DOI: 10.48011/asba.v2i1.1568

Carregamento Eficiente de Veículos Elétricos usando Algoritmo de Consenso ⋆

Dário M. Sobrinho * **Janaína B. Almada** ** **Ruth P. S. Leão** * **Raimundo F. Sampaio** *

* *Departamento de Engenharia Elétrica Universidade Federal do Ceará-UFC, CE, (e-mail: dariomacedo.eel@gmail.com, rleao@dee.ufc.br, rfurtado@dee.ufc.br).*
** *Instituto de Engenharias e Desenvolvimento Sustentável, Universidade da Integração Internacional da Lusofonia Afro-Brasileira-UNILAB, CE, (e-mail: janainaalmada@unilab.edu.br)*

Abstract: With the growth in the number of electric vehicles (EVs) in the last ten years, increases the concern and the challenge for electric distribution networks with additional load volume and random mobility of EVs. Managing the charging of a large number of EVs will be critical to the successful adoption of this new transport technology. This article presents a control and optimization strategy to manage the charging of EVs, aiming to reduce the electrical losses. The charging takes place according to the available capacity of a charging station present in a parking lot. For that, two case studies are carried out, for 10 EVs and for 100 EVs. The objective is achieved with the application of the consensus algorithm that only needs information exchanged between neighboring EVs. Distributed control has a low computational and communication cost compared to other control architectures. Consensus-based EV charging management is adaptable to the variable number of EVs. The results demonstrated that the coordination of charging can be effectively carried out by consensus.

Resumo: Com o crescimento do número de veículos elétricos (VEs) nos últimos dez anos, cresce a preocupação e o desafio para as redes elétricas de distribuição com o volume adicional de carga e a mobilidade aleatória dos VEs. O gerenciamento do carregamento de um número elevado de VEs será fundamental para a adoção bem-sucedida dessa nova tecnologia de transporte. Este artigo apresenta uma estratégia de controle e otimização para gerenciar o carregamento de VEs, visando a redução de perdas elétricas. O carregamento é realizado em função da potência disponível de uma estação de carregamento presente em um estacionamento. Para tanto, dois estudos de caso são realizados, para 10 VEs e para 100 VEs. O objetivo é alcançado com a aplicação do algoritmo de consenso que precisa apenas de informações trocadas entre VEs vizinhos. O controle distribuído possui um baixo custo computacional e de comunicação em relação a outras arquiteturas de controle. O gerenciamento de carregamento de VEs baseado em consenso é adaptativo ao número variável de VEs. Os resultados demonstram que a coordenação de carregamento pode ser eficientemente realizada por consenso.

Keywords: Electric vehicles; consensus algorithm; distributed control; efficient charging; charging station.

Palavras-chaves: Veículos elétricos; algoritmo de consenso; controle distribuído; carregamento eficiente; estação de carregamento.

1. INTRODUÇÃO

Nos últimos anos, a mobilidade urbana e a emissão de gases de efeito estufa cresceram em um ritmo bastante elevado (Tayarani et al., 2018). O desenvolvimento de VEs vem surgindo como uma alternativa à descarbonização do meio ambiente. De acordo com IEA (2019), o número de VEs deverá exceder 55 milhões em 2025 e 135 milhões em 2030 a nível mundial, excluindo-se dessa análise VEs de duas e três rodas. Aliado a esse crescimento, a demanda de energia referente aos VEs é projetada para alcançar quase 640 TWh em 2030, o que corresponde ao consumo total de eletricidade de países como Alemanha e Holanda (IEA, 2019). Diante deste cenário, as redes elétricas de distribuição enfrentam desafios com a inserção do transporte elétrico no mercado.

O carregamento não controlado de VEs pode causar impactos signficativos em redes de distribuição. Dentre os impactos negativos, se destacam, principalmente, o aumento de perdas elétricas e de queda de tensão, sobrecarga, circulação de correntes harmônicas, aumento de temperatura e de aceleração do envelhecimento de transformadores e etc. (Zheng et al., 2019).

⋆ Este trabalho recebeu apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES)

Para minimizar os possíveis impactos causados pelo carregamento de VEs, estratégias de controle devem ser adotadas com arquiteturas classificadas como: centralizada, descentralizada e distribuída.

No controle centralizado de carregamento, tem-se uma única unidade central de controle, responsável por gerenciar a potência e o tempo de carregamento dos VEs através da otimização de uma dada função objetivo. Sortomme et al. (2010) apresentam uma estratégia de controle que minimiza a variação total da carga de VEs, enquanto o trabalho de He et al. (2012) tem como objetivo minimizar custos de carregamento dos VEs. Embora de fácil aplicação prática, o controle centralizado lida com diversas variáveis e sua aplicação para uma larga escala de VEs resulta em um elevado custo computacional e de comunicação, além de baixa tolerância à falha em caso de perda da unidade central (Zheng et al., 2019).

O controle descentralizado de carregamento de VEs, em sua maioria é caracterizado pela hierarquização da estrutura de controle, requerendo determinado nível de comunicação entre os diferentes dispositivos do sistema. Em Ahn et al. (2011), um algoritmo de dois níveis de controle de carregamento é desenvolvido, objetivando alcançar deslocamento de carga e regulação de frequência. Já em Teng et al. (2016) é feito um controle totalmente descentralizado projetado para minimizar os impactos do carregamento de VEs na rede de distribuição. Quando comparado ao método de controle centralizado, o controle descentralizado de carregamento de VEs reduz os requisitos de comunicação e permite uma computação mais eficiente (Zheng et al., 2019).

