

## Modelagem e Análise de Estações de Recarga Rápida considerando uma estrutura de Microrredes e Padrões Estocásticos

Matheus S. da Cruz, Caroline B. F. Darui, Leonardo Nogueira F. da Silva \*  
Tiago G. Lucca, Nelson Knak Neto, Alzenira da Rosa Abaide \*

*\*Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Maria, RS  
(e-mails: matheussdcruz@gmail.com, carolinedarui@hotmail.com, leo.nogueirafs@gmail.com,  
tiagoglucca@hotmail.com, nelson.knak@ufsm.br, alzenira@ufsm.br)*

---

**Abstract:** One of the actions to reduce Greenhouse Emissions is the decarbonization of the transport sector. Among the alternatives for it, there are Electric Vehicles (EV). However, to increase the EV penetration, mainly in large countries, like Brazil or the US, it is necessary the development of Public Charging Infrastructure, such as Fast-Charging Stations (FCS) on Highways, to handle long-distance trips without long-charging times. The high powers that FCSs demands encourage the use of distributed resources, such as Photovoltaic and Wind Power, and Energy Storage Systems, characterizing microgrids. However, the random nature of the elements that make up the microgrids is a challenge for the characterization of load profiles that demonstrate the temporal behavior of FCS. In this context, this article presents a methodology for modeling FCS, considering stochastic models to characterize the load profiles of these microgrids, allowing for the expansion of the scenario numbers, which makes the analysis more comprehensive. From the models obtained, the need for models that consider stochastic patterns for expansion planning is evident.

**Resumo:** A descarbonização do setor de transportes vem sendo adotada como medida para redução da emissão de Gases do Efeito Estufa. Dentre as alternativas estão os Veículos Elétricos (VE). Contudo, o desenvolvimento de VEs, principalmente em países de grandes dimensões, passa pela implantação de infraestruturas públicas de recarga, as quais, as Estações de Recargas Rápidas (ERRs) em rodovias, que representam a capacidade de conclusão de viagens, maiores que a autonomia do VE, em tempo hábil. As elevadas potências que as ERRs demandam, incentivam a utilização dos recursos distribuídos, tais como a Fotovoltaica e a Eólica, além dos Sistemas de Armazenamento, caracterizando as microrredes. Contudo, a natureza aleatória dos elementos integrantes das microrredes são um desafio para a caracterização de perfis de carga que demonstrem o comportamento temporal das ERRs. Nesse contexto, o presente artigo apresenta uma metodologia para a modelagem das ERRs, considerando modelos estocásticos para caracterizar os perfis de carga dessas microrredes, permitindo ampliar o número de cenários, o que torna as análises mais abrangentes. A partir dos modelos obtidos, evidencia-se a necessidade de modelos que considerem padrões estocásticos para o planejamento da expansão.

**Keywords:** Fast-Charging Stations; Microgrids; Electric Vehicles; Photovoltaics; Wind Power; Energy Storage Systems.

**Palavras-chaves:** Estações de Recarga Rápida; Microrredes; Veículos Elétricos; Geração Fotovoltaica; Geração Eólica; Sistemas de Armazenamento.

---

### 1. INTRODUÇÃO

A relevância que o setor de transportes possui para o cumprimento das metas estipuladas no Acordo de Paris, fez com que, na última década, os Veículos Elétricos (VEs) ganhassem notoriedade na tentativa de reduzir a emissão de gases causadores do efeito estufa (Delgado et al., 2017). Ainda que o desenvolvimento dos VEs para a substituição dos convencionais à combustão seja um processo natural da tecnologia, alguns desafios são esperados para a descarbonização da frota veicular. Entre estes, pode-se citar a necessidade da criação de infraestruturas públicas de recarga para a difusão dos VEs, tendo em vista a dependência bilateral existente entre esses dois itens, baseado na experiência internacional (IEA, 2020).

Uma série de análises vem indicando que, dentre a parcela aproximada de 10% de recargas realizadas em infraestruturas públicas, grande parte serão Estações de Recargas Rápidas (ERRs), localizadas em rodovias, permitindo deslocamentos acima da autonomia dos veículos, com intervalos de recarga menores (Hardman et al., 2018; Jochem et al., 2019). Contudo, a modelagem ERRs em rodovias apresenta uma série de desafios, devido à alta estocasticidade do processo, seja pelo comportamento do usuário em relação ao estado de carga inicial, ansiedade e distância percorrida, ou fatores como número de eventos de recarga, participação de VEs no mercado local, e o fato da natureza da recarga em rodovias ser conflitante com estratégias de gerenciamento de demanda.

Além disso, o desenvolvimento das estações públicas de

recarga, especialmente as ERRs, traz consigo preocupações acerca das elevadas demandas que essas infraestruturas exigem, da ordem mínima de 50 kW (Silva et al., 2021). Como alternativa, a inclusão da microgeração local, principalmente a partir da Fotovoltaica (FV) e Eólica (EOL), pode contribuir à redução do perfil de carga do sistema de distribuição (Kumar et al., 2020).

A interconexão desses recursos distribuídos dá origem as chamadas microrredes, possibilitando que a carga seja atendida localmente por sua própria geração. Os benefícios para a adesão disruptiva das microrredes vão além da perspectiva técnica, visto que também são observados econômica, ecológica e socialmente (Haupt et al., 2020). Ainda, a maturidade alcançada pelas tecnologias de geração a partir das fontes renováveis, é outro importante fator que corrobora ao crescimento das microrredes (Wei et al., 2021). Contudo, a natureza estocástica dos recursos primários de microgeração dá espaço para que outro elemento integre as microrredes: o Sistema de Armazenamento de Energia (SAE).

