

Avaliação crítica de inserção de eletropostos em redes de distribuição considerando mitigação por agendamento de recargas^{*}

Hérciles E. O. Farias^{*} Camilo S. Rangel^{*} Bernardo Z. Franciscatto^{*}
Luciane N. Canha^{*} Zeno I. Nadal^{**} Rodrigo B. dos Santos^{**}

^{*} Centro de Excelência em Energia e Sistemas de Potência (CEESP),
Universidade Federal de Santa Maria (UFSM), RS, (e-mails:
hericleslannister@gmail.com, casapulvedar@gmail.com,
bernardoziquinatti@gmail.com, lucianecanha@ufsm.br).

^{**} Companhia Paranaense de Energia (COPEL), Curitiba, PR,
(e-mails: zeno.nadal@copel.com, rodrigo.braun@copel.com)

Abstract: This study seeks to assess and mitigate the installation impact of electric vehicle charging stations in distributed systems in terms of voltage level. The methodology applies the Monte Carlo simulation to obtain the possible critical cases of the system, given the installation of the recharging station, during a year of operation. A meta heuristic method, called Evolutionary Particle Swarm Optimization (EPSO), is used to schedule the electric vehicles recharges at the recharging station. The EPSO method uses as the objective function the ratio between the peak power and the mean power of the system (PAPR) in order to reduce the peak load seen by the grid. The case study was developed in a 33-bus test system. The load curves of the system are related to a distributed system from Canada and the electric vehicles recharge data used came from an UK project. The results showed that the insertion of the recharge station can lead to the appearance of critical cases in the system. However, with the use of the scheduling process it is possible to mitigate them, thus emphasizing the importance of this study.

Resumo: Este trabalho procura determinar e mitigar o impacto da instalação de estações de recarga de veículos elétricos em sistemas de distribuição em termos de níveis de tensão. A metodologia emprega a simulação de Monte Carlo para obter possíveis estados críticos do sistema frente a instalação da estação de recarga ao longo de um ano de operação. Um método meta heurístico, conhecido como Evolutionary Particle Swarm Optimization (EPSO), é utilizado para realizar o agendamento das recargas dos veículos elétricos na estação de recarga. O método EPSO usa como função objetivo o índice de relação entre potência de pico e a potência média (PAPR) de modo a agendar a carga com o objetivo de reduzir os picos de demanda na rede. O estudo de caso foi realizado num sistema teste de 33 barras. As curvas de demanda foram tomadas de um sistema de distribuição do Canadá. As curvas de carregamento dos Veículo Elétrico foram tomadas de um projeto do Reino Unido. Os resultados mostraram que a inserção do eletroposto pode levar a presença de casos críticos no sistema. No entanto, o remanejamento da demanda aplicando o método de agendamento conseguiu mitigar este impacto evitando a presença de casos críticos, ressaltando assim a importância deste trabalho.

Keywords: Electric Vehicles; Monte Carlo simulation; Electric Vehicle Charging Station; Distribution System; Evolutionary Particle Swarm Optimization.

Palavras-chaves: Veículos elétricos; Simulação de Monte Carlo; Eletropostos; Sistemas de distribuição; Evolutionary Particle Swarm Optimization.

1. INTRODUÇÃO

Nos últimos anos, o sistema de distribuição de energia elétrica passou por profundas transformações com a introdução de novas tecnologias, em especial as energias renováveis (fotovoltaica e eólica) combinado à necessidade de atualização e digitalização dos meios de comunicação

dos sistemas de dados (*smartgrids*), IRENA (2017). Junto com isto, o setor elétrico brasileiro tem apresentado interesse na inclusão de veículos elétricos (VE) dentro do sistema. Exemplo disto é a eletrovia instalada pela COPEL que conta com 730 quilômetros de extensão e utiliza 12 eletropostos espalhados ao longo da via, COPEL (2021).

Analogamente, pode-se citar também o projeto PD 2866-0519/2019, Interface de Inovação Multi Agente Envolvendo a Indústria Automobilística, os Sistemas de Energia

^{*} CNPq 465640/2014-1, processo CAPES no. 23038.000776/2017-54 e FAPERGS 17/2551-0000517-1.

e Infraestruturas de Mobilidade Elétrica para Eletrovias Inteligentes, desenvolvido na UFSM com o objetivo de fomentar o uso de carros elétricos no Brasil de forma rápida e planejada, contando com um sistema de gestão inteligente de eletrovias, CEESP (2020). A Figura 1 apresenta o eletroposto localizado no campus da UFSM em Santa Maria-RS, onde é possível visualizar tanto o carro elétrico modelo Nissan-Leaf quanto o ponto de carregamento instalado.



Figura 1. Eletroposto localizado em Santa Maria/RS.

