

## Modelagem de recarga de veículos elétricos aplicada para agendamentos considerando parametrização de dados por OCPP

Henrique Martins\*. Hericles Farias\*\*. Gustavo Fenner\*\*\*. Bernardo Ziquinatti\*\*\*\*. Camilo Rangel\*\*\*\*\*. Luciane Canha\*\*\*\*\*. Rodrigo Braun dos Santos\*\*\*\*\*

\*Universidade Federal de Santa Maria, Santa Maria, RS Avenida Roraima 1000

Tel: +55 55 3220-8792 email: henrique.hmart@gmail.com

\*\* e-mail: hericleslannister@gmail.com

\*\*\* e-mail: gustavopfenner@gmail.com

\*\*\*\* e-mail: bernardoiziquinatti@gmail.com

\*\*\*\*\* e-mail: casepulvedar1@gmail.com

\*\*\*\*\* e-mail: [lucianecanha@gmail.com](mailto:lucianecanha@gmail.com)

\*\*\*\*\* e-mail: rodrigo.braun@copel.com

---

**Abstract:** This paper presents a model for electric vehicle chargers with application in load scheduling, considering parametrization by OCPP protocol. The model seeks to find – considering information given by the user- the charging time that an electric vehicle can stay in a station, based on the battery charging model. The model uses a combination of KiBaM model with voltage model for determination of the charging time of the electric vehicle. The calibration uses real data collected by real time measuring in the chargers using the OCPP protocol. Finally, the model is applied with a framework system for scheduling of the electric vehicle use determining the charging hours and the economic and technical impact on the system. The real tests were made on an electric vehicle charging station for the COPEL - *Companhia Paranaense de Energia* located inside the Federal University of Santa Maria, Brazil.

**Resumo:** Este artigo apresenta um modelo de carregadores de veículos elétricos para aplicações em agendamento de recarga, considerando parametrização pelo protocolo OCPP. O modelo visa determinar - considerando informações fornecidas pelo usuário- o tempo de carregamento que pode levar um veículo elétrico num eletroposto, baseado numa modelagem da recarga da bateria. O modelo utiliza uma combinação do modelo KiBaM com um modelo de tensão, para determinação do tempo de recarga do veículo elétrico. A calibração do modelo utiliza dados reais coletados pela medição em tempo real de carregadores utilizando o protocolo OCPP: Finalmente, o modelo é aplicado em conjunto para um framework de agendamento de recarga de veículos elétricos determinando os horários de recarga e o impacto dele no sistema em termos econômicos e técnicos. Os testes reais foram realizados no eletroposto a cargo da Companhia Paranaense de Energia – COPEL localizado dentro das instalações da Universidade Federal de Santa Maria, Brasil.

**Keywords:** Electric Vehicle, Electric Vehicle Charging Station, Metaheuristic, KiBaM battery model, OCPP protocol, Load scheduling.

**Palavras-chaves:** Veículos Elétricos, Eletropostos, Meta-heurística, Modelo de Bateria KiBaM, Protocolo OCPP, Agendamento de Recargas

---

### 1. INTRODUÇÃO

Dentro dos desafios da mobilidade elétrica, os eletropostos tem surgido como infraestruturas necessárias para garantir o carregamento dos veículos elétricos em complemento ao carregamento residencial. O uso dos eletropostos procura um uso em escala dos veículos elétricos e um gerenciamento mais adequado da energia. (Yilmaz e Krein, 2013; Chen et al., 2020).

Este gerenciamento é importante para garantir dois pontos principais. O primeiro ponto procura que o consumidor não

tenha desconforto em tempos de espera por excesso de veículos. O segundo ponto procura que o carregamento dos veículos elétricos não impacte negativamente à rede elétrica em termos de perdas, excesso de demanda e incremento de custos. Considerando estes fatores, modelos de agendamento de recargas de veículos elétricos (*Electric Vehicle Charging Stations*, EVCS) se tornam fundamentais para garantir o gerenciamento adequado da energia dentro do eletroposto (Al-Gaili et al., 2019; Ding et al., 2020).

Relacionado ao gerenciamento de EVCS, os trabalhos em (Hafez e Bhattacharya, 2018; Hayajneh e Zhang, 2019; Hadian

*et al.*, 2020; Liu *et al.*, 2020) concentram-se em maximizar o número de cargas EV na estação, respeitando os limites da grade do Operador do Sistema de Distribuição (*Distribution System Operator*, DSO). Além disso, as técnicas de meta-heurísticas (MH) são apresentadas como soluções válidas, pois oferecem flexibilidade e simplicidade de implementação. Um exemplo de MH é apresentado em (Alonso *et al.*, 2014), onde um algoritmo genético (*Genetic Algorithm*, GA) é usado para achatar as curvas de carregamento diárias na EVCS. Em (Milas, Mourtzis e Tatakis, 2020) é mostrado que a técnica de otimização por enxame de partículas (*Particle Swarm Optimization*, PSO) teve um desempenho melhor do que o método GA ao programar a cobrança do consumidor.

