamento e coesão para criar um sistema de partículas para resolver problemas de otimização contínua.

Os algoritmos de enxames são algoritmos populacionais em que as partículas são diretamente influenciadas pelo grupo. Eberhart, Shi e Kennedy (2001), compreendendo a influência social, resumem o processo de adaptação cultural em três princípios: avaliar as partículas conforme sua capacidade de sentir o ambiente e perceber seu próprio comportamento; comparar partículas entre si; imitar as melhores partículas. Ou seja, cada unidade desta população possui sua própria experiência e é capaz de avaliá-la, da mesma forma como percebe o conhecimento de seus vizinhos. Com esse discernimento, a partícula direciona seu comportamento em função do ideal

social e de sua aprendizagem individual.

Mesmo que o cérebro possua processamento mental físico local, podendo-se tratar a cognição como atividade fundamentalmente individual e privada, todo indivíduo está inserido em um contexto histórico social em que toda atividade de reconhecimento perceptual para memória de resolução de problemas está envolvida em representações de outras pessoas, artefatos e formas culturais (LEVINE; RESNICK; HIGGINS, 1993). Portanto, a tomada de decisão de determinado indivíduo está em função, probabilisticamente, de seu passado (cognição individual) e do desempenho de seus vizinhos (cultura social). Bandura (1965b) observa, ainda, que a cultura otimiza a cognição, pois mesmo que as interações sejam locais, as inovações são transmitidas para toda a sociedade sem aprendizado experimental (o que o autor chama de *no-trial learning*).

Apesar de um agente individualmente no espaço não saber resolver o problema, coletivamente a população tem potencial para resolvê-lo. Analisando assim, a sociedade pode ser vista como uma entidade distribuída de processamento de informação, uma virtude detectada por Bandura (1965a), que percebe que conforme as habilidades se espalham pela sociedade, a população converge como um todo para processos ótimos. Isso é claramente visto em organizações tribais e no trabalho especializado da sociedade moderna.

Essas influências pessoais e sociais são semelhantes aos operadores de recombinação e crossover da computação evolutiva, já a conservação do movimento da partícula atua como uma mutação direcional. No entanto, a maior diferença entre os métodos está na seleção natural: nos métodos evolutivos os indivíduos menos aptos morrem, enquanto que nos algoritmos de enxame as partículas são preservadas durante todo o processo, sofrendo apenas adaptações na sua posição no decorrer.

Após inicializar a população no espaço de busca e avaliar os indivíduos, o PSO parte direto para o processo de combinação que aplicará as influências individuais e coletivas, determinando o novo posicionamento das partículas, calculado a partir de um vetor chamado velocidade. O vetor velocidade direciona a partícula em função da sua melhor posição no passado (ponderada pelo termo c_1 e um valor aleatório r_1); em função da melhor posição entre as partículas da população (ponderada pelo termo c_2 e um valor aleatório r_2); e em função da inércia do seu movimento atual (ponderada pelo termo w). Na figura 8 é representada vetorialmente a equação 9, que determina

a nova posição a partir da nova velocidade, calculada pela equação 8.

$$\mathbf{v}_i(\mathbf{t} + 1) = wv_i + c_1r_1(\mathit{pbest}_i - x_i) + c_2r_2(\mathit{gbest} - x_i) \quad (8)$$

$$\mathbf{x}_i(\mathbf{t} + 1) = \mathbf{x}_i(\mathbf{t}) + \mathbf{v}_i(\mathbf{t} + 1) \quad (9)$$

em que:

pbest_i é a melhor posição já visitada pela partícula presente;

gbest é a melhor posição global visitada pela população;

w é a constante de inércia;

c_1 é o parâmetro cognitivo;

c_2 é o parâmetro social;

r_1, r_2 são valores aleatórios entre 0 e 1 (componente estocástico).

Figura 8 – Cálculo vetorial



Fonte: Autoria própria.

O PSO é uma técnica simples, flexível, robusta e altamente distribuída. Porém, também possui rápida perda de diversidade, podendo apresentar convergência prematura a ótimos locais. Nesse caso, é comum ser utilizado operadores que espalham a população (LATIFF; TOKHI, 2009).

O pseudocódigo do PSO é apresentado em Algoritmo 2.

Algoritmo 2 – Otimização por enxame de partículas

```

Inicialização
2: enquanto pop < numero de individuos faça
    pop ← individuoi[variavelk(limiteInferiork, limiteSuperiork)]
4: finaliza enquanto
    gbest ← 0
6: enquanto critérios de parada não são atendidos faça
    para todos p em pop faça
8:     Fp ← f(p)
    se Fp ≥ f(pbest) então
10:     pbest ← p
    finaliza se
12: finaliza para
    best ← melhorindividuo
14: se best ≥ gbest então
    gbest ← best
16: finaliza se
    finaliza enquanto
18: Retorna ← gbest

```

Fonte: Autoria própria.

2.2.2.3 Exemplos de aplicações

No presente trabalho, o GA e o PSO são propostos como ferramentas de otimização dos parâmetros do controlador fuzzy. São técnicas difundidas de otimização. No trabalho de Eckert et al. (2018) é implementado um algoritmo genético multi-objetivo para otimização dos parâmetros do HESS e do PMC de um EV. Song et al. (2014) utilizam o GA para calibrar parâmetros do modelo dinâmico de degradação da capacidade de uma bateria $LiFePO_4$, objetivando obter um HESS mais completo. Em um controlador lógico fuzzy-genético (GFLC - do inglês *Genetic Fuzzy Logic Controller*) para melhoria de performance dinâmica de um gerador de indução auto excitado, o GA é importante na obtenção dos parâmetros fuzzy, assegurando melhor performance do sistema em geral (ATTIA; AL-TURKI; SOLIMAN, 2012). Independentemente da planta, o GA garante um melhor desempenho do controlador quando otimizado, assim como apresenta Hassanein, Aly e Abo-Ismael (2012) ao comparar um GFLC com um FLC em uma planta de caldeira de tubo de fogo.

Sintonizando um FLC e um PID com PSO para controlar a trajetória de um robô, Bingül e Karahan (2011) comparam o desempenho dos controladores submetendo à três diferentes funções custo, e, para testar a robustez, adicionando ruído branco e mudando a trajetória e os parâmetros do problema. Os resultados simulados provaram que o FLC sintonizado por PSO é melhor e mais robusto do que o PID

sintonizado pelo PSO.

Bevrani et al. (2012) utilizam um sistema inteligente online combinando lógica fuzzy e PSO para otimizar parâmetros de um controlador de frequência baseado em PI aplicado a uma microrrede, e compara o seu desempenho com um PI fuzzy puro, e com um projeto PI Ziegler-Nichols. Os resultados mostram que o sistema inteligente proposto apresenta melhor desempenho que os demais.

Otimizando um controlador adaptativo neuro-fuzzy para sistema de suspensão veicular, Kothandaraman e Ponnusamy (2012) utilizam a técnica PSO para buscar o melhor raio do sistema adaptativo neuro-fuzzy baseado em clustering subtrativo, melhorando o conforto de condução e apresentando boa capacidade de condução em estrada.

No trabalho de Sinha, Patel e Prasad (2010), GA e PSO são utilizados para otimizar parâmetros de um FLC atuando como controlador secundário em um sistema automático de geração de controle, melhorando o desempenho de performance dinâmica de três áreas de um sistema de energia hidrotérmica sobre diferentes condições de operação. O desempenho dos controladores sintonizados apresentou menor pico de sobressinal e menor tempo de estabilização do que um FLC sem sintonia, e apresentaram um desempenho melhor do que de um controlador PI. Os autores perceberam que na maioria dos casos, o desempenho do controlador sintonizado por GA é levemente melhor do que sintonizado por PSO em termos de oscilação de frequência e fluxo de potência vinculado.

3 DESENVOLVIMENTO

Neste capítulo são apresentados a metodologia e o desenvolvimento da implementação e análise realizada no trabalho. Todo processo computacional foi desenvolvido utilizando o software Matlab e o ambiente Simulink. O software foi escolhido por possuir modelos precisos de bateria e SC para a simulação do ESS. A ferramenta Simulink disponibiliza, em blocos, um ambiente intuitivo e prático para desenvolvimento e representação computacional do problema. As heurísticas foram implementadas em *script* no mesmo software.

3.1 DESENVOLVIMENTO DO MODELO MATEMÁTICO DA PLANTA

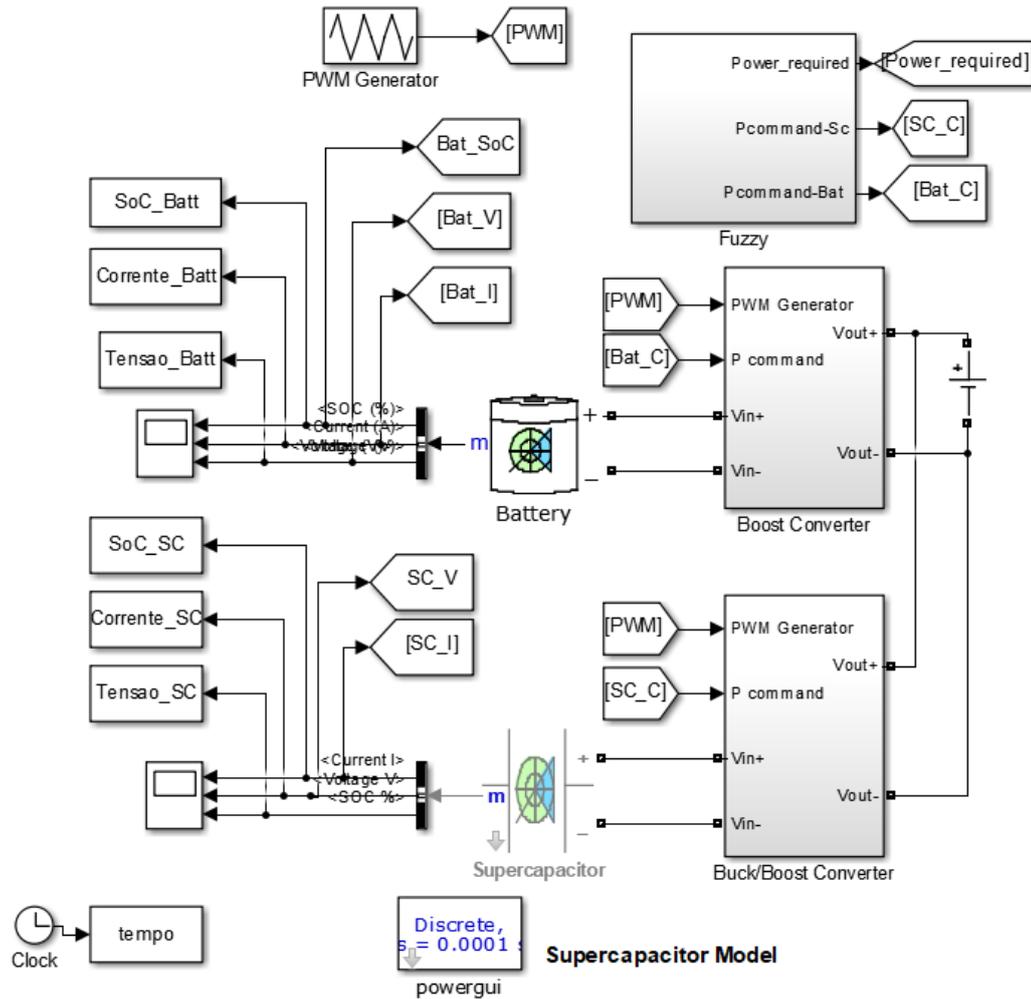
Para desenvolvimento do FLC, primeiramente deve-se estudar e conhecer o processo a ser controlado. Uma planta de HESS foi desenvolvida no Simulink conforme o diagrama de blocos apresentado na figura 9.

O sistema elaborado pode ser dividido em três conjuntos de blocos: conjunto Fuzzy (localizado na área superior), no qual é feito o PMC do sistema, abordado posteriormente; conjunto *Boost Converter* e *Battery* (localizado no centro), em que está presente a bateria e seu conversor CC-CC; conjunto *Buck/Boost Converter* e *Supercapacitor* (localizado abaixo), em que está presente o banco de capacitores e o seu conversor CC-CC (BLAUD, 2012).

A partir do transitório demandado o controlador fuzzy gera as saídas de potência demandada do SC e da bateria, que serão, em associação ao sinal PWM, as entradas respectivamente do conversor Buck-Boost (conjunto SC) e Boost (conjunto bateria). As saídas em tensão e corrente, tanto da bateria como do SC, geram a potência fornecida por cada dispositivo.

Para comparação de desempenho de autonomia, foi reconfigurado a planta em questão eliminando o SC, seu conversor e o FLC, deixando somente a bateria para fornecer a potência demandada. Assim, é possível analisar o ganho real em autonomia ao associar o SC e um controlador fuzzy para o PMC.

Figura 9 – Planta elaborada no ambiente Simulink



Fonte: Autoria própria

3.1.1 Configuração dos dispositivos de armazenamento

Os dispositivos de armazenamento foram simulados utilizando os blocos “Battery” e “Supercapacitor” do ambiente de simulação.

O modelo escolhido para a bateria foi o Li-íon, devido a sua estabilidade térmica, fator importante para precisão do equacionamento (WU et al., 2012), (MALEKI et al., 1999), (DOUGHTY; ROTH, 2012). Utilizando como base o circuito equivalente com uma resistência interna em série, a tensão de carga é obtida a partir da equação 10, enquanto a tensão de descarga modelada é apresentada na equação 11 (TREMBLAY; DESSAINT, 2009).

$$E_{carga}(it, i_* \in \{i_* < 0\}, i) = E_0 - K \cdot \frac{Q}{it + 0.1 \cdot Q} \cdot i_* \cdot -K \cdot \frac{Q}{Q - it} \cdot it + A \cdot e^{-B \cdot it} \quad (10)$$

$$E_{descarga}(it, i_* \in \{i_* > 0\}, i) = E_0 - K \cdot \frac{Q}{Q - it} \cdot i_* - K \cdot \frac{Q}{Q - it} \cdot it + A \cdot e^{-B \cdot it} \quad (11)$$

em que:

E_0 = Tensão constante (V)

K = Constante de polarização (Ah^{-1}) ou resistência de polarização (Ohms)

i_* = Dinâmica de corrente de baixa frequência (A)

i = Corrente da bateria (A)

it = Capacidade extraída (Ah)

Q = Capacidade máxima da bateria (Ah)

A = Tensão exponencial (V)

B = Capacidade exponencial (Ah^{-1})

A curva da corrente característica típica de descarga é composta de três seções: área de queda de tensão exponencial, que varia dependendo do tipo de bateria; área nominal, que representa a carga extraída até a tensão cair abaixo da tensão nominal; e a seção de descarga total, em que a tensão cai rapidamente. Na figura 10 é apresentada a curva característica para a corrente de descarga nominal, e, utilizando os mesmos parâmetros, as curvas para as correntes 6.5 A, 13 A e 32.5 A.

Para obter o estado de carga da bateria é utilizada a equação 12, no qual 100% é totalmente carregada e 0% é totalmente descarregada (TREMBLAY; DES-SAINTE, 2009).

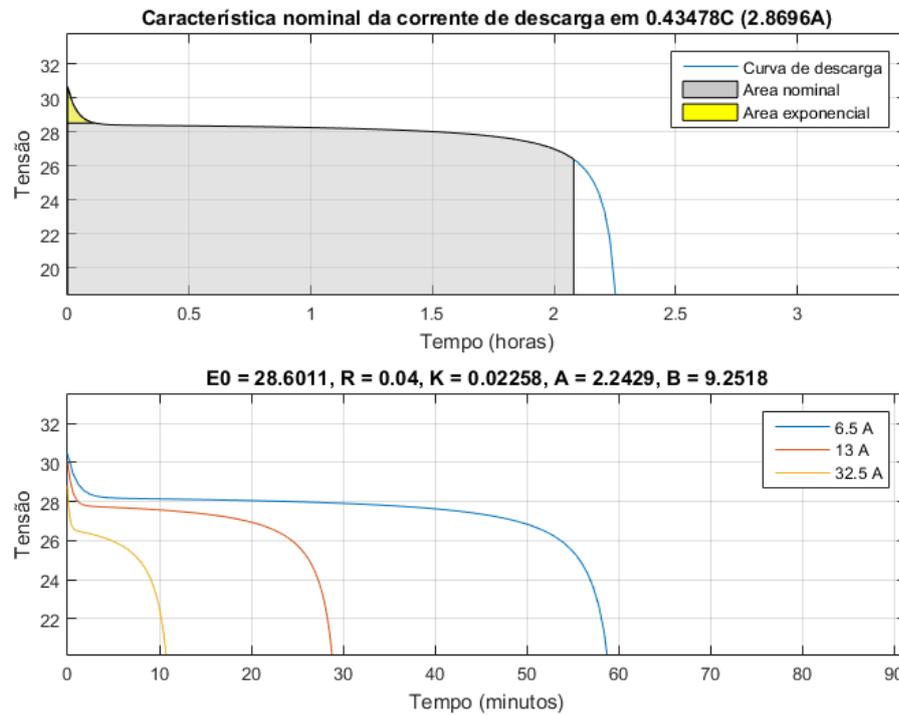
$$SOC_{bat} = 100 \cdot \left(1 - \frac{1}{Q} \int_0^t i(t) dt \right) \quad (12)$$

A tensão nominal definida foi 26.4 V, a capacidade nominal e capacidade máxima 6.6 Ah. Tensão a toda carga 30.7293 V, descarga nominal de corrente 2.8696 A, resistência interna 0.04 Ohms, capacidade em tensão nominal 5.9687 Ah. Os parâmetros para a zona exponencial foram 28.5222 V e 0.324261 Ah (TRUDES et al., 2017).

