

Gerenciamento Inteligente de Energia entre Baterias e Ultracapacitores em Veículos Elétricos Leves com Otimização por Enxame de Partículas

Márcio V. R. Campos* Lucas Jonys R. Silva** Thales A. Fagundes**
Rodolpho V. A. Neves* Joseph J. Kalil*** Ricardo Q. Machado**

* Departamento de Engenharia Elétrica, Universidade Federal de Viçosa, MG, (e-mail: marcio.campos, rodolpho.neves@ufv.br).

** Escola de Engenharia de São Carlos, Universidade de São Paulo, SP, (e-mail: lucasjonys, thales.fagundes, rquadros@usp.br).

*** Departamento de Engenharia Mecânica, Universidade Federal de Viçosa, MG, (e-mail: joseph.kalil@ufv.br).

Abstract: This paper presents the modelling of a DC microgrid powered by ion-lithium batteries and a bank of ultracapacitors (UCs), and used as power source in electric vehicles of the Formula SAE competition. The control strategy is implemented for the proper management between the energy sources, to reduce battery degradation and to explore the characteristics of the UCs, which have a high energy gradient to support the power peaks during the acceleration and braking regenerative energy while driving the vehicle. Additionally, computational tools were used to model the power plant, collect electrical data and apply particle swarm optimization (PSO). Finally, the simulations showed a reduction of the battery energy consumption (greater than 10%) with a lesser level of current stress (current peaks) on the Piracicaba-SP track, where the SAE competitions take place.

Resumo: Este artigo apresenta a modelagem de uma microrrede CC formada pela integração de baterias de íon-lítio e banco de ultracapacitores (UCs), utilizados em veículos elétricos da competição Fórmula SAE. Uma estratégia de controle é aplicada para o gerenciamento adequado entre as fontes de energia, a fim de reduzir a degradação das baterias e explorar as características dos UCs, que possuem um alto gradiente de energia para auxiliar nos picos de eventos de potência na aceleração e na frenagem regenerativa durante a condução do veículo. Ferramentas computacionais foram usadas para modelar os sistemas, coletar dados elétricos e aplicar otimização de enxame de partículas (PSO). O sistema simulou uma melhora no consumo de energia da bateria de mais de 10% com menor estresse de picos de corrente elétrica na pista de Piracicaba-SP, onde ocorre as competições SAE.

Keywords: DC microgrid; Ultracapacitors; Optimization; Electric Vehicle; SAE formula.

Palavras-chaves: Microrrede CC; Ultracapacitores; Otimização; Veículo Elétrico; Fórmula SAE.

1. INTRODUÇÃO

O crescente aumento do consumo de eletricidade tem gerado um apelo para um maior uso de fontes de energia renováveis, como as usinas fotovoltaicas e eólicas. Com essa transformação, tais fontes vêm se desenvolvendo cientificamente visando disponibilizar energia de forma barata, segura e confiável para os consumidores. As baterias, ultracapacitores (UCs) e células de hidrogênio têm se mostrado cada vez mais relevantes no propósito de armazenar e fornecer energia elétrica para cargas do setor doméstico, industrial, agrícola e automobilístico (Amaral et al., 2021).

No setor automobilístico, os veículos à combustão são os principais emissores de gases tóxicos e responsáveis pelo efeito estufa. Investir na mobilidade sustentável pode trazer resultados positivos para o meio ambiente através da redução da poluição atmosférica e da emissão de gases geradores de efeito estufa (GEE), contribuindo para melhorar a qualidade do ar urbano e a saúde das pessoas. Nos países da América Latina e do Caribe, a eletrificação dos veículos rodoviários surge como uma opção relevante para atingir estes objetivos (Borba, 2020).

Diante desse desafio de aumentar a participação dos veículos elétricos (VEs) no setor automobilístico, surgem pesquisas que buscam ampliar o uso do sistema de armazenamento de energia para trabalhar de forma eficiente com o sistema de tração do automóvel através de estratégias de controle e gerenciamento dessas fontes renováveis. Em Ortúzar et al. (2007) é projetado um sistema de baterias combinado com UCs com uma lógica de controle que

* Reconhecimentos aos suportes financeiros: Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) processo nº 2022/00628-9 e 2020/05865-3, CNPq 204540 e 312664/2021-4 (PQ), FAPEMIG APQ – 01028-19, CAPES 88887.682783/2022-00 e Fundação de Desenvolvimento da Pesquisa-Fundep Rota 2030/Linha V 27192/27.

aciona a sua descarga em acelerações e recarga nas desacelerações de acordo com o nível do seu estado de carga e velocidade do automóvel. Em Thounthong et al. (2009) é desenvolvido uma estratégia para gerenciar células de hidrogênio, baterias e UCs, simultaneamente, combinando a velocidade de resposta de cada fonte para atender a demanda de potência do veículo, com discussões relevantes sobre a alta densidade energética e da taxa reduzida de fornecimento de energia das células de hidrogênio.

As pesquisas avançaram para estratégias de controle com uso de otimização por programação dinâmica com função de custo envolvendo o controle preditivo através do reconhecimento do perfil de condução, dinâmica veicular e torque de aplicação dos motores (Bender et al., 2013).

Em Henao-Muñoz et al. (2020) é apresentado uma estratégia de controle baseado em decisões lógicas diretas para gerenciar a pressão dos freios nos eixos traseiros e dianteiros do veículo. É discutido sobre as modelagens em equações diferenciais dos sistemas aplicados em veículos Fórmula SAE. A análise dos modelos matemáticos envolvem dados mecânicos e elétricos do sistema de tração e de armazenamento de energia. Dados de comportamentos dinâmicos mais elaborados e o perfil de condução das pistas simuladas também são explorados.

Com o avanço da inteligência computacional, a otimização multiobjetivo está sendo mais explorada na literatura. Em Bai et al. (2020) é abordado um sistema integrado por diferentes variáveis que interferem no desempenho e degradação do sistema de armazenamento de energia híbrido, em especial nas baterias. O trabalho obteve como resultado uma redução da capacidade energética das baterias em veículos elétricos híbridos de mais de 31%, com economia de mais de 30% de acordo com a comparação do *benchmark* dos preços de referência.