A efetividade dos modelos de agendamento requer de informação precisa sobre os tempos de recarga dos veículos elétricos. Informações errôneas podem levar à problemas na recarga dos veículos elétricos, por tempos de recarga mais curtos ou compridos do esperado. Neste sentido a modelagem adequada da recarga das baterias dos veículos elétricos se torna fundamental.

À medida que as aplicações de bateria aumentam, cresce também a necessidade de modelos mais detalhados para representar com precisão o comportamento em relação à tensão, corrente, degradação, estado de saúde (*State of Health*, SOH) e estado de carga (*State of Charge*, SOC). Neste caso, a previsão de SOC e potência de carregamento é uma das aplicações mais difundidas de modelos de bateria. Existem quatro tipos de modelos para bateria: os modelos empíricos (Kim, Qiao e Qu, 2019; Saldana *et al.*, 2020), modelos abstratos (Hu, Li e Peng, 2012; Zhang *et al.*, 2019), modelos baseados na física (Li *et al.*, 2019) e modelos híbridos (Hossain *et al.*, 2020). Os modelos híbridos procuram usar duas ou mais abordagens para melhorar os resultados, cada um com vantagens e desvantagens.

A diferença dos modelos físicos e empíricos, os modelos abstratos são muito simples e práticos. Esses modelos oferecem uma forma alternativa de visualizar o problema, mantendo a dinâmica da bateria. Sua precisão e complexidade são variáveis.

O principal representante dos modelos abstratos é chamado de modelos de circuito elétrico (*Electric Circuit Models*, ECMs), os quais tem a sua precisão variada de acordo com a ordem matemática na formulação do modelo do circuito. Muitos trabalhos utilizam o modelo ECM por sua simplicidade, mesmo em ordens mais baixas, dada a boa precisão apresentada (Kwak *et al.*, 2020; Zhang, Xue e Fan, 2021), entretanto seu custo computacional é alto. Através dos modelos estudados, o modelo cinético de bateria (*Kinetic Battery Model*, KiBaM) foi o escolhido como alternativa para fazer a modelagem, dado sua alta eficiência e precisão, dom menor carga computacional (Fenner *et al.*, 2021).

Complementando o anterior, o *Open Charge Point Protocol* (OCPP), é um protocolo que busca comunicar o veículo elétrico com o eletroposto. Baseado neste protocolo é possível gerenciar a recarga do veículo elétrico de forma prática, oferecendo os comandos para operação do carregador.

Aproveitando o protocolo OCPP é possível coletar informações que descrevem o carregamento do veículo elétrico de forma mais precisa. Por exemplo, trabalhos como, (Alcaraz, Lopez e Wolthusen, 2017; Ravindran *et al.*, 2020), apresentam uma análise prática realizada através do simulador OCPP implementado pelo GIR (*Giaume Industrie & Recherche*). Este simulador, chamado OCPPJS e baseado em Nodes.js, consiste em um framework capaz de fornecer as ferramentas necessárias para a troca de mensagens entre o CS (gestão central-sistema) e os CPs (Carga-ponto).

Visando o agendamento adequado e eficiente dos veículos elétricos com informações realistas e precisas, este trabalho procura desenvolver um modelo da recarga da bateria dos veículos elétricos, considerando parametrização dos dados por OCPP. Este artigo é baseado na combinação de modelos completos apresentados em trabalhos anteriores por parte de autores deste trabalho. O modelo de bateria é baseado em (Fenner *et al.*, 2021) e aplica em conjunto vários conceitos utilizados na literatura, combinando o KiBaM com modelos de tensão e de corrente. Esse modelo é aplicado em conjunto com um *framework* para agendamento da recarga de veículos elétricos desenvolvido em (Farias *et al.*, 2021). Os dados extraídos foram obtidos a partir da recarga do veículo elétrico, modelo Nissan Leaf. Para a parametrização dos valores, foi utilizado um carregador de 50 kW, ambos presentes no laboratório da Universidade Federal de Santa Maria em colaboração com a Companhia Paranaense de Energia Elétrica - COPEL.

## 2. MODELAGEM PROPOSTA

### 2.1 Modelagem da recarga do EV

A fim de modelar o comportamento não linear dos EVs durante o carregamento, o KiBaM (*Kinetic Battery Model*) (Manwell e MCGowan, 1993) foi implementado. O modelo funciona representando a energia armazenada em uma bateria como a água reservada em um sistema de duas torres, como é visto na Fig. 1.

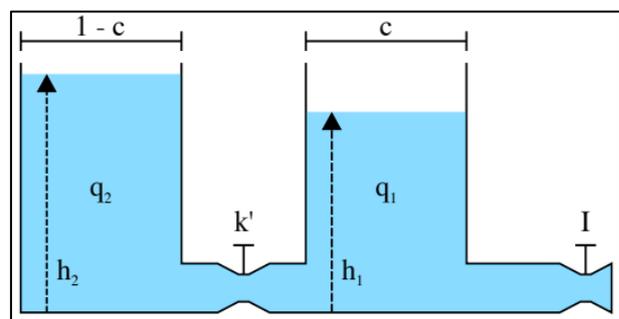


Fig. 1. Representação do modelo KiBaM. (Manwell e MCGowan, 1993).