Do ponto de vista das concessionárias, a entrada dos veículos elétricos na rede de distribuição representa desafios e oportunidades. Muitos dos desafios observados ocorrem devido à limitação física da infraestrutura atual, quando submetidos aos impactos que essas novas tecnologias podem gerar nos parâmetros técnicos. A introdução massiva dos VEs no mercado pode levar a diversos impactos nos fatores de controle e operação da rede, dentre alguns destes têm-se: maior congestionamento da rede em períodos de carga dos veículos, caso não haja um controle; flutuação dos níveis de tensão; aumento da curva de pico e perdas elétricas; problemas de qualidade de energia; além dos custos envolvendo a modernização e adequação da rede, Ma (2019); Anastasiadis et al. (2019); Munshi and Mohamed (2018); Dubey and Santoso (2015).

Consequentemente, as distribuidoras precisam considerar essa mudança de paradigma no sistema de distribuição em conjunto com a introdução dessas novas estruturas visando o impacto e futuras tendências em sua estratégia de planejamento. No caso do VE, o problema se encontra nas instalações das estruturas de carregamento do veículo, sendo que o aumento na demanda de energia necessária para carregar essa nova frota pode prejudicar o desempenho da rede de distribuição de energia. A alocação não adequada de um eletroposto no sistema poderia trazer problemas em termos de níveis de tensão, perdas, e custos de energia, dado o aumento da demanda de energia, Dubey and Santoso (2015); Zhang et al. (2019); Zheng et al. (2014). Neste sentido, pode-se ainda considerar, se para uma região é mais importante colocar um eletroposto de grande porte ou alocar vários de menor tamanho distribuídos ao longo da rede. Desta forma o planejamento da instalação dos postos de carregamento torna-se importante, IRENA (2019); Mehta et al. (2018); Zheng et al. (2014).

Com base neste contexto, este trabalho desenvolve uma metodologia para avaliar o impacto da instalação de eletropostos em sistemas de distribuição, aplicando simulação de Monte Carlo para avaliar casos críticos em termos de níveis de tensão, e utilizando um método meta heurístico para mitigação dos mesmos.

2. METODOLOGIA

De modo a identificar os casos críticos decorrentes da alocação de eletropostos em um sistema de distribuição, este estudo visa utilizar a técnica de Monte Carlo para avaliar, através de amostragem aleatória, os impactos técnicos na rede considerando diferentes cenários. Os cenários são descritos a seguir.

- **Caso Base:** Neste caso o sistema de estudo é analisado sem a presença do eletroposto;
- **Caso Não-Agendado:** Neste caso o eletroposto é adicionado à rede e sua carga não possui processo de agendamento, mas leva em conta o critério de chegada. Este critério é baseado na ideia de que os VEs que chegam na estação de recarga carregam seu veículo se houver um carregador disponível na estação;
- **Caso Agendado:** Neste caso o eletroposto é adicionado à rede e sua carga possui processo de agendamento. Neste processo o método meta heurístico EPSO é utilizado para agendar toda a carga do eletroposto.

Note que o cenário sem agendamento é utilizada como ponto de partida para avaliar os possíveis riscos associados à alocação de um eletroposto em uma barra qualquer do sistema. Já o cenário com agendamento visa mitigar os possíveis problemas associados à inserção de uma carga não planejada no sistema. Como o processo de agendamento de recarga funciona como um método de gerenciamento pelo lado da demanda (GLD), a ideia é diminuir possíveis picos de carga ao longo do dia, aliviando assim o lado da distribuidora. A metodologia deste estudo é apresentada na Figura 2.

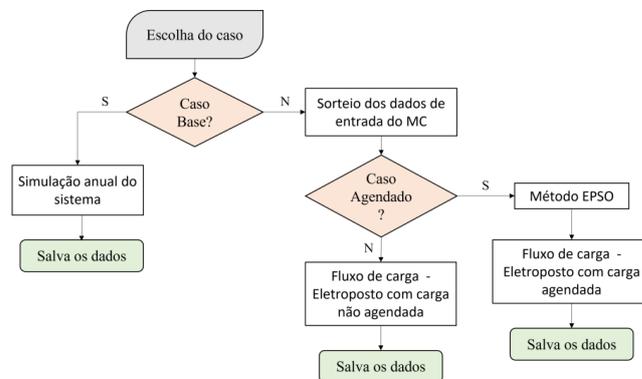


Figura 2. Metodologia do sistema.

2.1 Simulação de Monte Carlo

O método de Monte Carlo permite identificar casos críticos e riscos na alocação de eletropostos na rede em termos técnicos e econômicos. Um ponto interessante deste método estatístico é que ele permite selecionar uma parcela da população que seja representativa, e ao mesmo tempo, que não prejudique a qualidade dos resultados. As entradas necessárias para o método de Monte Carlo representam as curvas de demanda, preço da tarifa de energia e barra de localização do eletroposto, tais dados são sorteados em cada iteração. O estudo leva em conta um ano de simulação (365 dias), e para cada dia são analisados os parâmetros anteriormente mencionados frente à alocação do eletroposto, representando o comportamento diário do

sistema. Durante cada iteração, e para cada caso de estudo, são coletados os dados do fluxo de potência do sistema, este processo é repetido até que se atinja um valor específico de β , que representa o parâmetro de parada da simulação. O cálculo do fluxo de potência é realizado no OpenDSS e o controle das variáveis na simulação de Monte Carlo é realizado em Python. Este método permite criar um espaço de amostragem grande o suficiente de modo a ser representativo.