Segundo Alsaidan et al. (2018), o SAE é visto como a melhor opção para mitigar os desafios relacionados a energia intermitente gerada pela FV e EOL, uma vez que aumenta a confiabilidade da Microrrede com esses recursos distribuídos. A integração do SAE pode permitir que a energia gerada localmente seja armazenada para utilização posterior, considerando fatores técnicos ou econômicos. No caso específico da ERR, o SAE pode proporcionar tanto a redução da demanda no horário ponta quanto a arbitragem de energia (Maulik & Das, 2020). Entretanto, Kumar et al. (2020) salienta que os armazenadores também podem colaborar à rede da concessionária prestando serviços ancilares, como regulação de frequência e tensão.

As microrredes de ERR têm sido alvo de diversos trabalhos na literatura recente. Contudo, normalmente tais estudos restringem-se a otimização do dimensionamento do SAE (Salapic et al., 2018), diferentes métodos de controle (Wei et al., 2021) ou ainda análises de confiabilidade a partir da integração dos armazenadores (Ge et al., 2019). Observa-se uma carência de estudos que realizem a caracterização dos perfis de carga e geração dessas topologias de Microrrede que possibilitem avaliar seus respectivos impactos no sistema, bem como sua viabilidade técnica e econômica.

Nesse contexto, o presente trabalho apresenta uma metodologia para a modelagem das curvas de carga de ERR considerando a integração de VEs, FV, EOL e SAE. Considerando a natureza aleatória que os elementos integrantes dessas microrredes apresentam, a metodologia proposta caracteriza os perfis a partir modelos estocásticos, possibilitando fornecer um número maior de cenários para o planejamento de expansão, tornando as análises mais abrangentes. Para o estudo de caso, propõem-se a determinação do dimensionamento do SAE em uma estratégia de maximização do autoconsumo.

## 2. METODOLOGIA

Sendo o fluxo de potência de uma Microrrede, o agregado das curvas de carga e a geração dos recursos distribuídos, faz-se necessário conhecer os perfis que demonstrem essas variações

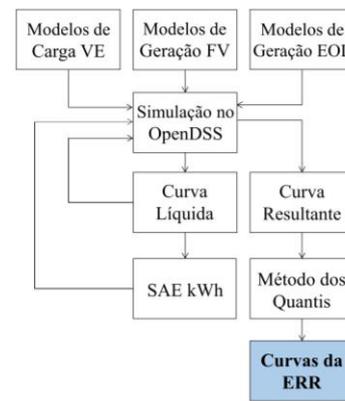


Fig. 1. Etapas para obtenção dos modelos que caracterizam os perfis de carga da ERR.

temporais ao longo de um período. Dessa forma, utiliza-se de modelos que representem o comportamento destes recursos interligados à Microrrede, podendo tais modelos serem determinísticos, probabilísticos ou mistos.

A obtenção dos modelos que caracterizam os perfis de carga de uma ERR, considerando a microgeração e o armazenamento local, seguem as etapas dispostas na Fig. 1.

Nas próximas subseções, cada etapa da metodologia é apresentada, demonstrando a composição para obtenção dos modelos.

### 2.1 Modelagem das Curvas de Carga

Conforme abordado anteriormente, a modelagem das curvas de carga para ERRs alocadas em rodovias compreende um processo estocástico. Essas curvas são caracterizadas por aspectos espaço temporais, dinâmica de tráfego, velocidade de deslocamento e estratégias inerentes aos usuários (Domínguez-Navarro et al., 2019). Nesse sentido, duas tendências de modelagem vêm sendo adotadas. A primeira é o reconhecimento de padrões, baseado na decomposição da série temporal histórica, como em Arias & Bae (2016) e Hardinghaus et al. (2016). Entretanto, a qualidade dos resultados está vinculada a capacidade de identificação de sazonalidades estáveis dentro do histórico.

Outra abordagem são os modelos de tráfego de veículos e a agregação com técnicas como a Teoria das Filas, que representa as probabilidades de uso e tempo de uso das ERRs, como em Gnann et al. (2018) e Bae & Kwasinski (2012). Para a geração de curvas de carga da ERR, nesse artigo é aplicada a metodologia de simulação de tráfego e operação da ERR proposta em Silva et al. (2021). A Fig. 2 apresenta um diagrama de blocos com as etapas desta metodologia.

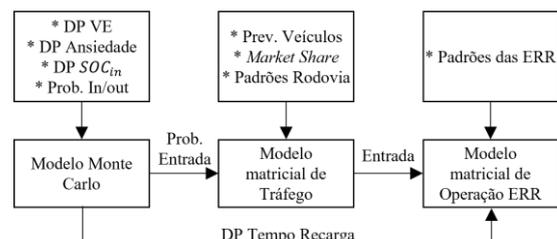


Fig. 2. Diagrama de blocos da modelagem das curvas de carga. Elaborado a partir de Silva et al. (2021).

- Simulação de Monte Carlo (SMC): Baseado em entradas relativas as Distribuições de Probabilidade (DP) do percentual de VEs comercializados por tipo, da taxa de ansiedade do usuário com a diminuição da autonomia, representado em estado de carga mínimo, do estado de carga inicial ( $SOC_{in}$ ) e das probabilidades de entrada e saída da rodovia. São rodados 10000 cenários e obtidas a DP de tempo de recarga e a probabilidade de entrada de cada ERR.
- Modelo de Tráfego: Solução matricial (linhas representam passo de simulação, e colunas a posição de pontos subsequentes da rodovia). Com base na previsão de veículos em pontos de entrada e saída, e a participação de VEs, se projeta o fluxo do tráfego ao longo do horizonte de simulação.
- Modelo de Operação: Solução matricial, que considera o número de carregadores e a matriz de ocupação e fila de espera de cada ERR. Dado o número de veículos de entrada e a DP de tempo de recarga, se obtém a curva de carga, bem como taxas de ocupação e comprimento de filas.

Um maior detalhamento em relação a modelagem matemática, encontram-se na referência Silva et al. (2021).

## 2.2 Modelagem em OpenDSS e Obtenção da Curva Líquida

A metodologia proposta considera que o SAE depende essencialmente dos períodos em que há a reversão do fluxo de potência. Dessa forma, o objetivo é evitar a injeção da energia excedente gerada na rede da concessionária, tornando a ERR o mais autônoma possível. Para tanto, deve-se conhecer o perfil de carga líquido, oriundo da integração dos modelos de VEs, FV e EOL.