A torre principal  $q_1$  e a torre secundária  $q_2$  são ligadas por uma restrição  $k$  que limita o fluxo de água e modela as características variáveis da bateria. No KiBaM a corrente entra e sai da bateria apenas pela torre principal, isso restringe o

intervalo de funcionamento do modelo pois não há capacidade além do topo.

O modelo é regido pelas seguintes relações considerado o trabalho dos autores em (Fenner *et al.*, 2021):

$$\begin{cases} q_1(t) = q_{1,0}e^{-k't} + \frac{(q_0k'c - 1)(1 - e^{-k't})}{k'} \\ \quad - \frac{Ic(k't - 1 + e^{-k't})}{k'} \\ q_2(t) = q_{2,0}e^{-k't} + q_0(1 - c)(1 - e^{-k't}) \\ \quad - \frac{I(1 - c)(k't - 1 + e^{-k't})}{k'} \end{cases} \quad (1)$$

Onde  $q_{1,0}$  e  $q_{2,0}$  são a quantidade de carga em  $t = 0$ , e  $q = q_{1,0} + q_{2,0}$ . Ao definir o tamanho das torres (constante  $c$ ) e a restrição de passagem (constante  $k$ ) é possível modelar o carregamento de qualquer bateria. Por exemplo, quando a torre principal enche rápido durante a carga, não é possível manter o carregamento rápido. Isto, devido a que a capacidade de água está na torre secundária e não é disponível. Este fato explica que a potência em dado ponto do carregamento, diminui exponencialmente.

Um modelo de tensão com resistência de saída é acoplado à saída do KiBaM, para permitir determinar a potência de carregamento e melhor identificar os limites de carga. O modelo de tensão é importante dado que uma bateria não pode exceder a tensão máxima durante o carregamento.

O modelo final simula tensão e corrente da bateria e funciona, dentre outras maneiras, com a forma descrita na Tabela 1:

De momento não existe forma de modelar um carregamento genérico para os veículos elétricos. Cada marca e modelo de veículo elétrico é diferente, não é apenas em termos de capacidade, mas a química e a disposição das baterias que mudam. Por conta disso, cada modelo de cada fabricante precisa ser modelado individualmente, e idealmente, em diferentes SOH (*State of Health*). Essa diferença em modelagem se dá alterando as constantes que governam o modelo proposto.

**Tabela 1. Entradas e Saídas do modelo de carregamento.**

Entradas:	Saídas:
-SOC inicial	-SOC final
-Modelo/Marca do EV	-Energia consumida
-Potência do carregador	-Curva de potência
-Tempo de carga desejado	-Autonomia obtida

Prevendo a modelagem de centenas de carros nas próximas décadas, um processo de meta-heurística similar a busca tabu é usado para automatizar o processo de extração de parâmetros. A entrada do processo para modelar um novo

veículo é a curva de potência de carregamento, a capacidade da bateria e suas ligações série-paralelo. O resultado do processo iterativo é uma série de constantes que, aplicadas ao KiBaM, descrevem o carregamento do veículo. É importante salientar que esse processo não é feito toda vez que o algoritmo é utilizado, já que a calibração garante um nível de eficiência satisfatório.

A calibração e modelagem da bateria serão usadas para determinar um tempo de carregamento mais preciso. Este auxílio facilita o processo de agendamento que será descrito na seção 2.3. Assim, sabendo a distância estimada de viagem e as características de carregamento pelo modelo anteriormente descrito, é possível identificar os tempos de carga e, conseqüentemente, ajustar esses tempos para o modelo de gerenciamento do eletroposto que visa o atendimento de vários clientes.

## 2.2 Tratamento dos dados por OCPP

O OCPP é um protocolo de comunicação de código aberto para carregadores de veículos elétricos. A visão do OCPP, é facilitar as integrações dos sistemas de gerenciamento de recarga com os carregadores.

Para este trabalho, o padrão que foi implementado refere-se a versão 1.6 do protocolo OCPP, utilizando o formato de mensagem JSON (*JavaScript Object Notation*). A vantagem de utilizar o formato JSON é a facilidade de integrar o sistema desenvolvido com aplicações de terceiros.

A arquitetura do protocolo é baseada na comunicação via *websocket*, que é fornecida com o objetivo de conectar o carregador com o servidor central.

A arquitetura desenvolvida consiste em: um sistema central, responsável pela comunicação *back-end* com os carregadores, o banco de dados para armazenamento das grandezas, das reservas e dos usuários, uma interface gráfica para a visualização dos dados de maneira iterativa e o serviço da API que possibilita a integração e envio de informações para os carregadores por diferentes dispositivos. A arquitetura é mostrada na Fig. 2.

Conforme a Fig. 2 o sistema de carregamento está composto pelos seguintes componentes:

**Estação de Recarga:** A estação de recarga é responsável pelo carregamento dos veículos. A estação de recarga mantém a comunicação com o sistema central via OCPP e informa ao sistema central os dados disponíveis do carregamento, também possibilita as operações de controle que o sistema central envia.