Nesse sentido, este trabalho propõe uma estratégia de controle capaz de gerenciar a energia entre baterias e UCs, priorizando a vida útil do sistema através da implementação de um algoritmo de comunicação rápida. Ele é baseado em funções de ativação sigmóides, comumente utilizadas em algoritmos de aprendizagem de máquina, com seus parâmetros escolhidos de forma *off-line*, a partir de otimização por enxame de partículas (PSO). A modelagem completa do VE, com equações dinâmicas do controlador de carga e da dinâmica veicular do automóvel SAE, foi realizada. A estratégia proposta é validada por meio de simulações considerando o circuito de competição SAE da cidade de Piracicaba-SP.

2. DESCRIÇÃO DO SISTEMA

O modelo do veículo com a estratégia de controle proposta é exibido na Figura 1. O conjunto formado pelas baterias de lítio e os UCs pode ser abordado como uma microrrede (MR) CC, fornecendo energia para o barramento principal do controlador de carga através dos conversores CC-CC elevadores. O controlador de tração é um *driver* responsável por injetar ou reaproveitar a potência trabalhada na carga, modelado para aplicação em motor de ímã permanente síncrono (PMSM). O método de controle vetorial de velocidade com torque eletromagnético como saída do motor é utilizado.

O algoritmo de otimização por enxame de partículas é utilizado para atualizar as variáveis da estratégia de controle que definirão o comportamento das fontes de energia. O objetivo é compartilhar potência e minimizar estresses de corrente na bateria, além de manter a MR em operação segura, estável e eficiente.

A carga da MR CC é determinada pela dinâmica veicular, considerando tanto as resistências mecânicas do veículo quanto a quantidade de energia a ser fornecida pela MR para realizar o movimento. O conjunto MR CC, controle de tração e dinâmica veicular compõem o trem de força do veículo. Dessa forma, a compreensão da dinâmica veicular é crucial para o desenvolvimento da estratégia de controle e gerenciamento a ser utilizada.

3. DINÂMICA VEICULAR

Durante a movimentação do VE, diversas forças se opõem ao seu movimento, entre as quais se destacam a força gravitacional, a força peso em pistas com declive, a força entre as rodas e a pista e a força aerodinâmica (Rohan et al., 2018). Essas forças resistivas consomem potência durante o movimento do veículo, mas garantem melhor desempenho de condução em função da sua capacidade de transferir força ao solo.

A relação entre a velocidade de translação do VE e a rotação do motor, desconsiderando o escorregamento dos pneus, pode ser definida por (Leal et al., 2012):

$$v_t = r_d \omega_r, \quad (1)$$

sendo v_t a velocidade tangencial do pneu, r_d o raio dinâmico do pneu e ω_r a velocidade angular da roda.

3.1 Forças resistivas ao movimento

Para o funcionamento do veículo, a potência do motor é utilizada para vencer as resistências ao movimento, como a resistência mecânica (Q_m), a resistência aerodinâmica (Q_a), a resistência de rolamento (Q_r) e a resistência de inércia (Q_I), dadas pelas relações (Leal et al., 2012):

$$Q_m = P_e(1 - \eta)/v_t, \quad (2)$$

$$Q_a = \frac{\rho v_t^2 C A}{2}, \quad (3)$$

$$Q_r = f G \cos \alpha, \quad (4)$$

$$Q_I = M \frac{dv_t}{dt}, \quad (5)$$

sendo P_e a potência de entrada no sistema de transmissão, η a eficiência da transmissão, ρ a densidade do ar, C o coeficiente de arraste do ar, A a área frontal do veículo, f o coeficiente da resistência de rolamento, α o ângulo de aclive da pista, M a massa total do veículo e G a aceleração da gravidade. A resistência total ao deslocamento do veículo é dada pela soma de todas as resistências ao movimento, excluída a mecânica (Leal et al., 2012):

$$Q_t = Q_a + Q_r + Q_I. \quad (6)$$

A força de tração F_t e a força de frenagem F_{fr} podem, então, ser representadas por (Henao-Muñoz et al., 2020; Rohan et al., 2018):

$$F_t = M \frac{dv_t}{dt} + \frac{1}{2} \rho C A v_t^2 + f G \cos \alpha, \quad (7)$$

$$F_{fr} = F_t(1 - k_a)(1 - k_{br}), \quad (8)$$

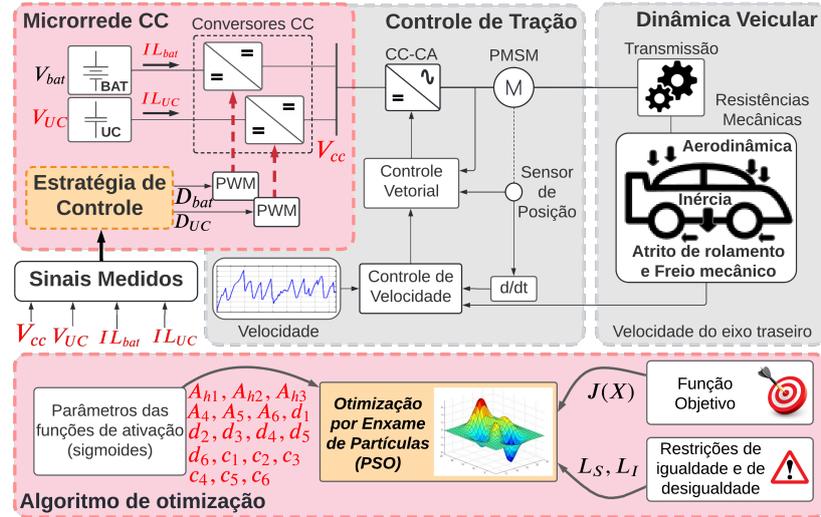


Figura 1. Diagrama completo do veículo com o sistema de gerenciamento de energia proposto.

sendo k_a e k_{br} coeficientes da porcentagem de força aplicada nos freios dianteiros e freios mecânicos nas rodas traseiras, respectivamente. As forças resistivas consomem uma potência dada por (Leal et al., 2012):

$$P_{cons} = Q_t v_t. \quad (9)$$

A Figura 2 exibe as potências disponíveis para aceleração e regeneração, bem como a potência consumida pelo arraste aerodinâmico e pelo rolamento do pneu, todas em função da velocidade tangencial do VE estudado. A potência de regeneração atinge um pico em torno de 45 km/h dada uma mesma taxa de variação de velocidade do veículo projetado para aceleração e desaceleração, permitindo que uma maior energia possa ser reaproveitada em uma velocidade média nessa faixa. Esse perfil de condução pode ser facilmente atingido em pistas urbanas com muitos semáforos e quarteirões, diferentemente das estradas em que o veículo atinge velocidades acima de 60 km/h e possui maior atrito de rolamento com o solo.