Uma maneira simples e eficiente de obter esse perfil, é através da simulação do fluxo de potência no *software* OpenDSS, onde os componentes são modelados como *loads* individuais, conectados à uma mesma barra. A obtenção do perfil de carga líquido é realizada através de um *monitor*, o qual permite obter os resultados do fluxo de potência na rede. O restante do circuito necessário para a simulação é modelado como uma barra infinita, tal como demonstrado na Fig. 3.

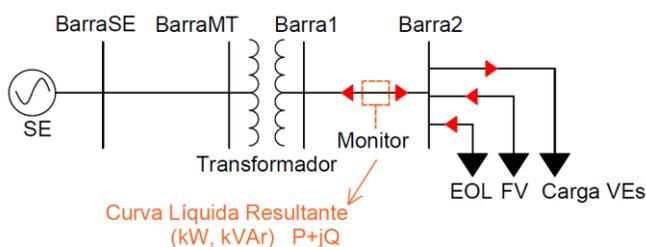


Fig. 3. Circuito para obtenção do perfil de carga líquido da ERR no *software* OpenDSS.

Desse modo, o processo realizado pelo *monitor* do OpenDSS para extrair a curva líquida  $L_{ERR}(t)$ , matematicamente, é a soma dos perfis de carga ( $VE_{ERR}(t)$ ) e geração ( $FV_{ERR}(t)$  e  $EOL_{ERR}(t)$ ), conforme (1).

$$L_{ERR}(t) = VE_{ERR}(t) - FV_{ERR}(t) - EOL_{ERR}(t) \quad (1)$$

Para a simulação, são informadas as respectivas curvas de carga e geração de cada componente em pu, bem como o valor máximo de potência (consumida ou fornecida). A simulação é realizada no modo *yearly*, permitindo extrair a curva líquida anual a partir do *monitor* modelado. Com base nesta curva líquida anual, pode-se prosseguir ao dimensionamento do SAE, descrito a seção seguinte.

## 2.3 Dimensionamento do SAE

A determinação da capacidade do SAE, em kWh, é realizada a partir da curva líquida anual. Como o objetivo é tornar a ERR autônoma, o SAE deve ser capaz de armazenar toda a energia excedente gerada pelos microgeradores. Além disso, considera-se um estado de carga (*State of Charge* – SoC) mínimo de 20%, a fim de prolongar a vida útil do SAE (Guena & Leblanc, 2006). A Fig. 4 demonstra um exemplo de curva líquida anual, a fim de determinar a capacidade do SAE.

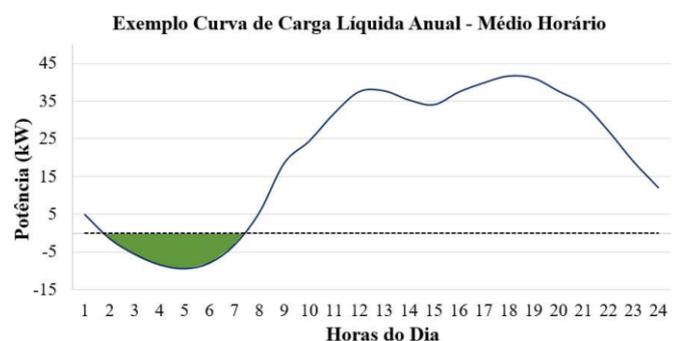


Fig. 4. Exemplo de curva líquida anual para dimensionamento do SAE.

Tendo em vista que a energia é excedente no período das 2 às 7 horas da manhã, o SAE deve ser dimensionado tal qual possa armazenar todo este montante, visando o despacho no período diurno. O dimensionamento pode ser realizado através da integração numérica da área hachurada em verde. Para tanto, a Regra dos Trapézios torna-se suficiente, tendo em vista sua simplicidade e erro desprezível, conforme (2).

$$A = \int_a^b f(x)dx \approx \frac{(x_1 - x_0)}{2} [f(x_0) + f(x_1)] \quad (2)$$

Em que,  $x_1$  e  $x_0$  representam os pontos do intervalo que se deseja calcular a área, sendo  $f(x_0)$  e  $f(x_1)$  os respectivos valores destes pontos na função  $f(x)$ . A partir do valor obtido em (2), pode-se aplicar um fator de 20% a fim de considerar a energia utilizável do SAE, com base na perspectiva do prolongamento da vida útil.

## 2.4 Obtenção da Curva de Carga Resultante com SAE

De posse dos perfis de carga dos carregadores (VEs), FV e EOL, bem como da capacidade necessária do SAE, pode-se simular novamente o fluxo de potência da Microrrede da ERR, agora com a integração do recurso armazenador.

Nesta etapa, VEs, FV e EOL são modelados como um só elemento, seguindo a mesma curva líquida anual. Somente o SAE é adicionado individualmente, conforme o modelo genérico de armazenamento disponível no OpenDSS, denominado *storage*. Além da capacidade de armazenamento, deve ser escolhido um modo de operação para o SAE, o qual

destaca-se o *follow* pela sua aplicabilidade segundo a metodologia considerada. Como regra geral, o modo *follow* permite ao *storage* carregar e descarregar seguindo a curva líquida anual.

A simulação é novamente realizada no OpenDSS considerando o período anual. A Fig. 5 demonstra o circuito necessário para obtenção da curva resultante da ERR com a integração do SAE.

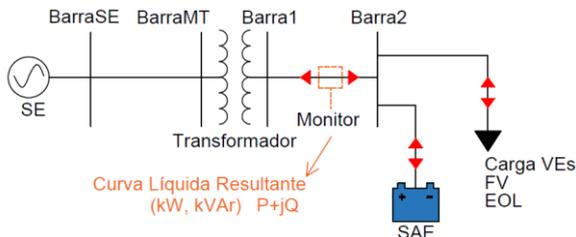


Fig. 5. Circuito para obtenção da curva de carga resultante da ERR com SAE, no *software* OpenDSS.