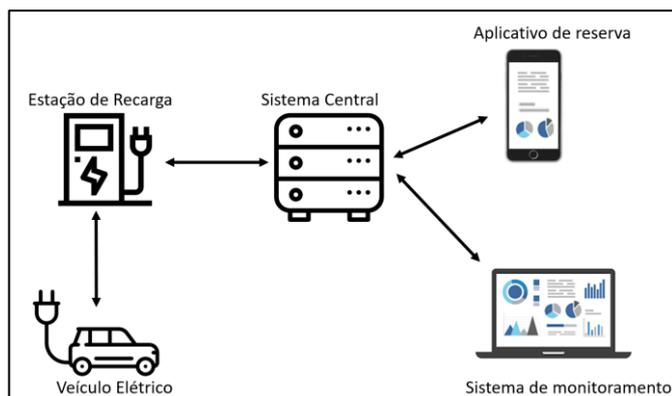


Fig. 2: Topologia do sistema de carregamento desenvolvido.

**Sistema Central:** O sistema central é responsável por coordenar todas as operações das estações de recarga. Desenvolvido na linguagem Python, o sistema central organiza as informações recebidas da estação de recarga e armazena em um banco de dados, que posteriormente é acessado pelos aplicativos de reserva e o sistema de monitoramento. Com este sistema é possível alterar os modos de funcionamento dos carregadores, as permissões de recargas, realizar o agendamento e limitar a carga do carregamento. O modelo de agendamento aplicado pelo sistema central será descrito na Seção 2.3. Integrado com um banco de dados, o sistema central consegue gerenciar usuários e administradores, com o objetivo de liberar os acessos via API para o operador das estações de recarga e para o usuário que deseja realizar uma reserva no sistema.

**Sistema de monitoramento:** Através do sistema de monitoramento, o operador pode observar as informações detalhadas sobre as estações de carregamento. Integrado com o sistema central e o banco de dados, o operador pode tomar as decisões de acordo com as informações em tempo real, ou consultar os dados históricos das recargas. O sistema também disponibiliza para os administradores, o controle da potência dos carregadores, as autorizações da recarga e o gerenciamento remoto, podendo cancelar ou iniciar uma recarga remotamente. A Fig. 3, exibe a tela de monitoramento integrada com o sistema central.

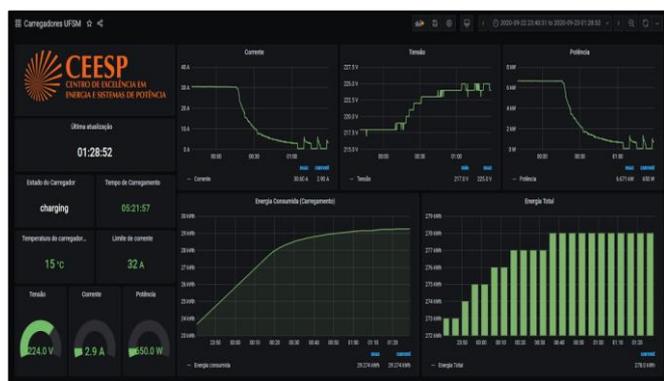


Fig. 3: Dashboard do sistema de monitoramento no eletroposto.

### 2.3 Modelagem do framework para agendamento da recarga.

O framework leva em conta um modelo discretizado de clusters que auxiliam o processo de agendamento de recargas. Estes clusters representam as janelas de tempo que o usuário pode escolher para realizar sua recarga no dia seguinte. Cada cluster possui 2 horas de duração. A Tabela 2 apresenta os clusters disponíveis para agendamento.

Tabela 2. Clusters para agendamento.

	C0	C1	C2	...	C10	C11
Início	0:00	2:00	4:00	...	20:00	22:00
Final	2:00	4:00	6:00	...	22:00	0:00

Conforme apresentado na Tabela 2, o usuário escolhe um cluster para realizar a solicitação de agendamento. A estação de recarga então irá, caso possível, habilitar o usuário dentro do cluster no dia da recarga. Usando os dados fornecidos pelo usuário relacionados ao veículo elétrico e estimativa de viagem, o modelo de carregamento dado na Seção 2.1 permite determinar os tempos possíveis de carga que podem ser alocados nos clusters para cada cliente.

#### 2.3.1. Método EPSO e Modelagem Matemática

O algoritmo utilizado para realizar a otimização do agendamento foi baseado na Otimização por Enxame Evolutivo de Partículas (*Evolutionary Particle Swarm Optimization*, EPSO) desenvolvida em (Miranda *et al*, 2007). Este método representa uma variação do conhecido método PSO (Poli *et al*, 2007). O método se baseia em características evolutivas ao utilizar de processos de mutação, cruzamento e seleção estratégica de parâmetros. Neste caso, o grupo de soluções possíveis do problema de otimização é tratado como uma partícula em movimento. A formulação do movimento das partículas é realizada conforme o trabalho publicado pelos autores deste trabalho em (Farias *et al*, 2021).