A estratégia de controle distribuído é o modelo descentralizado levado ao seu limite. A comunicação é local e acontece através de VEs vizinhos, consequentemente, o custo computacional e de comunicação é bem inferior se comparado às outras duas estratégias de controle. Hu et al. (2017) apresentam um algoritmo distribuído que utiliza um método subgradiente para minimizar os custos de carregamento de VEs em agregadores e responder às requisições individuas de energia para VEs durante um período de 24 horas. Em Hua et al. (2018), os autores propõem um algoritmo distribuído baseado no método de direção alternada de multiplicadores (ADMM), usado para decompor o múltiplo fluxo de carga otimizado em duas etapas resolvidas de forma alternativa e iterativa. Em Chen and Cheng (2014), uma estação de carregamento e descarregamento de VEs realiza regulação de frequência, utilizando o ADMM.

Dentre as estratégias de controle distribuídos, o algoritmo de consenso vem sendo utilizado em diversas aplicações envolvendo VEs, por exemplo: regulação de frequência (Yang et al., 2012); carregamento eficiente , (Xu, 2014); carregamento e descarregamento de VEs (Wang and Chen, 2019); carregamento cooperativo de VEs utilizando as condições de Karush-Kuhn-Tucker(KKT) (Rahbari-Asr and Chow, 2014); carregamento de VEs considerando hierarquia de transformadores (Zou et al., 2018).

Nesse contexto, este trabalho tem como objetivo realizar o carregamento eficiente de VEs, usando um algoritmo de consenso distribuído para minimizar as perdas de potência causadas pela resistência interna do modelo de bateria dos VEs. Baseado no trabalhos de Wang and Chen (2019), este artigo utiliza uma metodologia diferente para o cálculo da capacidade da bateria de cada VE e considera o carregamento como sendo o tipo 2 por ser mais frequentemente utilizado na Europa e na China (Knez et al., 2019). Nesse estudo, é assumido que os VEs estão localizados em um estacionamento que possui uma estação de carregamento com certa potência disponível definida. Dois estudos de caso são apresentados para demonstrar a efetividade do algoritmo frente a uma pequena e a uma grande quantidade de VEs.

2. DEFINIÇÃO DO PROBLEMA

Para o estudo realizado, é assumido que a estação de carregamento dispõe de um número definido de soquetes e de um certo valor de potência contratada para carregar todos os VEs. Cada VE representa um agente nesse processo de carregamento. O estacionamento funciona com cada usuário de um VE informando o seu tempo de permanência no estacionamento e a autonomia desejada para o VE no momento de saída do estacionamento. A autonomia do VE é vista através do estado de carga (SOC) do veículo.

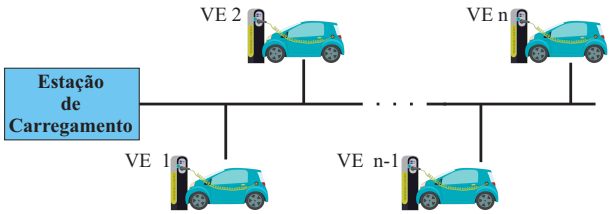

Figura 1. Camada de conexão física.

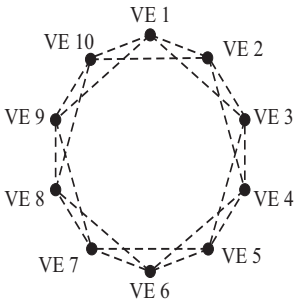

Figura 2. Camada de comunicação.

Como ilustrado na Figura 1, os VEs do estacionamento terão uma camada de conexão física, através dos soquetes da estação de carregamento de energia elétrica. Existe ainda a camada de comunicação, ilustrada na Figura 2, na qual cada veículo se comunica com seu vizinho adjacente. É através da camada de comunicação que os VEs trocarão informações necessárias ao funcionamento do algoritmo e irão obter uma concordância em relação ao objetivo pré-definido, que é realizar o carregamento de acordo com o seu tempo de permanência e a quantidade de autonomia necessária.

3. MODELAGEM MATEMÁTICA DO PROBLEMA

O problema é modelado a partir da bateria de um VE, a qual é considerada por seu circuito equivalente que

consiste em uma tensão de circuito aberto em série com uma resistência. O objetivo do problema é minimizar as perdas de potência causadas no carregamento, devido à resistência interna da bateria.

O modelo de bateria utilizado pode ser formulado em tempo discreto, como

$$V_{b,i} = V_{oc,i} + R_i \times I_{br,i}(k) \tag{1}$$

Em que $V_{b,i}$, $V_{oc,i}$, $I_{br,i}(k)$ e R_i são a tensão nos terminais da bateria, a tensão de circuito aberto, a corrente real de carregamento da bateria e resistência interna da bateria referentes do i-ésimo VE, respectivamente, k representa o k-ésimo instante do tempo da simulação.

A potência de carregamento do i-ésimo VE é obtida com

$$P_i(k) = V_{oc,i} \times I_{br,i}(k) + R_i \times I_{br,i}^2(k) \tag{2}$$

Através de (2), é possível obter a corrente de carregamento da bateria para o i-ésimo VE

$$I_{br,i}(k) = \frac{1}{2 \times R_i} \times (-V_{oc,i} + \sqrt{V_{oc,i}^2 + 4 \times R_i \times P_i(k)}) \tag{3}$$

Essa equação é sujeita à seguinte restrição

$$0 \leq I_{br,i}(k) \leq I_{br,i}^{max}(k) \tag{4}$$

O SOC de cada VE é calculado através de (5), cuja restrição é expressa em (6). O SOC de cada VE no momento de saída do estacionamento é calculado por (7).

$$SOC_i(k+1) = SOC_i(k) + \frac{\Delta T}{Q_i} \times I_{br,i}(k) \tag{5}$$

$$SOC_{i,o} \leq SOC_i(k) \leq SOC_i(K_i) \tag{6}$$

$$SOC_i(K_i) = SOC_{i,o} + \sum_{k=1}^{K_i} \frac{\Delta T}{Q_i} \times I_{br,i}(k) \tag{7}$$

em que ΔT, Q_i, $SOC_{i,o}$ e $SOC_i(K_i)$ representam, respectivamente, o período de amostragem da simulação em horas, a capacidade da bateria em Ah, o SOC inicial e o SOC final do i-ésimo VE. $K_i = T_i/\Delta T$, em que T_i representa o tempo de permanência do i-ésimo VE no estacionamento.