A composição da curva de carga resultante da ERR é realizada pelo *software* de acordo com o valor horário da curva líquida, bem como o estado de carga (SoC) do SAE. Desse modo, os valores negativos da curva líquida – os quais, representam geração excedente – fazem com que o SAE seja carregado, até o SoC máximo. Analogamente, valores positivos da curva líquida – que representam demanda da rede da concessionária – fazem com que o SAE seja descarregado, até o SoC mínimo.

Matematicamente, a extração da curva resultante  $R_{ERR}(t)$  realizada pelo *monitor* do OpenDSS pode ser expressa conforme (3) e (4).

$$R_{ERR}(t) = L_{ERR}(t) - SAE_{ERR}(t) \quad (3)$$

$$\begin{cases} L_{ERR}(t) < 0 \text{ e } SoC < 1, & SAE_{ERR}(t) \leq L_{ERR}(t) \\ L_{ERR}(t) < 0 \text{ e } SoC = 1, & SAE_{ERR}(t) = 0 \\ L_{ERR}(t) > 0 \text{ e } SoC > 0,2, & SAE_{ERR}(t) > L_{ERR}(t) \end{cases} \quad (4)$$

Os comportamentos das curvas (líquida, operação e SoC), que compõem a curva de carga resultante da ERR estão demonstrados graficamente pela Fig. 6.

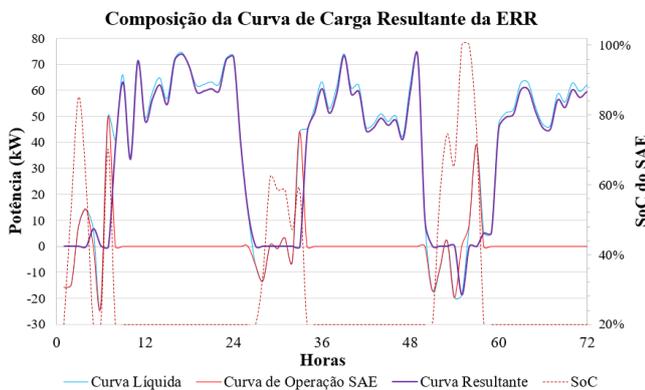


Fig. 6. Composição da curva de carga resultante da ERR.

Posteriormente a simulação do fluxo de potência anual, os 8760 dados da curva de carga resultante são classificados em diferentes patamares de probabilidade, a partir da aplicação do método dos quantis.

O método dos quantis permite considerar toda a série de dados, ao invés de trabalhar com um valor determinístico para cada hora do dia. De maneira geral, este método possibilita que as curvas sejam classificadas em diferentes patamares, segundo a probabilidade de ocorrência (Knak Neto et al., 2019). Por exemplo, para o quantil 0,75 (Q0,75), a demanda horária deverá ser igual ou inferior ao valor da curva em 75% do tempo. Desse modo, o método dos quantis permite incorporar aos modelos obtidos a incerteza associada a carga e a geração, características dos VEs e de fontes baseadas em recursos intermitentes, como a FV e a EOL. Consequentemente, sua aplicação permite obter um número de cenários robustos, tornando as análises de planejamento da expansão mais abrangentes.

### 3. ESTUDO DE CASO E RESULTADOS

Para fins de estudo de caso, propõe-se a modelagem de uma rodovia real, localizada no sul do Brasil, em um trecho composto de 241 km totais, com 5 pontos de conexão (PC), que corresponde a pontos de entrada e saída da rodovia, como cidades, e 3 ERRs, alocadas com base em estudos de infraestrutura locais. Além disso, devido a condições de espaço e característica de vento, definiu-se a ERR2, como aquela a ser composta por uma Microrrede. A Fig. 7 apresenta esse modelo. Ressalta-se que, para o estudo de caso proposto, o dimensionamento do SAE da Microrrede tem como objetivo maximizar o autoconsumo, reduzindo a injeção de energia no sistema da concessionária local.

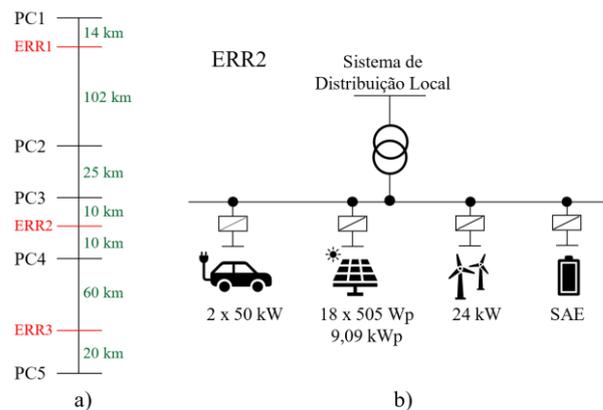


Fig. 7. Diagramas do estudo de caso proposto. Em a) é apresentada a rodovia modelada, e em b) os elementos da Microrrede da ERR2.

A ERR2 é composta por 2 carregadores de 50 kW, uma potência instalada fotovoltaica de 9,09 kWp e eólica de 24 kWp. Propuseram-se simulações no horizonte anual, estratificada em horas, considerando como entrada de dados informações de geração provenientes de séries sintéticas simuladas no *software* Homer, representadas pela média horária anual na Fig. 8, e informações de tráfego para o ano de 2019, nos pontos PC1 e PC5, obtidas em DNIT (2021). Como saída do modelo de Monte Carlo, estimou-se uma probabilidade de entrada na estação de 39,48% (PC1 para PC5), e 54,13% (PC5 para PC1). A Fig. 9 apresenta a DP de tempo de recarga. Com relação as entradas da SMC, as probabilidades In/out são exclusivas ao estudo de caso. As demais são similares a Silva et al. (2021).