Para o SC, é utilizada a equação Stern (equação 13) para expressar a tensão de saída, sendo $Q_T = \int i_{SC} dt$ (OLDHAM, 2008).

$$V_{SC} = \frac{N_s Q_T d}{N_p N_e \varepsilon \varepsilon_0 A_i} + \frac{2 N_e N_s R T}{F} \sinh^{-1} \left(\frac{Q_T}{N_p N_e^2 A_i \sqrt{8 R T \varepsilon \varepsilon_0 c}} \right) - R_{SC} \cdot i_{SC} \quad (13)$$

Figura 10 – Típica característica de descarga



Fonte: Autoria própria

em que:

A_i = Área interfacial entre eletrodos e eletrólito (m^2)

c = Concentração molar ($mol \cdot m^{-3}$), igual a $c = 1/(8NAr^3)$

F = Faraday constante

i_{SC} = Corrente do supercapacitor (A)

V_{SC} = Tensão do supercapacitor (V)

C_T = Capacitância total (F)

R_{SC} = Resistência total (ohms)

N_e = Número de camadas de eletrodos

NA = Constante de Avogadro

N_p = Número de SC paralelos

N_s = Número de SC em série

Q_T = Carga elétrica (C)

R = Constante ideal de gás

D = Raio molecular

T = Temperatura de operação (K)

ε = Permissividade do material

ε_0 = Permissividade do espaço livre

Para representar o fenômeno de auto-descarga, quando $i_{SC} = 0$, a carga elétrica do SC é modificada para $Q_T = \int i_{auto-des} dt$, onde:

$$i_{auto-des} = \begin{cases} \frac{C_T \alpha_1}{1 + s R_{SC} C_T} & \text{se } t - t_{OC} \leq t_3 \\ \frac{C_T \alpha_2}{1 + s R_{SC} C_T} & \text{se } t_3 < t - t_{OC} \leq t_4 \\ \frac{C_T \alpha_3}{1 + s R_{SC} C_T} & \text{se } t_4 < t - t_{OC} \end{cases} \quad (14)$$

Para obter o estado de carga do SC é utilizado a equação 15, no qual 100% é totalmente carregado e 0% é totalmente descarregado.

$$SOC_{SC} = 100 \frac{Q_{inic} - \int_0^t i(t) dt}{Q_T} \quad (15)$$

O SC foi construído seguindo os seguintes parâmetros: capacidade nominal 500 F, resistência equivalente em série 0.0021 Ohms, tensão nominal 16 V, 6 capacitores em série, tensão inicial 16 V, temperatura de operação 25°C (TRUDES et al., 2017).

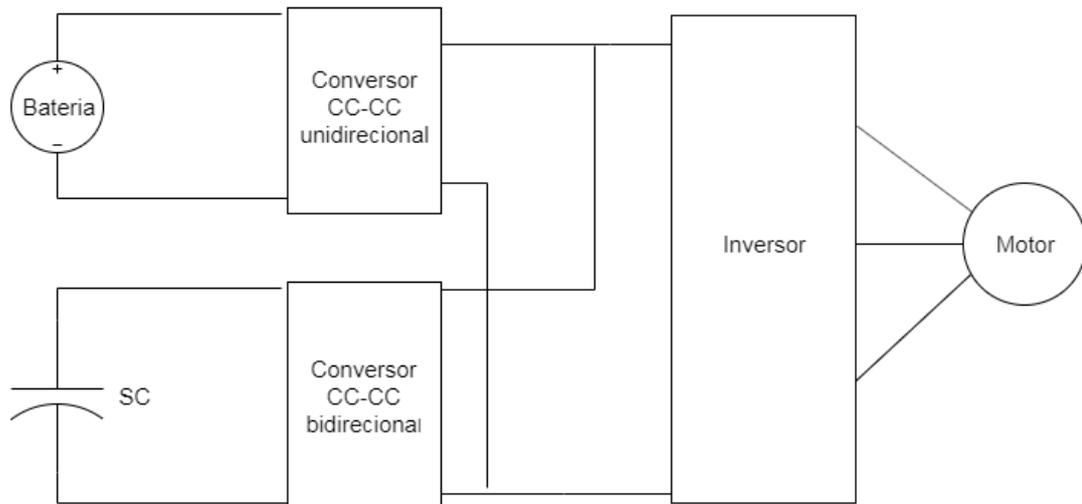
3.1.2 Topologia do sistema de armazenamento híbrido de energia

A definição da topologia do sistema de armazenamento híbrido de energia está alinhada diretamente com a estratégia de gerenciamento de potência. Certas topologias podem ser mais indicadas que outras dependendo do tipo de aplicação, fornecendo menor consumo e melhor dirigibilidade, e por isso, é necessário estudos e análises preliminares sobre o ciclo de condução submetido (LOPES, 2008).

Um ciclo de condução representa um programa de viagem em velocidade por tempo produzido a partir do estudo de tráfego local, realizado por diferentes países e organizações. Com isso, é possível medir em simulação a autonomia, emissão, e parâmetros de eficiência de um veículo de modo a mais se aproximar de um desempenho real em diferentes condições. Para o estudo de gerenciamento de energia de um EV, parâmetros como tempo de aceleração contínua, quantidade de frenagens e arranques, são importantes para executar uma gestão de potência precisa, bem como um correto dimensionamento dos dispositivos de armazenamento.

A topologia de um HESS depende significativamente da estratégia de aplicação de tensão previamente definida. Para uma estratégia em que $V_{bat} \neq V_{SC} \neq V_{DC}$, onde V_{bat} é a tensão da bateria, V_{SC} tensão do capacitor, e V_{DC} a tensão da conexão paralela de ambos, deve-se conectar os dois sistemas de armazenamento a conversores de potência, como apresentado na figura 11 (Jian Cao; EMADI, 2012).

Figura 11 – Estrutura desacoplada com dois conversores CC-CC



Fonte: Adaptado de Jian Cao e Emadi (2012)

A configuração com dois conversores CC-CC em paralelo tem alta precisão em desacoplar a potência demandada da bateria e SC, podendo ser realizado um controle apropriado. Esta configuração oferece alta estabilidade e flexibilidade nas operações, fluxo de corrente suave, melhor solução para variação de tensão; porém possui complexidade de controle e aumento de comutadores de semicondutor (GETHA; SUBRAMANI, 2017).

Segundo Vazquez et al. (2010), conversores de potência aplicados a sistema de armazenamento de energia (do inglês *Energy Storage System*) (ESS) devem:

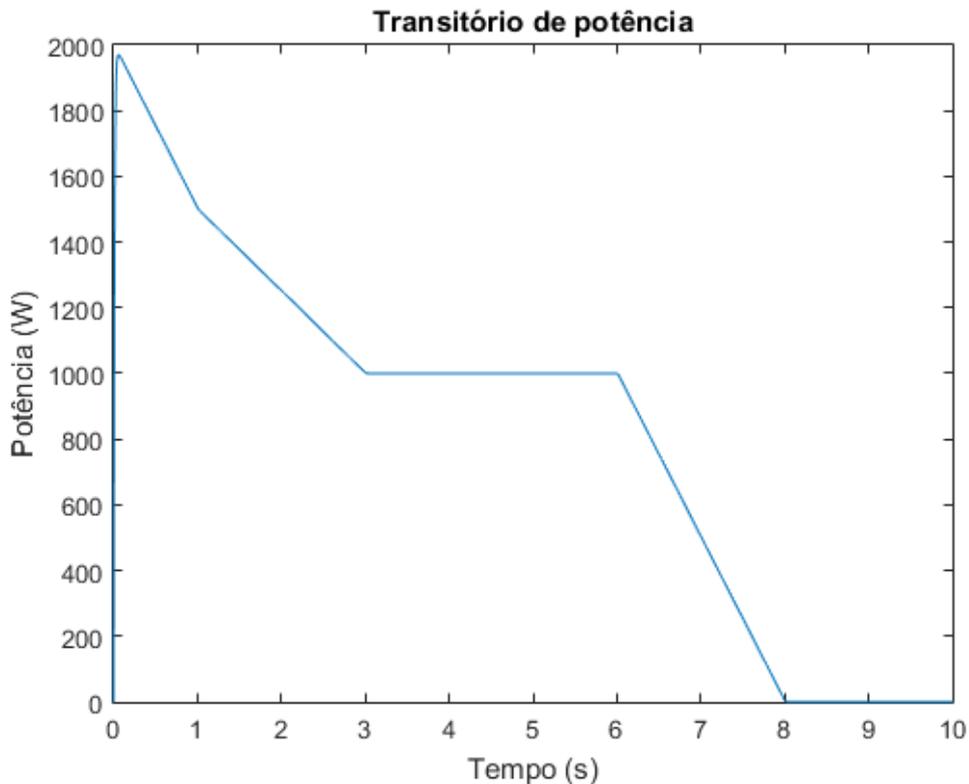
1. gerenciar fluxo de potência bidirecionalmente, controlando carga e descarga do sistema;
2. ter alta eficiência;
3. ter resposta rápida (para aplicações com regulação de frequência);
4. ter baixo peso e tamanho (para aplicações de transporte);
5. suportar picos de potência (aplicações de corte de picos);

6. gerenciar alta potência nominal (aplicações de nivelamento de carga).

A alta capacidade de carga e descarga do SC possibilita uma forma efetiva de armazenar energia regenerativa de frenagem, e, utilizando um sistema com conversores em paralelo, é possível admitir fluxo de potência negativo somente no SC (GEETHA; SUBRAMANI, 2017). Essa opção gera a necessidade de um conversor Buck-Boost no SC, atuando como elevador quando em descarga, e abaixador quando em carga.

O HESS é submetido a um perfil de potência que caracterize as acelerações, paradas e os períodos de velocidade constante, presentes em um ciclo de condução urbano. Ou seja, é necessário suportar picos de potência, sequências contínuas e a frenagem regenerativa. O transitório elaborado é apresentado na figura 12.

Figura 12 – Transitório de potência demandada



Fonte: Autoria própria

A partir desse transitório, deseja-se controlar o momento mais adequado para se utilizar a energia proveniente da bateria, e a energia provida pelo SC. Para fazer isso foi desenvolvido um controlador fuzzy.

3.2 CONTROLE DO GERENCIAMENTO DE POTÊNCIA

3.2.1 Controlador Fuzzy

Desenvolvendo estratégias de controle é possível reduzir algumas restrições no HESS, mas uma estratégia mal escolhida pode levar a ter um HESS bateria-SC menos eficiente que um sistema sem SC (ALLEGRE; BOUSCAYROL; TRIGUI, 2009).

Para desenvolver o controlador, os conjuntos fuzzy foram definidos conforme a tabela 4. A primeira entrada fuzzifica a potência requerida pelo sistema, enquanto que a segunda trata sua derivada, possibilitando melhor percepção dos picos e variações da demanda, o que é importante na determinação da potência a ser fornecida pelo SC. Para obter ainda melhor controle da gestão de potência, é considerado a tensão do SC, terceira variável de entrada, sendo importante para verificar disponibilidade de potência do SC de forma a não ocorrer saturação. As variáveis de saída são a potência demandada pelo SC, e a potência demandada pela bateria, relacionadas respectivamente em 8 e 7 funções. A saída relativa ao SC possui uma função a mais que trata valores negativos de potência, particularidade da frenagem regenerativa, em que o SC absorverá potência.

Tabela 4 – Funções de pertinência

Entradas	Funções de pertinência							
PwReq	PSB	PB	PPB	PM	PPA	PA	PSA	
dPwReq	Negativo		Zero	Positivo				
VsC	Baixo		Médio	Alto				
Saída	Funções de pertinência							
P-SC	N	PSB	PB	PPB	PM	PPA	PA	PSA
P-BAT	PSB	PB	PPB	PM	PPA	PA	PSA	

Fonte: Autoria própria.

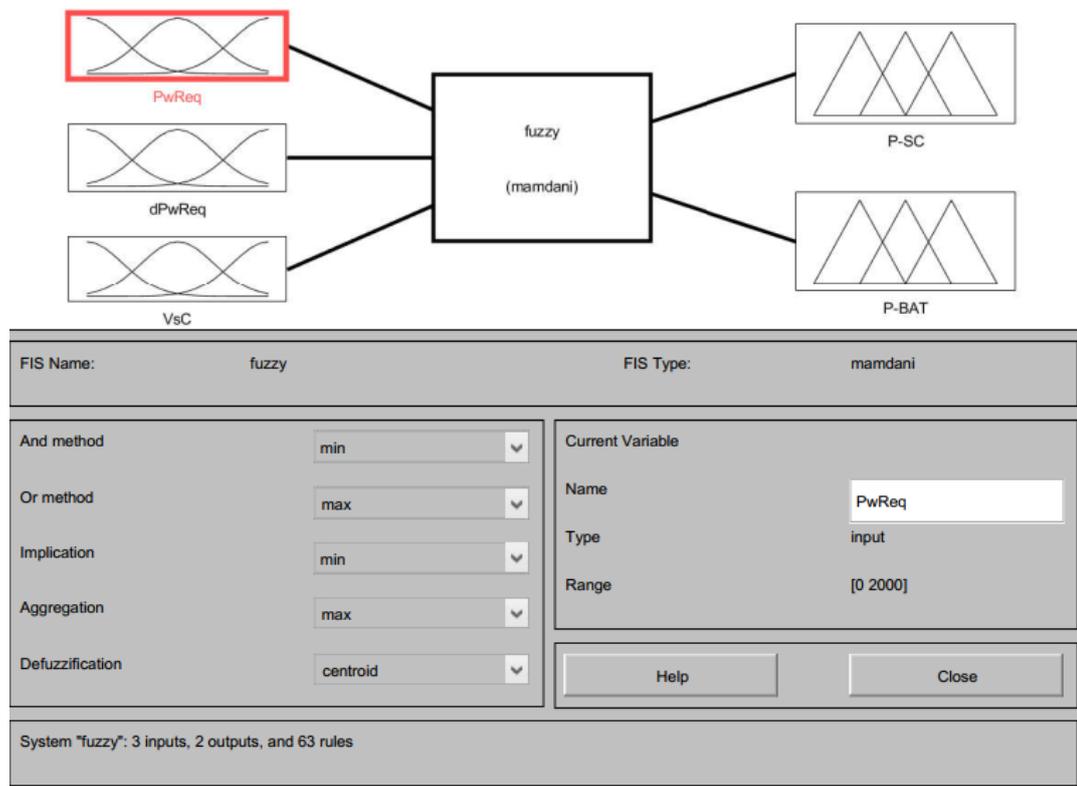
Para representar as variáveis de potência $PwReq$ (entrada), $P-SC$ (saída) e $P-BAT$ (saída) foram utilizadas funções gaussianas, uma vez que estratégias de transição suave entre SC e baterias evitam picos de corrente, causando menos danos a bateria (ALLEGRE; BOUSCAYROL; TRIGUI, 2009). As demais variáveis — $dPwReq$ (entrada) e VsC (entrada) —, foram representadas por triangulares, devido a facilidade de implementação e tratamento, diminuindo posteriormente o número de parâmetros a serem otimizados pelos métodos de CI.

Para a entrada $PwReq$ são 7 funções de pertinência que descrevem o espaço, sendo elas: PSB (Potência Super Baixa), PB (Potência Baixa), PPB (Potência Pouco Baixa), PM (Potência Média), PPA (Potência Pouco Alta), PA (Potência Alta), PSA (Potência Super Alta). Para $dPwReq$, são três: Negativo, Zero e Positivo. Já a entrada VsC foi subdividida nas funções: Baixo, Médio e Alto.

Para a saída $P-SC$, o universo de discurso foi descrito por: N (Negativo), PSB (Potência Super Baixa), PB (Potência Baixa), PPB (Potência Pouco Baixa), PM (Potência Média), PPA (Potência Pouco Alta), PA (Potência Alta), PSA (Potência Super Alta). Enquanto que a saída $P-BAT$, foi descrita por: PSB (Potência Super Baixa), PB (Potência Baixa), PPB (Potência Pouco Baixa), PM (Potência Média), PPA (Potência Pouco Alta), PA (Potência Alta), PSA (Potência Super Alta) (TRUDES et al., 2017).

Trata-se de um fuzzy tipo mamdani, com defuzzificação pelo método da centróide. O método de interligação “E” foi definido mínimo, o método “Ou” não foi utilizado. A implicação foi definida como mínima, e agregação máxima. O controlador elaborado é apresentado na figura 13 (TRUDES et al., 2017).

Figura 13 – Controlador lógico fuzzy



Fonte: Autoria própria

A codificação do fuzzy para o vetor de parâmetros a serem otimizados se deu em dois conjuntos distintos de variáveis: as relativas às funções de pertinência, e as relativas às regras de inferência. O primeiro contém as variáveis que constroem as funções sendo elas triangulares ou gaussianas, e o segundo, as variáveis que definem a função de saída de cada regra.

Para construir as funções gaussianas utiliza-se duas variáveis: relação de abertura e ponto central. Para construir as triangulares, utiliza-se: ponto da base esquerda, ponto do pico e ponto da base direita. Nas triangulares, a interligação permitida entre funções colaterais (em que o ponto esquerdo é o pico da anterior, e o pico da referencial é o direito da anterior) faz com que diminua a quantidade de variáveis a serem tratadas pelos algoritmos, ganhando em processamento.

Já as variáveis da base de regra definem qual será a função de pertinência de saída codificadas de 0 a K , em que 0 é saída nula e K é o número de funções de pertinência da saída em questão, ou seja: $0 \leq K_1 \leq 8, (K_1 \in \mathbb{N})$ para a potência do SC (*P-SC*), $0 \leq K_2 \leq 7, (K_2 \in \mathbb{N})$ para a potência da bateria (*P-BAT*). Como todas as possibilidades de funções de saída (apresentadas na tabela 9 no apêndice) são mapeadas, a opção de saída nula permite eliminar uma (e apenas uma) das variáveis linguísticas de saída relacionadas, possibilitando que uma relação de entrada tenha apenas uma saída definida.

