Operação ótima de baterias em presença de incertezas de carga e geração

Hernane G. C. Júnior * **Raphael P. B. Poubel** * **Márcio M. Afonso** *
Lucas E. A. C. Santos * **Wesley Peres** **

* *Programa de Pós-Graduação em Engenharia Elétrica (PPGEL), Centro Federal de Educação Tecnológica, MG, (e-mails: herncampos@gmail.com, poubel@cefetmg.br, marciomatias@cefetmg.br, leackls@outlook.com)*
** *Departamento de Engenharia Elétrica, Universidade Federal de São João del-Rei, MG, (e-mail: wesley.peres@ufsj.edu.br)*

Abstract: This work introduces an innovative methodology for optimizing battery operation aimed at reducing energy losses over a 24-hour period. By employing the Grey Wolf optimization technique, a model has been developed to achieve optimal battery operation under varying conditions of load and energy generation. Additionally, load and generation uncertainty have been incorporated using the Two Point Estimate Method, aimed at reducing computational time and making the analysis feasible. The results demonstrate that this approach enhances battery operation efficiency, even in uncertain scenarios.

Resumo: Este trabalho apresenta uma metodologia inovadora para a otimização da operação de baterias visando à redução das perdas de energia ao longo de um período de 24 horas. Utilizando a técnica de otimização Grey Wolf, foi desenvolvido um modelo para alcançar uma operação ótima das baterias em condições variáveis de carga e geração de energia. Além disso, as incertezas de carga e geração foram incorporadas por meio da técnica *Two Point Estimate Method* (2PEM), com o objetivo de reduzir o tempo computacional e viabilizar a análise. Os resultados mostram que essa abordagem melhora a eficiência da operação de baterias, mesmo em cenários de incerteza.

Keywords: Grey Wolf optimization; Load and generation uncertainty; Optimal operation; Distribution network; Two Point Estimate Method.

Palavras-chaves: Metaheurística Grey Wolf; Incerteza de carga e geração; Operação Ótima; Redes de Distribuição; 2PEM.

1. INTRODUÇÃO

Com a crescente preocupação em mitigar os impactos ambientais associados às fontes de energia convencionais, tem sido observada uma rápida expansão das Fontes de Energia Renovável (FER), conforme Roberts and McDowall (2005). Esta expansão das FERs tem contribuído para a disseminação dos sistemas de Geração Distribuída (GD), possibilitando a integração de sistemas de geração próximos às cargas (Akorede et al., 2010).

O aumento em grande escala da adoção de GD no sistema de energia, aliado à volatilidade das FERs, como parques eólicos e centrais fotovoltaicas, tem proporcionado desafios adicionais para o equilíbrio da rede elétrica. Esses desafios são agravados pelas características intrínsecas dessas fontes de energia, e pelas incertezas tanto na demanda quanto na geração (Impram et al., 2020).

Uma alternativa que tem ganhado força para mitigar os impactos das incertezas associadas ao uso das FERs é a implementação de Sistemas de Armazenamento de Energia com Baterias (BESS) conforme descrito por Reihani et al. (2016).

Os BESS podem reagir instantaneamente a perturbações e compensar as variações dos geradores convencionais (Branco et al., 2018). Além disso, ao contrário das hidrelétricas, um BESS não está restrito geograficamente. Essas características tornam os BESS modernos uma opção viável para suavizar a produção de energia proveniente da geração intermitente de energia renovável.

Neste ambiente, diversos estudos sobre utilização de BESS em redes de distribuição têm sido desenvolvidos. Em (Yang et al., 2018) é possível encontrar uma revisão de trabalhos com objetivo de determinar o tamanho adequado das unidades de armazenamento com intuito de minimizar o impacto das fontes intermitentes. Outros trabalhos que fizeram uso de BESS para melhorar a eficiência da rede foram: (Xu et al., 2012; Kabir et al., 2014; Zeraati et al., 2016; Datta et al., 2019; Mohamad et al., 2021).

No entanto, apesar dos avanços realizados, ainda há lacunas na literatura no que diz respeito ao uso de BESS para a redução das perdas técnicas em redes de distribuição sob condições de incerteza.