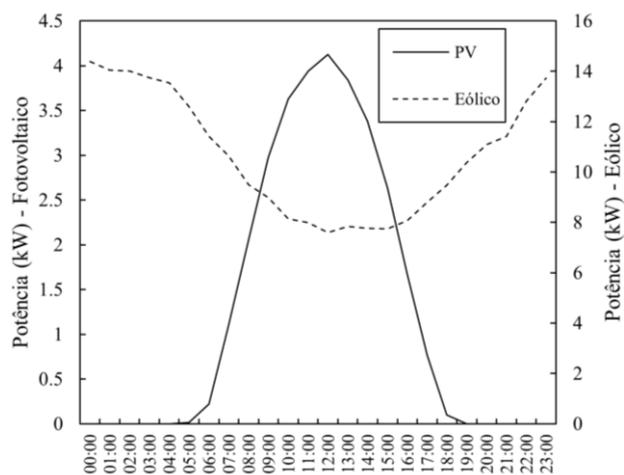


Fig. 8. Perfil médio horário de geração fotovoltaica e eólica, considerado no estudo de caso.

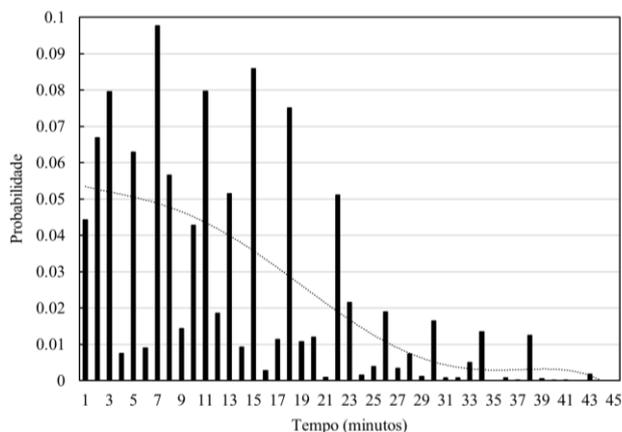


Fig. 9. Distribuição de probabilidade do tempo de recarga para a ERR2. Foi realizada a média para os diferentes tipos de dia do ano de simulação.

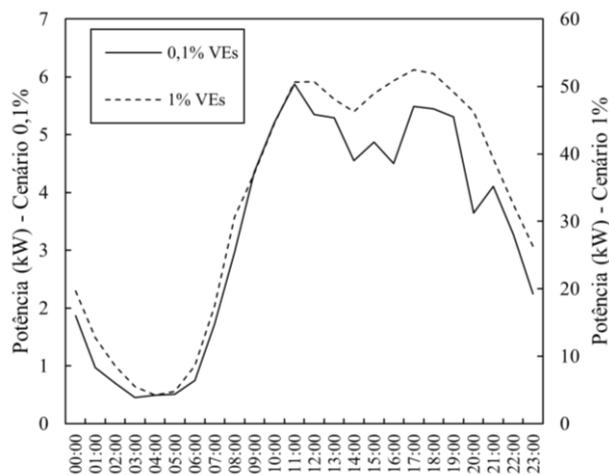


Fig. 10. Perfil médio horário de carga para os dois cenários de participação de VEs no mercado, 0,1% e 1%, para ERR2.

Ainda, consideraram-se dois cenários, representando a adesão dos VEs na frota veicular local, correspondendo ao percentual 0,1% e 1% de participação no mercado total de veículos. Por exemplo, dado um resultado de 1000 veículos ingressando na

rodovia modelada, estimaram-se 1 VE e 10 VEs, respectivamente, para os cenários propostos. Em Fig. 10 são apresentados os resultados médios horários de curva de carga para os dois cenários. Dessa forma, foram realizadas duas análises distintas segundo os modelos obtidos, a fim de verificar os impactos que a penetração dos VEs nas rodovias provoca na Microrrede da ERR2 considerada.

### 3.1 Cenário 0,1% de VEs

O cenário de 0,1% pode ser considerado um estágio inicial da adesão de VEs na frota veicular, onde não se observa quaisquer filas para o carregamento na estação. Isso se reflete em períodos que a demanda é baixa ou inexistente, fazendo com que as médias horárias também sejam reduzidas.

Contudo, FV e EOL estão a plena geração de suas potências instaladas, fazendo com que haja energia excedente em diversos períodos do dia. Segundo a metodologia considerada em 2.3, para o dimensionamento dos armazenadores, fez-se necessário a utilização de um SAE com capacidade de 240 kWh, tendo em vista a média elevada de reversão do fluxo de potência. Os quantis representativos para esse cenário são demonstrados na Fig. 11.

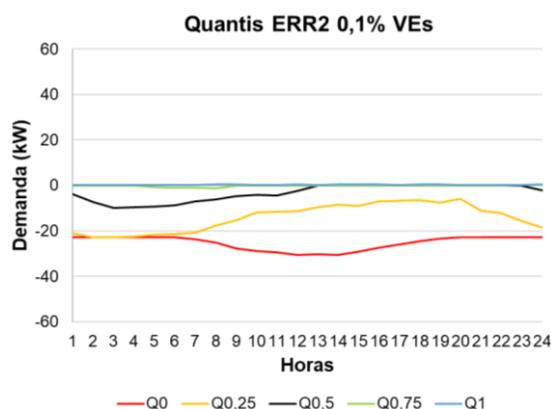


Fig. 11. Quantis representativos da ERR2 para o cenário 0,1% de VEs.

A caracterização dos quantis apresentada na Fig. 11 evidencia a necessidade da utilização de modelos estocásticos para a representação da carga em ERR2, tendo em vista a variabilidade dos resultados obtidos. Assim, as análises dos quantis podem ser feitas inicialmente a partir dos cenários extremos (Q1 e Q0), e posteriormente, os quantis mediano (Q0,5) e intermediários (Q0,25 e Q0,75).

Para Q1, observa-se que, sob a presença do SAE, a ERR2 se torna praticamente autônoma do ponto de vista da rede da concessionária, visto que o SAE é capaz de gerenciar a energia excedente gerada durante o período diário. Contudo, ressalta-se que esse quantil representa perfis de mínima geração e máxima demanda na ERR2.