Neste trabalho é proposto dois tipos de otimizações das variáveis: otimizar somente as variáveis relativas às regras; ou, otimizar as variáveis das regras e as que constroem as funções de pertinência, permitindo sua movimentação atrás do seu melhor posicionamento dentro do universo de discurso. Com isso, deseja-se visualizar qual a real melhora que o ajuste de posicionamento das funções traz para o sistema, e perceber se otimizar somente as regras é computacionalmente mais eficiente.

O espaço de busca dos algoritmos é limitado pelos limites inferiores e superiores. Na tabela 5 são apresentados os limites definidos para a proposta primeira: otimizar somente as 126 variáveis relativas à base de regras. Na tabela 10 são apresentados os limites para a segunda proposta: otimizar as funções e as regras, que totalizam 175 variáveis.

Como na proposta 126 não há otimização das funções de pertinência, na tabela 6 são apresentados os parâmetros que constroem as funções de pertinência, definidos a partir de valores médios entre os limites inferiores e superiores da pro-

Tabela 5 – Limites de busca para Proposta 126

Variável	1 2 3 4 5 ... 63	64 65 66 ... 126
Lim. Superior	8 8 8 8 8 ... 8	7 7 7 ... 7
Lim. Inferior	0 0 0 0 0 ... 0	0 0 0 ... 0

Fonte: Autoria própria.

posta 175 (tabela 10).

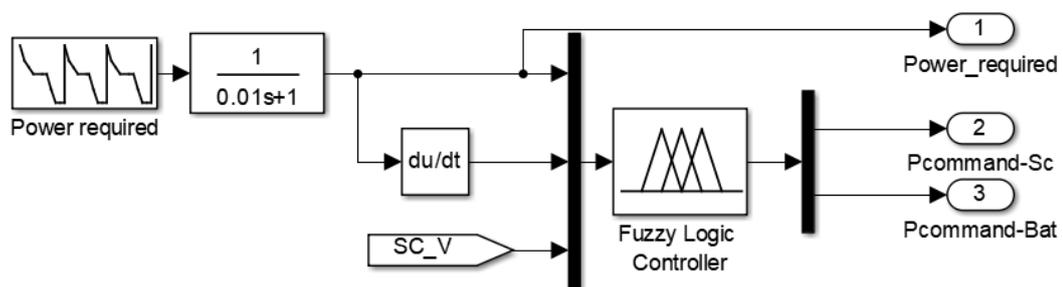
Tabela 6 – Parâmetros das funções de pertinência da Proposta 126

Variável	Parâmetros															
PwReq	90	-25	125	250	95	675	125	1000	125	1350	90	1750	125	2000		
dPwReq	1200						0									
VsC	0				8				22							
P-SC	125	-300	115	0	115	250	115	600	115	1000	115	1400	115	1800	115	2100
P-BAT	115	-35	85	125	85	315	85	515	85	715	100	850	115	1000		

Fonte: Autoria própria.

Na figura 14 é apresentado o diagrama de blocos elaborado para desenvolver o PMC utilizando o FLC, em que *Power required* é o transitório de potência demandada, que passa por um filtro de primeira ordem, então seguido pelo multiplexador que envia o transitório junto de sua derivada e a tensão do SC para o FLC. A saída 1 do sistema é a potência requerida, a saída 2 é a potência demandada somente do SC, enquanto a saída 3 é a potência demandada da bateria. Essas saídas serão direcionadas conforme apresentado na figura 9.

Figura 14 – Diagrama de blocos PMC utilizando fuzzy



Fonte: Autoria própria

Para comparação de desempenho, o controlador fuzzy como método de controle de gestão de potência é comparado com um limitador. Trata-se de um limitador de taxa que limita a primeira derivada do sinal, fazendo com que a sua saída não mude mais rápido que o limite especificado. Esse valor (T_x) é calculado usando a equação 16, em que $u(i)$ e $t(i)$ são a corrente e o tempo, e $y(i-1)$ e $t(i-1)$ são a saída

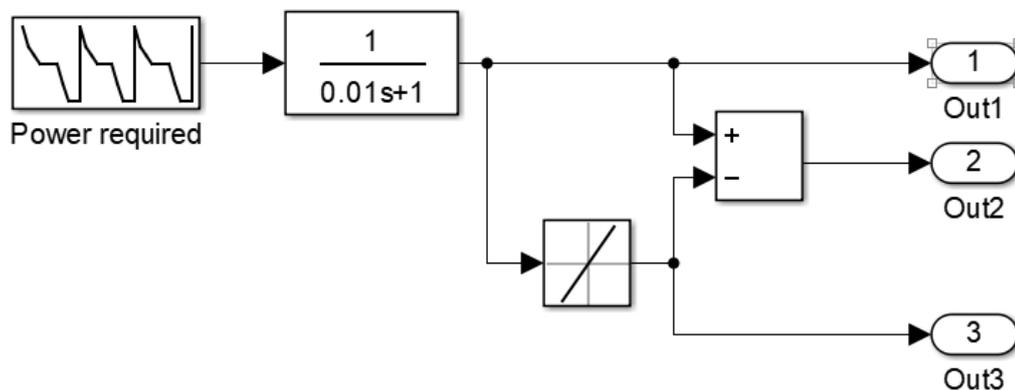
e o tempo imediatamente anterior. A saída é determinada comparando Tx a taxa de variação de subida R (definido $R = 300$) e a taxa de variação de descida F (definido $F = -300$) conforme a equação 17.

$$Tx = \frac{\mathbf{u}(i) - \mathbf{y}(i - 1)}{\mathbf{t}(i) - \mathbf{t}(i - 1)} \quad (16)$$

$$\left\{ \begin{array}{l} \text{se } Tx > R, \quad \mathbf{y}(i) = \Delta t \cdot R + \mathbf{y}(i - 1) \\ \text{se } Tx < F, \quad \mathbf{y}(i) = \Delta t \cdot F + \mathbf{y}(i - 1) \\ \text{se } F \leq Tx \leq R, \quad \mathbf{y}(i) = \mathbf{u}(i) \end{array} \right. \quad (17)$$

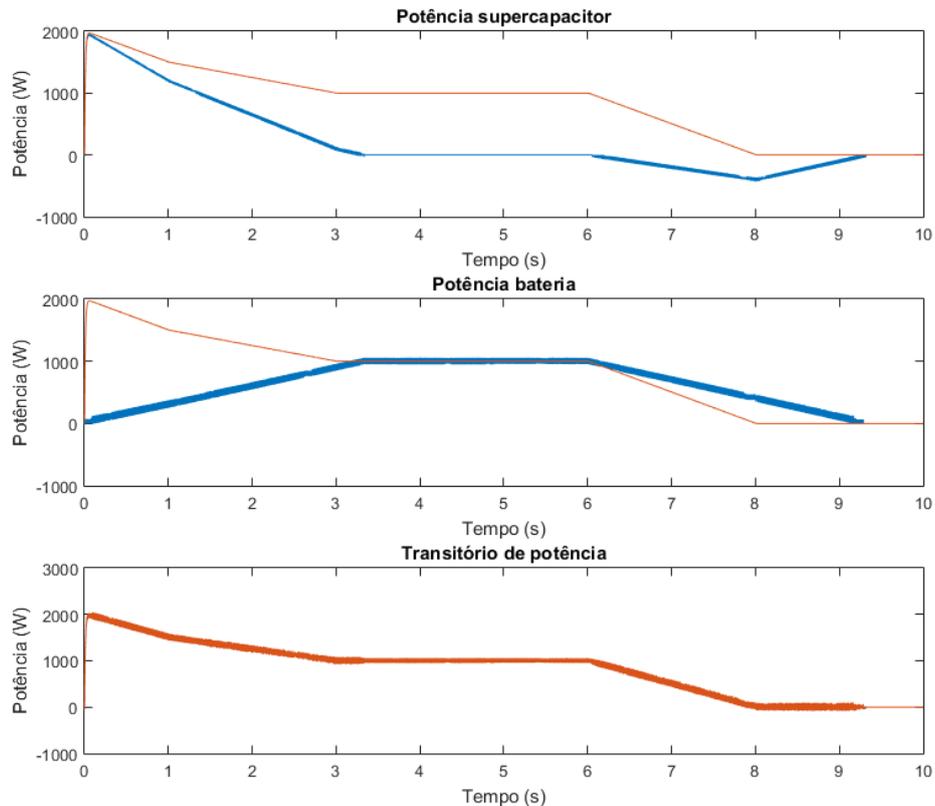
Na figura 15 é apresentado o diagrama de blocos do PMC implementado, em que *Power required* é o transitório de potência demandada, que passa por um filtro de primeira ordem, seguido pelo limitador apresentado, que dividirá a potência entre os dispositivos. Da mesma forma que o FLC, a saída 1 do sistema é a potência requerida, a saída 2 é a potência demandada somente do SC, enquanto a saída 3 é a potência demandada da bateria, que são direcionadas da mesma forma que o FLC na figura 9, uma vez que o substitui. Na figura 16 é apresentado como a potência é distribuída entre os dispositivos de armazenamento com a estratégia em questão para o transitório proposto.

Figura 15 – Diagrama de blocos PMC utilizando limitador



Fonte: Autoria própria

Figura 16 – Distribuição de potência com utilização do limitador



Fonte: Autoria própria

3.2.2 Algoritmo genético

O algoritmo genético foi implementado utilizando métodos de propostas consolidadas para a aplicação em questão, na qual cada indivíduo carregará as informações pertinentes a construção do controlador fuzzy.

A processo de otimização se inicia com uma população inicial de candidatos gerada aleatoriamente. Para inicializar cada indivíduo, é randomizado cada valor a partir de seu limite inferior e superior definidos com base no conhecimento prático e experimental, respeitando as condições do respectivo conjunto numérico.

O processo de avaliação dos indivíduos é feito simulando-se o controlador na planta desenvolvida e extraído dela o transitório de potência fornecido, suprido pelo SC e bateria juntos, e o transitório de potência requerido, demandado pelo sistema. Para desenvolver o cálculo de *fitness* é utilizado a integral do erro absoluto (IAE – do inglês *integral absolute error*), apresentado na equação (18), comumente utilizada em controles PID (Maiti et al., 2008). Com essa equação obtém-se o erro entre a

potência fornecida e a requerida, sendo que, como deseja-se que esse erro seja o menor possível, é obtido a sua inversa, apresentada na equação (19). Tem-se então a fórmula de cálculo do *fitness*.

$$I_k = \left| \sum_{k=2}^z \frac{\text{erro}(k) + \text{erro}(k-1)}{2} (\text{tempo}(k) - \text{tempo}(k-1)) \right| \quad (18)$$

$$\text{Fit} = \frac{1}{1 + I_k} \quad (19)$$

No processo de seleção, é proposto torneios eliminatórios, que se mostraram mais eficientes que roletas em testes prévios. Em específico, o torneio desenvolvido funciona selecionando aleatoriamente N indivíduos da população e compara-os, salvando o melhor. Isso faz com que as chances de selecionar um indivíduo com *fitness* alto aumentem quanto maior for N , sem perder a aleatoriedade. Entretanto, o valor dessa pressão seletiva deve ser balanceado de forma a manter a diversidade da população, evitando convergências prematuras. A intensidade seletiva é equacionada pela integral apresentada em Equação 20, percebendo-se que quanto maior o número de indivíduos N envolvidos no torneio, maior o valor I de intensidade, em que x e y são os valores de aptidão da população (PACHECO, 2019).

$$I = \int_{-\infty}^{\infty} N \cdot x \cdot \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{x^2}{2}} \cdot \left(\int_{-\infty}^x \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{y^2}{2}} dy \right)^{N-1} dx \quad (20)$$

Estatisticamente, a probabilidade combinatória de se selecionar um indivíduo com *fitness* acima da média pode ser escrito como segue na equação 21.

$$P = \left[1 - \left(\frac{I_r}{T} \right)^N \right] \cdot 100 \quad (21)$$

em que:

P é a probabilidade de seleção de indivíduos bons em percentual;

I_r é a quantidade de indivíduos ruins (abaixo da média de *fitness*);

T é o total de indivíduos da população;

N é o número de torneios.

Foi proposto neste trabalho duas formas de torneio eliminatório: torneio com N fixo, e torneio com N variável. No primeiro caso, ficou definido um valor fixo de $N = 3$ seleções. Em testes prévios, três seleções apresentaram resultados melhores do que seis e duas, se mostrando um valor adequado para o estudo em questão.

Para o torneio variável, foi proposto uma equação em que dependesse diretamente do tamanho da população, e inversamente da geração, porém, arredondando o valor para o número inteiro mais próximo, uma vez que N pertence ao conjunto dos números naturais. Essa relação foi ponderada de forma a considerar que uma pressão seletiva muito alta faz com que o algoritmo perca diversidade e posteriormente qualidade da solução, porém influencie de forma positiva a eliminar indivíduos desalinhados nas primeiras gerações. A proposta é apresentada na equação 22.

$$N = \frac{\sqrt{T}}{ai} + b \quad (22)$$

em que:

T é o tamanho da população;

i é a geração atual;

a é o coeficiente angular, definido 2;

b é o número mínimo de seleções, definido 3.

Após selecionar os dois indivíduos pais, realiza-se o crossover. A troca genética em questão é um crossover de 3 pontos, sendo dois pontos aleatórios e um fixo. A ideia central do método é dividir conjuntos distintos, e realizar um crossover de ponto aleatório para cada conjunto, sendo possível desenvolver individualmente cada conjunto (LEITE, 2009) (KOSHIYAMA; VELLASCO; TANSCHHEIT, 2013). O ponto fixo divide então as regras respectivas ao SC e as relativas a bateria em dois subconjuntos submetidos a crossovers de ponto aleatório. Desenvolvendo individualmente cada subconjunto é possível convergir cada um independentemente, aumentando a velocidade de convergência.

A mutação desenvolvida é relativamente simples. Sorteia-se aleatoriamente um indivíduo e, dentro deste, aleatoriamente um gene. Essa variável é gerada novamente seguindo os parâmetros de inicialização, e o indivíduo é devolvido à população. Foi implementado um adendo em código que, quando o melhor fitness da geração não varia depois de três gerações, a taxa de mutação é aumentada em 10% para a próxima linhagem. Isso permite ao código que, quando estiver preso em algum máximo, ele possa aumentar as chances de expandir a sua busca para um ponto diferenciado.

3.2.3 Otimização por enxame de partículas

O PSO é um algoritmo de implementação simples, mas que apresenta resultados muito robustos. A inicialização de suas variáveis, assim como a avaliação do *fitness* de seus indivíduos, se dá da mesma forma que o GA, uma vez que aplicado ao mesmo sistema.

Foi implementada usando sua formulação básica, onde cada indivíduo é representado por um vetor x_i , sua posição espacial, e em cada geração tem seu valor atualizado seguindo um cálculo vetorial de velocidades, apresentado no capítulo 2.

Cada partícula do sistema percorre o espaço de busca salvando sua posição sempre que passa por um ponto de *fitness* melhor que os já visitados anteriormente por ela. Essa posição é ponderada no cálculo da velocidade a partir do parâmetro cognitivo c_1 e um valor aleatório r_1 . Da mesma forma, a melhor posição global visitada entre todas as partículas é salva e ponderada no cálculo da velocidade pelo parâmetro social c_2 , e por um valor aleatório r_2 . Esses parâmetros, c_1 e c_2 , foram definidos, respectivamente, por 1 e 2.

Enquanto transita pelo espaço de busca, a nova velocidade da partícula é também influenciada pela inércia de sua velocidade anterior, o parâmetro de inércia w . Esse parâmetro foi submetido a estudo, avaliando se, para o problema em questão, é mais eficiente um valor fixo ou um valor variável de inércia. O valor fixo definido foi 0.5, já o variável é definido pela equação 23, onde $w_{max} = 1$ e $w_{min} = 0.3$ (WONG; WANG; LI, 2008).

$$w = w_{max} - (w_{max} - w_{min}) \cdot \frac{i}{G} \quad (23)$$

em que:

w_{max} é o limite inicial;

w_{min} é o limite final;

i é o número da geração atual;

G é o número total de gerações.

4 RESULTADOS E DISCUSSÃO

Neste capítulo serão apresentados os resultados simulados. A discussão é desenvolvida seguindo a ordem de apresentação: resultados GA, resultados PSO, comparação de desempenho entre ambos. Cada proposta foi simulada mais de uma vez, de forma a obter resultados concretos e possibilitar a análise em gráficos de dispersão. Devido ao tempo limitado disponível, foram simuladas cinco vezes cada proposta.

Primeiramente é feita a análise do erro dos controladores obtidos em cumprir a potência requerida. O estudo foi feito priorizando a eficiência dos dispositivos de armazenamento, então quanto mais próximo chegar o desempenho do controlador ao transitório demandado, mais eficiente é o HESS, além de claramente conseguir fornecer mais precisamente a potência demandada ao sistema. Tendo um PMC eficiente é possível aliviar a carga sobre a bateria, aumentando a autonomia do conjunto híbrido.