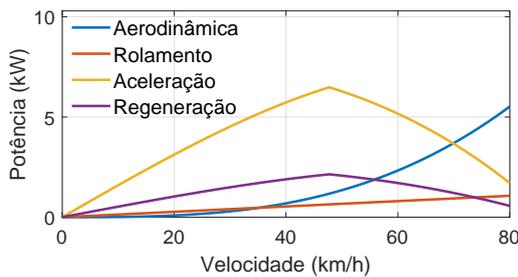


Figura 2. Potência do VE SAE dado uma mesma aceleração e desaceleração para diferentes velocidades.

3.2 Unidade de Transmissão

A unidade de transmissão foi modelada de acordo com a redução das engrenagens entre o eixo de alta velocidade e o eixo de baixa velocidade (Profumo et al., 1996). O torque produzido no motor é dado por (Rohan et al., 2018):

$$\tau_h = \frac{r_d F_t}{i_r}, \quad (10)$$

sendo i_r a taxa de redução das engrenagens.

O rotor do motor e as rodas do veículo são acoplados ao eixo de alta e baixa velocidade, respectivamente. A unidade de transmissão é modelada por (Rohan et al., 2018):

$$\begin{cases} J_{rd} \frac{d\omega_h}{dt} = \tau_h - \frac{\tau_l}{\eta i_r}, & P \geq 0 \\ J_{rd} \frac{d\omega_h}{dt} = \tau_h - \frac{\tau_l \eta}{i_r}, & P < 0 \end{cases}, \quad (11)$$

sendo J_{rd} a inércia do dispositivo de redução, P a potência gerada, $\frac{d\omega_h}{dt}$ a aceleração e τ_h e τ_l os torque do eixo de alta e baixa velocidade da entrada e saída do sistema de redução, respectivamente. Assim, a velocidade angular dos eixos se relacionam por:

$$\omega_l = \frac{\omega_h}{i_r}, \quad (12)$$

sendo ω_l e ω_h a velocidade angular do eixo de baixa velocidade e do eixo de alta velocidade, respectivamente.

A carga que será acoplada ao eixo de baixa velocidade está ligada à inércia das rodas do veículo, às resistências mecânicas e ao coeficiente de viscosidade do motor por (Rohan et al., 2018):

$$J \frac{d\omega_l}{dt} = \tau_l - \tau_{mec} - B\omega_{l_{mec}}, \quad (13)$$

sendo J a inércia das rodas do veículo concentrada no eixo do rotor, τ_{mec} o torque que deve ser compensado pelas resistências mecânicas, B o coeficiente de atrito viscoso do motor e $\omega_{l_{mec}}$ a velocidade real transmitida no eixo de baixa velocidade considerando as resistências mecânicas.

4. CONTROLE DE TRAÇÃO DO VEÍCULO

Como observado na Figura 1, o controle de tração é implementado pelo método clássico de controle de velocidade para motores síncronos de ímã permanente baseada no controle vetorial. A malha de controle de velocidade tem como saída o torque eletromagnético (T_e) de referência solicitado pelo veículo, dado por:

$$T_e = J \frac{d\omega_h}{dt} + C_{vcc} \omega_h + T_m, \quad (14)$$

sendo J a inércia total do sistema, C_{vcc} a capacitância do barramento CC do controlador de carga e T_m o torque mecânico aplicado ao eixo do motor.

Os componentes de referência direta e em quadratura (dq) da corrente do estator correspondentes ao torque comandado são derivados com base na estratégia de controle vetorial. Os componentes dq de referência da corrente do estator são usados para obter os sinais de porta necessários para o inversor por meio de um controlador de corrente de banda de histerese (Bimal, 2002).

A principal vantagem deste *driver* em comparação com os controlados por método escalar é sua resposta dinâmica rápida. O efeito de acoplamento inerente entre o torque e o fluxo na máquina é gerenciado por meio do controle de desacoplamento (orientação do fluxo do estator), que permite que o torque e o fluxo sejam controlados de forma independente. No entanto, devido à sua complexidade de computação, a implementação dessa unidade requer processadores de computação rápida (Bimal, 2002).

4.1 Dimensionamento do motor de tração

A potência efetiva na saída do motor de ímã permanente que vai ser transmitida às rodas motrizes é obtida da curva de potência ou curva de torque do motor, como mostra a Figura 3. A relação entre estas grandezas é dada por (Leal et al., 2012):

$$P = T\omega_h, \quad (15)$$

sendo P a potência gerada e T o torque do motor.

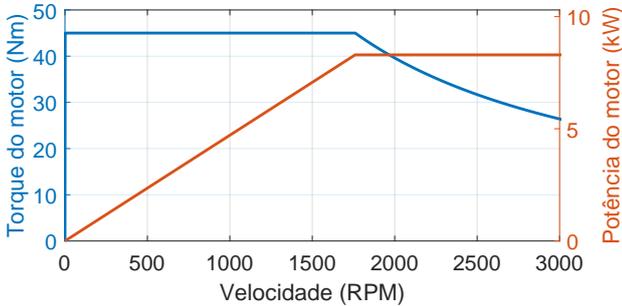


Figura 3. Curva de torque e potência *versus* velocidade angular do motor do veículo SAE.