Dado que, dependendo da solução, o universo de possíveis combinações pode vir a ser muito extenso, uma busca exaustiva de todas as variações acaba sendo impraticável, com base nisso o MC permite reduzir o tamanho da base dados ao determinar uma amostra significativa.

O processo da determinação do tamanho da população que seja significativa é descrito a seguir. Durante cada iteração é calculada a estimativa do valor esperado $\hat{E}(F)$ da função de teste $F(x)$ do sistema para uma dada configuração x_i sorteada com base no número de cenários N , Pereira et al. (1992). A Equação do valor esperado é apresentada em (1):

$$\hat{E}(F) = \frac{1}{N} \sum_{i=1}^N F(x_i), \quad (1)$$

a partir deste valor pode-se calcular a variância amostral $\hat{V}(F)$ por meio de Pereira et al. (1992), conforme apresentado em (2):

$$\hat{V}(F) = \frac{1}{N-1} \sum_{i=1}^N [F(x_i) - \hat{E}(F)]^2. \quad (2)$$

Como critério de parada, pode-se ainda utilizar de um fator chamado de β , definido em (3):

$$\beta = \frac{\delta(\hat{E}(F))}{\hat{E}(F)} = \sqrt{\frac{V(\hat{E}(F))}{\hat{E}(F)^2}}, \quad (3)$$

onde um baixo valor de β fornece um maior intervalo de confiança e conseqüentemente uma melhor representação dos dados. Utilizando (3), tem-se que N é definido como:

$$N = \frac{\hat{V}(F)}{\beta \hat{E}(F)^2}, \quad (4)$$

onde, pode-se observar um valor aproximado do número de iterações necessárias para a obtenção do valor esperado conforme o nível de confiabilidade estabelecido. A criação da população é continuada até que o critério de parada seja estabelecido.

No que se refere à variável de amostragem para o processo de Monte Carlo deste estudo, utilizou-se a métrica de custo de abastecimento diário. Definida como:

$$F1 = \sum_{i=1}^{Cts} Pt_i \times \Delta t \times Tar_i, \quad (5)$$

onde Pt representa a potência total que a rede 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, então a variável Δt equivale a 0.25 horas. A variável Cts representa o número de passos de tempo da simulação. Por fim a variável Tar é o custo da tarifa de energia de referência, neste caso, o preço de energia praticado pela rede.

2.2 Processo de agendamento de carga com uso da técnica EPSO

O método utilizado para realizar a otimização do agendamento foi a Otimização por Enxame Evolutivo de Partículas (do inglês Evolutionary Particle Swarm Optimization) ou EPSO, Miranda et al. (2007). Este método representa uma variação do conhecido método PSO, Poli et al. (2007), todavia, o método também apresenta algumas características darwinistas ao também utilizar de processos de mutação, cruzamento e seleção estratégica de parâmetros. Em (6) é apresentado a equação de movimento de uma partícula.

$$X_k^{new} = X_k + vel_k^{novo}, \quad (6)$$

onde uma nova partícula (X_k) é gerada a partir da anterior somada a um parâmetro de velocidade. A equação da velocidade da partícula é apresentada a seguir:

$$V_k^n = w e_{k0}^* \times vel_k + w e_{k1}^* \times (b_k - X_k) + w e_{k2}^* \times (b_G^* - X_k). \quad (7)$$

Onde a nova velocidade (V_k^n) é obtida a partir da combinação entre a velocidade anterior daquela partícula, somado com o melhor ponto encontrado pela partícula em sua vida anterior, e com o melhor ponto já encontrada pelo enxame de partículas na geração anterior. Note que cada parcela da equação é multiplicada por um peso (w), esse peso gera uma mutação e altera a nova velocidade da partícula. O valor de w é um valor extraído da distribuição gaussiana com média zero e variância unitária. Neste estudo uma partícula é representada por um vetor contendo os expoentes de deslocamento cuja função é modificar a configuração inicial do sistema. A equação que descreve a mudança de estado de uma partícula é apresentada como:

$$E_{pos}^{novo} = E_{pos} \times 2^{(-desloc)}, \quad (8)$$

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 VE conectado e 0 que não há. Este mesmo código binário representa na base decimal o valor de 48, ao utilizar um deslocamento à direita de valor 1 ($desloc = 1$), o novo código em decimal é 24, e na base binária temos o vetor $v = [011000]$. Esta lógica é então utilizada 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 função objetivo utilizada para o processo de agendamento, este estudo considera a utilização da métrica de PAPR (do inglês *Peak to Average Peak to Ratio*). Esta métrica nos diz o quanto a carga está distribuída, um baixo valor de PAPR significa que a carga está bem

distribuída/plana, enquanto que um valor alto representa que a carga possui um pico significativo de demanda. A função objetivo é apresentada na equação a seguir.

$$PAPR = \frac{P_{max}}{P_{med}} \quad (9)$$

onde, a variável P_{max} é a potência máxima da carga e P_{med} a potência média.