Entretanto, para Q0, mesmo a integração do SAE não consegue eliminar parcialmente a condição de fluxo reverso, embora reduza minimamente. Isso se deve a característica do quantil com perfis máxima geração e mínima demanda, o que faz com que o SAE atinja 100% do SoC rapidamente.

Q0,5 é caracterizado por perfis de carga e geração medianos.

Nesse caso, embora o SAE não consiga zerar o intercâmbio energético entre a ERR e a rede, permite um melhor gerenciamento da energia entre o período das 13 e 23 horas, horários em que a geração é reduzida e a carga é maior. Nas demais horas do dia, a baixa demanda de VEs e principalmente a geração EOL fazem com que a energia excedente seja injetada na rede.

Para Q0,75 observa-se um comportamento similar ao Q1 (embora a geração seja ligeiramente superior), implicando no quase total gerenciamento de energia da ERR2. Contudo, esse comportamento não ocorre para Q0,25, o qual é análogo ao Q0 (ainda que a carga seja ligeiramente superior).

De maneira geral, para esse cenário de integração de VEs, observa-se que, ainda que o SAE da Microrrede seja consideravelmente robusto, não é suficiente para evitar a reversão do fluxo de potência na rede em períodos que a geração é mais elevada ou a carga é reduzida.

No Apêndice A desse artigo são disponibilizados os dados dos quantis representativos da Microrrede da ERR2, para o cenário de 0,1% de VEs.

### 3.2 Cenário 1% de VEs

Nesse cenário, a adesão de VEs é 10 vezes maior em relação ao cenário anterior, e, ainda que represente uma pequena parcela do total de veículos, há a utilização de pelo menos 1 carregador por várias horas consecutivas do dia. Assim, tem-se um perfil de carga mais constante na ERR2, fazendo com que as médias horárias de demanda da Microrrede também sejam superiores.

Por sua vez, a microgeração local de FV e EOL permite reduzir a demanda da Microrrede, fazendo até mesmo que a reversão do fluxo ocorra em algumas horas do dia. Desse modo, o SAE dimensionado é reduzido a capacidade de 40 kWh. Para esse cenário, os quantis representativos são apresentados na Fig. 12.

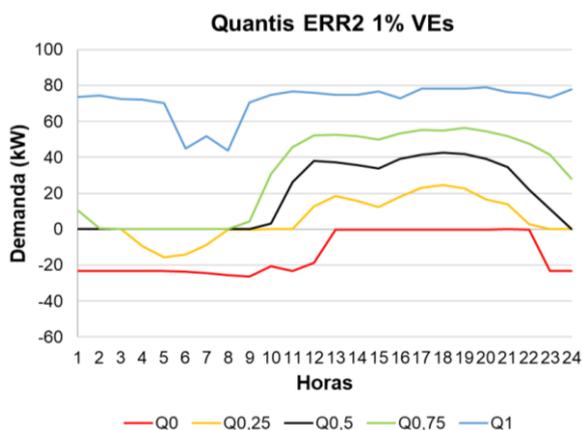


Fig. 12. Quantis representativos da ERR2 para o cenário 1% de VEs.

A partir da Fig. 12, observa-se que, apesar do SAE ser 6 vezes menor em relação ao cenário anterior, contribui de maneira mais significativa para a Microrrede.

Para Q1, demonstra-se que o SAE praticamente não interfere no perfil de carga da ERR. Isso se deve ao fato de haver pouca energia excedente para ser armazenada, uma vez que a recarga

dos VEs é maior e demanda toda energia gerada localmente, além da rede da distribuidora.

Contrariamente, em Q0, o fluxo de potência reverso ocorre das 23 às 13 horas, devido a carga ser reduzida nesse período. Entretanto, nas horas subsequentes, a energia armazenada pelo SAE em conjunto com a microgeração proporciona que o fluxo seja nulo, tornando a Microrrede temporariamente autônoma.

O perfil mediano de Q0,5 permite observar o melhor gerenciamento da energia pela Microrrede dentre os quantis. Por 9 horas consecutivas, o SAE contribui para zerar a demanda, além de auxiliar a microgeração na redução da energia proveniente da concessionária nas primeiras horas do dia.

Por sua vez, para Q0,75 também apresenta demanda nula entre às 2 e 8 horas da manhã, devido ao carregamento de VEs reduzido durante esse período. Para Q0,25, embora a demanda seja bastante reduzida durante o dia, há a ocorrência de fluxo reverso durante a madrugada, característica da carga inferior.

Desse modo, o cenário de 1% de VEs permite verificar que, de um modo geral, o SAE permite gerenciar a energia da Microrrede de maneira mais eficiente, visto que a reversão do fluxo de potência só é observada em momentos em que há concomitância de carga reduzida com elevada microgeração. Vale ressaltar que esses cenários possuem probabilidades menores, ainda que possam eventualmente ocorrer.

Os dados dos quantis representativos da Microrrede da ERR2, para o cenário de 1% de VEs, são apresentados no Apêndice B.

## 4. CONCLUSÕES

O crescimento do mercado de VEs no mundo introduz a necessidade de infraestruturas públicas de carregamento, especialmente em rodovias. A alta potência exigida pelas ERRs faz com a microgeração associada ao armazenamento sejam aspectos a serem avaliados, caracterizando as microrredes.

Ainda, a natureza aleatória dos elementos que integram as microrredes de ERRs impõe a necessidade por modelos que considerem a estocasticidade dos processos. Nesse contexto, o presente artigo apresentou uma metodologia para modelagem de microrredes de ERRs que considera os padrões estocásticos de carga e geração. A partir do modelo de tráfego e operação da ERR proposta em Da Silva et al. (2011), realizou-se a integração de dois cenários de VEs com a microgeração FV e EOL, abordando ainda o SAE como recurso a fim de mitigar a reversão do fluxo de potência. As curvas resultantes foram simuladas no software OpenDSS, sendo os dados processados no MATLAB para a classificação em diferentes quantis representativos.