Cada partícula é representada por um vetor contendo os expoentes de deslocamento cuja função é modificar a configuração inicial de uma matriz binária U. A equação que descreve a mudança de posição de uma partícula é apresentada como:

$$E_{pos}^{novo} = E_{pos} \times 2^{-desloc} \quad (2)$$

Onde  $E_{pos}^{novo}$  é a nova partícula gerada,  $E_{pos}$  é a antiga partícula e  $desloc$  é o número de deslocamentos à direita. Por exemplo, dado um vetor  $v = [110000]$ , onde as colunas representam os passos de tempo, 1 significa que existe um EV conectado e 0 que não há. O vetor do exemplo representa na base decimal o valor de 48. Ao utilizar um deslocamento à direita de valor 1 ( $desloc=1$ ), o vetor deslocado na base binária é  $v = [011000]$ , representando o código decimal de 24. Esta lógica é então

utiliza para modificar as partículas, que também representam um candidato à solução do problema de agendamento, em cada população ao longo N gerações de estudo.

No que se refere à modelagem matemática do problema de otimização, tem-se que o framework possui como objetivos a redução dos custos associados ao abastecimento das recargas e a redução do pico de carga vista pela concessionária de energia. O *framework* considera tanto o interesse da estação de recarga como o interesse da rede de distribuição. A função objetivo associada à redução de custos é apresentada como:

$$F1 = \sum_{i=0}^{Cts} Pt_i \times \Delta t \times Tar_i \quad (3)$$

Onde  $Pt$  representa a potência total que o eletroposto tem que suprir em um dado instante de tempo  $i$ . A modelagem também considera que o estudo foi discretizado em passos de tempo de 15 minutos. Portanto, a variável  $\Delta t$  equivale a 0.25 horas. A variável  $Tar$  é o custo da tarifa de energia de referência, neste caso, o preço de energia praticado pela rede. A função associada ao interesse da rede é apresentada a seguir:

$$F2 = \frac{P_{\max}}{P_{\text{méd}}} \quad (4)$$

Onde  $F2$  também é chamado de PAPR (*Power to Average Peak Ratio*). Está métrica é utilizada para verificar se a carga agendada apresentada um alto pico de demanda (alto valor PAPR), ou se a carga está mais distribuída/plana (valor de PAPR próximo à unidade). A variável  $P_{\max}$  representa o pico de demanda em um cluster do eletroposto. Já a variável  $P_{\text{méd}}$  representa a média de potência do cluster. As funções são combinadas linearmente através de:

$$F_{obj} = w \times F1 + (1 - w) \times F2 \quad (5)$$

Onde  $w$  é o peso associado às funções. Este peso serve para dar mais importância à uma certa métrica enquanto diminui a importância de outra. Variando o peso  $w$  pode-se então realizar uma busca pelo ponto de Pareto do sistema, de modo a escolher a melhor resposta que satisfaça os interesses da estação de recarga e da rede.

O resultado final deste processo é a determinação dos horários de carga para cada veículo considerando a disponibilidade de carregadores em cada cluster.

### 3. ESTUDO DE CASO

#### 3.1 Dados de entrada

Para o estudo foi modelada a recarga através dos dados obtidos via OCPP do VE Nissan Leaf utilizando um carregador CC de

50 kW. Os dados foram extraídos com o intervalo de 30 segundos, através do OCPP, como padrão do protocolo. Os dados contidos nestas mensagens eram referentes às grandezas instantâneas da recarga, como energia e potência do carregamento. O veículo e eletroposto para os testes se localizam na Universidade Federal de Santa Maria, Santa Maria -RS, Brasil.

A Fig. 4, exibe como foi realizado o carregamento.



Fig. 4: Carregamento do VE na estação de recarga rápida.

Para a extração dos dados, o veículo recebeu uma carga a partir do SoC de 2% até completar a capacidade da bateria de 50 kW do Nissan Leaf. Nesse tempo, além do dado obtido via OCPP um wattímetro trifásico monitorava a potência consumida pelo carregador, com intuito de validar a qualidade do dado recebido. A potência trifásica de carregamento pode ser vista na Fig. 5.

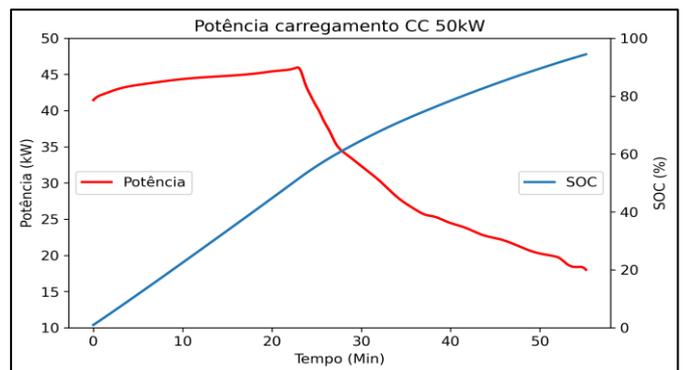


Fig. 5: Potência trifásica de carregamento 2-95%

Nesse teste, em 23 minutos o carro partiu de 2% para 51% de SOC. Partindo desse estágio, a carga começou a ficar mais lenta. Analisando os dados do wattímetro foi possível observar o fator de potência unitário até 95% de SOC. A partir de 95% ele se torna capacitivo e é evitado na modelagem. A semelhança dos dados obtidos via OCPP e via wattímetro ficaram dentro da margem de erro de medição do equipamento utilizado e, portanto, são considerados iguais.