As perdas de potência causadas pela resistência interna da bateria podem ser minimizadas com

$$min \sum_{k=1}^{K_i} I_{br,i}^2(k) \times R_i \tag{8}$$

Equação 8 pode ser representada através de (9), de acordo com propriedades de inequação (Gwanyama, 2004).

$$\sum_{k=1}^{K_i} I_{br,i}^2(k) \times R_i \geq \left(\frac{(\sum_{k=1}^{K_i} I_{br,i}(k))^2}{K_i} \right) \times R_i \tag{9}$$

Em (9), de acordo com uma das propriedades de inequações, a igualdade entre os dois lados da expressão é mantida quando a corrente da bateria do i-ésimo VE mantém um valor constante durante todo o tempo. Caso essa corrente se mantenha constante, o lado direito de (9) atinge seu maior valor, enquanto produz o menor valor no lado esquerdo. Ou seja, as perdas de potência causadas pela resistência interna da bateria são minimizadas. A corrente ideal que produz esse efeito pode ser representada como

$$I_i^{ideal}(k) = \frac{Q_i \times (SOC_i(K_i) - SOC_{i,o})}{K_i \times \Delta T} \tag{10}$$

Assim sendo, cada VE, para minimizar as perdas causadas pelo carregamento, deseja manter essa corrente constante, como foi definido em (9). Entretanto, não é possível realizar isso de forma prática por causa das diferenças da capacidade de potência disponível para cada VE em cada passo de simulação. Além disso, o algoritmo acontece em tempo real, por conseguinte, a corrente de referência do k-ésimo passo de simulação é atualizada de acordo com o tempo de carregamento restante e a capacidade de bateria que necessita ser carregada, através de (11).

$$I_i^{ref}(k) = \frac{(SOC_i(K_i) - SOC_i(k)) \times Q_i}{(Ki - k) \times \Delta T} \tag{11}$$

Também é necessário a utilização de um fator de prioridade de carregamento para cada um dos VEs, o qual varia de acordo com o tempo restante no local de carregamento e a capacidade de bateria que falta ser carregada (Wang and Chen, 2019). Esse fator é definido por (12).

$$\rho_i(k) = \frac{1}{SOC_i(k) \times (T_i - k \times \Delta T)} \tag{12}$$

Com a análise feita, a minimização das perdas de potência causada pela resistência interna da bateria é equivalente a forçar a corrente real de carregamento da bateria $I_{br,i}(k)$ a seguir a corrente de referência $I_i^{ref}(k)$. Ou seja, o problema de otimização pode ser modelado da seguinte forma

$$C = min \sum_{i=1}^{Nev} = min \sum_{i=1}^{Nev} (\rho_i(k) \times (I_i^{ref}(k) - I_{br,i}(k))^2)$$

$$= \sum_{i=1}^{Nev} (\rho_i(k) \times (I_i^{ref}(k)^2 - \frac{I_i^{ref}(k) \times V_{oc,i}}{R_i} + \frac{V_{oc,i}^2}{2 \times R_i^2} + \frac{P_i(k)}{R_i} - (\frac{I_i^{ref}(k)}{R_i} + \frac{V_{oc,i}}{2 \times R_i^2}) \times \sqrt{V_{oc,i}^2 + 4 \times R_i \times P_i(k)}))) \tag{13}$$

O problema formulado possui as seguintes equações de restrições

$$P_i^{min} \leq P_i(k) \leq P_i^{max} \tag{14}$$

$$\sum_{i=1}^{Nve} P_{i(k)} \leq P_{disp.}(k) \tag{15}$$

em que $P_{disp.}(k)$ é a potência total de carregamento disponível da estação de carregamento. Equação (14) representa a restrição de potência que pode ser carregada, em cada instante de tempo, no i-ésimo VE. Equação (15) representa a restrição de carregamento de potência para todos os VE.

O desvio de potência para o i-ésimo VE é calculado por (16).

$$P_{D,i}(k) = P_i(k) - P_{rede,i}(k) \tag{16}$$

A análise realizada leva em consideração uma função objetivo, a qual será minimizada utilizando no algoritmo de consenso o custo incremental dessa função. O custo incremental para o i-ésimo VE é obtido com

$$r_i = \frac{\partial C_i}{\partial P_i(k)} = \rho_i(k) \times \left(\frac{1}{R_i} - \frac{V_{o,i} + 2R_i I_i^{ref}(k)}{R_i \sqrt{V_{o,i}^2 + 4R_i P_i(k)}} \right) \tag{17}$$

O custo incremental é limitado de acordo com os limites de potência, conforme definido por Wood et al. (2013).

$$\begin{cases} r_i^* = \dfrac{\partial C_i}{\partial P_i(k)}, \; para \; P_i^{min} < P_i(k) < P_i^{max} \\ r_i^* > \dfrac{\partial C_i}{\partial P_i(k)}, \; para \qquad P_i(k) = P_i^{max} \\ r_i^* < \dfrac{\partial C_i}{\partial P_i(k)}, \; para \qquad P_i(k) = P_i^{min} \end{cases} \tag{18}$$

em que r_i^* representa o custo incremental para o algoritmo de consenso.