Neste contexto, este trabalho apresenta uma metodologia que visa reduzir as perdas técnicas em redes elétricas por

meio da operação ótima das baterias utilizando a técnica de Otimização *Grey Wolf* (GWO). Diferentemente dos trabalhos anteriores, essa abordagem incorpora incertezas de geração e carga utilizando o método de estimativa de dois pontos (*Two Point Estimate Method*), o que permite uma análise mais eficiente em termos de tempo computacional (Hong, 1998). Para validar a metodologia proposta, a análise será conduzida no ambiente de simulação do software OpenDSS, focando na minimização das perdas técnicas durante a operação diária da rede elétrica.

2. METODOLOGIA PROPOSTA

2.1 Modelo do sistema de armazenamento

O modelo utilizado para a bateria combina um armazenamento ideal, um inversor e o cálculo das perdas associadas, conforme ilustrado na Fig. 1. Este modelo faz parte do módulo de armazenamento de energia chamado "storage", do *software* OpenDSS discutido em Dugan and McDermott (2011), que permite integrar unidades de armazenamento à rede de distribuição.

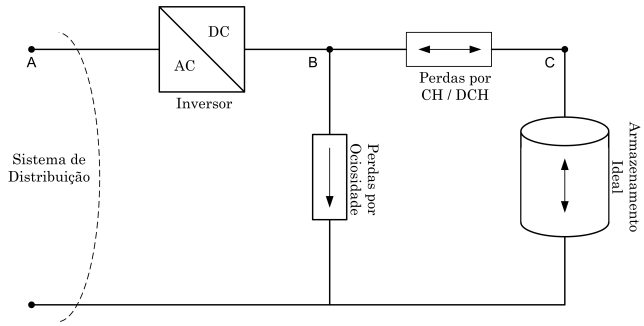

Figura 1. Modelo do sistema de armazenamento.

O componente de armazenamento de energia, possui três modos de operação para simular os estados de carga, descarga e ociosidade.

Na situação de carga, a rede elétrica fornece uma potência de entrada (P_{in}), no ponto A, que é multiplicada pelo fator de eficiência do inversor (η_{inv}) antes de ser armazenada, levando em conta as perdas por ociosidade (P_{idl}), no ponto B, e de carregamento (η_{CH}). A equação 1 descreve a energia armazenada (kWh_{in}) na bateria (ponto C), na forma ideal, após o processo de carregamento.

$$kWh_{in} = (P_{in} \cdot \eta_{inv} - P_{idl}) \cdot \eta_{CH} \tag{1}$$

No processo de descarga (kWh_{out}), a energia é retirada da unidade de armazenamento (ponto C), sofrendo perdas relacionadas à ociosidade e descarga (η_{DCH}). Essa energia é então convertida pelo inversor, considerando novamente seu rendimento, antes de ser injetada na rede, no ponto A. A equação 2 descreve o processo de descarga da bateria.

$$kWh_{out} = \frac{P_{out}}{(\eta_{inv} + \eta_{DCH})} + \frac{P_{idl}}{\eta_{DCH}} \tag{2}$$

No estado de ociosidade, não há carga ou descarga da unidade de armazenamento ideal ($kWh_{in} = kWh_{out} = 0$), apenas são computadas as perdas por ociosidade, fornecidas pela rede de distribuição, ponto A. A equação 3 descreve as perdas por ociosidade.

$$P_{idl} = \frac{P_{in}}{\eta_{inv}} \tag{3}$$

2.2 Incertezas no problema de planejamento

A demanda elétrica varia ao longo do dia e em diferentes períodos do ano, devido a uma variedade de fatores, como condições climáticas, atividades humanas e sazonalidade. Além disso, a introdução de geração fotovoltaica distribuída aumenta a variabilidade e a incerteza da geração de energia, devido à natureza intermitente e dependente da luz solar.

Essas incertezas proporcionam desafios para os operadores de rede e requerem estratégias de gerenciamento, para garantir a confiabilidade e eficiência do sistema de distribuição.

A Fig. 2 ilustra as fontes de incerteza consideradas neste estudo. Em particular, cada barramento de carga contribui com uma variável incerta $S_{\text{barra } k}$, enquanto os barramentos que possuem geração distribuída acrescentam duas variáveis incertas, $S_{\text{barra } k}$ e $P_{\text{pv } k}$.