3. ESTUDO DE CASO

O sistema base utilizado para realizar as simulações do estudo de caso é baseado no modelo IEEE-33 barras, Rajasekhar and Pindoriya (2020) e apresentado na Figura 3.

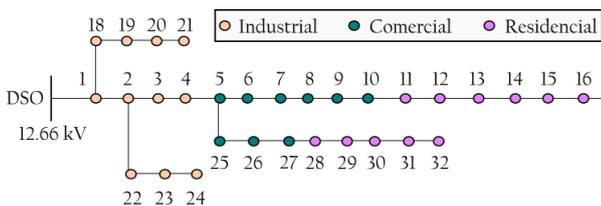


Figura 3. Representação do sistema IEEE-33 barras modificado.

No sistema da Figura 3 o eletroposto pode ser alocado em qualquer barra (numerada de 1 a 32). Em cada barra já existe uma certa carga associada, podendo esta ser do tipo industrial, comercial ou residencial. As curvas PU de cada tipo de carga, bem como os valores base associados à cada são apresentados na Figura 4 e na Tabela 1.

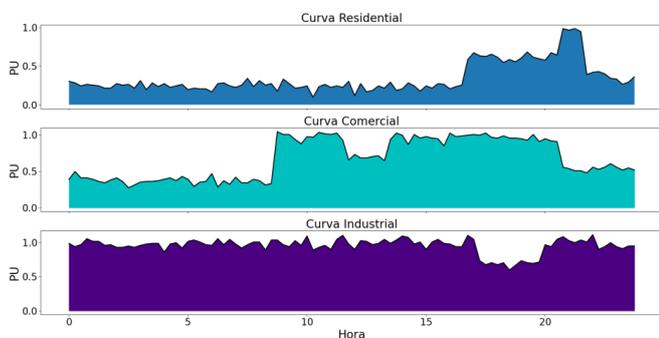


Figura 4. Curvas por unidade (PU) de cada tipo de Unidade Consumidora.

Na Tabela 1 o tipo da carga conectada à uma certa barra pode ser residencial (res), comercial (com) ou industrial (ind).

3.1 População de solicitações de recarga

Para criar a população de solicitações de recargas a ser atendida pelo eletroposto, foram utilizados os histogramas da Figuras 5 e 6, baseados em EA (2015).

Com base nos dados de número médio de solicitações de recarga por horário e de número médio de VEs por SoC de chegada na estação, é possível, através de amostragem aleatória, gerar a população de solicitações de recarga para este estudo. De modo a agrupar a carga atendida pela

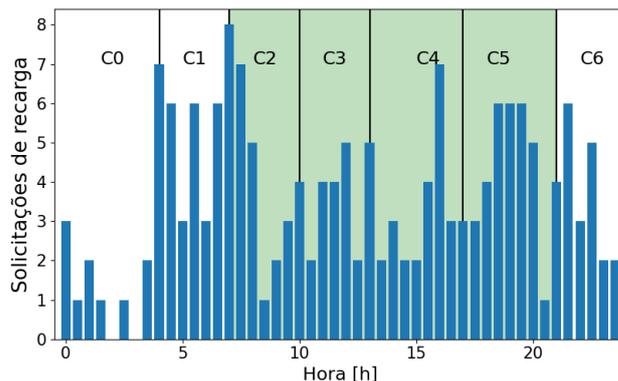


Figura 5. Histograma da média de solicitações de recarga.

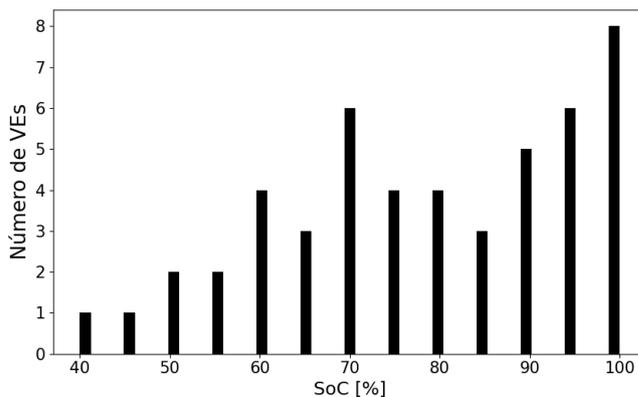


Figura 6. Histograma do SoC dos VEs durante a solicitação.

estação, este estudo considera o sistema de *clusters*, onde cada um representa uma janela de tempo de 2 horas, como neste estudo é considerado que a estação permanece ativa durante todo o dia, existem 12 *clusters* ao todo. A ideia principal de utilizar janelas de tempo fixas é permitir que o processo de agendamento seja realizado *cluster a cluster*. Os dados da população gerada são apresentados na Tabela 2.