De acordo com (17), a potência de carregamento do i-ésimo VE pode ser representada por

$$P_i(k) = \begin{cases} \dfrac{(V_{oc,i} + 2R_i I_i^{ref}(k))^2}{4R_i(\frac{1-R_i r_i}{\rho_i(k)})^2} - \dfrac{V_{o,i}^2}{4R_i}, \; para \; 0 \le P_i(k) \le P_i^{max} \\ P_i^{max}, \qquad\qquad para \quad P_i(k) > P_i^{max} \\ P_i^{min}, \qquad\qquad para \quad P_i(k) < P_i^{min} \end{cases} \tag{19}$$

em que $P_i(k)$ representa o carregamento ótimo de potência para os VEs. As potências P_i^{max} e P_i^{min} são definidas como sendo 7,4 kW e 0, respectivamente. Esses valores estão de acordo com o carregamento tipo 2 (Mennekes), que é a forma de carregamento mais frequente atualmente na Europa e China (Knez et al., 2019).

4. PARÂMETROS INICIAIS DOS VES

Os parâmetros utilizados para calcular a capacidade da bateria de cada VE considerado na simulação foram retirados de diferentes modelos de VEs presentes no mercado, sendo eles: Hyundai INONIQ Electric (2020) de 38,3 kWh; Renault Kangoo Z.E (2017) de 33 kWh; VW e-Golf (2017) de 36 kWh; Renault ZOE R110 ZE40 (2018) de 41 kWh; BMW i3 (2018) de 42,2 kWh (EVSpecifications, 2020). A capacidade de bateria dos VEs é selecionada aleatoriamente dentro de um intervalo de 36 a 42,2 kWh. Partindo desse ponto, como a modelagem do problema considera a unidade de capacidade da bateria em Ah e não em kWh, essa potência em kWh é convertida em Ah através de (20).

$$Q(Ah) = \frac{Q(kWh) \times 1000}{V_{nom}} \tag{20}$$

Para demonstrar a prioridade no carregamento de VEs com menores tempos de permanência, usando o fator de prioridade ρ_i definido em (12), 30% da quantidade total de VEs é definida com um tempo de permanência entre 3h e 4h. Os demais VEs irão ter um tempo de permanência entre 4,5h e 6h. A escolha do tempo de permanência para cada VE dentro desses dois diferentes intervalos é realizada de forma aleatória, através de uma distribuição uniforme.

Os parâmetros restantes necessários ao funcionamento do modelo são obtidos, de acordo com a Tabela 1.

Tabela 1. Parâmetros dos VEs

$V_{oc,i}$ (V)	$V_{oc,i} = 300 + 0,1 \times randi([-100\ 100], 1, 1)$
R_i (Ω)	$R_i = 1 + 0,01 \times randi([-10\ 30], 1, 1)$
$QkWh_i$ (kWh)	$QkWh_i = 36 + 0,1 \times randi([-50\ 62], 1, 1)$
SOC_i	$SOC_i = 0,3 + 0,01 \times randi([-5\ 10], 1, 1)$
$SOC_i(K_i)$	$SOC_i(K_i) = 0,85 + 0,01 \times randi([-5\ 5], 1, 1)$
V_{nom} (V)	$V_{nom} = 340 + randi([-20\ 20], 1, 1)$

5. ALGORITMO UTILIZADO

A teoria dos grafos foi utilizada nesse estudo para simular a rede de comunicação que possui os VEs interligados. A troca de informações é realizada através do algoritmo de consenso em tempo discreto. As informações trocadas entre um VE e os seus vizinhos são o custo incremental e o desvio de potência.

5.1 Teoria dos grafos

Um grafo G é definido por $G = (V, E)$, em que $V = \{1, 2, ..., n\}$ representa um conjunto de nós e $E = (i, j) \subseteq V \times V$ representa um conjunto de arestas. Nesse trabalho, cada nó representa um VE. O nó i representa o i-ésimo VE, enquanto a aresta (i, j) representa a conexão entre o i-ésimo e o j-ésimo VE. Os vizinhos do i-ésimo VE são definidos como $N_i = \{j \in V | (i, j) \in E\}$. O tipo de grafo utilizado nesse trabalho é o grafo não direcionado, ou seja, a aresta (i, j) pode levar informação do agente i até o agente j e vice-versa (Ren and Beard, 2008).

5.2 Algoritmo de consenso em tempo discreto

O algoritmo de consenso em tempo discreto pode ser implementado através de (21). Levando em consideração a estimativa de erro de rastreamento, de acordo com o proposto em Lewis et al. (2013), o algoritmo de consenso pode ser representado por (22).

$$x_i[k+1] = \sum_{j=1}^{n} d_{ij}(k) x_j(k), \qquad i = 1, ..., n \tag{21}$$

$$x_i[k+1] = \sum_{j=1}^{n} d_{ij}(k) x_j(k) + \varepsilon\delta(k), \qquad i = 1, ..., n \tag{22}$$

em que $x_i[k+1]$ representa a informação atualizada do i-ésimo agente no instante $k+1$; $x_j(k)$ representa a informação do j-ésimo agente no instante k; ε representa o coeficiente de controle; d_{ij} representa o coeficiente da matriz de pesos estocástica, a qual influencia a velocidade de convergência do algoritmo. Nesse estudo, a matriz de pesos utilizada é a matriz de Metropolis, que se caracteriza por ser adaptativa à quantidade de agentes (Bakken, 2014). O elemento d_{ij} da matriz de pesos pode ser definido por (23).

$$d_{ij} = \begin{cases} \dfrac{2}{n_i + n_j + 1}, & j \in N_i \\ 1 - \displaystyle\sum_{j \in N_i} \dfrac{2}{n_i + n_j + 1}, & i = j \\ 0, & \textit{caso contrário} \end{cases} \tag{23}$$

em que n_i e n_j representam o número de vizinhos do agente i e do agente j, respectivamente.

Para que o algoritmo alcance a convergência, é necessário que a matriz de peso D possua as seguintes propriedades:

(1) A soma das linhas e das colunas deve ser igual a 1;
(2) O valor absoluto de todos os autovalores de D devem ser ≤ 1, de acordo com o teorema do círculo de Gershgorin (Lewis et al., 2013).