Integrando a potência trifásica consumida e comparando com o valor de energia em CC entregue pelo carregador, foi possível estimar a eficiência de recarga de 94,1%.

### 3.2 Validação do modelo de VE.

Os dados do carregamento obtidos via OCPP foram utilizados no processo de meta-heurística para calibrar o KiBaM, que simula a tensão da bateria. Como a tensão nos terminais da bateria era desconhecida, a potência de carregamento e a eficiência do carregador foram utilizadas para estimar os valores de tensão e corrente presentes durante a recarga.

O algoritmo iterativo que testa as constantes de carregamento, durante 2 horas obteve resultados satisfatórios. No entanto para garantir maior precisão o programa funcionou por mais 4 horas. Esse tempo para convergência é grande, mas vale salientar que esse processo é feito apenas uma vez para descrever o veículo e, portanto, não impacta na velocidade dos agendamentos. As constantes obtidas para o KiBaM foram  $c = 0.2862$ ,  $k = 0.0014$

A Fig. 6 mostra a modelagem de um carregamento 2-95% CC 50kW feita com dados obtidos via OCPP de um Nissan Leaf 2020.

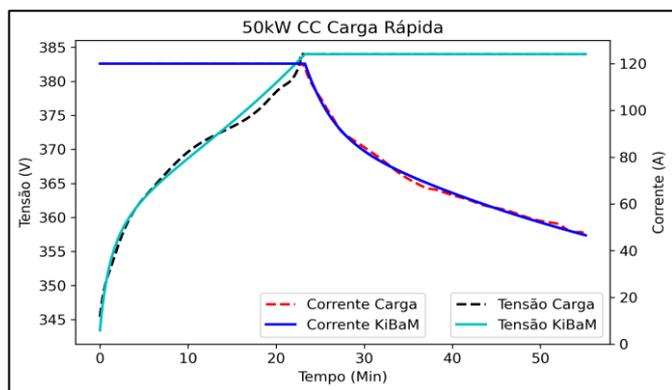


Fig. 6. Carga rápida 50kW

Para simular 58 minutos de carregamento com passo de um segundo, um computador equipado com um i7-7770HQ e 16GB de RAM levou 14.1ms. Nessa velocidade de simulação, durante um segundo de processamento seria possível simular um mês de carregamento. O que mostra uma demanda computacional baixa dado que os modelos de agendamento trabalham por máximo 24 horas na frente.

Analisando a performance do modelo com o dado referência, o KiBaM treinado com o Nissan Leaf possui um erro máximo na previsão do consumo de energia de 0,5%. Quanto ao SOC, o erro médio foi de 0,32%, sendo maior ao final da recarga. O erro na previsão do tempo de recarga e tempo de carga rápida foi menor que 30 segundos.

### 3.3 Aplicação do modelo de agendamento

Neste estudo de caso considera-se 1 dia operacional do eletroposto. O estudo propõe analisar o impacto do processo de agendamento no eletroposto comparando o caso otimizado de agendamento com um caso em que não existe o agendamento e o critério de atendimento é por chegada dos EVs. As informações apresentadas nas seções anteriores servem como indicação do tempo real de carregamento/disponibilidade de uso que cada EV possui no eletroposto. A intenção aqui é comparar a entrada de vários veículos demandando uso no eletroposto.

#### 3.3.1 População para Agendamento

De modo a criar a população de solicitações de recargas a serem atendidas pela estação, foram utilizados os dados do histograma em (Farias *et al*, 2021), baseados em um projeto envolvendo VEs no Reino Unido (Cross, 2016). Dado que são escassos os dados a respeito do uso de VEs no Brasil, neste estudo, os dados deste último projeto são utilizados como referência para criação da população do estudo de caso. A Tabela 3 apresentou a população obtida, onde Nsol é o número de solicitações e Ctot é carga total em kWh.

Tabela 3. Solicitações de recarga.

Cluster	Nsol	Ctot	Cluster	Nsol	Ctot
C0	2	40	C6	12	200
C1	2	24	C7	16	274
C2	12	224	C8	35	564
C3	16	286	C9	22	282
C4	11	192	C11	13	170
C5	14	208	C11	0	0

#### 3.3.2 Carga otimizada e Carga por critério de chegada

A proposta deste estudo de caso é analisar o impacto do processo de agendamento. A critério de comparação, um cenário alternativo é criado. O cenário alternativo leva em conta que o eletroposto não possui agendamento de carga e utiliza como critério de uso a ordem de chegada. A criação desta população não agendada é criada a partir da randomização dos horários de conexão das solicitações da Tabela 3. A Fig. 7 apresenta o comparativo da população agendada obtida através do método EPSO e da população criada a partir do carregamento por critério de chegada.