Observando a Tabela 2, note que o *cluster* com maior carga associada é o C8, cuja janela de tempo abrange o período das 16:00 as 18:00.

3.2 Caso Base

De modo a quantificar o real impacto do processo de agendamento de recarga na curva de carga total vista pela concessionária, um caso base, onde se analisa o estado inicial do sistema, é proposto para comparar o antes e depois da inserção da carga do eletroposto. A Figura 7 apresenta o fluxo de potência ativa totalizado visto pela concessionária durante um ano inteiro.

Na Figura 7 o gráfico superior apresenta a curva diária no sistema e o inferior a variação de demanda ao longo do ano. A Figura 8 apresenta os valores de tensão máxima e mínima do sistema ao longo de um ano inteiro para o caso base.

Na Figura 8 note que referente as tensões máximas e mínimas, o sistema opera o ano inteiro dentro da faixa

Tabela 1. Valores base das UC e localização no sistema.

Tipo	Barra	Potência		Tipo	Barra	Potência		Tipo	Barra	Potência	
		kW	kVA _r			kW	kVA _r			kW	kVA _r
ind	1	100	60	res	12	60	35	ind	23	90	50
ind	2	90	40	res	13	120	80	ind	24	420	200
ind	3	120	80	res	14	60	10	com	25	420	200
ind	4	60	30	res	15	60	20	com	26	60	25
com	5	60	20	res	16	60	20	com	27	60	25
com	6	200	100	res	17	90	40	res	28	120	70
com	7	200	100	ind	18	90	40	res	29	200	600
com	8	60	20	ind	19	90	40	res	30	150	70
com	9	60	20	ind	20	90	40	res	31	210	100
com	10	45	30	ind	21	90	40	res	32	60	40
res	11	60	35	ind	22	90	40	Total		3745	2320

Tabela 2. População de solicitações de recarga para cada *cluster*.

Cluster	Nsol	Ctot (kWh)	Cluster	Nsol	Ctot (kWh)
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	C10	13	170
C5	14	208	C11	0	0

3.3 Otimização da carga do eletroposto

Tendo como base a população de solicitações de recarga da Tabela 2, a técnica meta heurística EPSO é utilizada para realizar o processo de agendamento otimizado das recargas. Neste estudo os seguintes parâmetros estratégicos do método EPSO foram utilizados:

- **Gerações:** Número de gerações igual a 1000;
- **Partículas:** Número de partículas por população igual a 50;
- **Critério de Parada:** Número de gerações consecutivas sem melhoria igual a 30.

A Figura 9 apresenta a carga agendada obtida em cada *cluster* para o dia operacional da ERVE.

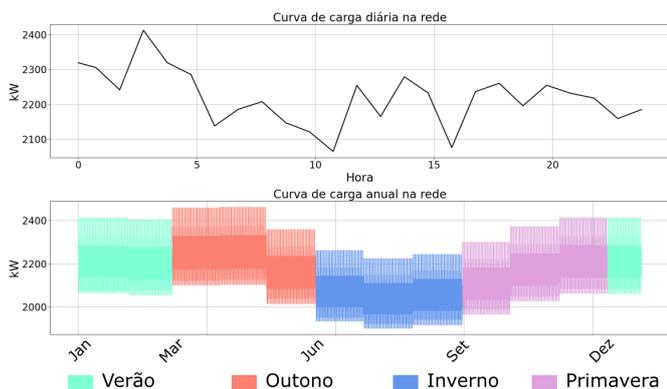


Figura 7. Curva de carga diária e anual do sistema base.

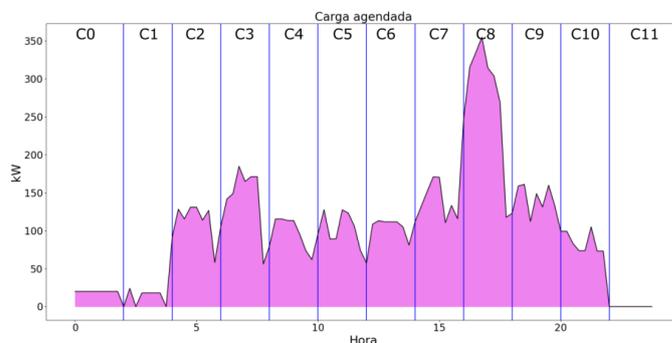


Figura 9. Curva agendada diária.

Na Figura 9 note que o *cluster* com a menor carga associada é o C0 (00:00 as 02:00) e o de maior é o C8 (16:00 as 18:00).