As análises a partir dos quantis permitiram demonstrar a importância da utilização de métodos estocásticos para representação da incerteza dos padrões de carga e geração. De um modo geral, verificou-se a contribuição que o SAE pode oferecer as microrredes de ERRs, principalmente para o cenário de 1% de VEs, tornando o armazenador menos sensível as variações de carga durante o dia.

Além disso, ressalta-se que o estudo de dimensionamento do armazenador deu-se sob a ótica de maximizar o autoconsumo da Microrrede composta pela ERR. No entanto, outras estratégias podem alterar o dimensionamento e o ponto de operação, como o uso do armazenador em estratégias de peak-shaving, e recarga a partir do sistema de distribuição, em horários de menores tarifas, principalmente a fim de reduzir os custos de energia e demanda nos horários de pico.

Assim, as análises podem ser expandidas, especialmente ao considerar outras estratégias de dimensionamento e controle para o SAE. Entretanto, ressalta-se a necessidade da utilização de metodologias que considerem a estocasticidade dos padrões de VEs, FV e EOL, a fim de fornecer cenários mais abrangentes para compor estudos de planejamento de expansão que considerem as Microrredes de ERRs.

#### AGRADECIMENTOS

Os autores agradecem ao apoio técnico e financeiro da Companhia Estadual de Energia Elétrica e do Grupo Equatorial Energia (Programa de P&D da ANEEL através do projeto CEEE/EQUATORIAL/UFSM nº 5000004061), Instituto Nacional de Ciência e Tecnologia em Sistemas de Geração Distribuída (INCTGD), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq - nº 465640/2014-1), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES - nº 23038.000776/2017-54), Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS - nº 17/2551-0000517-1) e Universidade Federal de Santa Maria (UFSM), Instituições Brasileiras.

#### REFERÊNCIAS

- Alsaidan, I., Khodaei, A., & Gao, W. (2018). A Comprehensive Battery Energy Storage Optimal Sizing Model for Microgrid Applications. *IEEE Transactions on Power Systems*, 33(4), 3968–3980. <https://doi.org/10.1109/TPWRS.2017.2769639>.
- Arias, M. B., & Bae, S. (2016). Electric vehicle charging demand forecasting model based on big data technologies. *Applied Energy*, 183, 327–339. <https://doi.org/10.1016/j.apenergy.2016.08.080>.
- Bae, S., & Kwasinski, A. (2012). Spatial and temporal model for electric vehicle rapid charging demand. 2012 IEEE Vehicle Power and Propulsion Conference, VPPC 2012, 3(1), 345–348. <https://doi.org/10.1109/VPPC.2012.6422675>
- Delgado, F., Costa, J. E. G., Febraro, J., & Silva, T. B. da. (2017). *Cadernos FGV Energia: Carros elétricos*. [https://fgvenergia.fgv.br/sites/fgvenergia.fgv.br/files/caderno\\_carros\\_eletricos-fgv-book.pdf](https://fgvenergia.fgv.br/sites/fgvenergia.fgv.br/files/caderno_carros_eletricos-fgv-book.pdf)
- DNIT. (2021). PNCT – Plano Nacional de Contagem de Tráfego. <[http://servicos.dnit.gov.br/dadospnct/Contagem Continua](http://servicos.dnit.gov.br/dadospnct/ContagemContinua)>.
- Domínguez-Navarro, J. A., Dufo-López, R., Yusta-Loyo, J. M., Artal-Sevil, J. S., & Bernal-Agustín, J. L. (2019). Design of an electric vehicle fast-charging station with integration of renewable energy and storage systems. *International Journal of Electrical Power and Energy Systems*, 105(March 2018), 46–58. <https://doi.org/10.1016/j.ijepes.2018.08.001>
- Ge, S., Sun, H., Liu, H., Li, J., Zhang, X., & Cao, Y. (2019). Reliability evaluation of multi-energy microgrids: Energy storage devices effects analysis. *Energy Procedia*, 158, 4453–4458. <https://doi.org/10.1016/j.egypro.2019.01.769>
- Gnann, T., Funke, S., Jakobsson, N., Plötz, P., Sprei, F., & Bennehag, A. (2018). Fast charging infrastructure for electric vehicles: Today's situation and future needs. *Transportation Research Part D: Transport and Environment*, 62, 314–329. <https://doi.org/10.1016/j.trd.2018.03.004>
- Guena, T., & Leblanc, P. (2006). How depth of discharge affects the cycle life of lithium-metal-polymer batteries. INTELEC, International Telecommunications Energy Conference (Proceedings). <https://doi.org/10.1109/INTLEC.2006.251641>
- Hardinghaus, M., Blümel, H., & Seidel, C. (2016). Charging Infrastructure Implementation for EVs - The Case of Berlin. *Transportation Research Procedia*, 14, 2594–2603. <https://doi.org/10.1016/j.trpro.2016.05.410>
- Hardman, S., Jenn, A., Tal, G., Axsen, J., Beard, G., Daina, N., Figenbaum, E., Jakobsson, N., Jochem, P., Kinnear, N., Plötz, P., Pontes, J., Refa, N., Sprei, F., Turrentine, T., & Witkamp, B. (2018). A review of consumer preferences of and interactions with electric vehicle charging infrastructure. *Transportation Research Part D: Transport and Environment*, 62, 508–523. <https://doi.org/10.1016/j.trd.2018.04.002>
- Haupt, L., Schöpf, M., Wederhake, L., & Weibelzahl, M. (2020). The influence of electric vehicle charging strategies on the sizing of electrical energy storage systems in charging hub microgrids. *Applied Energy*, 273(February). <https://doi.org/10.1016/j.apenergy.2020.115231>
- IEA, I. E. A. (2020). Global EV Outlook 2020: Entering the decade of electric drive? In *Global EV Outlook 2020*. <https://doi.org/10.1787/d394399e-en>
- Jochem, P., Szimba, E., & Reuter-Oppermann, M. (2019). How many fast-charging stations do we need along European highways? *Transportation Research Part D: Transport and Environment*, 73(January), 120–129. <https://doi.org/10.1016/j.trd.2019.06.005>
- Knak Neto, N., Abaide, A. da R., Miranda, V., Vilaça Gomes, P., Carvalho, L., Sumaili, J., & Bernardon, D. P. (2019). Load modeling of active low-voltage consumers and comparative analysis of their impact on distribution system expansion planning. *International Transactions on Electrical Energy Systems*, 29(8), 1–19. <https://doi.org/10.1002/2050-7038.12038>
- Kumar, J., Parthasarathy, C., Västi, M., Laaksonen, H., Shafie-Khah, M., & Kauhaniemi, K. (2020). Sizing and allocation of battery energy storage systems in Åland islands for large-scale integration of renewables and electric ferry charging stations. *Energies*, 13(2). <https://doi.org/10.3390/en13020317>
- Maulik, A., & Das, D. (2020). Determination of optimal size of battery energy storage system (BESS) for a renewable power based microgrid. 2020 IEEE 17th India Council International Conference, INDICON 2020. <https://doi.org/10.1109/INDICON49873.2020.9342575>