As simulações foram organizadas da seguinte forma:

1. GA

- a) Proposta 126: otimizar 126 parâmetros;
 - i. GA1: número de torneios fixo
 - ii. GA2: número de torneios variável
- b) Proposta 175: otimizar 175 parâmetros;
 - i. GA1: número de torneios fixo
 - ii. GA2: número de torneios variável

2. PSO

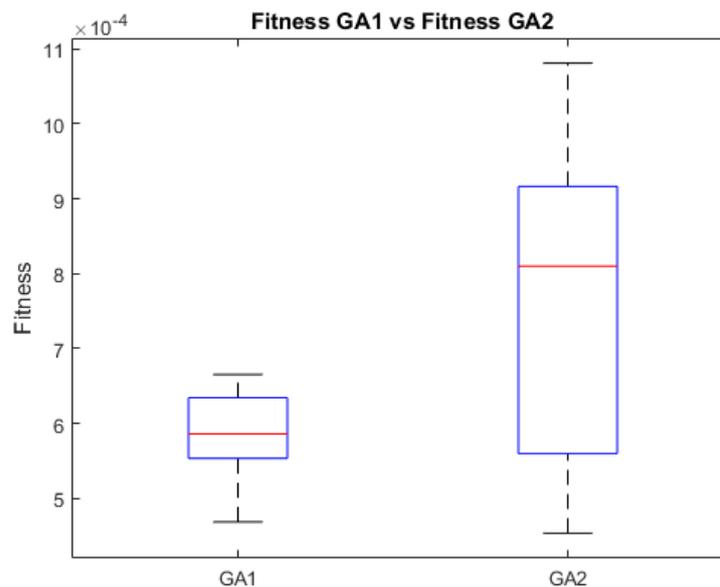
- a) Proposta 126: otimizar 126 parâmetros;
 - i. PSO1: coeficiente de inércia fixo
 - ii. PSO2: coeficiente de inércia variável
- b) Proposta 175: otimizar 175 parâmetros;
 - i. PSO1: coeficiente de inércia fixo
 - ii. PSO2: coeficiente de inércia variável

Para realizar as simulações foi utilizado computador com processador Intel Core i3-4160 3,6 GHz, com 8 GB de RAM, e um SSD UV400 de até 90.000 IOPS e 15.000 IOPS de velocidade de leitura e escrita. As simulações completas de cada algoritmo proposto, para populações de 60 indivíduos em 30 gerações, levaram em torno de 144 horas (ou 6 dias), ou seja, cada cálculo de *fitness* levou aproximadamente 1 minuto.

4.1 ALGORITMO GENÉTICO

Para realizar as simulações do GA foi definido um tamanho de população de 60 indivíduos com limite de 30 gerações. Na figura 17 é apresentado a dispersão de *fitness* dos resultados obtidos a partir das simulações do GA. A marcação mais superior representa o valor máximo, enquanto que o traço mais inferior o mínimo atingido pelo conjunto. Na caixa azul, a marca vermelha centralizada representa a mediana, enquanto que os limites são os quartis de dispersão, sendo que o quartil superior correspondente a marca de 75% dos dados, e o quartil inferior 25% dos dados.

Figura 17 – Dispersão de *fitness* proposta GA_126



Fonte: Autoria própria

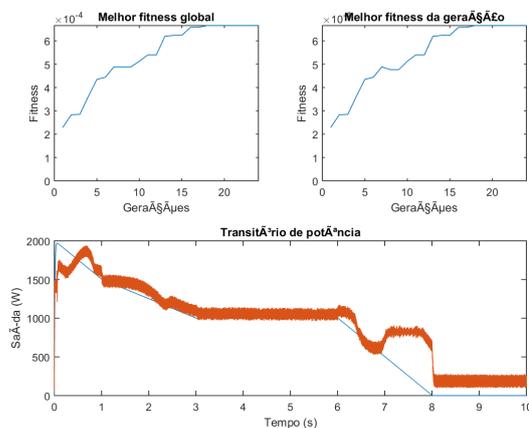
A proposta de número de torneios variáveis (GA2) apresentou maior dispersão, porém trouxe resultados melhores, com um *fitness* máximo de 0,001081, contra um *fitness* máximo de 0,0006656 para o GA1. Além de obter uma solução melhor, a

mediana do GA2 é também mais alta que do GA1. Nas figuras 18a e 18b são apresentados os desempenhos dos controladores obtidos em cumprir o transitório de potência imposto, e a evolução do *fitness* no decorrer das gerações. A linha azul representa a demanda de potência, enquanto que a faixa alaranjada é a potência fornecida pelo HESS.

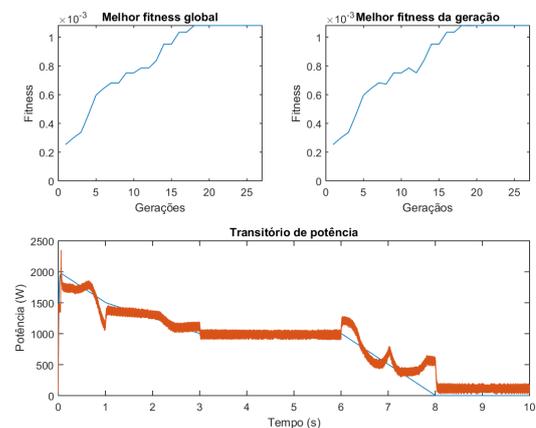
Nota-se que o controlador obtido pelo torneio variável teve melhor desempenho na transição para 0 W, que representa a frenagem regenerativa. Ou seja, o controlador conseguiu encontrar regras que lidam melhor com essa demanda, que deve ser balanceada utilizando o SC.

Figura 18 – Resultados proposta GA_126

(a) GA1



(b) GA2



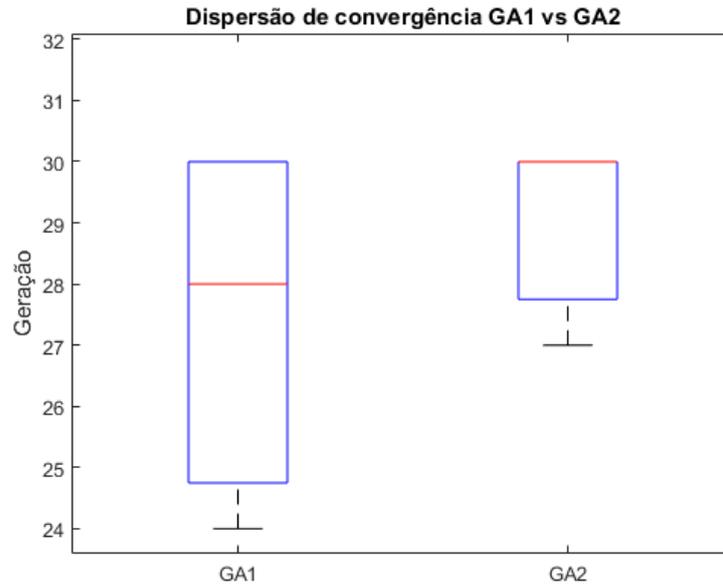
Fonte: Autoria própria.

Como o GA é um algoritmo que consegue convergir sua população como um todo, encontrando um valor final, é possível analisar a dispersão de convergência entre os algoritmos propostos.

Na figura 19 é apresentado a comparação dos diagramas de caixa das propostas. Analisando a mediana, percebe-se o GA1 (3 torneios fixos) com convergência mais rápida em geral. Como o limite de gerações proposto foram 30 gerações, nota-se que, principalmente para o GA2 (torneios variáveis), isso foi um gargalo para obtenção de possíveis resultados melhores em algumas iterações, uma vez que o algoritmo sofreu uma parada forçada, não encontrando sua solução natural final.

Na figura 20 é apresentado a dispersão de *fitness* dos resultados obtidos a partir das simulações do GA 175 variáveis. Percebe-se que, apesar de apresentar um *fitness* maior, de 0,001141, o GA1 apresenta uma mediana relativamente mais baixa

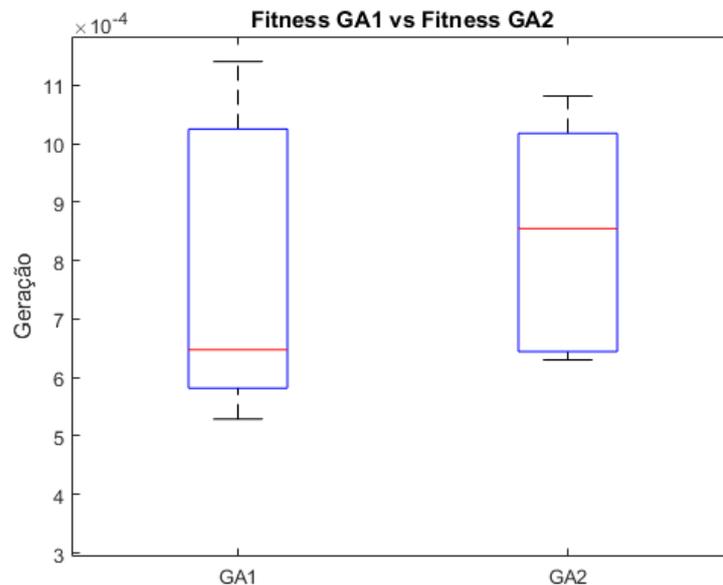
Figura 19 – Dispersão de convergência proposta GA_126



Fonte: Autoria própria

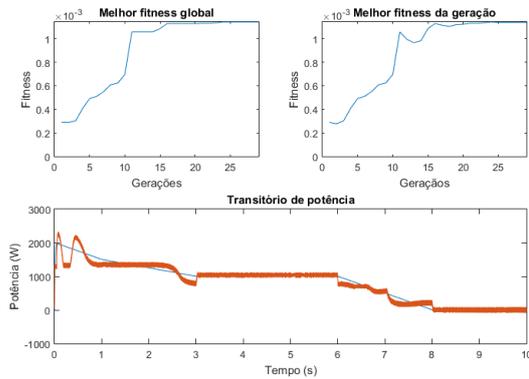
do que o GA2, que apresentou *fitness* máximo de 0,001082. Entretanto, novamente o GA2 apresentou maior dispersão de *fitness*. Nas figuras 21a e 21b são apresentados os desempenhos dos melhores controladores encontrados em cumprir o transitório de potência, e a evolução do *fitness* no decorrer das gerações. Apesar da proposta GA2 oscilar menos e estar mais próxima do transitório ideal, a proposta GA1 apresentou melhor desempenho na transição de frenagem, sendo superior pelo cálculo de *fitness*.

Figura 20 – Dispersão de *fitness* proposta GA_175

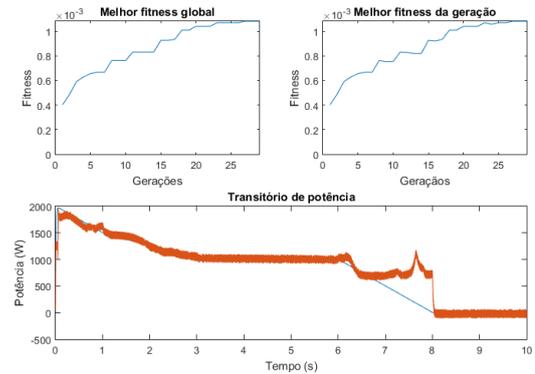


Fonte: Autoria própria

Figura 21 – Resultados proposta GA_175
(a) GA1



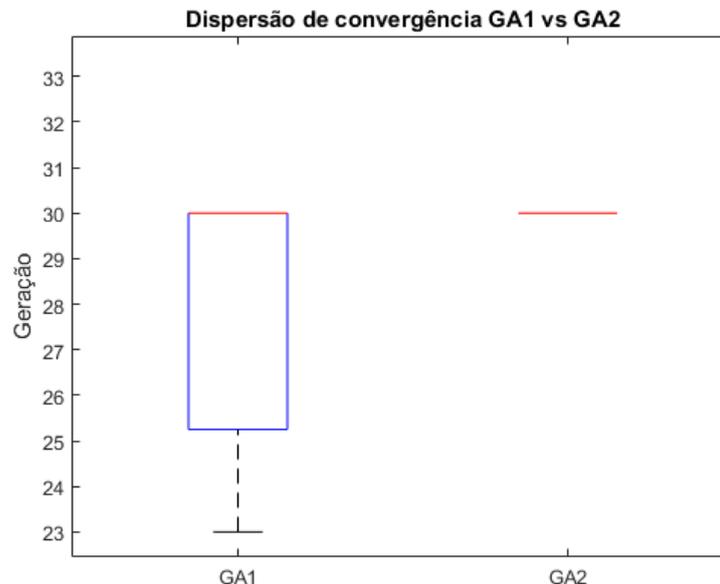
(b) GA2



Fonte: Autoria própria.

A dispersão de convergência, apresentado na figura 22, apresenta que novamente a proposta de torneios variáveis teve sua parada forçada influenciando mais vezes do que na primeira proposta. Mesmo tendo uma convergência mais lenta, as soluções do GA2 apresentaram um desempenho tão bom quanto o GA1, sendo possível que com mais gerações talvez alcançasse um desempenho ainda melhor do que o apresentado.

Figura 22 – Dispersão de convergência proposta GA_175

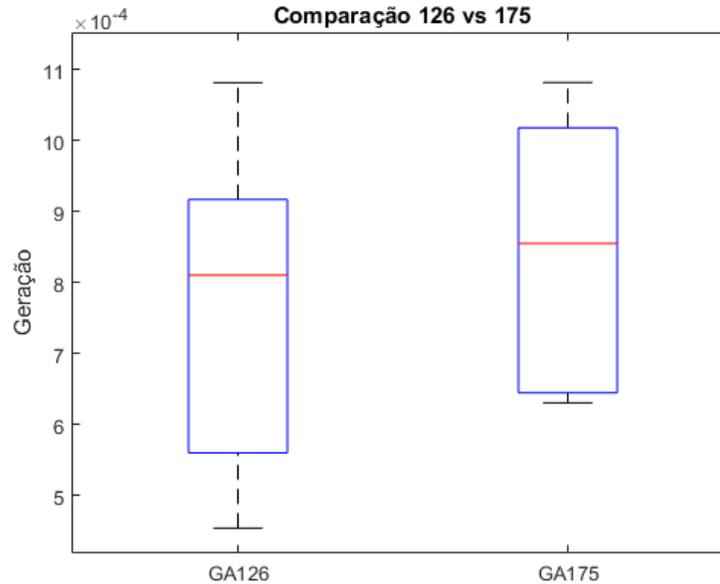


Fonte: Autoria própria

Na figura 23 é apresentado a comparação de *fitness* entre a melhor proposta de otimização de 126 parâmetros com a de 175, avaliadas pela mediana. Em ambas propostas, o GA de torneios variáveis apresentou melhor desempenho geral, mesmo

que no segundo caso (175 parâmetros), por pouca diferença, não tenha obtido o controlador com melhor *fitness*.

Figura 23 – Comparação 126 e 175 parâmetros



Fonte: Autoria própria

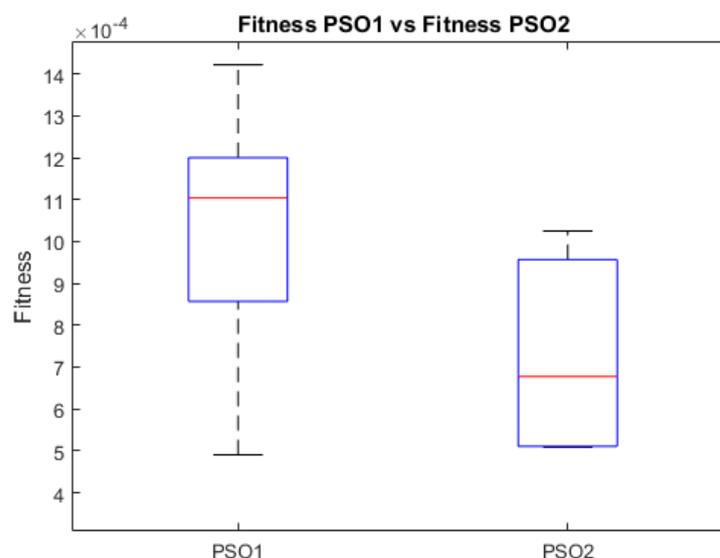
A partir dos resultados apresentados, percebe-se que, para o GA1, otimizar os parâmetros das funções de pertinência trouxe melhoria para obtenção de melhores soluções, enquanto que para o GA2, o ganho foi relativamente menor, mostrando que sua proposta possui uma busca local melhor, já que independentemente da inclusão dos parâmetros das funções de pertinência, que são importantes para o ajuste fino da solução, encontrou respostas equivalentes. A proposta de torneios variáveis desempenhou como esperado, apresentando um início mais forte, atingindo *fitness* mais alto nas primeiras gerações, e ainda assim apresentando bons resultados finais. Entendendo-se que pressões seletivas fixas altas, por exemplo 6 torneios, tendem a convergir prematuramente aos valores encontrados nas primeiras gerações, o dinamismo da proposta de número de torneios variáveis conseguiu associar bem o início forte de uma pressão seletiva alta com a alta diversidade que uma pressão seletiva baixa proporciona, sendo nas duas propostas de quantidade de parâmetros predominante no desempenho geral, avaliado pela mediana de sua dispersão.

4.2 OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

Para realizar as simulações do PSO foi definido um tamanho de população de 60 partículas com limite de 30 gerações. A partir dos gráficos *boxplot*, é analisado a dispersão de desempenho das propostas feitas, porém não é analisado a dispersão de convergência, uma vez que o PSO não consegue convergir sua população a uma única posição. Com isso, todas as simulações foram paradas com o limite de 30 gerações.

Na figura 24 é apresentado a dispersão de *fitness* dos resultados da proposta com 126 parâmetros a serem otimizados. Percebe-se que, apesar de apresentar uma dispersão maior, o PSO1 (coeficiente fixo) apresentou resultados melhores, com um *fitness* máximo de 0,001422 contra 0,001025 do PSO2 (coeficiente variável). Nas figuras 25a e 25b são apresentados os desempenhos dos controladores em cumprir o transitório de potência, e a evolução do *fitness* no decorrer das gerações. Nota-se que o PSO1 obteve um controlador muito mais preciso, mas ambos apresentaram a mesma dificuldade no ponto de transição para 0 W. No correr das gerações, nota-se que o coeficiente de inércia fixo (PSO1) conseguiu evoluir seu *fitness* continuamente, enquanto que o coeficiente de inércia variável teve dificuldades para encontrar melhor desempenho.