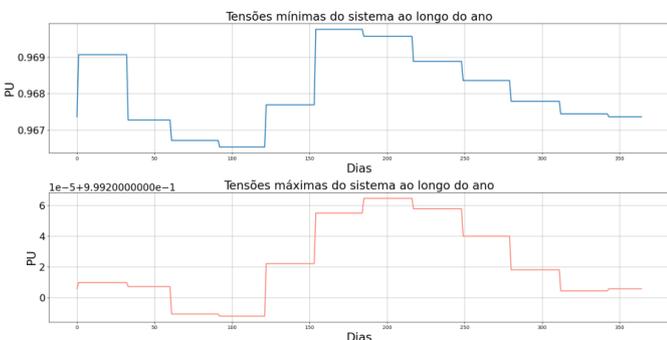


Figura 8. Tensões mínimas e máximas ao longo do ano.

de 0.95 à 1.05 pu de tensão operacional, logo o sistema se encontra em estado normal de operação.

3.4 Cenário sem agendamento - Critério de chegada

De modo a quantificar o impacto do processo de agendamento na carga total vista pela concessionária, o cenário de agendamento também é comparado com um cenário onde não existe agendamento, em outras palavras o usuário abastece no eletroposto seguindo o critério de chegada na estação.

Na Figura 10 note que a carga de característica não agendada possui um pico de demanda muito maior que a do tipo agendada. Isto é devido ao processo de agendamento ter utilizado a função PAPR para deixar a curva de carga

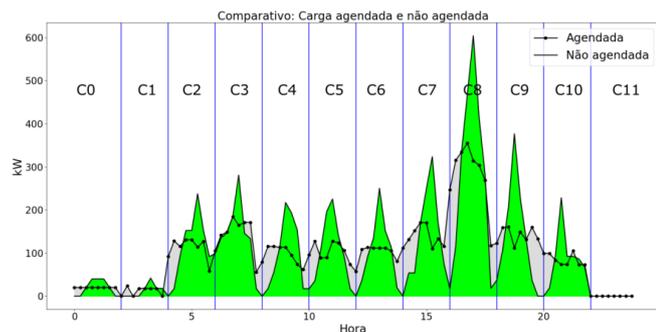


Figura 10. Comparativo: carga agendada e não agendada.

agendada mais plana, reduzindo possíveis picos de carga no sistema. Note também que o maior pico de carga ainda ocorre no cluster C8 em ambos os casos.

Note que para o *cluster* C8 a redução de pico de carga é bastante significativa, sem o uso do processo de agendamento a rede possivelmente teria que lidar com a carga em excesso despachando algum ativo energético mais caro, como uma termelétrica, ou dependendo de geração intermitente como solar ou eólica em caso de baixa hidrologia.

Monte Carlo: Casos críticos do sistema Tendo como referência os níveis de tensão base do sistema, o método de Monte Carlo foi utilizado para gerar uma população de casos a fim de identificar casos críticos da alocação do eletroposto em diferentes barras do sistema. Inicialmente comparou-se os resultados obtidos com o método de Monte Carlo considerando que a carga do eletroposto é do tipo não agendada com os valores base do sistema. A Figura 11 apresenta o histograma dos níveis de tensão para ambos os casos e considerando um ano de operação.

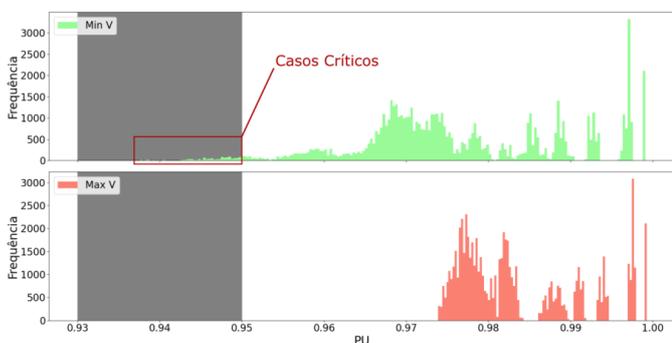


Figura 11. Tensões máximas e mínimas no sistema com a carga não agendada.

Na Figura 11 note que referente as tensões mínimas do sistema, ainda que o número de ocorrências seja baixo, existem situações onde registrou-se tensões abaixo de 0.95 PU, ou seja, o sistema opera em condição de subtensão. Já referente as tensões máximas, o sistema apresentou valores abaixo de 1.0 PU. A Figura 12 apresenta as barras cuja tensão ficou abaixo de 0.95 PU denotadas na Figura 11.