Salapic, V., Grzanic, M., & Capuder, T. (2018). Optimal sizing of battery storage units integrated into fast charging EV stations. 2018 IEEE International Energy Conference, ENERGYCON 2018, 1–6. <https://doi.org/10.1109/ENERGYCON.2018.8398789>

Silva, L. Da, Abaide, A. A., Sausen, J. P., Paixao, J., & Correa, C. H. (2021). Proposal of a load curve modeling applied to highway EV Fast charging stations. 2021 56th International Universities Power Engineering Conference: Powering Net Zero Emissions, UPEC 2021 - Proceedings, 1–6. <https://doi.org/10.1109/UPEC50034.2021.9548220>

Wei, W., Zaixun, L., & Qiong, W. (2021). Research on Photovoltaic-Energy Storage-Charging Smart Charging Station and Its Control optimization. 2021 4th International Conference on Energy, Electrical and Power Engineering, CEEPE 2021, 951–956. <https://doi.org/10.1109/CEEPE51765.2021.9475701>

Apêndice A. CURVAS DE CARGA – CENÁRIO DE 0,1%

Neste apêndice são apresentadas as curvas de carga (em kW) obtidas para uma microrrede de ERR, considerando o cenário de 0,1% de VEs na frota veicular.

**Tabela A1. Curvas de Carga - Cenário de 0,1%**

Hora	Quantil				
	0	0,25	0,5	0,75	1
1	-22.75	-21.11	-3.86	0.01	0.07
2	-22.75	-22.75	-7.25	0.01	0.07
3	-22.75	-22.75	-9.88	0.00	0.07
4	-22.75	-22.65	-9.50	0.00	0.07
5	-22.75	-21.74	-9.18	-0.57	0.07
6	-22.92	-21.50	-8.81	-1.06	0.07
7	-23.68	-20.96	-7.00	-1.08	0.15
8	-25.10	-17.63	-6.23	-1.27	0.51
9	-27.69	-15.28	-4.62	-0.02	0.39
10	-28.73	-11.80	-4.23	-0.01	0.26
11	-29.34	-11.73	-4.44	-0.01	0.08
12	-30.48	-11.43	-2.52	-0.01	0.44
13	-30.29	-9.69	-0.07	0.00	0.21
14	-30.54	-8.39	-0.05	0.01	0.44
15	-29.29	-8.99	-0.07	0.01	0.50
16	-27.39	-7.12	-0.04	0.01	0.42
17	-26.11	-6.62	-0.03	0.01	0.07
18	-24.44	-6.39	-0.03	0.01	0.53
19	-23.27	-7.72	-0.03	0.01	0.40
20	-22.75	-5.83	-0.03	0.01	0.07
21	-22.75	-11.17	-0.02	0.01	0.10
22	-22.75	-12.07	-0.02	0.01	0.07
23	-22.75	-15.51	-0.04	0.01	0.07
24	-22.75	-18.40	-2.04	0.01	0.46

Apêndice B. CURVAS DE CARGA – CENÁRIO DE 1%

Neste apêndice são apresentadas as curvas de cargas (em kW) obtidas para uma microrrede de ERR, considerando o cenário de 1% de VEs na frota veicular.

**Tabela B1. Curvas de Carga - Cenário de 1%**

Hora	Quantil				
	0	0,25	0,5	0,75	1
1	-23.30	0.01	0.04	10.52	73.55
2	-23.30	0.00	0.04	0.34	74.59
3	-23.30	-0.01	0.02	0.06	72.70
4	-23.30	-9.50	0.01	0.03	72.04
5	-23.30	-15.48	0.00	0.02	70.34
6	-23.47	-14.07	-0.04	0.01	44.86
7	-24.23	-8.71	-0.03	0.00	51.87
8	-25.52	-0.15	-0.03	0.00	43.70
9	-26.38	-0.08	-0.03	4.25	70.75
10	-20.49	-0.05	3.19	30.70	74.82
11	-23.17	0.01	26.17	45.58	76.61
12	-18.51	12.62	37.93	52.07	75.96
13	-0.17	18.34	37.37	52.77	74.77
14	-0.18	15.99	35.69	51.79	74.77
15	-0.20	12.20	33.95	49.96	76.71
16	-0.18	18.10	39.20	53.42	72.87
17	-0.14	23.22	41.62	55.22	78.43
18	-0.13	24.76	42.78	55.07	78.45
19	-0.15	22.72	41.83	56.32	78.10
20	-0.16	16.59	39.23	54.39	78.93
21	-0.07	13.86	34.78	51.88	76.47
22	-0.13	2.95	22.01	47.57	75.40
23	-23.30	0.03	11.14	41.44	73.31
24	-23.30	0.02	0.07	28.04	77.78