Analisando a curva do motor, a velocidade base é próxima de 1500 *RPM* com torque de 45 *Nm*, os quais indicam maior eficiência do equipamento. Esse ponto é ajustado através da relação de transmissão do eixo traseiro para que o veículo opere em uma velocidade média de 43 *km/h* garantindo uma maior capacidade de recuperar energia disponível das acelerações.

4.2 Velocidade do veículo

Para que o controle de tração seja satisfeito, é necessário inserir dados da velocidade de referência no modelo implementado. O estudo de caso deste trabalho é um carro de corrida desenhado pela equipe de estudantes da Universidade Federal de Viçosa (UFV), em Viçosa-MG. Os parâmetros aerodinâmicos são apresentados na Tabela 1. O *software* Optimum Lap foi utilizado para

obter o perfil de velocidade do veículo em uma competição real com base nos parâmetros do protótipo do projeto de extensão UFVolts Majorados na UFV (Henao-Muñoz et al., 2020). A pista selecionada é um circuito real, na cidade de Piracicaba-SP, utilizado na competição SAE 2017 e desenvolvida por grupos de estudantes de outras equipes fórmula SAE. O perfil de velocidade do veículo é apresentada na Figura 4, na qual também é apresentada a velocidade média durante o percurso.

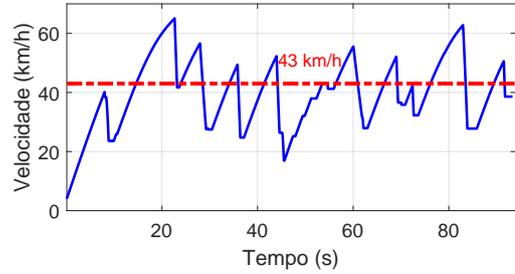


Figura 4. Perfil de velocidade em uma volta no circuito de Piracicaba - SP.

O fornecimento de energia para o veículo é feito pela MR CC, composta por baterias, UCs e conversores CC-CC, cuja operação é coordenada pela estratégia de controle proposta. Assim, é necessário previamente o conhecimento e modelagem da MR.

5. MICRORREDE CC DO VEÍCULO

A Figura 5 mostra o esquema elétrico da MR CC proposta com a integração das fontes armazenadoras ao barramento principal do controlador de carga. Utilizou-se como fonte primária a bateria e como fonte auxiliar um banco de UCs.

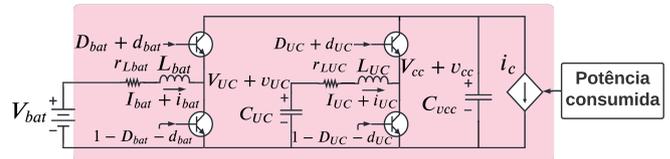


Figura 5. Baterias e UC integrado ao barramento CC do *driver* através dos conversores CC-CC.

Para a modelagem da MR com os conversores independentes em cada fonte, como exibido na Figura 5, utilizou-se o método do modelo médio (variáveis maiúsculas) e modelo em pequenos sinais (variáveis minúsculas). As equações da MR foram organizadas na forma diferencial para implementação na simulação em bloco de espaço de estados, como exibido em (16) (Bastos, 2016). Essa implementação tornou o processamento do algoritmo de otimização mais rápido, por não exigir alta taxa de amostragem e eliminar o uso do controle de malha de corrente com elevadas frequências de chaveamento para os conversores CC-CC. Esse método mostrou mais vantagem devido ao fato de não ser analisado harmônicos neste sistema estudado.

$$\dot{x} = Ax + BX + FV_{bat} + Gi_c, \quad (16)$$

sendo $x = [i_{bat} \ i_{UC} \ v_{cc} \ v_{UC}]^T$, $X = [I_{bat} \ I_{UC} \ V_{cc} \ V_{UC}]^T$ e as matrizes:

$$A = \begin{bmatrix} \frac{r_{Lbat}}{L_{bat}} & 0 & \frac{D_{bat}}{L_{bat}} & 0 \\ 0 & \frac{r_{LUC}}{L_{UC}} & \frac{D_{UC}}{L_{UC}} & -1 \\ \frac{D_{bat}}{C_{vcc}} & \frac{D_{UC}}{C_{vcc}} & 0 & 0 \\ 0 & \frac{-1}{C_{UC}} & 0 & 0 \end{bmatrix}, \quad (17)$$

$$B = \begin{bmatrix} 0 & 0 & \frac{d_{bat}}{L_{bat}} & 0 \\ 0 & 0 & \frac{d_{UC}}{L_{UC}} & 0 \\ \frac{d_{bat}}{C_{vcc}} & \frac{d_{UC}}{C_{vcc}} & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}, \quad (18)$$

$$F = \begin{bmatrix} 1 \\ L_{bat} & 0 & 0 & 0 \end{bmatrix}^T, \quad (19)$$

$$G = \begin{bmatrix} 0 & 0 & -1 \\ C_{vcc} & 0 & 0 \end{bmatrix}^T. \quad (20)$$

As variáveis obtidas nas equações diferenciais da MR foram dimensionadas de acordo com a demanda de potência da carga, considerando níveis de *ripple* na corrente dos indutores dos conversores de $\Delta IL_{bat} = 0,1 A$ e $\Delta IL_{UC} = 1 A$ e eficiência acima de 95%.

5.1 Estratégia de Controle

O modelo de gerenciamento de cargas desenvolvido neste trabalho, exibido na Figura 6, foi adaptado de uma estratégia de controle para balancear o estado de carga de armazenadores de energia conectados a uma rede de distribuição com barramento infinito (Bhosale et al., 2021). Neste trabalho, um controlador PI estabiliza o barramento principal (V_{cc}) após uma demanda de potência, que é alterado devido a baixa inércia do seu capacitor e a baixa impedância do motor em uma descarga ou recarga muito elevada. A saída do controlador é a corrente de referência (I_{ref}) a ser injetada no sistema elétrico de tração para mantê-lo estável, a qual será compartilhada entre as baterias de lítio e os UCs de acordo com as capacidades energéticas (Ah_{bat} e Ah_{UC}) convertidas em níveis de potência necessários para a movimentação do VE.