5.3 Regra de iteração do algoritmo

O algoritmo de consenso utilizado nesse estudo funciona a partir das seguintes equações que são executadas iterativamente:

$$r_i[t+1] = \sum_{j=1} d_{ij} r_j[t] - \varepsilon P_{D,i}[t] \tag{24}$$

$$P_i[t+1] = \frac{(V_{oc,i} + 2R_i I_i^{ref}(k))^2}{4R_i(\frac{1-R_i r_i[t+1]}{\rho_i(k)})^2} - \frac{V_{oc,i}^2}{4R_i} \tag{25}$$

$$P'_{D,i}[t] = P_{D,i}[t] + (P_i[t+1] - P_i[t]) \tag{26}$$

$$P_{D,i}[t+1] = \sum_{j=1} d_{ij} P'_{D,j}[t] \tag{27}$$

em que t é o passo de simulação do algoritmo de consenso; $r_i[t+1]$ é o custo incremental da troca de informações entre o i-ésimo VE e o seus vizinhos; $P_i[t+1]$ é a potência de carregamento do i-ésimo VE na iteração $t+1$; $P_{D,i}[t+1]$ é o desvio de potência, i.e., a diferença entre a potência de carregamento do VE e a potência disponível para carregamento do i-ésimo VE.

5.4 Implementação do algoritmo de consenso

É assumido que apenas o primeiro VE conhece a potência disponível de carregametno da estação de carregamento. Dessa forma, a inicialização do algoritmo de consenso, iteração $t = 1$, é realizada de acordo com as seguintes equações:

$$P_{rede,i}[1] = \begin{cases} P_{rede}(k), & para \;\; i = 1 \\ 0, & \textit{caso contrário} \end{cases} \tag{28}$$

$$P_i = \left\{ \begin{array}{l} P_{rede,i}[1], \; se \;\; P_i^{min} \leq P_{rede}(k) \leq P_i^{max} \\ P_i^{max}, \quad\;\; se \;\; P_{rede}(k) \geq P_i^{max} \\ P_i^{min}, \quad\;\; se \;\; P_{rede}(k) \leq P_i^{min} \end{array} \right\} para \;\; i = 1$$
$$0, \;\; para \;\; i \neq 1 \tag{29}$$

$$P_{D,i}[1] = P_i[1] - P_{rede,i}[1] \tag{30}$$

$$r_i = \rho_i(k) \times \left(\frac{1}{R_i} - \frac{V_{o,i} + 2R_i I_i^{ref}(k)}{R_i \sqrt{V_{o,i}^2 + 4R_i P_i(k)}} \right) \tag{31}$$

A Figura 3 ilustra o funcionamento do algoritmo proposto.

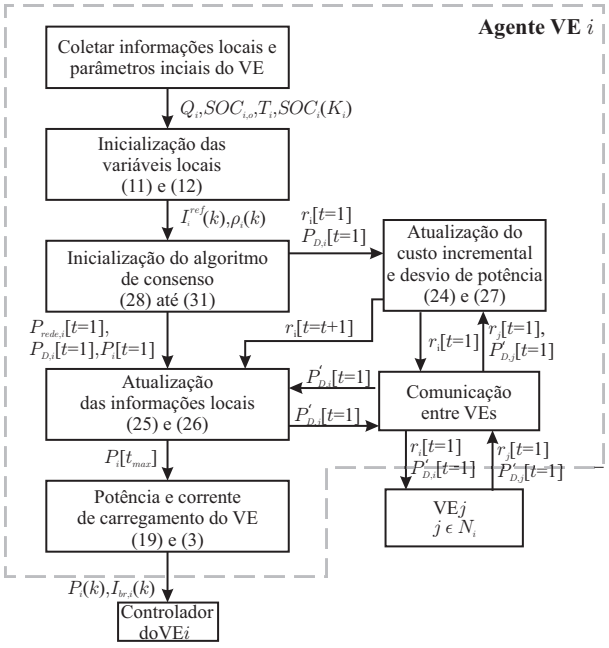

Figura 3. Troca de informações entre VEs vizinhos.

Inicialmente, o i-ésimo VE coleta as informações referentes à capacidade de bateria, ao SOC atual do VE, ao SOC final desejeado e ao tempo de carregamento. Após isso, a corrente de referência e o fator de prioridade do VE são inicializados através de (11) e (12), respectivamente. O algoritmo de consenso é inicializado com as equações (28)-(31). Com isso, as informações locais P_i e $P'_{D,i}$ são atualizados através de (25) e (26). O custo incremental r_i e o desvio de potência $P_{D,i}$ são atualizados através de (24) e (27). As informações $P'_{D,i}$ e r_i são compartilhadas com os vizinhos do i-ésimo VE. Simultaneamente, o i-ésimo VE recebe as informações $P'_{D,j}$ e r_j dos VEs vizinhos. Finalmente, a potência e a corrente de carregamento finais são obtidas através de (19) e (3).

6. RESULTADOS E DISCUSSÃO

Nessa seção, dois estudos de caso são apresentados com o objetivo de demonstrar e validar a funcionalidade do algoritmo de consenso para o problema de minimização da redução de perdas do carregamento de VEs.

6.1 Estudo de caso 1

Nesse estudo de caso, é assumido que a estação de carregamento possui 10 soquetes para carregar os VEs. Os VEs 4, 6 e 9 foram selecionados aleatoriamente para terem um tempo de permanência menor que os outros VEs, saindo após permancerem na estação 3,5h, 3,0h e 4,0h, respectivamente. Os demais VEs têm seu tempo de permanência escolhido de forma aleatória dentre o intervalo de 4,5h e 6h. O objetivo é demonstrar a adaptabilidade do algoritmo a saídas aleatórias. A potência de carregamento disponível é definida como sendo de 34 kW e o passo de tempo da simulação como sendo de 5 minutos. A troca de informações entre os agentes é realizada a cada 0,01 segundos. O coeficiente de controle é definido como sendo 5×10^{-6}. Cada VE possui 4 vizinhos, se comunicando com os seus vizinhos adjacentes de acordo com a sua organização na camada de comunicação, conforme mostra a Figura 2.