Inc =	$S_{\text{barra 1}}$	···	$S_{\text{barra k}}$	$P_{\text{pv 1}}$	···	$P_{\text{pv k}}$

Figura 2. Variáveis incertas.

Uma simplificação considerada foi a de que, todas as cargas conectadas a um mesmo barramento, são muito parecidas, ou seja, uma redução da potência ativa traria uma redução da potência reativa de forma proporcional, mantendo o fator de potência do barramento constante.

Esta simplificação permite uma redução no número de variáveis incertas. Ao invés de se considerar P_k e Q_k variáveis incertas e independentes para a potência do barramento k ($S_{barra\ k}$), apenas para variável P_k será atribuída uma incerteza. Já a variável Q_k será obtida como uma consequência baseado no fator de potência original.

Como o fator de potência é único, temos que a tangente do ângulo de potência, descrita pela equação (4), deverá ser mantida constante, apesar de uma variação nos valores médios (${P_k}^m$ e ${Q_k}^m$), aqui denotados por ${P_k}^*$ e ${Q_k}^*$. Logo, podemos escrever a relação expressa pela equação (5) e, por conseguinte, inferir a relação delineada na equação (6).

$$tan(\alpha) = \frac{Q_k}{P_k} \tag{4}$$

$$tan(\alpha) = \frac{Q_k^m}{P_k^m} = \frac{Q_k^*}{P_k^*} \tag{5}$$

$${Q_k}^* = {Q_k}^m \cdot \frac{P_k^*}{{P_k}^m} \tag{6}$$

E, desta forma, cada barramento de carga k terá uma variável incerta $S_{barra\ k}$ obtido através da aplicação da incerteza na variável P_k e cálculo da correspondente variável Q_k.

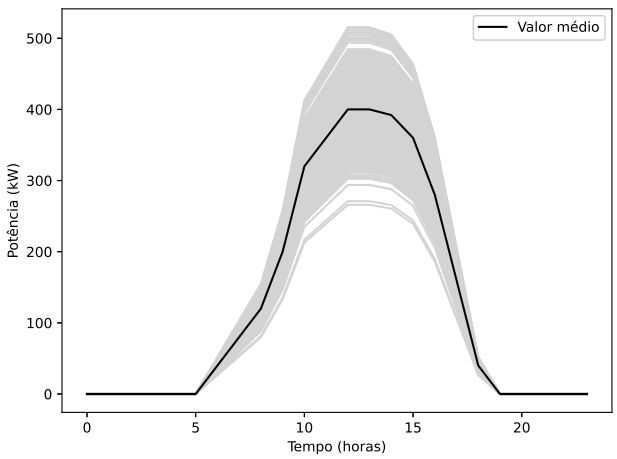

Figura 3. Geração fotovoltaica com incerteza.

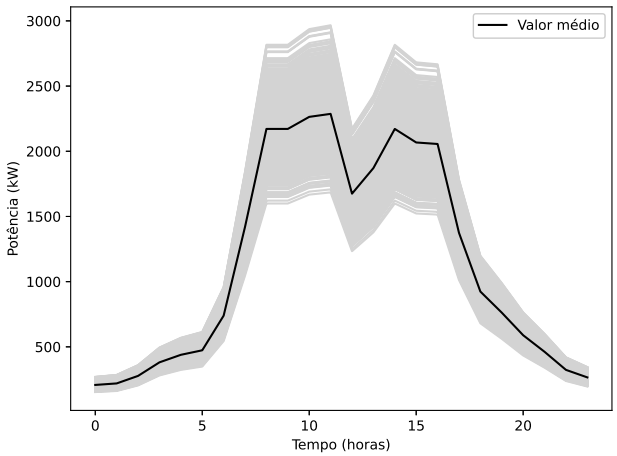

Figura 4. Demanda com incerteza.

Para este trabalho, será considerado uma incerteza de 10% nas variáveis incertas. A Fig. 3 ilustra o comportamento da geração fotovoltaica, considerada neste trabalho, quando a incerteza é aplicada.

Já a Fig. 4 ilustra o comportamento da demanda no barramento de instalação da unidade fotovoltaica da Fig. 3, quando a mesma incerteza de 10% é considerada.