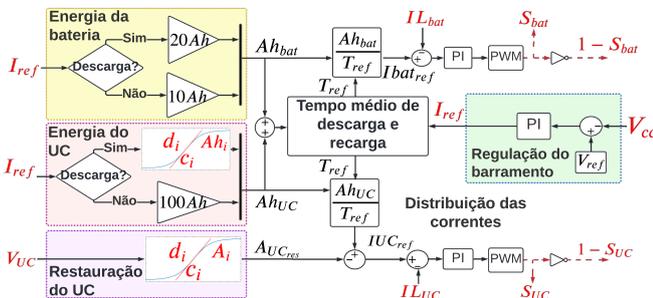


Figura 6. Algoritmo implementado para o gerenciamento das fontes de energia. Através do ciclo de trabalho gerado pelos PIs, o PWM gera os pulsos S_{bat} e S_{UC} .

A lógica do compartilhamento das cargas entre as fontes consiste em reduzir o estresse de corrente em altas de-

mandas de energia sobre as baterias de forma que, nas descargas, os UCs auxiliem quando houver altas acelerações, em que a corrente de referência se torna muito elevada. As funções de ativação sigmóides no gerenciamento dos UCs têm como saída a energia a ser entregue por eles em altos picos de corrente elétrica, dadas por:

$$Ah_{UC} = \sum_{i=1}^3 \frac{Ah_i}{1 + e^{d_i(c_i - I_{ref})}}, \quad (21)$$

sendo Ah_i , d_i e c_i a capacidade energética de saturação, o gradiente ou a velocidade de resposta e os coeficientes de ativação da função para a i -ésima função de ativação sigmoide. I_{ref} é o sinal correspondente à corrente de referência para o banco de UCs auxiliar as baterias em diferentes níveis de corrente acima do valor nominal.

Nas frenagens regenerativas ocorrem picos de potência a serem recuperados pelo sistema de armazenamento de energia. Como os UCs possuem características mais apropriadas para serem recarregados com elevados níveis de corrente em pequenos instantes, eles solicitam uma maior demanda de energia em relação às baterias que, por sua vez, são menos adequadas para serem submetidas a altas correntes de recarga. Dessa forma, o esquema de gerenciamento torna o processo de regeneração de energia mais vantajoso para as baterias, reduzindo sua degradação.

Para a distribuição das correntes das fontes, a estratégia de gerenciamento calcula o tempo médio (T_{ref}) para descarga e recarga, obtido pela razão entre a capacidade total e a corrente de referência:

$$T_{ref} = \frac{Ah_{bat} + Ah_{UC}}{I_{ref}}. \quad (22)$$

Assim, a capacidade de cada fonte armazenadora é dividida pelo tempo de referência para gerar os sinais $I_{bat_{ref}}$ e $I_{UC_{ref}}$ que irão compor o controle de corrente interna do sistema dos conversores aplicados, dados por:

$$I_{bat_{ref}} = \frac{Ah_{bat}}{T_{ref}}, \quad (23)$$

$$I_{UC_{ref}} = \frac{Ah_{UC}}{T_{ref}} - A_{UC_{res}}, \quad (24)$$

sendo $A_{UC_{res}}$ uma nova função de ativação utilizada para gerar a corrente de referência dos UCs com o objetivo de restaurar a sua energia e impedir que baixas tensões sejam atingidas e, assim, prejudiquem os conversores CC-CC com altos níveis de corrente, dada por:

$$A_{UC_{res}} = \sum_{i=4}^6 \frac{A_i}{1 + e^{d_i(V_{UC} - c_i)}}, \quad (25)$$

sendo A_i , d_i , c_i e V_{UC} a corrente de saturação, a velocidade de resposta, os coeficientes preditivos de ativação e os sinais de tensão medidos do UC, respectivamente. Por fim, a partir das correntes de referências definidas em (23) e (24), calcula-se os erros de corrente na bateria e no UC que, por sua vez, são processados por controladores PIs para gerar o ciclo de trabalho a ser aplicado no PWM dos conversores CC-CC no circuito chaveado.

Para definir os parâmetros das funções de ativação da estratégia com o intuito de tornar o desempenho da estratégia ótimo em relação a um objetivo de projeto, o algoritmo de otimização PSO é aplicado neste trabalho.

6. ALGORITMO DE OTIMIZAÇÃO

Para a otimização dos parâmetros das funções de ativação da estratégia de controle, o algoritmo PSO foi utilizado devido a sua simplicidade de implementação, baixo esforço computacional, necessidade de poucos parâmetros de ajuste e por fazer uso de operadores matemáticos primitivos (Abousleiman e Rawashdeh, 2016).

Em cada iteração do PSO, as partículas ou os parâmetros utilizados na otimização se movem na direção da melhor solução do sistema. Um conjunto de partículas formam um grupo, e cada grupo move suas partículas guardando os resultados obtidos e comparando com os resultados anteriores, salvando os melhores. O grupo escolhido é aquele que possui as partículas que entregam a melhor otimização do sistema. Em cada iteração, é selecionado o grupo e cada partícula se move de posição de acordo com a sua velocidade e o caminho ótimo encontrado anteriormente (Nammalvar e Ramkumar, 2018). A operação do algoritmo é descrita por:

$$\begin{cases} \mathbf{V}_k^{n+1} = \omega \mathbf{V}_k^n + (C_1 r_1 + C_2 r_2)(\mathbf{P}_k^n - \mathbf{X}_k^n) \\ \mathbf{X}_k^{n+1} = \mathbf{X}_k^n + \mathbf{V}_k^{n+1} \end{cases}, \quad (26)$$

sendo \mathbf{X}_k e \mathbf{V}_k a posição e a velocidade da k -ésima partícula, respectivamente, \mathbf{P}_k e \mathbf{P}_g a melhor solução da iteração anterior e a melhor solução global, respectivamente, m o número de partículas, n o número de iterações, ω o peso de inércia, C_1 o grau social, C_2 o grau cognitivo e r_1 e r_2 intervalos aleatórios entre 0 e 1. A Figura 7 exhibe as etapas do algoritmo para a busca da solução ótima de acordo com uma função objetivo escolhida no projeto.