Com os parâmetros definidos pela Tabela 1, a simulação é realizada.

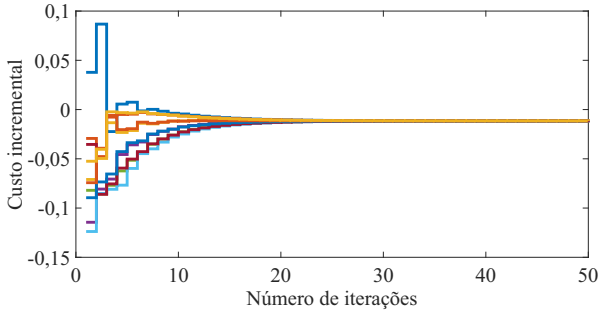

Figura 4. Custo incremental.

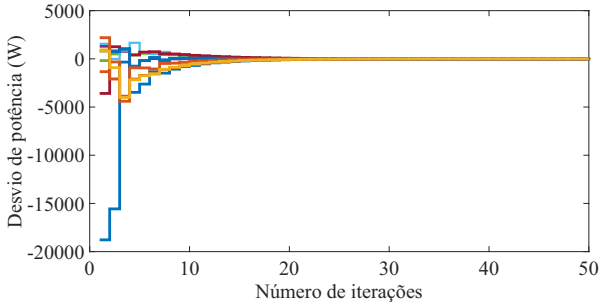

Figura 5. Desvio de potência.

As Figuras 4 e 5 ilustram a convergência do algoritmo em relação às informações de custo incremental e desvio de potência, respectivamente. Em ambas as figuras a convergência acontece perto da 30ª iteração. Em termos de tempo, o algoritmo precisou de 0,3 segundos ($30 \times 0{,}01$) para convergir. A convergência do custo incremental em um valor próximo de zero indica que os agentes conseguem chegar a um acordo em relação ao valor de potência que será distribuído. Por outro lado, a convergência do desvio de potência em um valor próximo de zero indica que os VEs conseguem utilizar completamente a potência disponível.

Na Figura 6, as correntes de referência e de carregamento da bateria são mostradas. Essas correntes são representadas para os VEs 4, 6 e 9 com saídas do estacionamento às 3,5h, 3,0h e 4,0h, respectivamente. À medida que o

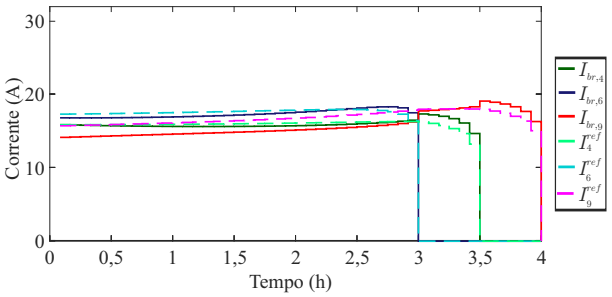

Figura 6. Corrente de referência e corrente de carregamento.

tempo de partida de cada um dos VEs se aproxima, a sua corrente de carregamento tende a se aproximar da corrente de referência. Há um pequeno erro referente à diferença entre a potência disponível para carregar cada VE individualmente e a potência necessária para carregar o VE. Para o 6º VE, esse erro é relativamente pequeno no início e vai se tornando menor com o avanço do tempo de permanência até a corrente de carregamento da bateria se tornar maior que a corrente de referência, quando o 6º VE já está perto de deixar o estacionamento. A mesma situação acontece com os outros dois VEs.

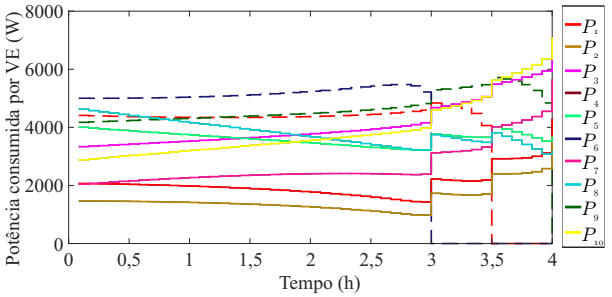

Figura 7. Potência consumida pelos VEs.

A Figura 7 mostra a potência consumida por cada um dos VEs durante o período de 4h. Os VEs 4, 6 e 9 estão utilizando mais potência em relação aos outros VEs. Isso acontece por causa do fator de prioridade de carregamento, que é maior para o VE com menos tempo de permanência no estacionamento. Também é válido destacar que, no momento de saída do VE 6, ocorre uma redistribuição da potência, anteriormente alocada ao VE 6, para os demais VEs. Isso evidencia a adaptabilidade do algoritmo a saídas aleatórias. O mesmo acontece quando os VEs 4 e 9 saem do estacionamento.

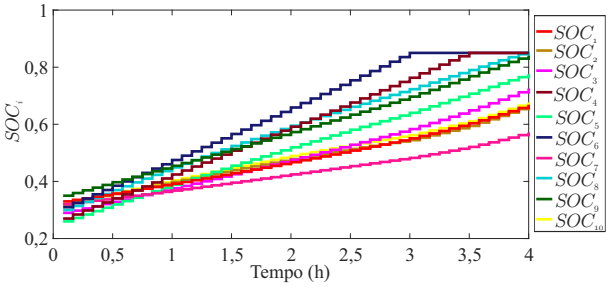

Figura 8. SOC dos VEs.

Na Figura 8, pode-se notar que o SOC dos VEs se aproximam do seu SOC desejado à medida que seu tempo

de saída está se aproximando, com maior prioridade para os VEs 4, 6 e 9.