2.3 Two Point Estimate Method

Nesta seção, será introduzida a formulação da abordagem *Two Point Estimate Method* (2PEM). Essa metodologia substitui as variáveis de entrada incertas por pontos determinísticos posicionados em ambos os lados de seus valores médios. Isso resulta em uma redução na carga computacional, pois o número de amostras a serem analisadas (2m) é apenas o dobro do número de variáveis de entrada incertas ($m = 2 \cdot (n_{bd} + n_{pv})$), onde n_{bd} representa o número de barramentos do sistema com cargas e n_{pv} o número de unidades de geração fotovoltaica.

Desse modo, a metodologia é executada duas vezes para cada variável incerta: primeiro, utilizando um valor abaixo da média e, em seguida, utilizando um valor acima da média, enquanto as outras variáveis permanecem em seus valores médios.

De forma resumida, a metodologia consiste em, para cada variável do conjunto m, determinar suas localizações extremas β_1 e β_2 utilizando as equações (7) e (8).

$$\beta_1 = \sqrt{m} \tag{7}$$

$$\beta_2 = -\sqrt{m} \tag{8}$$

Posteriormente, determina-se duas concentrações para a variável i, c_1 e c_2, posicionadas em ambos os lados do valor médio μ_i, com auxílio do desvio padrão σ_i, conforme as equações (9) e (10).

$$c_1 = \mu_i + \beta_1 \sigma_i \tag{9}$$

$$c_2 = \mu_i + \beta_2 \sigma_i \tag{10}$$

Em seguida, determinamos duas amostras para a variável de entrada i, que são representadas por C_1 e C_2, conforme as equações (9) e (10).

$$C_1 = [\mu_1, \mu_2, \ldots, c_1, \ldots, \mu_m]^T \tag{11}$$
$$C_2 = [\mu_1, \mu_2, \ldots, c_2, \ldots, \mu_m]^T \tag{12}$$

De posse das duas amostras, o problema de planejamento é resolvido, individualmente, para cada uma delas e o valor das perdas técnicas armazenado. O processo descrito é repetido até que todas as variáveis incertas tenham sido analisadas.

Para mais detalhes sobre a ténica, o leitor é direcionado ao trabalho de Hong (1998).

2.4 Modelo de otimização

O problema de otimização é focado na determinação de uma estratégia de controle para otimizar a operação diária da bateria.

A função objetivo consiste em minimizar as perdas ativas na rede elétrica em um período de 24 horas, conforme (13).

$$\min \sum_{t=1}^{24} Perdas(t) \tag{13}$$

Já as principais restrições do problema são descritas pelas equações (14) - (17).

A equação (14) apresenta a maneira em que a variável P^t_{kbat}, equação (15), irá influenciar o balanço de potência ativa de uma barra k do sistema, para um instante t de tempo.

$$P^t_k + P^t_{kbat} + P^t_{k\text{pv}} - P^t_{dk} = 0 \quad (k \in \Omega_B) \tag{14}$$

em que:

- Ω_B é o conjunto de barramentos no sistema;
- P^t_k é injeção de potência ativa na barra k e instante t. Tal injeção é calculada com base nas tensões complexas nodais e na matriz admitância de barras;

- P^t_{kbat} é a potência injetada ou absorvida pela bateria na barra k e instante t. Quando a potência é injetada, a bateria encontra-se em processo de descarga ($P^t_{kbat} \geq 0$). Quando a potência é absorvida, a bateria encontra-se em processo de carregamento ($P^t_{kbat} \leq 0$). Na operação ociosa ($P^t_{kbat} = -P_{idl}$) e, por fim, na ausência de bateria na barra, tem-se que $P^t_{kbat} = 0$;
- P^t_{kpv} é a potência gerada pela fonte solar fotovoltaica não despachável com base na incidência solar na barra k e instante t. Na ausência de GD na barra, $P^t_{\text{kpv}} = 0$. Neste trabalho as unidades fotovoltaicas operam com fator de potência unitário;
- P^t_{dk} é a potência ativa demandada na barra k e instante t.