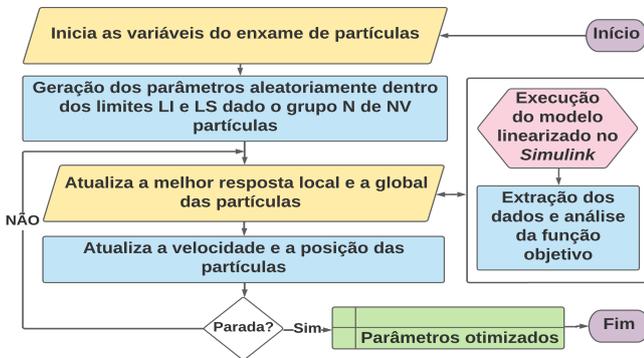


Figura 7. Fluxograma do algoritmo PSO implementado.

6.1 Função objetivo

No sistema de gerenciamento de cargas, os melhores valores dos parâmetros das funções sigmóides serão identificados para produzir um melhor desempenho da bateria com um maior auxílio do banco de UCs. Essas funções são aplicadas para reduzir picos altos de corrente da bateria e evitar que a tensão dos UCs atinja níveis muito baixos. Os erros são contabilizados a partir da extrapolação dos valores limites L_1 e L_2 para a corrente máxima esperada da bateria e da tensão mínima esperada dos UCs, respectivamente. A função objetivo é escolhida como:

$$J(t) = \int_0^T [K_1 E_{L_1}(\mathbf{X}(t)) + K_2 E_{L_2}(\mathbf{X}(t))] dt, \quad (27)$$

sendo E_{L_1} o erro acima do limite de pico de 70 A da bateria e E_{L_2} o erro abaixo da tensão mínima de 40 V dos UCs. Os ganhos K_1 e K_2 , coeficientes de peso da função de custo definidos de forma empírica por ajustes manuais, são iguais a 10 e 12, respectivamente, e T é o tempo máximo da simulação do modelo de 93 s, com passos de 1 μs .

A avaliação da função de custo é feita quando as partículas atualizam sua velocidade e posição e, após realizada a simulação, os resultados da função de custo são coletados. Dessa forma, as melhores experiências pessoais e globais dos grupos de partículas são atualizadas como:

$$\begin{aligned} \text{Se } J(\mathbf{X}_{kj}^{n+1}) < J(\mathbf{P}_{melhor}_{kj}^n) \\ \mathbf{P}_{melhor}_{kj}^n = \mathbf{X}_{kj}^{n+1} \end{aligned} \quad (28)$$

e

$$\begin{aligned} \text{Se } J(\mathbf{P}_{melhor}_{kj}^n) < J(\mathbf{P}_{global}) \\ \mathbf{P}_{global} = \mathbf{P}_{melhor}_{kj}^n, \end{aligned} \quad (29)$$

sendo \mathbf{X}_{kj}^{n+1} e $\mathbf{P}_{melhor}_{kj}^n$ a partícula atual e a partícula de melhor custo de índice k do grupo j para n iterações. O valor \mathbf{P}_{global} é o melhor custo obtido de todos os grupos.

6.2 Restrições dos parâmetros

Para minimização dos erros da função objetivo, é necessário a implementação de restrições para os parâmetros utilizados nas funções de ativação da estratégia de controle de energia dos UCs. Os limites de cada partícula são:

$$\begin{cases} LI_{Ah} < [Ah_1 Ah_2 Ah_3] < LS_{Ah} \\ LI_d < [d_1 d_2 d_3 d_4 d_5 d_6] < LS_d \\ LI_c < [c_1 c_2 c_3 c_4 c_5 c_6] < LS_c \\ LI_A < [A_4 A_5 A_6] < LS_A \end{cases}, \quad (30)$$

sendo LI_{Ah} e LS_{Ah} os limites inferiores e superiores da capacidade energética fornecida pelos UCs, respectivamente, LI_d e LS_d os limites da velocidade de resposta, LI_c e LS_c os limites dos coeficientes de ativação e LI_A e LS_A os limites da corrente elétrica de restauração dos UCs.

7. RESULTADOS DE SIMULAÇÃO

Nesta seção, a operação da estratégia de controle e gerenciamento veicular proposta é validada através de simulações. A Tabela 1 mostra as variáveis dimensionadas para o veículo SAE estudado, enquanto a Tabela 2 informa os valores dos componentes trabalhados na MR. O módulo de bateria utilizado é composto por 30 células de $LiFePO_4$ em série, da fabricante *Zhejiang Gushen Energy Technology*, modelo GSF46160M-28. Foram utilizados dois conjuntos de 28 UCs em série, da fabricante *LS Materials*, modelo LSUC 002R8S 0100F EA.

Para as simulações foram utilizados os softwares *Matlab/Simulink* e *PLECS*, sendo verificadas a resposta do veículo em aceleração e desaceleração, a simulação do sistema de gerenciamento de cargas e uma análise de eficiência do VE. Para as simulações, considerou-se o ângulo de inclinação de aclave $\alpha = 0$, ou seja, uma pista plana característica de competições SAE.

Os parâmetros de desempenho da otimização por enxame de partículas são exibidos na Tabela 3. O desempenho apresentado é obtido utilizando o processador Intel(R) Core(TM) i5-3210M CPU, 2.50 GHz.

Tabela 1. Parâmetros do veículo.

Parâmetro	Valor
Massa total M (kg)	350
Largura L (m)	1,2
Coefficiente de Arraste C	0,85
Coefficiente de força descendente C_d	1,2
Área frontal A (m ²)	0,95
Raio da roda r_d (m)	0,28
Coefficiente da resistência de rolamento f	0,014
Distância entre eixos L_{ltr} (m)	1,53
Eficiência da transmissão η (%)	92
Taxa de redução das engrenagens i_r	3,9
Densidade do ar ρ (kg/m ³)	1,27
Aceleração gravitacional G (m/s ²)	9,81

Tabela 2. Parâmetros elétricos do veículo.