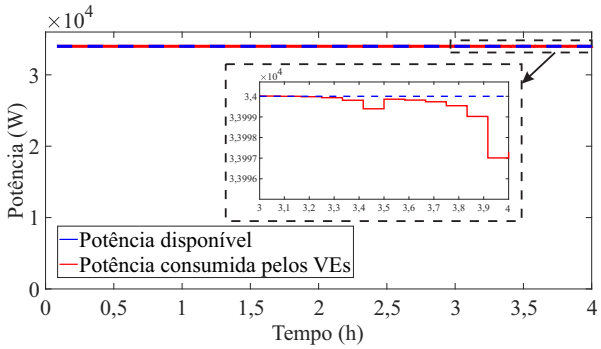

Figura 9. Potência total disponível e potência total consumida.

A Figura 9 mostra a relação entre a potência total consumida pelos VEs e a potência disponível. Há um pequeno erro causado pela saída súbita de VEs do estacionamento, como pode ser percebido através do detalhe na Figura 9.

6.2 Estudo de caso 2

Diferentemente do primeiro caso, nesse estudo é assumido que existem 100 soquetes de carregamento na estação. Desses 100 VEs, 30 são configurados para sair às 3,0h, 3,5h e 4,0h com o intuito de demonstrar a escalabilidade do algoritmo e a sua adaptabilidade a saídas aleatórias nesse cenário. Os 70 VEs restantes têm o seu tempo de permanência definido de forma aleatória dentre o intervalo de 4,5h até 6h. A potência de carregamento disponível é definida como sendo de 340 kW e o passo de tempo de simulação como sendo de 5 minutos. A troca de informações entre os VEs é realizada a cada 0,01 segundos. O coeficiente de controle é definido com sendo 5×10^{-6}. Cada VE possui 10 vizinhos e a comunicação se dá de forma semelhante ao estudo de caso 1.

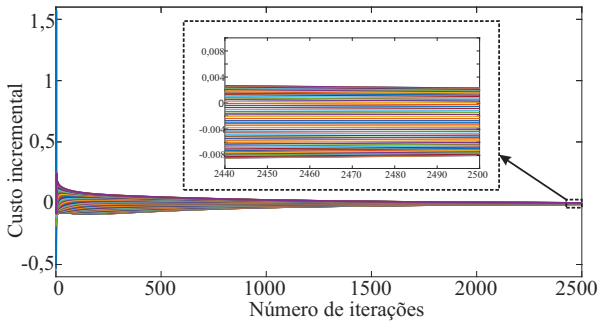

Figura 10. Custo incremental para 100 VEs.

As Figuras 10 e 11 representam a convergência do algoritmo para as informações de custo incremental e de desvio de potência. Assim como no primeiro caso, é possível ver que o algoritmo proposto convergiu para valores próximos de 0 em ambas as figuras. Foram 2500 iterações, o que representa 25 segundos (2500 × 0,01) para alcançar a convergência do custo incremental e do desvio de potência. Podemos notar que existe uma diferença significativa em relação ao caso anterior. Isso acontece devido à consideração de uma grande escala de VEs (100 VEs com 30 saídas),

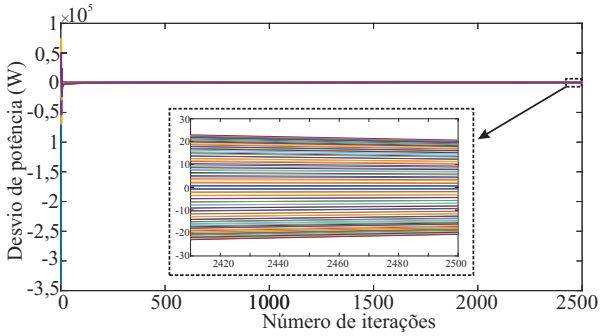

Figura 11. Desvio de potência para 100 VEs.

diferentemente do primeiro caso que considerava 10 VEs e contava com 3 saídas.

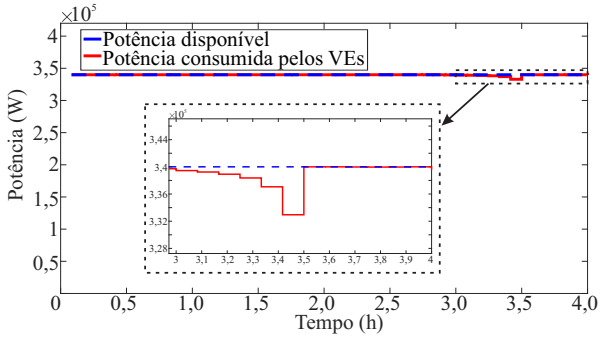

Figura 12. Potência total disponível e potência total consumida para 100 VEs.

Na Figura 12, podemos ver que os VEs conseguem maximizar a utilização da potência disponível da estação de carregamento. O erro causado diz respeito às saídas aleatórios de 30 VEs durante o período de 3,0h a 4,0h.

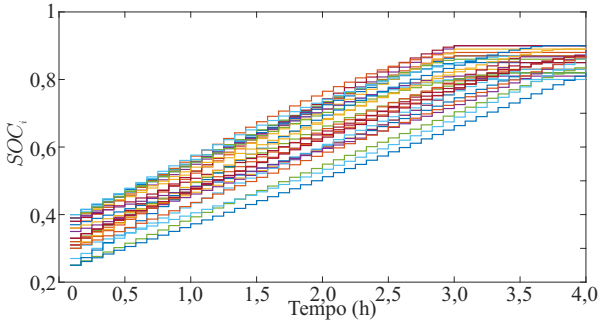

Figura 13. SOC dos 30 VEs que saem do estacionamento.

A Figura 13 mostra que os 30 VEs que saem do estacionamento conseguem atingir um nível adequado de *SOC*.