$$P^t_{kbat} = \begin{cases} \Delta SoC^t \cdot kW_{rated}, & \text{se } \Delta SoC^t \neq 0 \\ -P_{idl}, & \text{caso contrário} \end{cases} \tag{15}$$

Em que ΔSoC é a variável contínua no intervalo $[-1, 1]$, conforme inequação (16), indicativa de carga, descarga e ociosidade da bateria. Já kW_{rated} é a potência nominal da bateria, ou seja, a capacidade de carga e descarga em um hora de operação.

$$-1 \leq \Delta SoC \leq 1 \tag{16}$$

$$0 \leq SOC^0 + \sum_{t=1}^{24} (\Delta SoC^t \cdot kW_{rated}) \leq kWh_{rated} \tag{17}$$

Aqui, SOC^t denota a quantidade de carga disponível em uma bateria na hora t. Um SOC igual a 0 indica uma bateria totalmente descarregada, enquanto SOC igual a kWh_{rated} indica uma carga completa.

2.5 Metaheurística Grey Wolf

Para a solução do problema de otimização apresentado na subseção 2.4, optou-se pela técnica *Grey Wolf Optimization* (GWO),

Desenvolvida por Mirjalili et al. (2014), a técnica GWO simula a colaboração entre lobos durante o processo de busca, perseguição e ataque às presas para explorar espaços de busca multidimensionais.

A escolha da técnica foi motivada pela eficácia dessa metaheurística em encontrar soluções ótimas ou próximas do ótimo, especialmente em problemas de otimização de alta dimensionalidade, conforme documentado por Khandelwal et al. (2018).

Na GWO, a posição de cada lobo representa uma solução candidata, caracterizada por um vetor X_i, conforme a equação (18), e sua respectiva aptidão $fob(X_i)$, que reflete a hierarquia de liderança dos lobos na natureza. Quatro tipos de lobos são definidos de acordo com sua aptidão: alfa (α), beta (β), delta (δ) e ômega, nesta ordem. A Fig. 5 ilustra o indivíduo X_i para o problema de despacho ótimo de baterias, apresentado na Seção 2.4.

$$X_i = [\, x_1 \;\; x_2 \;\; x_3 \;\; ... \;\; x_n \,] \tag{18}$$

Indíviduo					
ΔSoC^1	ΔSoC^2	ΔSoC^3	ΔSoC^4	···	ΔSoC^{24}

Figura 5. Formato do indivíduo da GWO.

Além disso, é fundamental ressaltar que a avaliação do desempenho do indivíduo, representado na Fig. 5, envolve a resolução de $m = 2 \cdot (n_{bd} + n_{pv})$ fluxos de potência, um para cada cenário proporcionado pela metodologia 2PEM. Somente após a avaliação de todos os cenários e o cálculo das perdas correspondentes, a função objetivo $fob(X_i)$ será conhecida, revelando assim a aptidão do indivíduo ao problema probabilístico.

Para modelar matematicamente o comportamento de caça, presume-se que os lobos alfa, beta e delta possuem um conhecimento superior sobre a localização das presas. Portanto, são armazenadas as três melhores soluções obtidas até o momento. Enquanto isso, os outros lobos (ômegas) atualizam suas posições com base nas melhores soluções, conforme a equação (19).

$$X_i^{p+1} = \frac{X_\alpha^{p+1} + X_\beta^{p+1} + X_\delta^{p+1}}{3} \tag{19}$$

onde p representa a iteração corrente, X_α^{p+1}, X_β^{p+1} e X_δ^{p+1} são as contribuições dos lobos alfa, beta e delta, respectivamente, para a nova posição X_i^{p+1} dos indivíduos ômegas. A equação (20) fornece a contribuição de cada lobo à nova posição dos indivíduos.

$$X_{\alpha,\beta,\delta}^{p+1} = X_i^p - (2 \cdot a \cdot r_1 - a) \cdot |2 \cdot r_2 \cdot X_{\alpha,\beta,\delta} - X_i^p| \tag{20}$$

onde a é um parâmetro que decresce linearmente de dois a zero, enquanto r_1 e r_2 são números aleatórios entre $[0, 1]$.

Essas atualizações são iterativamente aplicadas até que um critério de parada seja alcançado, geralmente o número máximo de iterações, como adotado neste estudo.