Conforme apresentado na Fig. 7, a carga sem o processo de agendamento apresenta altos picos de demanda ao longo do dia. Assim, com a otimização do agendamento é possível diminuir os picos de demanda da carga (a carga apresenta um perfil mais plano), o que é atingido pela função PAPR e ao mesmo tempo também é possível evitar que a carga seja concentrada durante períodos caros da tarifa de energia.



Fig. 7. Carga agendada e não agendada.

### 3.3.3 Métricas do Sistema

De modo a quantificar o impacto do processo de otimização a Tabela 4 apresenta, de maneira sumarizada, os principais indicadores técnicos e econômicos para os dois casos de estudo.

**Tabela 4. Métricas sumarizadas.**

Caso	PAPR (F2)	Custo (F1)
Agendado	3.45	1465.84
Não Agendado	5.88	1441.13

Note-se que o caso agendado apresentou uma redução significativa na função de PAPR do sistema em comparação ao caso sem agendamento (cerca de 40% menor). O valor estimado do custo de fornecimento para o dia operativo apresentou ser bastante próximo para ambos os casos, sendo até menor no caso sem agendamento, no entanto, como a otimização procura pelo Ponto de Pareto do sistema, a resposta final acabou não priorizando tanto a função de custo. O ponto escolhido representa então a melhor configuração que leva em conta ambas as funções.

## 4. CONCLUSÕES

Este trabalho apresentou uma modelagem de carregamento de veículos elétricos considerando diferentes estágios operativos. Estes estágios consideraram tanto o agendamento como o carregamento em tempo real. No estágio de agendamento foi realizado um modelo de otimização da recarga dos veículos elétricos aplicando o EPSO como meta-heurística. No estágio de operação foi implementado um modelo para determinar o comportamento da recarga do veículo elétrico, sendo parametrizada por protocolo OCPP.

A implementação e operação do OCPP mostrou-se importante para modelagem dos veículos elétricos, ressaltando o uso prático e visando aplicações comerciais.

O modelo de carregamento - aplicável em tempo real- mostrou um bom desempenho, com custo computacional baixo e precisão satisfatória. O processo de meta-heurística utilizado para descrever o carregador funcionou bem e deve ser capaz

de adaptar o KiBaM a qualquer carro presente no mercado sem grandes dificuldades. A precisão e confiabilidade das previsões do modelo tendem a aumentar à medida que mais dados são alimentados ao processo de meta-heurística.

A falta de dados com recargas em diferentes condições ambientais (temperatura e umidade extrema), diferentes potências e SOC de partida diferentes são pontos a considerar em trabalhos futuros para garantir uma modelagem ainda mais robusta. No entanto, os resultados mostrados são promissórios para implementações iniciais. Treinar o KiBaM em carregadores de potências diferentes permite extrair mais funcionalidade do processo de agendamento, e é o próximo passo a ser dado.

Finalmente o modelo de gerenciamento da recarga utilizado mostrou-se satisfatório ao comparar os impactos na rede e impactos econômicos com os obtidos em carregamentos realizados sem agendamento. Neste sentido o modelo consegue reduzir custos e impacto na rede e facilita sua implementação prática. Desta forma a modelagem do carregamento utilizando o KiBaM se acopla ao modelo de agendamento ao determinar adequadamente os tempos disponíveis (e reais) de carga que os veículos elétricos possuem nas suas solicitações.

## AGRADECIMENTOS

Os autores agradecem ao Programa de P&D ANEEL Chamada P022, à Copel-Dis pelo suporte financeiro através do projeto PD 2866-0519/2019, à Universidade Federal de Santa Maria, Programa de Pós-Graduação em Engenharia Elétrica com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES/PROEX) - Código de Financiamento 001. Também são gratos pelo apoio financeiro do CNPQ projeto PQ 1-D 310761/2018-2, INCT-GD processo CNPq 465640/2014-1, processo CAPES no. 23038.000776/2017-54 e FAPERGS 17/2551- 0000517-1.

## REFERÊNCIAS

- Alcaraz, C., Lopez, J. and Wolthusen, S. (2017) "OCPP Protocol: Security Threats and Challenges," IEEE Transactions on Smart Grid, 8(5), pp. 2452–2459. doi:10.1109/TSG.2017.2669647.
- Al-Ogaili, A.S. et al. (2019) "Review on scheduling, clustering, and forecasting strategies for controlling electric vehicle charging: Challenges and recommendations," IEEE Access, 7. doi:10.1109/ACCESS.2019.2939595.
- Alonso, M. et al. (2014) "Optimal charging scheduling of electric vehicles in smart grids by heuristic algorithms," Energies, 7(4), pp. 2449–2475. doi:10.3390/en7042449.
- Chen, T. et al. (2020) "A Review on Electric Vehicle Charging Infrastructure Development in the UK," Journal of Modern Power Systems and Clean Energy. pp. 193–205. doi:10.35833/MPCE.2018.000374.
- Cross, J. D., & Hartshorn, R. (2016). My Electric Avenue: Integrating electric vehicles into the electrical networks.