Parâmetro	Valor	
	Bateria	UC
Tensão total das fontes V_{bat}, V_{UC}	96 V	80 V
Perdas das fontes $R_{in_{bat}}, R_{in_{UC}}$	30 mΩ	8,9 mΩ
Indutância dos conversores L_{bat}, L_{UC}	0,63 mH	0,47 mH
Perdas dos indutores $R_{L_{bat}}, R_{L_{UC}}$	0,01 Ω	0,01 Ω
Corrente média I_{bat}, I_{UC}	70 A	40 A
Ciclo de trabalho médio D_{bat}, D_{UC}	0,7	0,55
Frequência de chaveamento f_s	12 kHz	
Capacitância do UC C_{UC}	7 F	
Capacitância do barramento C_{vcc}	3500 μF	
Taxa C das baterias (1C a 5C)	30 Ah a 150 A	
Densidade de energia das baterias	170 Wh/kg	
Densidade de potência máxima dos UCs	9,11 kW/kg	
Tensão do barramento V_{cc}	100 V	

Tabela 3. Parâmetros da otimização PSO.

Número de iterações	10
Número de partículas	12
Número de populações	30
Tempo de processamento (min)	25
Valor global inicial da função objetivo	82441,55
Valor global final da função objetivo	4312,86

7.1 Resposta em aceleração e desaceleração

A Figura 8a e 8b mostra o resultado de amostras em altas acelerações e desacelerações do VE com condição inicial em 50 V e 80 V, respectivamente. Iniciando em 50 V, os UCs atuaram trocando baixa energia com as baterias de forma a ter um nível capaz de auxiliá-las nos picos de potência provocados pelas acelerações do veículo, como observado na Figura 8a. Nela, os UCs auxiliam as baterias até alcançar o seu limite inferior próximo a 40 V. Na frenagem, o UC recuperou a maior parte da energia utilizada após a aceleração e atingiu um saldo maior, aumentando sua capacidade para auxiliar as baterias em uma nova aceleração. Observa-se que foram regeneradas altas correntes elétricas devido à baixa tensão. Em níveis inferiores essa alta recarga pode aumentar o custo dos conversores CC com a adição de novos indutores e semicondutores para permitir uma alta taxa de corrente elétrica de conversão de tensão com maior eficiência.

Com a condição inicial dos UCs em 80 V, durante a descarga de aceleração as baterias foram auxiliadas com uma maior parcela de energia, tornando sua resposta mais suave e evitando que elas ultrapassem 70 A. Nas recargas, os UCs regeneraram boa parte da energia utilizada com

poucos desvios no barramento CC. Nas duas situações, as baterias regeneraram em até 10% da energia nas frenagens e o sistema manteve erros inferiores a 2% no barramento.

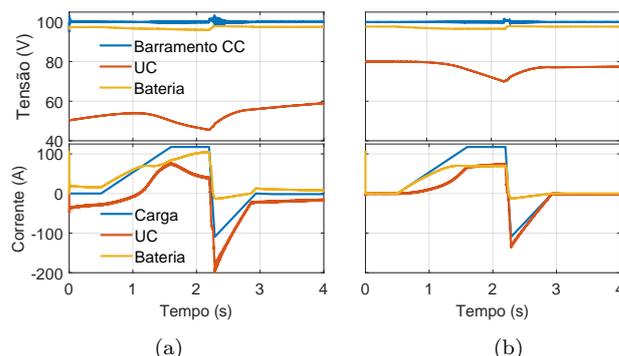


Figura 8. Aceleração e desaceleração para (a) UC em 50 V (b) UC em 80 V.

7.2 Simulação do gerenciamento das cargas

Os resultados da simulação completa considerando a dinâmica da MR CC, controle de tração e resistências mecânicas do veículo são apresentados na Figura 9. A velocidade de resposta do veículo seguiu a dinâmica da velocidade de referência obtida dos dados do *software Optimum Lap*. As respostas dinâmicas para acelerações e desacelerações do veículo também são exibidas. O UC iniciou em 80 V e terminou a volta com 65 V, aproximadamente, auxiliando as baterias em todas os instantes. O nível de tensão foi sempre mantido acima de 40 V.

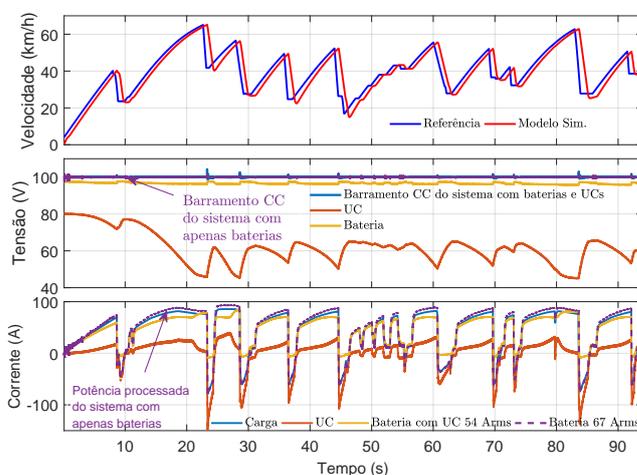


Figura 9. Gerenciamento de energia durante uma volta completa na pista de Piracicaba-SP.

Ainda na Figura 9 é possível observar rampas de desacelerações mais íngremes do que as rampas de acelerações, indicando frenagens abruptas. Entre 20 e 25 s, um curto tempo, há uma redução da velocidade do veículo de 63 para 40 km/h, provocando uma alta energia de regeneração. Isso resulta em uma absorção de até 150 A de corrente que passará nos indutores do conversor do UC. Essa alta potência de recarga requer atenção, uma vez que a maioria das frenagens são mais bruscas nas pistas de corrida, necessitando de componentes mais robustos e caros.