Ademais, para este trabalho foram escolhidos 24 indivíduos, para comporem a população de lobos, um para cada variável apresentada na Fig. 5, e 100 iterações para a convergência da metodologia.

3. ESTUDO DE CASO

3.1 Sistema teste IEEE 13 barramentos

O sistema elétrico escolhido para avaliar a metodologia desenvolvida na Seção 2 foi o IEEE 13 barramentos. O diagrama unifilar do sistema está ilustrado na Figura 6.

Ainda que seja um sistema de pequeno porte, ele apresenta diversas características de interesse ao simular redes de distribuição conforme Schneider et al. (2017).

Ademais, será realizada uma modificação no sistema, a partir da instalação de uma unidade de geração fotovoltaica (conforme descrito no Apêndice A) e de uma unidade de armazenamento de energia (descrito no Apêndice B), no barramento 671.

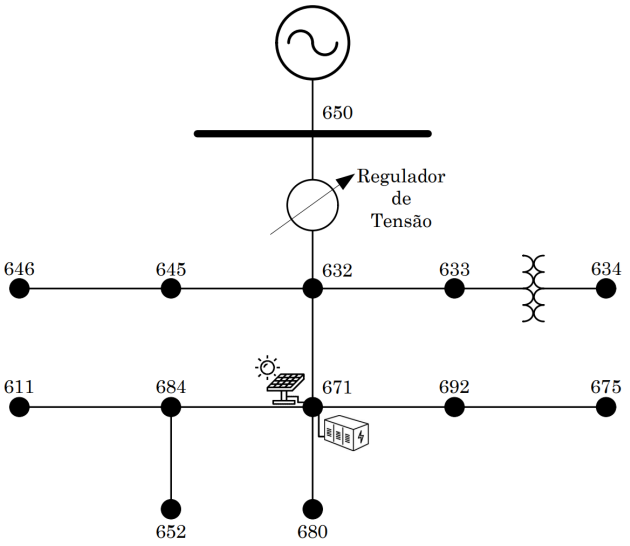

Figura 6. Diagrama unifilar do sistema IEEE 13 barras.

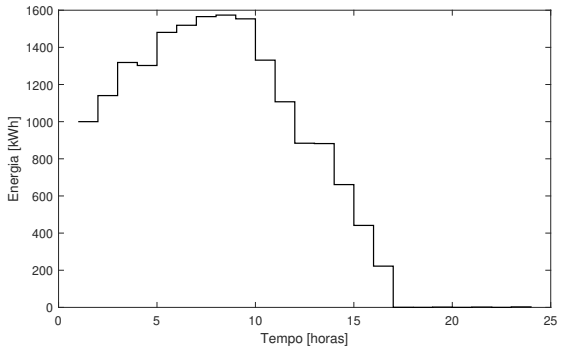

Figura 7. Energia armazenada na bateria.

3.2 Operação ótima com incertezas

Esta seção visa a análise da rede a partir da metodologia proposta. A Fig. 7 apresenta a curva de despacho da unidade de armazenamento.

Pode-se observar uma tendência de carga durante o período da madrugada, quando a demanda é reduzida (conforme ilustrado na Fig. C.1 do Apêndice C). Em seguida, a partir das 10 horas, ocorre uma descarga intensa da bateria devido ao aumento da demanda. Finalmente, a bateria atinge sua descarga completa às 17 horas, momento em que a carga industrial começa a diminuir para níveis mais baixos (conforme demonstrado na Fig. C.1 do Apêndice C).

A obtenção da Fig. 7 exigiu a resolução de 76.800 fluxos de potência, com cada fluxo demandando, em média, 0,026 segundos. Embora o número de fluxos avaliados seja substancial, o emprego de outras técnicas para avaliar a incerteza seria consideravelmente mais oneroso, em termos computacionais. Por exemplo, a utilização de uma metodologia de simulação Monte Carlo exigiria a análise de milhares de cenários, ao passo que a metodologia 2PEM exigiu apenas a avaliação de 32 cenários distintos para cada indivíduo do GWO, em cada geração.