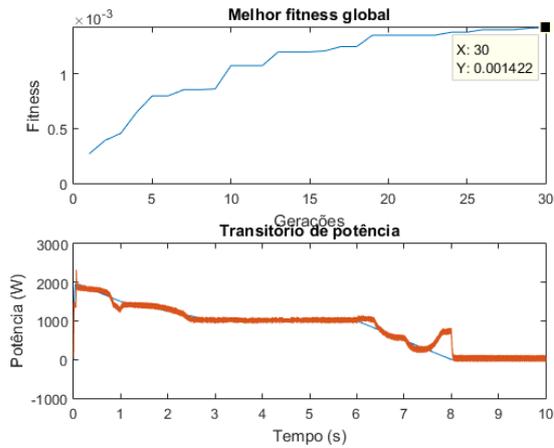
Figura 24 – Dispersão de *fitness* proposta PSO_126



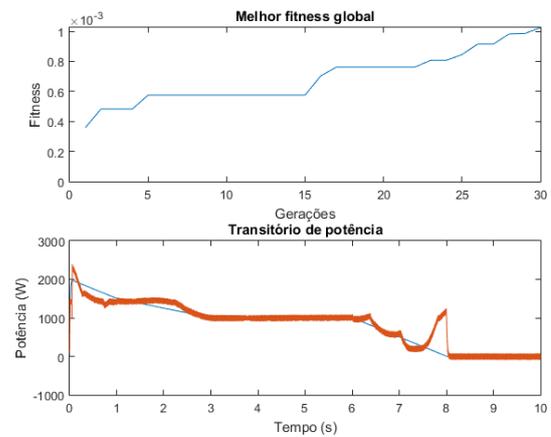
Fonte: Autoria própria

Na figura 26 é apresentado a dispersão de *fitness* dos resultados da proposta

Figura 25 – Resultados proposta PSO_126
(a) PSO1



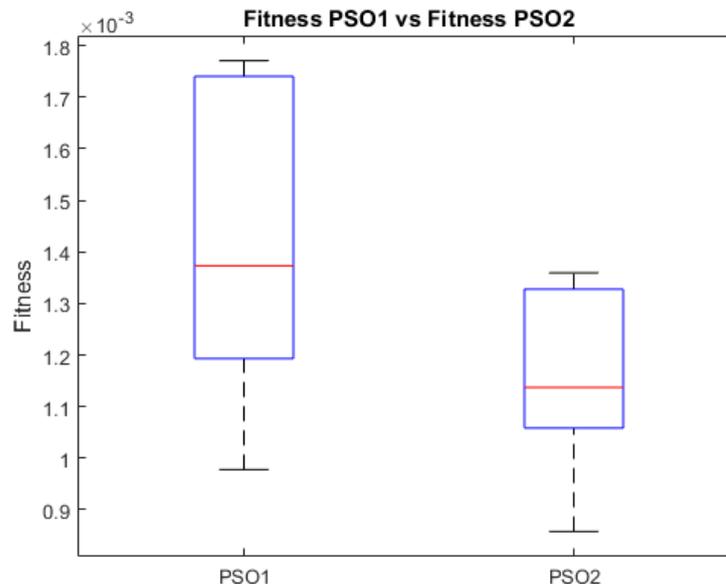
(b) PSO2



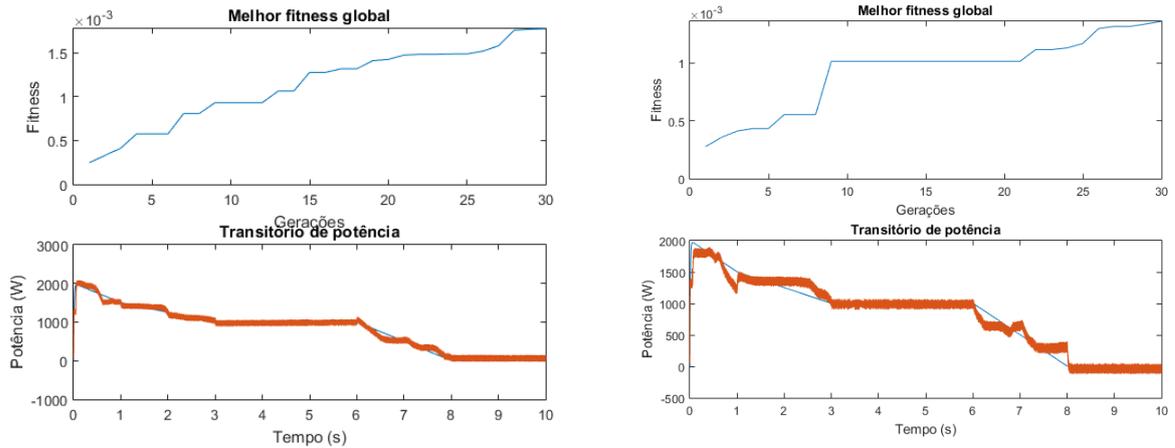
Fonte: Autoria própria.

com 175 parâmetros a serem otimizados. Nota-se que novamente, apesar de apresentar uma dispersão grande, o PSO1 apresentou resultados melhores, com um *fitness* máximo de 0,001771 contra 0,001359 do PSO2. Nas figuras 27a e 27b, são apresentados os desempenhos dos controladores em cumprir o transitório de potência, e a evolução do *fitness* no decorrer das gerações. Percebe-se que o controlador encontrado conseguiu responder quase integralmente a potência demandada, enquanto que o PSO2 novamente apresentou dificuldades em fazer a busca, ficando por muitas gerações com a melhor posição encontrada estagnada.

Figura 26 – Dispersão de *fitness* proposta 175



Fonte: Autoria própria



(a) PSO1

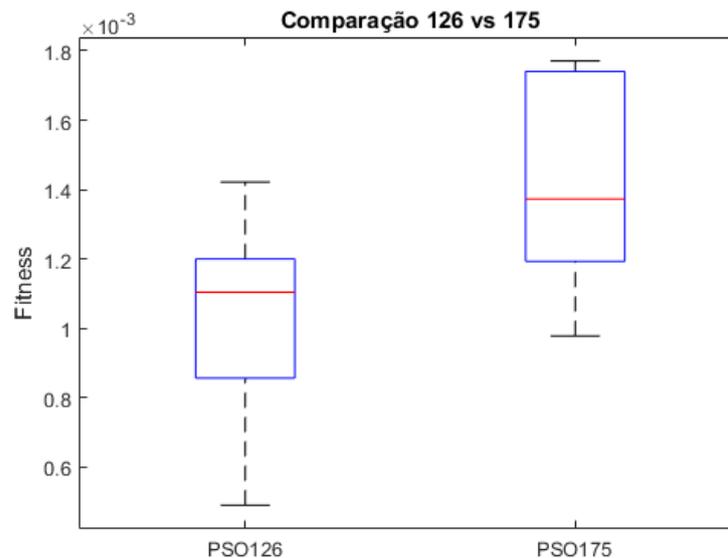
(b) PSO2

Figura 27 – Resultados proposta PSO_175

Fonte: Autoria própria.

A partir dos resultados apresentados, percebe-se que, para o PSO, otimizar os parâmetros das funções de pertinência trouxe melhorias para o controlador final, mostrando que o PSO consegue lidar melhor que o GA com o aumento do número de variáveis a serem otimizadas. Na figura 28 é apresentada a comparação de *fitness* entre as melhores propostas de otimização de 126 parâmetros e de 175, evidenciando o melhor desempenho da segunda.

Figura 28 – Boxplot propostas PSO



Fonte: Autoria própria

Em ambas as propostas (126 e 175), o melhor desempenho foi provido pelo coeficiente de inércia fixo (PSO1), apresentando uma considerável diferença de de-

sempenho em relação ao coeficiente de inércia variável proposto, que possuiu pobreza de busca quando passou por valores próximos de 0,7.

4.3 ANÁLISE GERAL DE DESEMPENHO

Evidencia-se acima de tudo que ambas as heurísticas conseguiram otimizar o problema em questão. Na tabela 7 é apresentado o resumo dos melhores resultados encontrados entre as 8 metodologias. O PSO com coeficiente de inércia fixo para 175 parâmetros apresentou o melhor desempenho com um *fitness* de 0,001771, seguido do PSO de coeficiente fixo para 126 parâmetros, com 0,001422. O terceiro maior foi o PSO com coeficiente variável para 175 parâmetros, e em sequência, o GA de torneios fixos com 0,001141.

Tabela 7 – Comparação dos maiores *fitness*

Metodologia	<i>Fitness</i> máximo
PSO1_175	0,001771
PSO1_126	0,001422
PSO2_175	0,001359
GA1_175	0,001141

Fonte: Autoria própria

Em função da mediana, a tabela 8 apresenta um resumo com os melhores algoritmos. Analisando a mediana percebe-se quais foram as metodologias mais consistentes para um gráfico de dispersão de 5 amostras. Nesse sentido, o melhor algoritmo foi o PSO com coeficiente de inércia fixo para 175 parâmetros, com *fitness* mediano de 0,001373. Em seguida, vem o PSO de coeficiente variável para 175 parâmetros, com 0,001137; depois o PSO de coeficiente fixo para 126 parâmetros, com 0,001104; e por fim, GA de torneios variáveis para 175 parâmetros, com 0,0008547.

Tabela 8 – Comparação das maiores medianas

Metodologia	Mediana do <i>fitness</i>
PSO1_175	0,001373
PSO2_175	0,001137
PSO1_126	0,001104
GA2_175	0,0008547

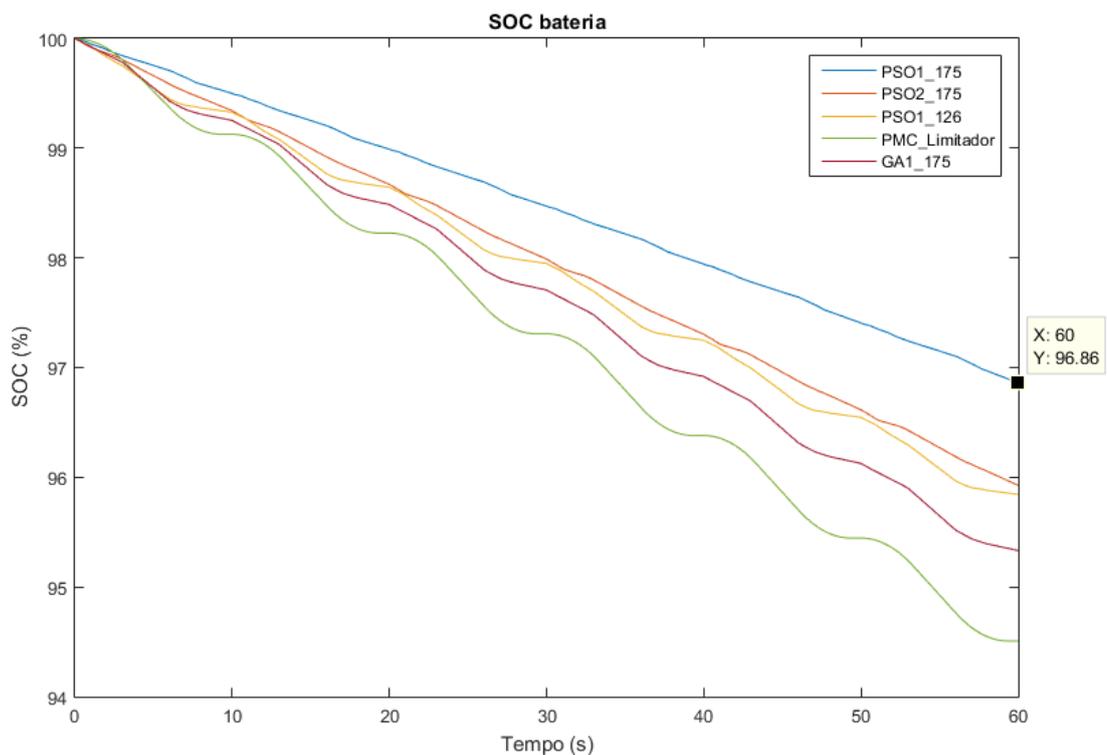
Fonte: Autoria própria

Percebe-se a partir dos resultados apresentados que o PSO possui uma vantagem de desempenho em otimizar o problema em questão.

Dentre as propostas do PSO, recebe destaque o PSO de coeficiente de inércia fixo, que apresentou os *fitness* mais altos, e para o caso de 175 parâmetros, o algoritmo mais consistente dentre os relacionados. Para os GAs, se destacou o algoritmo de torneios variáveis, que apresentou maior consistência tanto para 126 como para 175 parâmetros, além de ter encontrado uma solução próxima do melhor resultado encontrado entre os GAs.

Todo o trabalho e otimizações desenvolvidas foram em busca da melhoria de desempenho do HESS de forma que cada dispositivo forneça a potência no momento em que é mais eficiente, e com isso, tenha a maior possibilidade de aumentar a autonomia dos EVs. Na figura 29 é apresentada a comparação de autonomia entre os controladores obtidos e o HESS com o PMC realizado por um limitador em um período de simulação de 60 segundos, ou seja, repetindo 6 vezes o transitório base.

Figura 29 – Comparação de autonomia entre os controladores encontrados



Fonte: Autoria própria

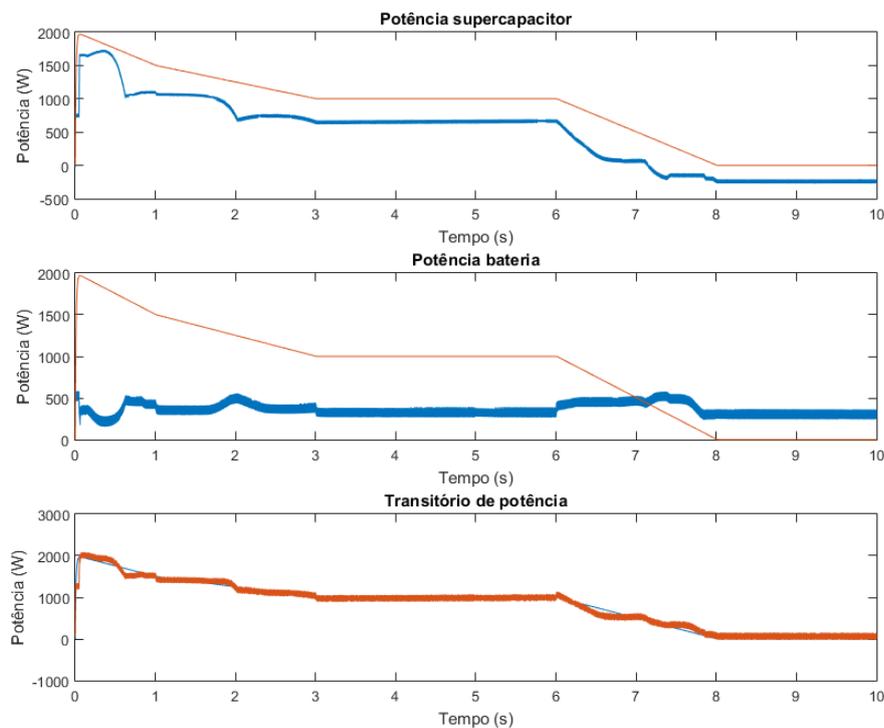
O algoritmo que encontrou o controlador com melhor desempenho, aumentando a autonomia do veículo, foi o PSO com coeficiente de inércia fixo otimizando os 175 parâmetros de construção do controlador fuzzy, aperfeiçoando a disposição das funções de pertinência e o desempenho da base de regras. Isso mostra que o con-

trole de potência realizado pelo controlador fuzzy conseguiu gerenciar com eficiência o momento mais adequado para cada dispositivo de armazenamento entrar em ação.

Na figura 30 é apresentado como o melhor FLC obtido fez a distribuição de potência entre o SC e a bateria. Observa-se que o SC forneceu a maior quantidade de potência durante o transitório, com um pico em torno de 1700 W, enquanto a bateria forneceu continuamente em torno de 500 W, lembrando que o limite máximo de potência que poderia ser fornecida — de acordo com os limites superiores definidos na tabela 10 para construção das funções de pertinência do controlador — é, respectivamente, 2200 e 1000 W. Nota-se que o controlador foi bem sintonizado, pois ao fornecer somente uma potência contínua, o estresse na bateria é reduzido.

Quando entra na região em que a demanda de potência cai, representando a frenagem regenerativa, a potência fornecida pelo SC cai imediatamente, e em sequência começa a consumir potência, entrando em período de recarga. Percebe-se que o PMC ajustou corretamente esse período, pois em casos de frenagem regenerativa quem mais tem capacidade física para receber essa potência é o SC, preservando novamente a bateria.

