

Otimização da Curva de Demanda em Redes de Distribuição com Geração Distribuída Fotovoltaica, Utilizando Algoritmo Genético e Armazenadores de Energia

Daniel Bonfim Lima* Jonas Felipe A. Rodrigues Santos**
Daniel Barbosa***

* Universidade Federal da Bahia (UFBA), Mestrando em Engenharia Elétrica, Salvador, Brasil, (e-mail: daniel_blima@hotmail.com)

** Universidade Federal da Bahia (UFBA), Graduando em Engenharia Elétrica, Salvador, Brasil, (e-mail: jonas_philipi@hotmail.com)

*** Universidade Federal da Bahia (UFBA), Professor de Engenharia Elétrica, Salvador, Brasil, (e-mail: dbarbosa@ufba.br)

Abstract: The increase in accessibility to residential energy generation and the consequent growth in the number of consumers causes a negative impact on the electricity grid, especially in a high penetration scenario. One of the most relevant effects of this phenomenon is the occurrence of a reverse power flow and the demand curve sinking. In order to mitigate these effects, this article presents a methodology for optimizing the Demand Curve of a Medium Voltage Distribution Network with the presence of Distributed Photovoltaic Generation Systems using Energy Storage Systems (ESS). This optimization was done through Software OpenDSS and the development of a Genetic Algorithm (GA) in Python capable of defining the ESS Optimal Operation Regime against the main network electrical parameters, based on the demand characteristics required by the electrical system and generation curve.

Resumo: O aumento da acessibilidade à geração residencial de energia e o consequente crescimento no número de prossumidores provoca impactos negativos à rede elétrica, especialmente em um cenário de alta penetração. Um dos efeitos mais relevantes desse fenômeno é a ocorrência de fluxo reverso de potência e o afundamento da curva de demanda. Visando mitigar esses efeitos, o presente artigo apresenta uma metodologia para otimização da Curva de Demanda de uma Rede de Distribuição de Média Tensão com a presença de Sistemas de Geração Distribuída Fotovoltaica (SGDFV) utilizando Sistemas de Armazenamento de Energia (SAE). Essa otimização foi feita através do Software OpenDSS e do desenvolvimento de um Algoritmo Genético (AG) no Python capaz de definir o Regime de Operação ótimo do SAE frente aos principais parâmetros elétricos da rede, baseado nas características da demanda requerida pelo sistema elétrico e curva de geração dos SGDFV.

Keywords: Electric Power Distribution Systems; Energy Storage; Distributed Photovoltaic Generation; Genetic Algorithm; OpenDSS.

Palavras-chaves: Sistemas de Distribuição de Energia; Baterias; Geração Distribuída Fotovoltaica; Algoritmo Genético; OpenDSS.

1. INTRODUÇÃO

O Plano Decenal de Expansão de Energia 2030, estudo anual elaborado pela Empresa de Pesquisa Energética (EPE), considera as perspectivas de crescimento e expansão do setor energético no período entre 2021 e 2030, destacando uma visão ampla e integrada das diversas fontes disponíveis. Esse estudo tem caráter informativo e orientativo que serve de balizador para análises e projeções da expansão do Sistema Elétrico, abarcando as dimensões técnicas, econômicas e estratégicas (EPE, 2021).

Mesmo considerando as possíveis mudanças regulatórias que alterariam o Sistema de Compensação de Energia Elétrica (SCEE) e instituiriam a aplicação de Tarifa Binômica

(ANEEL, 2012, 2015) na Geração Distribuída (GD), que em tese permitirá a redução da atratividade deste modelo de Geração, ela ainda apresenta projeções de crescimentos exponenciais da sua capacidade instalada entre 300% e 750% até 2030 (EPE, 2021), sendo a Energia Fotovoltaica a grande protagonista.

Por outro lado, o aumento da penetração da GD Fotovoltaica, em particular, carrega consigo impactos relevantes nos parâmetros das redes elétricas, tais como Fluxo de Potência, Perdas Técnicas, Fator de Potência e Níveis de Tensão (Kazmi et al., 2017). Na maioria dessas redes, devido às características da curva de geração dos Sistemas de Geração Distribuída Fotovoltaica (SGDFV), existe um descolamento temporal entre a energia ofertada e a neces-

sária, principalmente no horário de ponta. Tal fato pode ocasionar uma variação muito grande entre as demandas máxima e mínima requeridas pelo sistema elétrico, impactando na configuração e na operação dos componentes das redes (HassanzadehFard and Jalilian, 2018).