4. CONCLUSÃO

Este trabalho apresentou uma metodologia para otimizar a operação de baterias, visando reduzir as perdas de energia ao longo de um período de 24 horas. Por meio da técnica de otimização Grey Wolf, foi desenvolvido um modelo que alcança uma operação ótima em condições variáveis de carga e geração de energia.

Além disso, ao incorporar as incertezas de carga e geração, utilizando o método *Two Point Estimate* (2PEM), conseguiu-se reduzir o tempo computacional e tornar a análise viável. Os resultados obtidos demonstram a aplicabilidade dessa abordagem, mesmo em cenários de incerteza, contribuindo para aprimorar a eficiência da operação de unidades de armazenamento.

Como continuidade deste estudo, tem-se a intenção de avaliar sistemas de maior escala, envolvendo um número mais expressivo de unidades de geração fotovoltaica e baterias, considerando o potencial da abordagem probabilística para lidar com as complexidades das redes elétricas reais. Além disso, pretende-se realizar uma comparação entre a operação probabilística proposta e a operação determinística da bateria, visando aprofundar a análise e avaliar a eficácia da abordagem diante de cenários mais desafiadores e representativos.

AGRADECIMENTOS

Os autores agradecem ao PPGEL (UFSJ e CEFET-MG) pelo apoio e auxílio financeiro.

REFERÊNCIAS

Akorede, M.F., Hizam, H., and Pouresmaeil, E. (2010). Distributed energy resources and benefits to the environment. *Renewable and sustainable energy reviews*, 14(2), 724–734.

Branco, H., Castro, R., and Lopes, A.S. (2018). Battery energy storage systems as a way to integrate renewable energy in small isolated power systems. *Energy for Sustainable Development*, 43, 90–99.

Datta, U., Kalam, A., and Shi, J. (2019). Battery energy storage system control for mitigating pv penetration impact on primary frequency control and state-of-charge recovery. *IEEE Transactions on Sustainable Energy*, 11(2), 746–757.

Dugan, R.C. and McDermott, T.E. (2011). An open source platform for collaborating on smart grid research. In *2011 IEEE power and energy society general meeting*, 1–7. IEEE.

Hong, H.P. (1998). An efficient point estimate method for probabilistic analysis. *Reliability Engineering and System Safety*, 59, 261–267.

Impram, S., Nese, S.V., and Oral, B. (2020). Challenges of renewable energy penetration on power system flexibility: A survey. *Energy Strategy Reviews*, 31, 100539.

Kabir, M.N., Mishra, Y., Ledwich, G., Dong, Z.Y., and Wong, K.P. (2014). Coordinated control of grid-connected photovoltaic reactive power and battery energy storage systems to improve the voltage profile of a residential distribution feeder. *IEEE Transactions on industrial Informatics*, 10(2), 967–977.

Khandelwal, A., Bhargava, A., Sharma, A., and Sharma, H. (2018). Modified grey wolf optimization algorithm for transmission network expansion planning problem. *Arabian Journal for Science and Engineering*, 43, 2899–2908.

Mirjalili, S., Mirjalili, S.M., and Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46–61.

Mohamad, F., Teh, J., and Lai, C.M. (2021). Optimum allocation of battery energy storage systems for power grid enhanced with solar energy. *Energy*, 223, 120105.

Reihani, E., Sepasi, S., Roose, L.R., and Matsuura, M. (2016). Energy management at the distribution grid using a battery energy storage system (bess). *International Journal of Electrical Power & Energy Systems*, 77, 337–344.

Roberts, B. and McDowall, J. (2005). Commercial successes in power storage. *IEEE Power and Energy Magazine*, 3(2), 24–30.

Schneider, K.P., Mather, B., Pal, B., Ten, C.W., Shirek, G.J., Zhu, H., Fuller, J.C., Pereira, J.L.R., Ochoa, L.F., de Araujo, L.R., et al. (2017). Analytic considerations and design basis for the ieee distribution test feeders. *IEEE Transactions on power systems*, 33(3), 3181–3188.

Xu, N., Ding, M., and Chung, C. (2012). Control strategies of bess for compensating renewable energy fluctuations. In *9th IET International Conference on Advances in Power System Control, Operation and Management (APSCOM 2012)*, 1–5. IET.