- Ding, Z. et al. (2020) “Technical Review on Advanced Approaches for Electric Vehicle Charging Demand Management, Part II: Applications in Transportation System Coordination and Infrastructure Planning,” *IEEE Transactions on Industry Applications*, pp. 5695–5703. doi:10.1109/TIA.2020.2993760.
- Fenner, G.P. et al. (2021) “Comprehensive model for real battery simulation responsive to variable load,” *Energies*, 14(11). doi:10.3390/en14113209.
- Hadian, E. et al. (2020) “Optimal allocation of electric vehicle charging stations with adopted smart charging/discharging schedule,” *IEEE Access*, 8, pp. 196908–196919. doi:10.1109/ACCESS.2020.3033662.
- Hafez, O. and Bhattacharya, K. (2018) “Integrating EV charging stations as smart loads for demand response provisions in distribution systems,” *IEEE Transactions on Smart Grid*, 9(2), pp. 1096–1106. doi:10.1109/TSG.2016.2576902.
- Hayajneh, H.S. and Zhang, X. (2019) “Evaluation of electric vehicle charging station network planning via a co-evolution approach,” *Energies*, 13(1). doi:10.3390/en13010025.
- Hossain, M. et al. (2020) “A Parameter Extraction Method for the Li-Ion Batteries with Wide-Range Temperature Compensation,” *IEEE Transactions on Industry Applications*, 56(5), pp. 5625–5636. doi:10.1109/TIA.2020.3011385.
- Hu, X., Li, S. and Peng, H. (2012) “A comparative study of equivalent circuit models for Li-ion batteries,” *Journal of Power Sources*, 198, pp. 359–367. doi:10.1016/j.jpowsour.2011.10.013.
- Kim, T., Qiao, W. and Qu, L. (2019) “An enhanced hybrid battery model,” *IEEE Transactions on Energy Conversion*, 34(4), pp. 1848–1858. doi:10.1109/TEC.2019.2935700.
- Kwak, M. et al. (2020) “Parameter Identification and SOC Estimation of a Battery under the Hysteresis Effect,” *IEEE Transactions on Industrial Electronics*, 67(11), pp. 9758–9767. doi:10.1109/TIE.2019.2956394.
- Li, B. et al. (2019) “Real-time energy management in microgrids with reduced battery capacity requirements,” *IEEE Transactions on Smart Grid*, 10(2), pp. 1928–1938. doi:10.1109/TSG.2017.2783894.
- Liu, W.L. et al. (2020) “Coordinated Charging Scheduling of Electric Vehicles: A Mixed-Variable Differential Evolution Approach,” *IEEE Transactions on Intelligent Transportation Systems*, 21(12), pp. 5094–5109. doi:10.1109/TITS.2019.2948596.
- Manwell, J. F., & McGowan, J. G. (1993). Lead acid battery storage model for hybrid energy systems. *Solar energy*, 50(5), 399-405.
- Milas, N., Mourtzis, D. and Tatakis, E. (2020) “A decision-making framework for the smart charging of electric vehicles considering the priorities of the driver,” *Energies*, 13(22). doi:10.3390/en13226120.
- Miranda, V., Keko, H., & Jaramillo, A. (2007). EPSO: Evolutionary particle swarms. In *Advances in evolutionary computing for system design* (pp. 139-167). Springer, Berlin, Heidelberg.
- Farias, H. E., Sepulveda Rangel, C. A., Weber Stringini, L., Neves Canha, L., Pegoraro Bertineti, D., da Silva Brignol, W., & Iensen Nadal, Z. (2021). Combined Framework with Heuristic Programming and Rule-Based Strategies for Scheduling and Real Time Operation in Electric Vehicle Charging Stations. *Energies*, 14(5), 1370.
- Poli, R., Kennedy, J., & Blackwell, T. (2007). Particle swarm optimization-An overview. *Swarm Intelligence*. Volume 1, Issue 1.
- Ravindran, S. et al. (2020) “OCPP based Electric Vehicle Supply Equipment and its user interface for AC charging in Indian scenario,” in 2020 IEEE 17th India Council International Conference, INDICON 2020; doi:10.1109/INDICON49873.2020.9342410.
- Saldana, G. et al. (2020) “Empirical Electrical and Degradation Model for Electric Vehicle Batteries,” *IEEE Access*, 8, pp. 155576–155589. doi:10.1109/ACCESS.2020.3019477.
- Yilmaz, M. and Krein, P.T. (2013) “Review of the impact of vehicle-to-grid technologies on distribution systems and utility interfaces,” *IEEE Transactions on Power Electronics*, pp. 5673–5689. doi:10.1109/TPEL.2012.2227500.
- Zhang, Q. et al. (2019) “A fractional-order kinetic battery model of lithium-ion batteries considering a nonlinear capacity,” *Electronics (Switzerland)*, 8(4). doi:10.3390/electronics8040394.
- Zhang, Z., Xue, B. and Fan, J. (2021) “Noise Adaptive Moving Horizon Estimation for State-of-Charge Estimation of Li-Ion Battery,” *IEEE Access*, 9, pp. 5250–5259. doi:10.1109/ACCESS.2020.3047971.