Na Figura 12 note que as barras que sofreram com subtensão foram as numeradas de 13 a 17, o que já era esperado, visto que estas barras eram as mais distantes da subestação. A barra que apresentou maior ocorrência de problemas com subtensão foi a 17. Esta barra representa

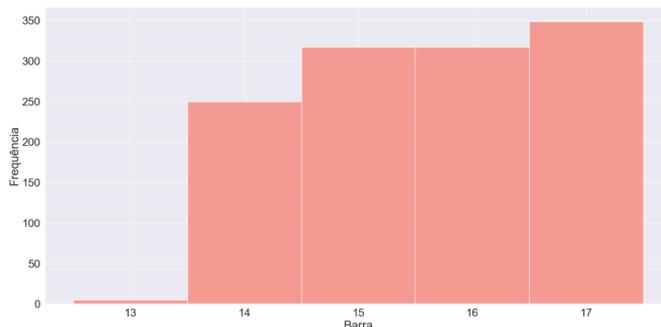


Figura 12. Barras críticas do sistema.

a de maior distância à subestação. Estes resultados confirmam que a inserção do eletroposto, com a carga do tipo não agendada, nas barras apresentadas gera problemas de subtensão. De maneira a prover uma solução para este problema de subtensão, a Figura 13 apresenta o histograma dos valores de tensão para o caso de carga agendada do eletroposto.

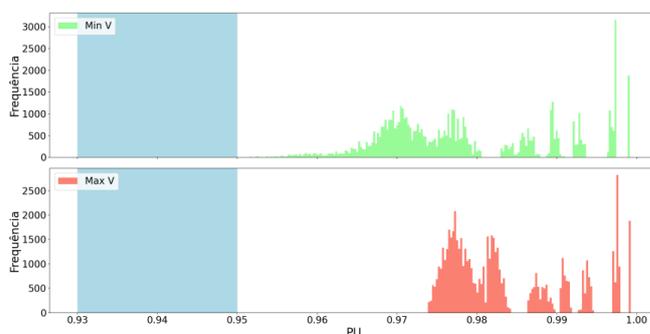


Figura 13. Tensões máximas e mínimas no sistema com a carga agendada.

Na Figura 13 note que agora, referente as tensões mínimas, o sistema não apresentou nenhum caso com subtensão, e referente as tensões máximas, o sistema opera com casos entre 0.97 e 1.0 PU, ou seja, em condições normais de operação. Pode-se se afirmar então que o processo de agendamento de cargas proposto para o eletroposto forneceu uma melhoria nos níveis de tensão para as barras em que o eletroposto foi alocado, eliminando todos os casos de subtensão que estavam ocorrendo no caso não agendado. Tomando como base a barra com maior ocorrência de subtensões, que é a barra 17, a Figura 14 apresenta o comparativo da variação de tensão no barramento para um dia qualquer do ano.

Na Figura 14 note que o caso com a inserção da carga do eletroposto sem o agendamento provoca problemas de subtensão na barra 17 durante o período da madrugada (04:00-06:00). Todavia, durante o mesmo período, para o caso com agendamento este problema não mais persiste. Este último representa o impacto do processo de agendamento na carga vista pela rede, como o problema de subtensão foi resolvido com uso da estratégia de agendamento tem-se que a estação de recarga conseguiu manejar a própria carga com uso de uma estratégia de GLD, sem uso de recursos distribuídos ou sem gerar modificações em sua infraestrutura.

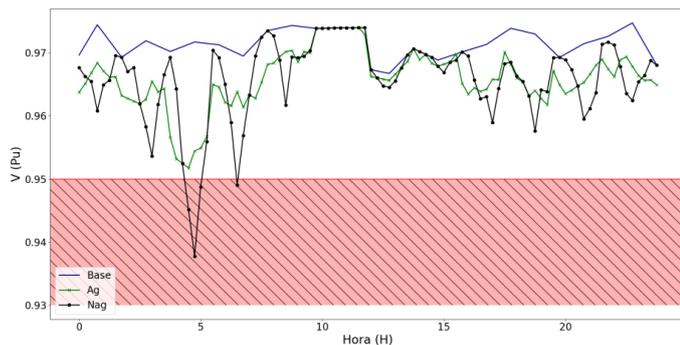


Figura 14. Comparativo de tensões mínimas para os três casos para a barra 17.

4. CONCLUSÕES

Este estudo apresentou uma metodologia para identificação e mitigação de casos críticos e riscos associados à inserção de eletropostos de grande porte em redes de distribuição. A metodologia combinou o processo de amostragem aleatório de Monte Carlo com o método meta heurístico EPSO para identificar e reduzir a ocorrência de problemas de subtensão causados pela carga do eletroposto na rede de distribuição.

Os resultados do estudo de caso mostraram que com uso do processo de agendamento otimizado foi possível mitigar os problemas de subtensão causados pela carga do eletroposto nas barras mais distantes do sistema. Um outro ponto interessante é que mesmo que a medida de mitigação não fosse considerada, ainda sim a identificação de casos críticos e riscos associados à alocação do eletroposto nestas barras representa uma funcionalidade muito importante da metodologia, visto que após identificado os casos críticos, podem ser empregados diferentes metodologias de mitigação. Neste estudo a metodologia focou na utilização de um processo agendamento de carga, no entanto metodologias com uso de recursos distribuídos em conjunto com o agendamento também podem representar soluções válidas. Como trabalhos futuros os autores também consideram estender o uso do método EPSO para busca otimizada da melhor barra para a alocação de eletropostos, bem como a utilização de funções multi-critério dentro do processo de agendamento otimizado.