Yang, Y., Bremner, S., Menictas, C., and Kay, M. (2018). Battery energy storage system size determination in renewable energy systems: A review. *Renewable and Sustainable Energy Reviews*, 91, 109–125.

Zeraati, M., Golshan, M.E.H., and Guerrero, J.M. (2016). Distributed control of battery energy storage systems for voltage regulation in distribution networks with high pv penetration. *IEEE Transactions on Smart Grid*, 9(4), 3582–3593.

Apêndice A. UNIDADE FOTOVOLTAICA

As equações (A.1) e (A.2) mostram a relação entre os parâmetros configuráveis e a potência de saída total do sistema fotovoltaico utilizado no trabalho, $P_{Saida}(t)$.

$$P(t) = Ppmp \cdot E_b \cdot E(t) \cdot FC(Temp(t)) \tag{A.1}$$

$$P_{Saida}(t) = P(t) \cdot n_{inv}(P_{saida}) \tag{A.2}$$

Onde:

- $P(t)$: Potência na saída do módulo fotovoltaico no instante t;
- $Ppmp$: Potência nominal no ponto de máxima potência;
- E_b: Valor base de irradiância em kW/m^2;
- $E(t)$: Valor da irradiância, em por unidade, no instante t;
- $FC(Temp(t))$: Fator de correção do $Ppmp$ em função da temperatura no instante t;
- $n_{inv}(P_{saida})$: Eficiência do inversor para uma dada potência de saída.

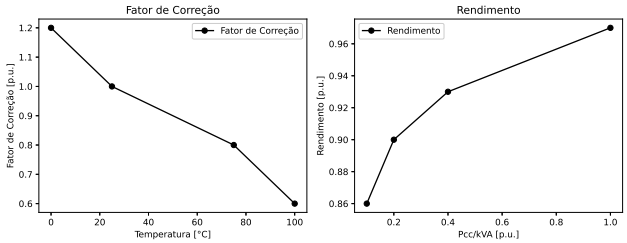

Figura A.1. Fator de correção e rendimento inversor.

Os valores característicos, utilizados neste trabalho, estão apresentados na Tabela A.1.

Tabela A.1. Sistema de geração fotovoltaico.

Ppmp	$S_{inversor}$ (VA)	Fato de potência	E_b
1500	2000	unitário	0,98

Já as tabelas A.2 e A.3 apresentam os valores de incidência solar e temperatura, para cada hora do dia, utilizados neste trabalho. Já a Fig. A.1 apresenta as curvas de eficiência do inversor.

Tabela A.2. Curva de irradiância em por unidade.

0; 0; 0; 0; 0; 0; .1; .2; .3; .5; .8; .9; 1.0; 1.0; .98; .9; .7; .4; .1; 0; 0; 0; 0; 0

Tabela A.3. Curva de temperatura em ^{o}C.

25; 25; 25; 25; 25; 25; 25; 25; 35; 40; 45; 50; 60; 60; 55; 40; 35; 30; 25; 25; 25; 25; 25; 25

Apêndice B. ARMAZENAMENTO DE ENERGIA

Informações adicionais do sistema de armazenamento são apresentadas na Tabela B.1.

Tabela B.1. Sistema de armazenamento.

Capacidade (kWh)	Descarga Máx.(kW)	SoC^0 (kWh)
2000	200	1000

Apêndice C. CURVA DE CARGA

A Fig. C.1 apresenta as curvas de carga utilizadas neste trabalho.

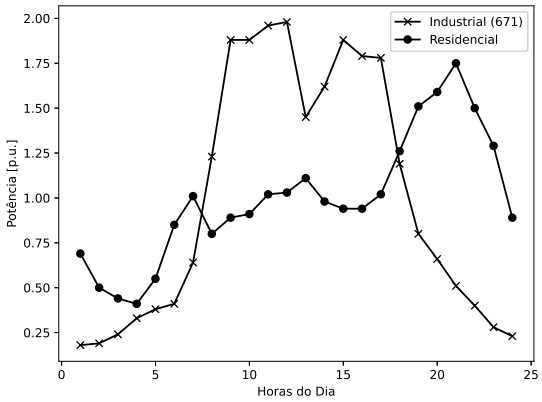

Figura C.1. Curvas de carga.