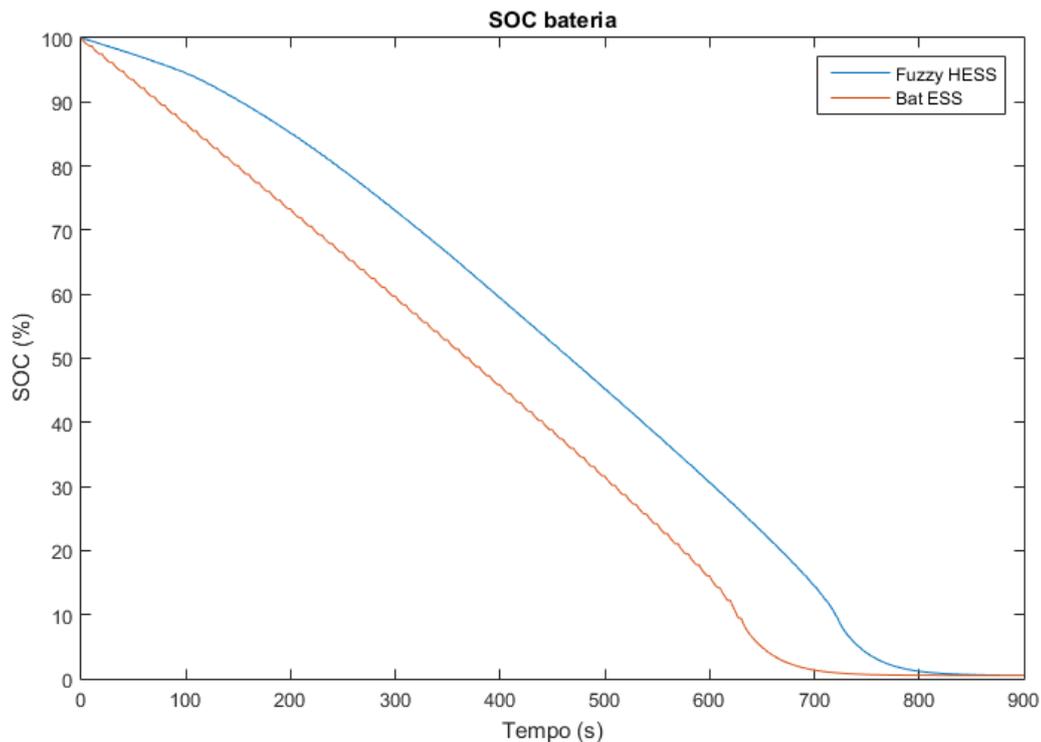
Figura 30 – Distribuição de potência entre os dispositivos



Fonte: Autoria própria

Comparando o HESS bateria-SC com o FLC sintonizado por PSO com um ESS composto somente do conjunto de bateria, percebe-se um aumento de 14,28% de autonomia, conforme apresenta a figura 31, que analisa o SOC de sua descarga completa. Isso representa que, associando um SC a bateria e controlando a distribuição de potência de forma correta, ela suportou o transitório proposto por mais aproximadamente 100 segundos. Além do grande aumento de autonomia obtido, o HESS proposto pode trazer aumento da vida-útil da bateria, uma vez que o estresse nela submetido é reduzido e controlado, e também pode diminuir o tamanho do conjunto, diminuindo assim a massa do veículo, já que o SC possui a densidade de potência necessária para fornecer.

Figura 31 – Comparação de autonomia HESS vs ESS



Fonte: Autoria própria

4.4 CONTROLADORES FUZZY

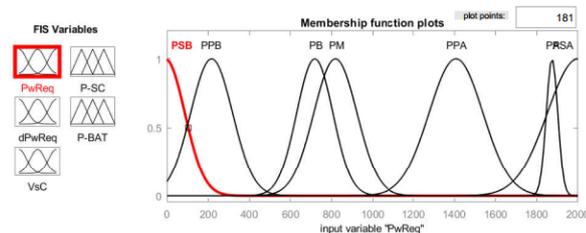
Nesta seção é apresentado o melhor controlador encontrado do GA e o melhor do PSO.

Nas figuras que seguem é apresentado o melhor controlador encontrado entre as metodologias do GA. Na figura 32 é visto a disposição das funções de pertinência,

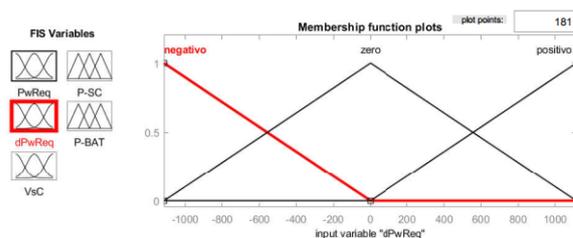
respectivamente, das variáveis de entrada e saída. Para descrever o espaço, as funções da variável $PwReq$ foram movidas em direção as regiões de potência que haviam transição, como 2000, 1400, 1000 e 0. Dessa forma o sistema teria mais precisão em lidar com essas faixas. A variável $dPwReq$ manteve-se simétrica, enquanto VsC tendeu a detectar melhor os valores mais baixos.

Figura 32 – Funções de pertinência GA

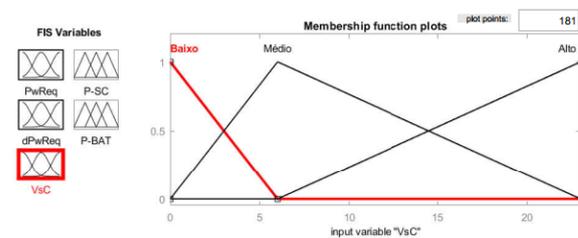
(a) Entrada: $dPwReq$



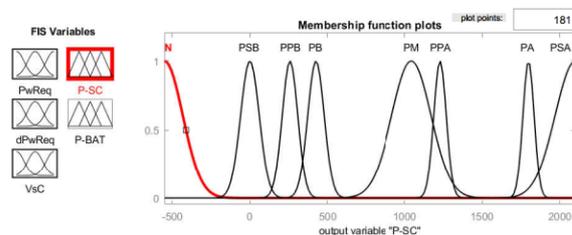
(b) Entrada: $dPwReq$



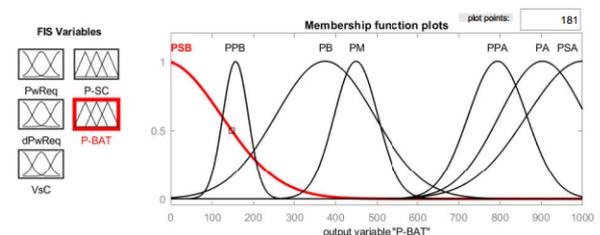
(c) Entrada: VsC



(d) Saída: $dPwReq$



(e) Saída: VsC



Fonte: Autoria própria.

As variáveis de saída do SC ficaram bem distribuídas no universo de discurso, com pouca sobreposição e focando seus pontos nas regiões de transição, como 2000, 1800, 1000, 0 e -500. Já para $P-BAT$, as funções ficaram mais sobrepostas, com maior quantidade nas regiões de 800 a 1000 W, e 200 a 500 W.

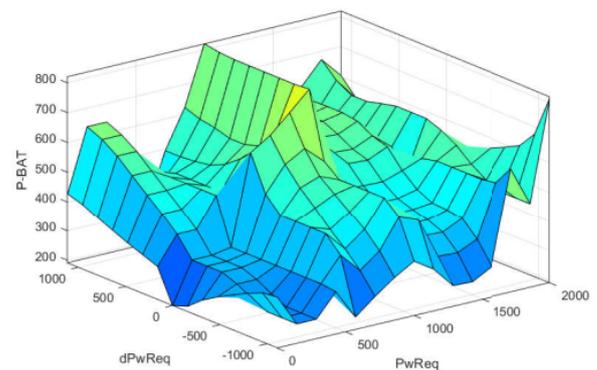
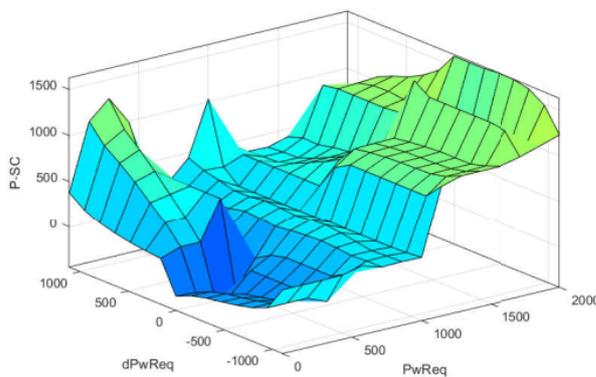
Na figura 33 é apresentado as superfícies que representam a base de regras. Nota-se que para as entradas $PwReq$ e $dPwReq$, as saídas $P-SC$ e $P-BAT$ apresentaram uma superfície semelhante, em que os menores valores de entrada tenderam a sair menores valores, e na medida que os valores de entrada sobem, sobem também os valores de saída. Diferencia-se, entretanto, que, corretamente, o momento em que

a derivada da entrada é 0, a potência de saída da bateria sobe consideravelmente, enquanto que para $P-SC$, é um momento que diminui a potência de saída.

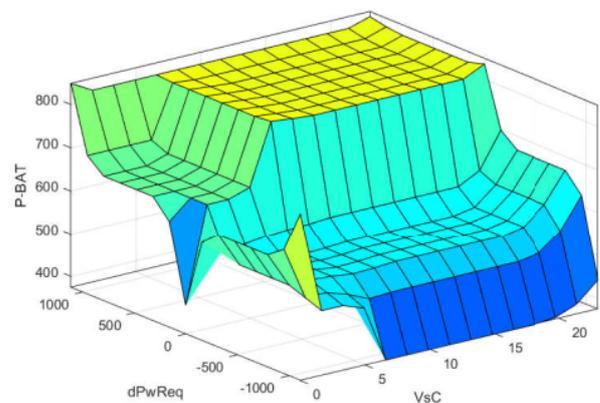
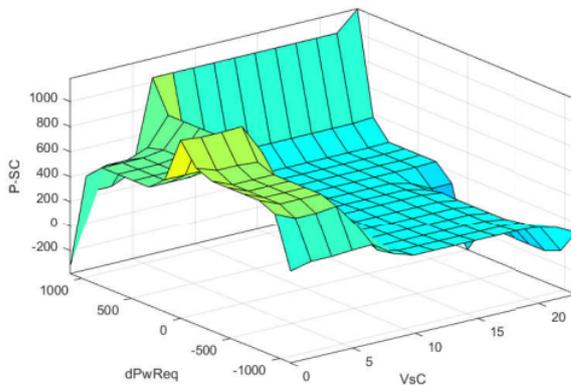
Para a entrada $dPwReq$ e VsC as saídas apresentaram comportamentos distintos, em que, quando uma das saídas apresentava um valor alto, a outra saída tendia a apresentar um valor mais baixo.

Figura 33 – Superfícies do conjunto de regras GA

(a) Superfície para saída P-SC, entradas PwReq e $dPwReq$ (b) Superfície para saída P-bat, entradas PwReq e $dPwReq$



(c) Superfície para saída P-SC, entradas $dPwReq$ e VsC (d) Superfície para saída P-bat, entradas $dPwReq$ e VsC



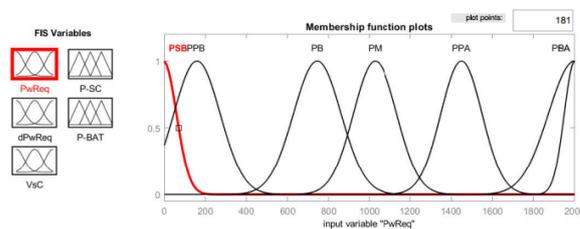
Fonte: Autoria própria.

Nas figuras que seguem é apresentado o melhor controlador encontrado entre as metodologias do PSO. Na figura 34 é visto a disposição das funções de pertinência, respectivamente, das variáveis de entrada e saída. Para descrever o espaço, novamente, as funções da variável $PwReq$ foram movidas em direção as regiões de potência que haviam transição, como 2000, 1400, 1000 e 0, porém de forma mais distribuída. A variável $dPwReq$ obtida pelo PSO também manteve-se simétrica, enquanto VsC novamente tendeu a detectar melhor os valores mais baixos. Já as variáveis de

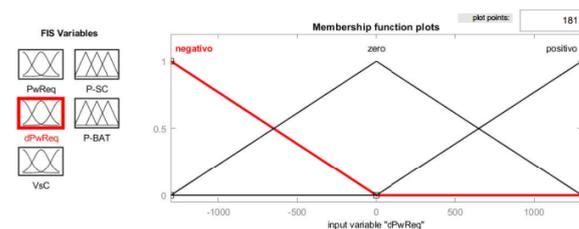
saída do SC ficaram um pouco menos distribuídas no universo de discurso do que a solução encontrada pelo GA, com mais sobreposição, mas também focando seus pontos nas regiões de transição, como 2000, 1800, 500, 0 e -500. Já para *P-BAT*, as funções ficaram mais sobrepostas, semelhante ao encontrado pelo GA, com maior quantidade nas regiões de 800 a 1000 W, e 200 a 500 W. Percebe-se com isso que as soluções para as funções de pertinência encontradas pelo PSO e o GA tendem a pontos semelhantes, indicando que estão em uma bacia que leva ao ótimo.

Figura 34 – Funções de pertinência PSO

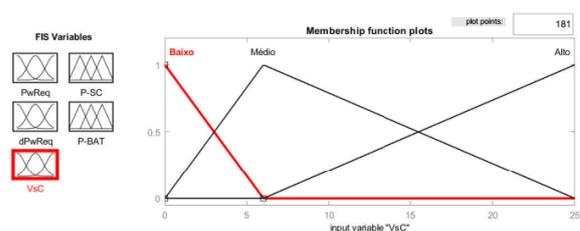
(a) Entrada: PwReq



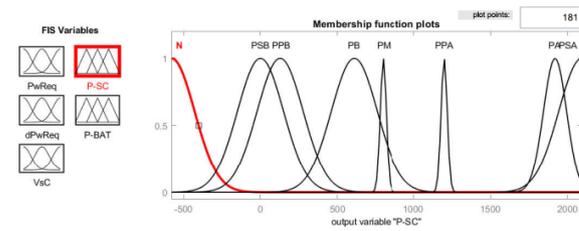
(b) Entrada: dPwReq



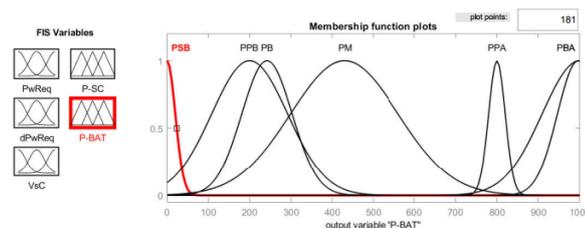
(c) Entrada: VsC



(d) Saída: P-SC



(e) Saída: P-BAT



Fonte: Autoria própria.

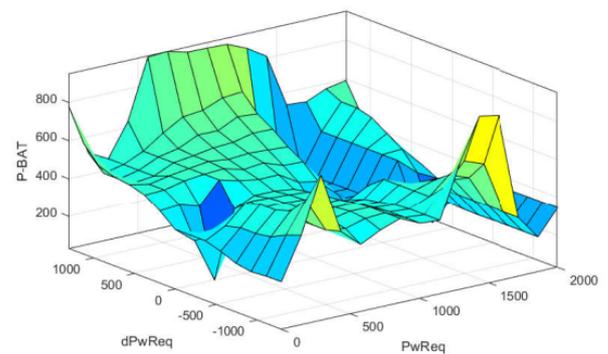
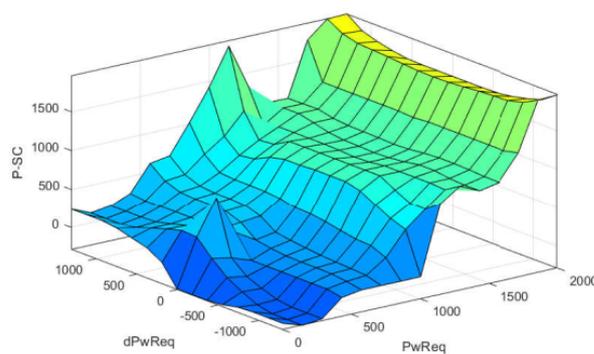
Na figura 35 é apresentado as superfícies que representam a base de regras. Nota-se que para as entradas *PwReq* e *dPwReq*, a saída *P-SC* apresentou uma superfície mais linear, em que os menores valores de entrada tenderam a sair menores valores, e na medida que os valores de entrada sobem, sobem também os valores de saída. Já para a saída *P-BAT*, a superfície tendeu a ser mais contínua na faixa de saída de 500 W, possuindo alguns picos nas regiões extremas.

Para a entrada *dPwReq* e *VsC* as saídas apresentaram comportamentos não

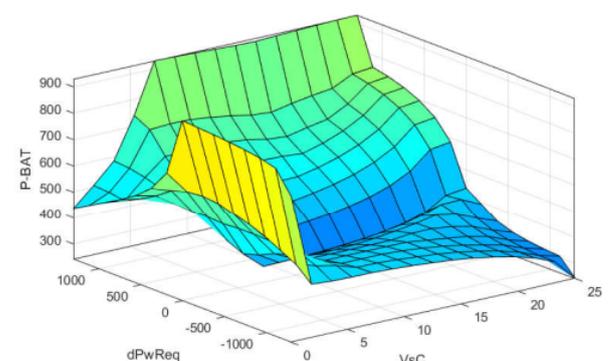
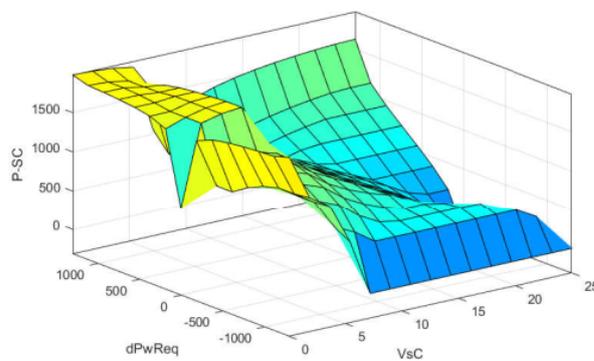
tão antagônicos quanto o GA, sendo obtido, na maior parte das entradas, saídas com características semelhantes. Fica claro, entretanto, que para a saída *P-BAT*, quando *VsC* está entre 0 e 10 e *dPwReq* é nulo, o valor de saída é alto, apresentando um pico na região, enquanto que, nesse momento, há um pico negativo na saída do *P-SC*. Para os demais pontos de *VsC* em que a derivada é 0, essa situação sofre uma inflexão, sendo a potência agora fornecida em sua maior parte pelo SC e não pela bateria.

Figura 35 – Superfícies do conjunto de regras PSO

(a) Superfície para saída *P-SC*, entradas *PwReq* e *dPwReq* (b) Superfície para saída *P-bat*, entradas *PwReq* e *dPwReq*



(c) Superfície para saída *P-SC*, entradas *dPwReq* e *VsC* (d) Superfície para saída *P-bat*, entradas *dPwReq* e *VsC*



Fonte: Autoria própria.