7. CONCLUSÃO

Este trabalho apresentou uma estratégia de controle para carregamento eficiente de veículos elétricos com base no algoritmo de consenso distribuído. Os métodos distribuídos são potencialmente mais práticos, pois a troca de informação é realizada nas vizinhanças adjacentes, reduzindo os requisitos de comunicação e recursos de computação.

Foram apresentados dois estudos de caso, considerando uma estação de carregamento para 10 VEs e para 100 VEs

a fim de avaliar efetividade do processo de carregamento usando o algoritmo de consenso.

O algoritmo de consenso realizou o controle distribuído do carregamento eficiente de VEs com precisão. Os resultados demonstraram uma convergência próxima de zero para o custo incremental e para o desvio de potência. O algoritmo também se mostrou adaptativo a saídas aleatórias de VEs, redistribuindo a potência referente dos VEs que saíram aos VEs que permaneceram no estacionamento. O algoritmo também permitiu o aproveitamento da potência disponível fornecida pela estação de carregamento, embora com uma pequena queda nos horários referentes a saídas aleatórias de VEs.

Por conseguinte, a aplicação do algoritmo de consenso evidenciou que apenas a comunicação local entre VEs pode ser utilizada para realizar o carregamento eficiente de VEs. O método também apresentou uma boa escalabilidade, visto que foi aplicado a uma grande quantidade de VEs.

AGRADECIMENTOS

Os autores agradecem à CAPES pelo apoio no desenvolvimento deste trabalho, através da concessão de bolsa de pesquisa, e ao Programa de Pós-Graduação em Engenharia Elétrica da UFC pelo suporte proporcionado.

REFERÊNCIAS

Ahn, C., Li, C.T., and Peng, H. (2011). Optimal decentralized charging control algorithm for electrified vehicles connected to smart grid. *Journal of Power Sources*, 196(23), 10369–10379.

Bakken, D. (2014). *Smart Grids: Clouds, Communications, Open Source, and Automation*. CRC Press.

Chen, S. and Cheng, R.S. (2014). Distributed charging control of plug-in electric vehicles via the stochastic alternating direction method of multipliers. In *2014 IEEE 80th Vehicular Technology Conference (VTC2014-Fall)*, 1–5. IEEE.

EVSpecifications (2020). specifications, news and comparisons. `https://www.evspecifications.com/`. Acessado em 20/04/2020.

Gwanyama, P.W. (2004). The hm-gm-am-qm inequalities. *College Mathematics Journal*, 47–50.

He, Y., Venkatesh, B., and Guan, L. (2012). Optimal scheduling for charging and discharging of electric vehicles. *IEEE transactions on smart grid*, 3(3), 1095–1105.

Hu, J., Yang, G., Bindner, H.W., and Xue, Y. (2017). Application of network-constrained transactive control to electric vehicle charging for secure grid operation. *IEEE Transactions on Sustainable Energy*, 8(2), 505–515.

Hua, F., Duan, C., Zhang, C.K., Jiang, L., Mao, C., and Wang, D. (2018). Admm-based multiperiod optimal power flow considering plug-in electric vehicles charging. *IEEE TRANSACTIONS ON POWER SYSTEMS*, 33(4), 3886–3897.

IEA (2019). Global ev outlook.

Knez, M., Zevnik, G.K., and Obrecht, M. (2019). A review of available chargers for electric vehicles: United states of america, european union, and asia. *Renewable and Sustainable Energy Reviews*, 109, 284–293.

Lewis, F.L., Zhang, H., Hengster-Movric, K., and Das, A. (2013). *Cooperative control of multi-agent systems: optimal and adaptive design approaches*. Springer Science & Business Media.

Rahbari-Asr, N. and Chow, M.Y. (2014). Cooperative distributed demand management for community charging of phev/pevs based on kkt conditions and consensus networks. *IEEE Transactions on Industrial Informatics*, 10(3), 1907–1916.

Ren, W. and Beard, R.W. (2008). *Distributed consensus in multi-vehicle cooperative control*. Springer.

Sortomme, E., Hindi, M.M., MacPherson, S.J., and Venkata, S. (2010). Coordinated charging of plug-in hybrid electric vehicles to minimize distribution system losses. *IEEE transactions on smart grid*, 2(1), 198–205.

Tayarani, M., Nadafianshahamabadi, R., Poorfakhraei, A., and Rowangould, G. (2018). Evaluating the cumulative impacts of a long range regional transportation plan: Particulate matter exposure, greenhouse gas emissions, and transportation system performance. *Transportation Research Part D: Transport and Environment*, 63, 261–275.

Teng, J.H., Liao, S.H., and Wen, C.K. (2016). Design of a fully decentralized controlled electric vehicle charger for mitigating charging impact on power grids. *IEEE Transactions on Industry Applications*, 53(2), 1497–1505.

Wang, L. and Chen, B. (2019). Distributed control for large-scale plug-in electric vehicle charging with a consensus algorithm. *International Journal of Electrical Power & Energy Systems*, 109, 369–383.

Wood, A.J., Wollenberg, B.F., and Sheblé, G.B. (2013). *Power generation, operation, and control*. John Wiley & Sons.

Xu, Y. (2014). Optimal distributed charging rate control of plug-in electric vehicles for demand management. *IEEE Transactions on power Systems*, 30(3), 1536–1545.

Yang, H., Chung, C., and Zhao, J. (2012). Application of plug-in electric vehicles to frequency regulation based on distributed signal acquisition via limited communication. *IEEE Transactions on Power Systems*, 28(2), 1017–1026.

Zheng, Y., Niu, S., Shang, Y., Shao, Z., and Jian, L. (2019). Integrating plug-in electric vehicles into power grids: A comprehensive review on power interaction mode, scheduling methodology and mathematical foundation. *Renewable and Sustainable Energy Reviews*, 112, 424–439.

Zou, S., Hiskens, I., and Ma, Z. (2018). Consensus-based coordination of electric vehicle charging considering transformer hierarchy. *Control Engineering Practice*, 80, 138–145.