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, Interface de Inovação Multi Agente Envolvendo a Indústria Automobilística, os Sistemas de Energia e Infraestruturas de Mobilidade Elétrica para Eletrovias Inteligentes, 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 465640/2014-1, processo CAPES no. 23038.000776/2017-54 e FAPERGS 17/2551-0000517-1.

REFERÊNCIAS

- Anastasiadis, A.G., Kondylis, G.P., Polyzakis, A., and Vokas, G. (2019). Effects of increased electric vehicles into a distribution network. *Energy Procedia*, 157, 586–593. doi:10.1016/J.EGYPRO.2018.11.223.
- CEESP (2020). Ceesp - ufsm desenvolve projeto de mobilidade elétrica eficiente. URL <http://ceesp.ufsm.br/index.php/blog/162-ufsm-desenvolve-projeto-de-mobilidade-eletrica-eficiente>. Acesso em 02/03/2022.
- COPEL (2021). Copel inaugura eletroposto na sede do tribunal de justiça do paraná, em curitiba - copel - pura energia. URL <https://www.copel.com/site/copel-inaugura-eletroposto-na-sede-do-tribunal-de-justica-do-parana-em-curitiba/>. Acesso em 02/03/2022.
- Dubey, A. and Santoso, S. (2015). Electric vehicle charging on residential distribution systems: Impacts and mitigations. *IEEE Access*, 3, 1871–1893. doi:10.1109/ACCESS.2015.2476996.
- EA, T. (2015). My electric avenue - mea. URL <http://myelectricavenue.info>. Acesso em 03/04/2022.
- IRENA (2019). Electric-vehicle smart charging innovation landscape brief | mendeley. URL <https://www.mendeley.com/search/?page=1&query=ELECTRIC-VEHICLE%20SMART%20CHARGING%20INNOVATION%20LANDSCAPE%20BRIEF&sortBy=relevance>.
- IRENA, I.R.E.A. (2017). Electric vehicles: Technology brief. URL <https://www.irena.org/publications/2017/Feb/Electric-vehicles-Technology-brief>. Acesso em 02/03/2022.
- Ma, C.T. (2019). System planning of grid-connected electric vehicle charging stations and key technologies: A review. *Energies*, 12. doi:10.3390/EN12214201.
- Mehta, R., Srinivasan, D., Khambadkone, A.M., Yang, J., and Trivedi, A. (2018). Smart charging strategies for optimal integration of plug-in electric vehicles within existing distribution system infrastructure. *IEEE Transactions on Smart Grid*, 9, 299–312. doi:10.1109/TSG.2016.2550559.
- Miranda, V., Keko, H., and Jaramillo, A. (2007). Epsos: Evolutionary particle swarms bt - advances in evolutionary computing for system design. doi:10.1007/978-3-540-72377-6_6. URL https://doi.org/10.1007/978-3-540-72377-6%7B%5C_%7D6.
- Munshi, A.A. and Mohamed, Y.A.R.I. (2018). Extracting and defining flexibility of residential electrical vehicle charging loads. *IEEE Transactions on Industrial Informatics*, 14, 448–461. doi:10.1109/TII.2017.2724559.
- Pereira, M.V., Maceira, M.E., Oliveira, G.C., and Pinto, L.M. (1992). Combining analytical models and monte-carlo techniques in probabilistic power system analysis. *IEEE Transactions on Power Systems*, 7, 265–272. doi:10.1109/59.141713.
- Poli, R., Kennedy, J., and Blackwell, T. (2007). Particle swarm optimization: An overview. *Swarm Intelligence*, 1, 33–57. doi:10.1007/s11721-007-0002-0.
- Rajasekhar, B. and Pindoriya, N.M. (2020). Heuristic approach for transactive energy management in active distribution systems. *IET Smart Grid*, 3, 406–418. doi:10.1049/iet-stg.2019.0221.

- Zhang, Q., Zhu, Y., Wang, Z., Su, Y., and Li, C. (2019). Reliability assessment of distribution network and electric vehicle considering quasi-dynamic traffic flow and vehicle-to-grid. *IEEE Access*, 7, 131201–131213. doi:10.1109/ACCESS.2019.2940294.
- Zheng, Y., Dong, Z.Y., Xu, Y., Meng, K., Zhao, J.H., and Qiu, J. (2014). Electric vehicle battery charging/swap stations in distribution systems: Comparison study and optimal planning. *IEEE Transactions on Power Systems*, 29, 221–229. doi:10.1109/TPWRS.2013.2278852.