5 CONCLUSÕES E PERSPECTIVAS

Os EVs e HEVs prometem ser o futuro dos veículos convencionais, alavancados pela alta eficiência dos EM que, além de possibilitar a frenagem regenerativa, apresentam maior torque. Em associação ao apelo ambiental, que cresce progressivamente no correr das décadas, os veículos elétricos e híbridos tornaram-se uma tecnologia emergente alvo de grandes investimentos em todo o mundo, buscando a performance ótima em todos os pontos do veículo.

O principal alvo, tanto de estudos quanto de ceticismo, é o ESS e o desempenho e autonomia que as baterias podem prover. Historicamente, a autonomia foi um ponto de fracasso da experiência elétrica dos automóveis, uma vez que está diretamente ligada ao rendimento do veículo. Ainda hoje se busca sobrepujar a eficiência e custo-benefício dos veículos a combustão, de forma a obter seu máximo desempenho e ganhar maior força de mercado.

Motivado com isso, o presente trabalho buscou trazer uma opção versátil para gerir o controle de potência de um EV equipado com um HESS de bateria e SC. Tal sistema híbrido apresenta aumento de complexidade do PMC, necessitando de um controlador conciso e bem desenvolvido, de forma a realmente trazer os benefícios que um sistema bateria-SC promete, tais qual: redução de estresse, tamanho e custo da bateria, aumento da vida-útil da bateria, melhoria da gestão de potência, e aumento da autonomia do veículo. É proposto então um controlador fuzzy, sistema que consegue lidar bem com quantidades imprecisas, vagas e não-lineares.

O controlador fuzzy normalmente é desenvolvido utilizando a experiência de um especialista, que possui entendimento do problema e a percepção das respostas geradas. Entretanto, esse tipo de sintonia costuma ser lenta e não apresenta o máximo desempenho que o controlador pode prover. Deste modo, foi proposto a otimização dos parâmetros fuzzy a partir de meta-heurísticas bio-inspiradas, métodos de busca estimulado pelas ciências naturais.

As meta-heurísticas ganharam peso no desenvolvimento de sistemas otimizados com o crescente aumento de processamento que os computadores modernos trouxeram, trazendo a inteligência computacional para os mais diversos segmentos. Dentre os métodos de CI existentes, foi proposto otimizar os parâmetros fuzzy com

um método maduro, o algoritmo genético, e com outro método também muito consistente: a otimização por enxame de partículas.

Neste trabalho foi proposto uma análise de forma a perceber se, da otimização dos parâmetros fuzzy, é eficiente melhorar somente a base de regras, ou se se faz necessário aprimorar também o conjunto de funções de pertinência do sistema. Dispostos então em simulação uma proposta que aperfeiçoa somente os 126 parâmetros relativos somente às regras, e uma proposta que otimiza 175 parâmetros, melhorando as regras e as funções de pertinência, promete-se obter um controlador que responda a potência requerida da forma mais eficaz.

O GA foi proposto de duas formas: utilizando número de torneios variável, e número de torneios fixo. Levados as simulações, a proposta de torneios variáveis apresentou resultados melhores e mais consistentes em otimizar os 126 parâmetros, enquanto que para otimizar 175 parâmetros, o torneio de número fixo encontrou um resultado pouco melhor que o variável, porém o variável que apresentou novamente maior consistência.

O PSO foi proposto também de duas formas: coeficiente de inércia fixo, e coeficiente de inércia variável. Levados as simulações, a proposta com coeficiente de inércia fixo apresentou resultados melhores e mais consistentes tanto em otimizar os 126 parâmetros quanto em otimizar o controlador com 175 parâmetros.

Entre o melhor controlador encontrado pelo PSO e o melhor controlador encontrado para o GA, o PSO apresentou o melhor desempenho. Isso levou ao sistema a obter um aumento considerável de autonomia.

O PSO conseguiu desenvolver melhor com o aumento do número de variáveis, apresentando uma diferença mais larga que o GA entre os controladores que otimizaram também as funções de pertinência e os controladores que melhoraram somente as regras. Ou seja, quando implementando um PSO para aperfeiçoar os parâmetros fuzzy, tem-se um ganho grande ao otimizar também o conjunto de funções, enquanto que, quando implementando um GA para aprimorar os parâmetros fuzzy, tem-se pouco ganho ao otimizar também as funções de pertinência.

Por fim, percebe-se que adicionar um SC em paralelo a bateria pode sim aumentar o desempenho do sistema e poupar maiores estresses da bateria, uma vez que SC possuem a densidade de potência necessária. Associando um SC a um ESS somente de bateria, e realizando o devido PMC, pode-se obter um ganho de autono-

mia de 14,28%, que, em grandes escalas, é um grande ganho.

O controlador fuzzy mostrou-se como uma ferramenta relevante para o PMC, conseguindo separar corretamente o momento em que o SC deveria atuar, e o momento em que a bateria deveria prover potência. Com o auxílio das gaussianas, as funções de pertinência, que descreviam o espaço, conseguiram desempenhar uma transição suave entre SC e bateria, diminuindo o consumo e estresse da bateria. Quando comparado com a estratégia de controle que utilizara um limitador, mostrou um desempenho mais eficiente.

O trabalho cumpriu com seus objetivos, esclarecendo diversos pontos avançados, e apresentando os métodos mais eficazes para se obter a maior eficiência de um HESS que utiliza um controlador fuzzy como método de PMC. Ambas as heurísticas desenvolveram como esperado, mostrando que a sintonia automática do controlador fuzzy traz grande desenvolvimento ao sistema, aumentando consideravelmente a autonomia do HESS quanto melhor a sintonização.

Para trabalhos futuros, pode-se analisar ainda a possibilidade de iterativamente ajustar os limites dos parâmetros das funções de pertinência baseando-se nos resultados anteriores do controlador sintonizado por CI, trazendo a condição de realizar um ajuste fino na solução, obtendo um controlador ainda mais preciso. Pode-se também submeter o controlador encontrado a um sistema de simulação mais completo, em que represente de forma mais precisa as condições internas e externas de um EV em ciclo de condução urbano.

Para o GA e PSO, é possível implementar uma metodologia multiobjetivo, em que se buscava diminuir o consumo de bateria e diminuir o erro entre potência requerida e potência fornecida, identificando assim a fronteira de pareto do sistema (HORN; NAFPLIOTIS; GOLDBERG, 1994). Para o PSO, pode ser feito uma análise dos parâmetros social e individual, implementação de um operador mutação, entre outros ajustes (KO; WU, 2008).

REFERÊNCIAS

Adinolfi, A. et al. Experimental assessment of energy saving due to trains regenerative braking in an electrified subway line. **IEEE Transactions on Power Delivery**, v. 13, n. 4, p. 1536–1542, Oct 1998. ISSN 1937-4208. Citado na página 26.

ALLEGRE, A. L.; BOUSCAYROL, A.; TRIGUI, R. Influence of control strategies on battery/supercapacitor hybrid Energy Storage Systems for traction applications. In: **2009 IEEE Vehicle Power and Propulsion Conference**. [S.l.: s.n.], 2009. p. 213–220. Citado na página 48.

ATTIA, Abdel-Fattah; AL-TURKI, Yusuf. A.; SOLIMAN, Hussein F. Genetic Algorithm-Based Fuzzy Controller for Improving the Dynamic Performance of Self-Excited Induction Generator. **Arabian Journal for Science and Engineering**, v. 37, n. 3, p. 665–682, abr. 2012. ISSN 1319-8025, 2191-4281. Disponível em: <<http://link.springer.com/10.1007/s13369-012-0211-8>>. Citado na página 39.

BANDURA, Albert. Influence of models' reinforcement contingencies on the acquisition of imitative responses. **Journal of personality and social psychology**, American Psychological Association, v. 1, n. 6, p. 589, 1965. Citado na página 37.

_____. Vicarious processes: A case of no-trial learning. In: **Advances in experimental social psychology**. [S.l.]: Elsevier, 1965. v. 2, p. 1–55. Citado na página 37.

BEVRANI, H. et al. Intelligent Frequency Control in an AC Microgrid: Online PSO-Based Fuzzy Tuning Approach. **IEEE Transactions on Smart Grid**, v. 3, n. 4, p. 1935–1944, dez. 2012. ISSN 1949-3053, 1949-3061. Citado na página 40.

BINGÜL, Zafer; KARAHAN, Oğuzhan. A Fuzzy Logic Controller tuned with PSO for 2 DOF robot trajectory control. **Expert Systems with Applications**, v. 38, n. 1, p. 1017–1031, jan. 2011. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417410007591>>. Citado na página 39.

BLAUD, Pierre Clément. **Développement d'un modèle de simulation de supercondensateur et validation expérimentale**. 2012. Tese (Doutorado) — École de technologie supérieure, 2012. Citado na página 41.

BOX, George E. P. Evolutionary operation: a method for increasing industrial productivity. **Journal of the Royal Statistical Society: Series C (Applied Statistics)**, v. 6, n. 2, p. 81–101, 1957. Disponível em: <<https://rss.onlinelibrary.wiley.com/doi/abs/10.2307/2985505>>. Citado na página 32.

Larry R. Brandenburg e Edward T. King. **Hybrid electric vehicle regenerative braking energy recovery system**. 1994. US5291960A. Disponível em: <<https://patents.google.com/patent/US5291960A/en>>. Citado na página 26.

BREMERMANN, H J. Optimization Through Evolution and Recombination. *Self-Organizing Systems-1962*, p. 12, 1962. Citado na página 32.

BUEKERS, Jurgen et al. Health and environmental benefits related to electric vehicle introduction in EU countries. **Transportation Research Part D: Transport and Environment**, v. 33, p. 26–38, dez. 2014. ISSN 13619209. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S136192091400128X>>. Citado na página 14.

CASTANHO, Diego Solak et al. **APLICAÇÃO DE UM CONTROLADOR PID FUZZY ADAPTATIVO OTIMIZADO VIA ALGORITMO GENÉTICO À UM MOTOR DE CORRENTE CONTÍNUA DIDÁTICO**. 2018. Disponível em: <<https://doity.com.br/anais/xiiisimmec2018/trabalho/69004>>. Citado na página 28.

CASTRO, Leandro Nunes De. **Fundamentals of natural computing: basic concepts, algorithms, and applications**. [S.l.]: Chapman and Hall/CRC, 2006. Citado na página 32.

CASTRO, Leandro Nunes de. *Fundamentals of Natural Computing*. p. 100, 2007. Citado na página 36.

CHENCI, Gabriel Pupin; LUCAS, Carlos Alberto. **UMA INTRODUÇÃO A LÓGICA FUZZY**. p. 12, 2011. Citado na página 27.

Cikanek, S. R.; Bailey, K. E. Regenerative braking system for a hybrid electric vehicle. In: **Proceedings of the 2002 American Control Conference (IEEE Cat. No.CH37301)**. [S.l.: s.n.], 2002. v. 4, p. 3129–3134 vol.4. ISSN 0743-1619. Citado na página 26.

CLIMAINFO. **Uma breve história dos veículos elétricos**. [S.l.], 2019. Disponível em: <<http://climainfo.org.br/2017/09/25/uma-breve-historia-dos-veiculos-eletricos/>>. Citado 2 vezes nas páginas 13 e 15.

CORRÊA, Fernanda Cristina. **Desenvolvimento e Análise de Estratégias de Gerenciamento de Potência em Veículo Elétrico Híbrido de Configuração Paralela**. 2013. Tese (Doutorado), 2013. Citado na página 13.

CROLLA, D.; MASHADI, B. **Vehicle Powertrain Systems**. Wiley, 2011. ISBN 978-1-119-96102-4. Disponível em: <https://books.google.com.br/books?id=N8rrnOv_kBoC>. Citado na página 15.

DARWIN, Charles. **On the origin of species by means of natural selection, or, The preservation of favoured races in the struggle for life** /. London :John Murray, 1859. -1859. 564 p. <https://www.biodiversitylibrary.org/bibliography/68064> — Freeman, R.B. Charles Darwin (2nd ed.), | 373 — Garrison-Morton: | 220. Disponível em: <<https://www.biodiversitylibrary.org/item/135954>>. Citado 2 vezes nas páginas 32 e 33.

DOUGHTY, Daniel H.; ROTH, E. Peter. A General Discussion of Li Ion Battery Safety. **The Electrochemical Society Interface**, v. 21, n. 2, p. 37–44, jan. 2012. ISSN 1064-8208, 1944-8783. Disponível em: <<http://interface.ecsdl.org/content/21/2/37>>. Citado na página 42.

EBERHART, Russell; KENNEDY, James. Particle swarm optimization. In: CITESEER. **Proceedings of the IEEE international conference on neural networks**. [S.l.], 1995. v. 4, p. 1942–1948. Citado na página 36.

EBERHART, Russell C; SHI, Yuhui; KENNEDY, James. **Swarm intelligence**. [S.l.]: Elsevier, 2001. Citado na página 36.

ECK, Nees Jan Van; WALTMAN, Ludo. BIBLIOMETRIC MAPPING OF THE COMPUTATIONAL INTELLIGENCE FIELD. **International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems**, v. 15, n. 5, p. 625–645, 2007. Disponível em: <<https://www.worldscientific.com/doi/abs/10.1142/S0218488507004911>>. Citado na página 31.

ECKERT, Jony Javorski et al. Energy storage and control optimization for an electric vehicle. **International Journal of Energy Research**, v. 42, n. 11, p. 3506–3523, set.

2018. ISSN 0363-907X. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1002/er.4089>>. Citado 5 vezes nas páginas 16, 19, 20, 21 e 39.

EEA. **Fontes de poluição atmosférica na Europa**. [S.l.], 2014. Disponível em: <<https://www.eea.europa.eu/pt/sinais-da-aea/sinais-2013/infografia/fontes-de-poluicao-atmosferica-na-europa-2/view>>. Citado na página 13.

EHSANI, Mehrdad (Ed.). **Modern electric, hybrid electric, and fuel cell vehicles: fundamentals, theory, and design**. Boca Raton: CRC Press, 2005. (Power electronics and applications series). ISBN 978-0-8493-3154-1. Citado na página 26.

ESA. **Energy Storage Technologies | Energy Storage Association**. 2019. Disponível em: <<http://energystorage.org/energy-storage/energy-storage-technologies>>. Citado na página 19.

FERENTINOS, K.P.; ARVANITIS, K.G.; SIGRIMIS, N. Heuristic optimization methods for motion planning of autonomous agricultural vehicles. **Journal of Global Optimization**, v. 23, n. 2, p. 155–170, 2002. ISSN 09255001. Disponível em: <<http://link.springer.com/10.1023/A:1015527207828>>. Citado na página 35.

FETCENKO, M.A. et al. Recent advances in NiMH battery technology. **Journal of Power Sources**, v. 165, n. 2, p. 544–551, mar. 2007. ISSN 03787753. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0378775306021215>>. Citado na página 22.

FRIEDBERG, R. M. A learning machine: Part i. **IBM J. Res. Dev.**, IBM Corp., Riverton, NJ, USA, v. 2, n. 1, p. 2–13, jan. 1958. ISSN 0018-8646. Disponível em: <<http://dx.doi.org/10.1147/rd.21.0002>>. Citado na página 32.

FRIEDBERG, R. M.; DUNHAM, B.; NORTH, J. H. A learning machine: Part ii. **IBM J. Res. Dev.**, IBM Corp., Riverton, NJ, USA, v. 3, n. 3, p. 282–287, jul. 1959. ISSN 0018-8646. Disponível em: <<http://dx.doi.org/10.1147/rd.33.0282>>. Citado na página 32.

GAO, Yimin; CHEN, Liping; EHSANI, Mehrdad. Investigation of the effectiveness of regenerative braking for ev and hev. **SAE Transactions**, SAE International, v. 108, p. 3184–3190, 1999. ISSN 0096736X, 25771531. Disponível em: <<http://www.jstor.org/stable/44733986>>. Citado na página 26.

GEETHA, A.; SUBRAMANI, C. A comprehensive review on energy management strategies of hybrid energy storage system for electric vehicles: Energy management strategies of hybrid energy storage system for EV. **International Journal of Energy Research**, v. 41, n. 13, p. 1817–1834, out. 2017. ISSN 0363907X. Disponível em: <<http://doi.wiley.com/10.1002/er.3730>>. Citado 3 vezes nas páginas 23, 46 e 47.

GOLDBERG, David E; HOLLAND, John H. Genetic algorithms and machine learning. **Machine learning**, Springer, v. 3, n. 2, p. 95–99, 1988. Citado na página 32.

GONZÁLEZ-GIL, Arturo; PALACIN, Roberto; BATTY, Paul. Sustainable urban rail systems: Strategies and technologies for optimal management of regenerative braking energy. **Energy Conversion and Management**, v. 75, p. 374–388, nov. 2013. ISSN 0196-8904. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0196890413003518>>. Citado na página 26.

HANNAN, M.A. et al. Review of energy storage systems for electric vehicle applications: Issues and challenges. **Renewable and Sustainable Energy Reviews**, v. 69, p. 771–789, mar. 2017. ISSN 13640321. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1364032116309182>>. Citado 7 vezes nas páginas 15, 16, 19, 20, 21, 23 e 24.

HASSANEIN, Osama I.; ALY, Ayman A.; ABO-ISMAIL, Ahmed A. Parameter Tuning via Genetic Algorithm of Fuzzy Controller for Fire Tube Boiler. **International Journal of Intelligent Systems and Applications**, v. 4, n. 4, p. 9–18, abr. 2012. ISSN 2074904X, 20749058. Disponível em: <<http://www.mecs-press.org/ijisa/ijisa-v4-n4/v4n4-2.html>>. Citado na página 39.

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. 1st. ed. [S.l.]: MIT Press, 1975. Citado 2 vezes nas páginas 32 e 33.