7.3 Análise de eficiência

A Tabela 4 exibe alguns parâmetros para avaliação da eficiência do sistema de armazenamento de energia híbrido com baterias e UCs com a estratégia de controle desenvolvida. Nela, é possível perceber que, sem o sistema acoplado, espera-se que a bateria aumente o seu número de ciclos, reduzindo sua vida útil com perdas de energia devido a um regime de operação maior.

Tabela 4. Consumo em uma volta na pista.

	Baterias	Baterias + UC
Distância (<i>km</i>)	1,09	1,09
Energia consumida (<i>Wh</i>)	136,77	118,00
Corrente eficaz da bateria (<i>A</i>)	67,00	54,11

O auxílio do UC permite que as baterias trabalhem com um desempenho melhor, reduzindo picos de corrente e consumo de energia elétrica nas pistas de competição SAE. O controle de tração favoreceu as respostas do motor, suavizando os gradientes nas acelerações. Assim, o sistema se torna mais adaptável para que as baterias trabalhem dentro da sua faixa de operação eficiente.

8. CONCLUSÃO

Este trabalho apresentou uma estratégia de gerenciamento de energia para um veículo SAE híbrido com fornecimento de energia por baterias de lítio e banco de ultracapacitores. Alguns parâmetros dessa estratégia são otimizados através do algoritmo de otimização PSO para reduzir a degradação das baterias e explorar os UCs em eventos de picos de demanda de potência.

Com o perfil de carga simulado, foi possível obter resultados dinâmicos condizentes com a realidade a fim de projetar os controladores com a estratégia proposta. O modelo da carga considerou as forças resistivas do arraste aerodinâmico, atrito de rolamento, inércia do veículo e perdas da unidade de transmissão. O equacionamento da frenagem mecânica e elétrica foi simplificado por valores fixos de distribuição de forças nos eixos do VE e não permitiu uma análise mais aprofundada de um melhor aproveitamento de energia. Para uma condução considerando a inclinação do veículo, uma estratégia de controle de frenagem mecânica e elétrica deve ser implementada para impedir que os UCs alcancem o nível máximo de sua tensão quando a pista tiver muitas descidas com alta energia potencial. Em pistas com subidas íngremes, a autonomia das baterias pode ser menor, pois os UCs não tem condições de auxiliá-las por muito tempo.

Através da avaliação das respostas obtidas nas simulações computacionais, foi identificado um melhor reaproveitamento de energia e menos perdas no sistema com os UCs. Houve recuperação de energia em altas desacelerações obtendo uma economia acima de 10% do consumo de energia. O sistema também pode ser utilizado em eletroposto para auxiliar no compartilhamento de cargas da rede elétrica, o que torna a MR mais versátil para uso no mercado de energia elétrica.

REFERÊNCIAS

- Abousleiman, R e Rawashdeh, O. (2016). Electric vehicle modelling and energy-efficient routing using particle swarm optimisation, *IET Intelligent Transport Systems*, 10(2), 65-72.
- Amaral, M., Venâncio, R., Peterlevitz, A. e Zanin, H. (2021). Recent advances on quasi-solid-state electrolytes for supercapacitors. *Journal Of Energy Chemistry*, 2021.
- Bai, Y., Li, J., He, H., Dos Santos, R.C., e Yang, Q. (2020). Optimal design of a hybrid energy storage system in a plug-in hybrid electric vehicle for battery lifetime improvement. *IEEE Access*, 8, 142148–142158.
- Bastos, R.F. (2016). Sistema de gerenciamento para a integração em CC de fontes alternativas de energia e armazenadores híbridos conectados a rede de distribuição via conversores eletrônicos, Tese Ph.D., Universidade de São Paulo.
- Bender, F.A., Kaszynski, M., e Sawodny, O. (2013). Drive cycle prediction and energy management optimization for hybrid hydraulic vehicles. *IEEE Transactions on vehicular technology*, 62(8), 3581–3592.
- Bhosale, R.T., Gupta, R., e Agarwal, V. (2021). A Novel Control Strategy to Achieve SOC Balancing for Batteries in a DC MicroGrid without Droop control. *IEEE Transactions on Industry Applications*.
- Bimal, K. (2002) Bose — The University of Tennessee, Knoxville, Modern Power Electronics and AC Drives, book, Copyright 2002, 728 pages.
- Borba, B. (2020) Cenários para acelerar a penetração de veículos elétricos leves no Brasil. Big Push para a Mobilidade Sustentável. CEPAL.
- Henao-Muñoz, A.C., Pereirinha, P., e Bouscayrol, A. (2020). Regenerative braking strategy of a Formula SAE electric race car using energetic macroscopic representation. *World electric vehicle journal* 11(2), 45.
- Leal, Ld.C.M., Rosa, E.d., e Nicolazzi, L.C. (2012). Uma introdução à modelagem quase-estática de automóveis. Publicação interna do GRANTE-Departamento de Engenharia Mecânica da UFSC, Florianópolis, Brazil.
- Nammalvar, P. e Ramkumar, S. (2018). Parameter improved particle swarm optimization based direct-current vector control strategy for solar PV system. *Advances in Electrical and Computer Engineering*, 18(1), 105–112.
- Ortúzar, M., Moreno, J., e Dixon, J. (2007). Ultracapacitor-based auxiliary energy system for an electric vehicle: Implementation and evaluation. *IEEE Transactions on industrial electronics*, 54(4), 2147–2156.
- Profumo, F., Madlena, M., e Griva, G. (1996). State variables controller design for vibrations suppression in electric vehicles. *PESC Record. 27th Annual IEEE Power Electronics Specialists Conference*, Volume 2, 1940–1947. IEEE.
- Rohan, A., Asghar, F., e Kim, S.H. (2018). Design of fuzzy logic tuned PID controller for electric vehicle based on IPMSM using flux-weakening. *Journal of Electrical Engineering and Technology*, 13(1), 451–459.
- Thounthong, P., Rael, S., e Davat, B. (2009). Control of fuel cell/battery/supercapacitor hybrid source for vehicle applications. 2009 IEEE International Conference on Industrial Technology, 193(1), 376–385.