HOLLAND, John H. Genetic algorithms and adaptation. In: _____. **Adaptive Control of Ill-Defined Systems**. Boston, MA: Springer US, 1984. p. 317–333. ISBN 978-1-4684-8941-5. Disponível em: <https://doi.org/10.1007/978-1-4684-8941-5_21>. Citado na página 32.

HOMAI FAR, Abdollah; MCCORMICK, Ed. Simultaneous design of membership functions and rule sets for fuzzy controllers using genetic algorithms. **IEEE transactions on fuzzy systems**, IEEE, v. 3, n. 2, p. 129–139, 1995. Citado na página 31.

HORN, Jeffrey; NAFPLIOTIS, Nicholas; GOLDBERG, David E. A niched pareto genetic algorithm for multiobjective optimization. In: CITESEER. **Proceedings of the first IEEE conference on evolutionary computation, IEEE world congress on computational intelligence**. 1994. v. 1, p. 82–87. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.34.4189&rep=rep1&type=pdf>>. Citado na página 76.

HU, Jianjun et al. Energy Management Strategy for the Hybrid Energy Storage System of Pure Electric Vehicle Considering Traffic Information. **Applied Sciences**, v. 8, n. 8, p. 1266, jul. 2018. ISSN 2076-3417. Disponível em: <<http://www.mdpi.com/2076-3417/8/8/1266>>. Citado 3 vezes nas páginas 27, 28 e 29.

HUSAIN, I. **Electric and Hybrid Vehicles: Design Fundamentals, Second Edition**. Taylor & Francis, 2011. ISBN 978-1-4398-1178-8. Disponível em: <https://books.google.com.br/books?id=7AAWH_63HuAC>. Citado 4 vezes nas páginas 15, 16, 20 e 21.

JANTZEN, Jan. Design of fuzzy controllers. **Technical University of Denmark, Department of Automation, Bldg**, v. 326, p. 362–367, 1998. Citado na página 30.

Jian Cao; EMADI, A. A New Battery/UltraCapacitor Hybrid Energy Storage System for Electric, Hybrid, and Plug-In Hybrid Electric Vehicles. **IEEE Transactions on Power Electronics**, v. 27, n. 1, p. 122–132, jan. 2012. ISSN 0885-8993, 1941-0107. Disponível em: <<http://ieeexplore.ieee.org/document/5764539/>>. Citado 4 vezes nas páginas 21, 23, 29 e 46.

JONG, Kenneth De; FOGEL, David B; SCHWEFEL, Hans-Paul. A2.3 A history of evolutionary computation. p. 13, 1997. Citado 2 vezes nas páginas 32 e 35.

KHALIGH, Alireza; Zhihao Li. Battery, Ultracapacitor, Fuel Cell, and Hybrid Energy Storage Systems for Electric, Hybrid Electric, Fuel Cell, and Plug-In Hybrid Electric Vehicles: State of the Art. **IEEE Transactions on Vehicular Technology**, v. 59, n. 6, p. 2806–2814, jul. 2010. ISSN 0018-9545, 1939-9359. Disponível em: <<http://ieeexplore.ieee.org/document/5446335/>>. Citado 5 vezes nas páginas 20, 21, 22, 24 e 25.

KO, Chia-Nan; WU, Chia-Ju. A pso-tuning method for design of fuzzy pid controllers. **Journal of Vibration and Control**, v. 14, n. 3, p. 375–395, 2008. Disponível em: <<https://doi.org/10.1177/1077546307080038>>. Citado na página 76.

KOSHIYAMA, A. S.; VELLASCO, M. M.B.R.; TANSCHKEIT, R. Gpf-control: Um modelo fuzzy-genético para problemas de controle. **Proceeding Series of the Brazilian Society of Applied and Computational Mathematics**, v. 1, p. 1–6, 2013. Citado na página 55.

KOSKO, Bart; ISAKA, Satoru. Fuzzy logic. **Scientific American**, JSTOR, v. 269, n. 1, p. 76–81, 1993. Citado na página 28.

KOTHANDARAMAN, Rajeswari; PONNUSAMY, Lakshmi. PSO tuned Adaptive Neuro-fuzzy Controller for Vehicle Suspension Systems. **Journal of Advances in Information Technology**, v. 3, n. 1, p. 57–63, fev. 2012. ISSN 1798-2340. Disponível em: <<http://www.jait.us/index.php?m=content&c=index&a=show&catid=148&id=777>>. Citado na página 40.

LATIFF, I. Abd; TOKHI, M. O. Fast convergence strategy for Particle Swarm Optimization using spread factor. In: **2009 IEEE Congress on Evolutionary Computation**. [S.l.: s.n.], 2009. p. 2693–2700. ISSN: 1089-778X, 1941-0026. Citado na página 38.

LEITE, L. da C. M. **Geração e Simplificação da Base de Conhecimento de um Sistema Híbrido Fuzzy-Genético**. [S.l.], 2009. Citado na página 55.

LEVINE, John M; RESNICK, Lauren B; HIGGINS, E Tory. Social foundations of cognition. **Annual review of psychology**, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 44, n. 1, p. 585–612, 1993. Citado na página 37.

LOPES, Juliana. **Estratégias de gerenciamento de potência em ônibus de transporte urbano elétrico híbrido série**. jul. 2008. Tese (Mestrado em Dinâmica das Máquinas e Sistemas) — Universidade de São Paulo, São Carlos, jul. 2008. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/18/18149/tde-19012011-110222/>>. Citado 2 vezes nas páginas 29 e 45.

Maiti, D. et al. Tuning pid and $pi/\lambda d\delta$ controllers using the integral time absolute error criterion. In: **2008 4th International Conference on Information and Automation for Sustainability**. [S.l.: s.n.], 2008. p. 457–462. Citado na página 53.

MALEKI, Hossein et al. Thermal Stability Studies of Li-Ion Cells and Components. **Journal of The Electrochemical Society**, v. 146, n. 9, p. 3224–3229, set. 1999. ISSN

0013-4651, 1945-7111. Disponível em: <<http://jes.ecsdl.org/content/146/9/3224>>. Citado na página 42.

MATULKA, Rebecca. **The History of the Electric Car**. [S.l.], 2014. Disponível em: <<https://www.energy.gov/articles/history-electric-car>>. Citado 2 vezes nas páginas 14 e 15.

MCCLELLAN, Keith. The Morrison Electric: Iowa's First Automobile. **The Annals of Iowa**, v. 36, n. 8, p. 561–568, abr. 1963. ISSN 0003-4827, 2473-9006. Disponível em: <<http://ir.uiowa.edu/annals-of-iowa/vol36/iss8/2>>. Citado na página 14.

MI, C.; MASRUR, M.A.; GAO, D.W. **Hybrid Electric Vehicles: Principles and Applications with Practical Perspectives**. Wiley, 2011. ISBN 978-1-119-97011-8. Disponível em: <<https://books.google.com.br/books?id=ldPZ3NYhF68C>>. Citado 5 vezes nas páginas 15, 16, 20, 21 e 23.

Nasri, A.; Moghadam, M. F.; Mokhtari, H. Timetable optimization for maximum usage of regenerative energy of braking in electrical railway systems. In: **SPEEDAM 2010**. [S.l.: s.n.], 2010. p. 1218–1221. ISSN null. Citado na página 26.

OGATA, K. **Engenharia de controle moderno**. PRENTICE HALL BRASIL, 2011. ISBN 9788576058106. Disponível em: <<https://books.google.com.br/books?id=iL3FYgEACAAJ>>. Citado na página 29.

OLDHAM, Keith B. A Gouy–Chapman–Stern model of the double layer at a (metal)/(ionic liquid) interface. **Journal of Electroanalytical Chemistry**, v. 613, n. 2, p. 131–138, fev. 2008. ISSN 1572-6657. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S002207280700486X>>. Citado na página 43.

ONUBR. **A ONU e o meio ambiente**. [S.l.], 2019. Disponível em: <<https://nacoesunidas.org/acao/meio-ambiente/>>. Citado na página 13.

PACHECO, Marco Aurélio Cavalcanti. ALGORITMOS GENÉTICOS: PRINCÍPIOS E APLICAÇÕES. p. 9, 2019. Citado na página 54.

PACHECO, Marco Aurélio Cavalcanti et al. Algoritmos genéticos: princípios e aplicações. 1999. Citado na página 34.

PEDRYCZ, Witold; GOMIDE, Fernando. **An introduction to fuzzy sets: analysis and design**. [S.l.]: Mit Press, 1998. Citado na página 30.

PETERSON, Scott B.; APT, Jay; WHITACRE, J. F. Lithium-ion battery cell degradation resulting from realistic vehicle and vehicle-to-grid utilization. **Journal of Power Sources**, v. 195, n. 8, p. 2385–2392, abr. 2010. ISSN 0378-7753. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378775309017443>>. Citado na página 24.

REYNOLDS, Craig W. Flocks, herds and schools: A distributed behavioral model. In: **Proceedings of the 14th Annual Conference on Computer Graphics and Interactive Techniques**. New York, NY, USA: ACM, 1987. (SIGGRAPH '87), p. 25–34. ISBN 0-89791-227-6. Disponível em: <<http://doi.acm.org/10.1145/37401.37406>>. Citado na página 36.

RONDEAU, L et al. A defuzzification method respecting the fuzzification. **Fuzzy sets and systems**, Elsevier, v. 86, n. 3, p. 311–320, 1997. Citado na página 30.

ROSS, Timothy J. Membership functions, fuzzification and defuzzification. In: **Fuzzy systems in medicine**. [S.l.]: Springer, 2000. p. 48–77. Citado na página 30.

SHAW, I. S.; SIMÕES, M. G. **Controle e modelagem Fuzzy**. 1st. ed. [S.l.]: EDITORA EDGARD BLÜCHER LTDA, 1999. Citado 4 vezes nas páginas 16, 27, 28 e 29.

SINHA, S. K.; PATEL, R. N.; PRASAD, R. Application of GA and PSO Tuned Fuzzy Controller for AGC of Three Area Thermal- Thermal-Hydro Power System. **International Journal of Computer Theory and Engineering**, p. 238–244, 2010. ISSN 17938201. Disponível em: <<http://www.ijcte.org/show-29-643-1.html>>. Citado na página 40.

SONG, Ziyu et al. Energy management strategies comparison for electric vehicles with hybrid energy storage system. **Applied Energy**, v. 134, p. 321–331, dez. 2014. ISSN 03062619. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0306261914008381>>. Citado 3 vezes nas páginas 24, 25 e 39.

TREMBLAY, Olivier G.; DESSAINT, Louis-A. Experimental validation of a battery dynamic model for EV applications. In: . [S.l.: s.n.], 2009. Citado 2 vezes nas páginas 42 e 43.

TRUDES, G. P. et al. Aplicação da lógica fuzzy no gerenciamento de sistemas de armazenamento de energia do veículo elétrico. **13° Congresso Ibero-americano de Engenharia Mecânica, 2017, Lisboa**, 13° Congresso Ibero-americano de Engenharia Mecânica, 2017. Citado 3 vezes nas páginas 43, 45 e 49.

VAZQUEZ, Sergio et al. Energy Storage Systems for Transport and Grid Applications. **IEEE Transactions on Industrial Electronics**, v. 57, n. 12, p. 3881–3895, dez. 2010. ISSN 0278-0046. Disponível em: <<http://ieeexplore.ieee.org/document/5582228/>>. Citado 2 vezes nas páginas 22 e 46.

WANG, Bin et al. A novel multimode hybrid energy storage system and its energy management strategy for electric vehicles. **Journal of Power Sources**, v. 281, p. 432–443, maio 2015. ISSN 03787753. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0378775315002359>>. Citado 2 vezes nas páginas 25 e 26.

WANG, Fei-Yue; LIU, Derong. **Advances in Computational Intelligence: Theory and Applications**. WORLD SCIENTIFIC, 2006. ISBN 978-981-256-734-5 978-981-277-392-0. Disponível em: <<https://www.worldscientific.com/worldscibooks/10.1142/6072>>. Citado na página 31.

WONG, Ching-Chang; WANG, Hou-Yi; LI, Shih-An. PSO-based Motion Fuzzy Controller Design for Mobile Robots. **International Journal of Fuzzy Systems**, v. 10, n. 1, p. 9, 2008. Citado na página 56.

WU, Z. W. et al. Design of a soft switching bidirectional DC-DC power converter for ultracapacitor-battery interfaces. **International Journal of Automotive Technology**, v. 13, n. 2, p. 325–336, fev. 2012. ISSN 1229-9138, 1976-3832. Disponível em: <<http://link.springer.com/10.1007/s12239-012-0030-7>>. Citado 3 vezes nas páginas 23, 28 e 42.

YAGER, Ronald R; ZADEH, Lotfi A. **An introduction to fuzzy logic applications in intelligent systems**. [S.l.]: Springer Science & Business Media, 2012. v. 165. Citado na página 27.

YOONG, M.K et al. Studies of regenerative braking in electric vehicle. In: **2010 IEEE Conference on Sustainable Utilization and Development in Engineering and Technology**. [S.l.: s.n.], 2010. p. 40–45. Citado na página 26.

ZADEH, Lotfi Asker. Probability measures of fuzzy events. **Journal of mathematical analysis and applications**, Academic Press, v. 23, n. 2, p. 421–427, 1968. Citado na página 27.

ZHANG, Shuo; XIONG, Rui; CAO, Jiayi. Battery durability and longevity based power management for plug-in hybrid electric vehicle with hybrid energy storage system. **Applied Energy**, v. 179, p. 316–328, out. 2016. ISSN 03062619. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0306261916309412>>. Citado na página 27.

ZUBEN, Fernando Von. *Computação Evolutiva: Uma Abordagem Pragmática*. jan. 2000. Citado na página 34.

APÊNDICES

APÊNDICE A – APÊNDICE A

A.1 TABELAS FLC

Tabela 9 – Mapeamento das possibilidades de regras

Regra	Entradas			Saídas	
	PwReq	dPwReq	VsC	P_UC	P_bat
Regra 1	7	1	1	K1	K2
Regra 2	7	1	2	K1	K2
Regra 3	7	1	3	K1	K2
Regra 4	7	2	1	K1	K2
Regra 5	7	2	2	K1	K2
Regra 6	7	2	3	K1	K2
Regra 7	7	3	1	K1	K2
Regra 8	7	3	2	K1	K2
Regra 9	7	3	3	K1	K2
Regra 10	6	1	1	K1	K2
Regra 11	6	1	2	K1	K2
Regra 12	6	1	3	K1	K2
Regra 13	6	2	1	K1	K2
Regra 14	6	2	2	K1	K2
Regra 15	6	2	3	K1	K2
Regra 16	6	3	1	K1	K2
Regra 17	6	3	2	K1	K2
Regra 18	6	3	3	K1	K2
Regra 19	5	1	1	K1	K2
Regra 20	5	1	2	K1	K2
Regra 21	5	1	3	K1	K2
Regra 22	5	2	1	K1	K2
Regra 23	5	2	2	K1	K2
Regra 24	5	2	3	K1	K2
Regra 25	5	3	1	K1	K2
Regra 26	5	3	2	K1	K2
Regra 27	5	3	3	K1	K2
Regra 28	4	1	1	K1	K2
Regra 29	4	1	2	K1	K2
Regra 30	4	1	3	K1	K2
Regra 31	4	2	1	K1	K2
Regra 32	4	2	2	K1	K2
Regra 33	4	2	3	K1	K2
Regra 34	4	3	1	K1	K2

Regra	Entradas			Saídas	
	PwReq	dPwReq	VsC	P_UC	P_bat
Regra 35	4	3	2	K1	K2
Regra 36	4	3	3	K1	K2
Regra 37	3	1	1	K1	K2
Regra 38	3	1	2	K1	K2
Regra 39	3	1	3	K1	K2
Regra 40	3	2	1	K1	K2
Regra 41	3	2	2	K1	K2
Regra 42	3	2	3	K1	K2
Regra 43	3	3	1	K1	K2
Regra 44	3	3	2	K1	K2
Regra 45	3	3	3	K1	K2
Regra 46	2	1	1	K1	K2
Regra 47	2	1	2	K1	K2
Regra 48	2	1	3	K1	K2
Regra 49	2	2	1	K1	K2
Regra 50	2	2	2	K1	K2
Regra 51	2	2	3	K1	K2
Regra 52	2	3	1	K1	K2
Regra 53	2	3	2	K1	K2
Regra 54	2	3	3	K1	K2
Regra 55	1	1	1	K1	K2
Regra 56	1	1	2	K1	K2
Regra 57	1	1	3	K1	K2
Regra 58	1	2	1	K1	K2
Regra 59	1	2	2	K1	K2
Regra 60	1	2	3	K1	K2
Regra 61	1	3	1	K1	K2
Regra 62	1	3	2	K1	K2
Regra 63	1	3	3	K1	K2

Fonte: Autoria própria.

Tabela 10 – Limites proposta 175 parâmetros

Parâmetro	Lim. Inferior	Lim. Superior
1	60	120
2	-50	0
3	100	150
4	150	250
5	70	120
6	600	750
7	100	150

Parâmetro	Lim. Inferior	Lim. Superior
8	800	1200
9	100	150
10	1250	1450
11	20	70
12	1600	2000
13	100	150
14	2000	2000
15	1100	1300
16	0	0
17	0	0
18	6	10
19	19	25
20	100	150
21	-600	0
22	20	150
23	0	0
24	20	150
25	100	400
26	20	150
27	400	800
28	20	150
29	800	1200
30	20	150
31	1200	1600
32	20	150
33	1600	2000
34	20	150
35	2000	2200
36	20	150
37	-70	0
38	20	150
39	50	200
40	20	150
41	230	400
42	20	150
43	430	600
44	20	150
45	630	800
46	50	150
47	850	1000
48	80	150

Parâmetro	Lim. Inferior	Lim. Superior
49	1000	1000
50	0	8
51	0	8
52	0	8
53	0	8
...
112	0	8
113	0	7
114	0	7
115	0	7
...
175	0	7

Fonte: Autoria própria.