Diversos trabalhos avaliaram e propuseram metodologias de mitigação dos impactos gerados pela alta penetração de GD, principalmente no que tange a Controle de Tensão e Potência Reativa, através da combinação de GD com Banco de Capacitores, Reguladores de Tensão e Sistemas de Armazenamento de Energia (SAE) (Sedghi et al., 2015; Meirinhos et al., 2017). As técnicas de Otimização por Enxame de Partículas (Zad et al., 2015), *Algorithm of the Innovative Gunner* (Kacejko and Pijarski, 2021) e Algoritmo Genético (AG) (Babacan et al., 2017), são exemplos de modelos utilizados na definição dos regimes de operação das rede elétricas e seus respectivos equipamentos.

Nesse contexto de minimizar os impactos provocados pelas SGDFVs e considerando que os SAEs possuem a capacidade de absorver e de injetar potência na rede elétrica de maneira controlada, pode-se gerenciar a energia injetada pela GD. Devido a essa habilidade, os SAEs são uma solução promissora para o problema de sobregeração de GD Solar, de modo que diversos estudos buscam explorar o emprego dessas tecnologias. Howlader et al. (2017) utilizam as técnicas de Armazenamento por Bombeamento Hidráulico (*Pumped Storage Hydro*) e Usina Solar Centralizada (*Concentrated Solar Power*) como métodos de armazenamento de energia para diminuir o uso de unidades térmicas e nivelar a curva de demanda, reduzindo gastos e emissões de CO₂. Por fim, Julianto et al. (2020) propõem a utilização de Sistemas de Armazenamento por Ar Comprimido para equilibrar das cargas e com isso resolve de forma satisfatória o problema do afundamento da curva de demanda.

Apesar das tecnologias de armazenamento citadas alcançarem resultados relevantes, a bateria eletroquímica é uma das técnicas mais estudada, graças às vantagens, como: o tempo de resposta muito rápido, a controlabilidade, a modularidade e a escalabilidade (Yang et al., 2018). A localização, a capacidade de armazenamento de energia, a potência nominal e o regime de operação (ciclo de carga e descarga) são os parâmetros fundamentais a serem otimizados para alcançar o aproveitamento máximo dos benefícios oferecidos pela bateria, havendo diversos estudos que buscam alcançar essa maximização por diferentes métodos (Jannesar et al., 2018). Wong et al. (2020) implementam o Algoritmo de Otimização da Baleia (*Whale Optimization Algorithm*) para alcançar o posicionamento e tamanho ótimo das baterias buscando redução das perdas técnicas. Com um objetivo semelhante, Zheng et al. (2013) buscam minimizar perdas com otimização das variáveis localização e tamanho da bateria, porém utilizando a Otimização por Enxame de Partículas *Fuzzy* (*Fuzzy Particle Swarm Optimization*). Finalmente, Babacan et al. (2017) utilizam a técnica de AG para encontrar a melhor alocação da bateria a fim de diminuir respectivamente a flutuação de tensão e as perdas elétricas em redes com alta penetração de GD Solar.

Portanto, o presente trabalho se propõe a apresentar metodologia focada na otimização da curva de demanda em re-

des com alta penetração de GD Solar, utilizando SAE com regime de operação controlado através de AG, que atua na redução de perdas elétricas, melhoria de indicadores operacionais e pode ser utilizada como suporte no planejamento do sistema elétrico. Além disso, foi utilizado um banco de baterias centralizado para reduzir os impactos negativos da GD Solar, tendo em vista as vantagens dessa tecnologia frente à outras alternativas de armazenamento de energia. Para isso foi realizada a otimização da potência nominal e da curva de despacho da bateria através de Algoritmo Genético e em seguida foi determinada a capacidade de armazenamento a partir da energia utilizada para a operação.

2. ALGORITMO GENÉTICO

Na natureza, as populações de uma espécie são formadas por indivíduos que possuem características únicas, os genes. Conforme o tempo passa, a seleção natural atua e uma nova população é produzida a partir do cruzamento dos indivíduos mais aptos e assim as melhores combinações de genes são automaticamente escolhidas. Fazendo um paralelo com a teoria evolutiva, no AG, a População é formada por n indivíduos, sendo cada um desses uma solução candidata para o problema, e dentro do indivíduo estão os genes, que nada mais são do que as variáveis a serem otimizadas.

A entrada inicial do algoritmo é dada por uma População de n indivíduos gerada aleatoriamente, onde cada uma dessas soluções tem sua aptidão avaliada pela Função Custo. Em seguida, uma fração dos melhores Indivíduos é selecionada para compor a População da próxima geração. O restante dos Indivíduos passa por operações genéticas (Cruzamentos e Mutações entre si), produzindo novas soluções para integrar a nova População formada. A População é novamente avaliada e o *loop* se repete até o critério de parada ser atendido. Esse processo é resumido na figura 1.

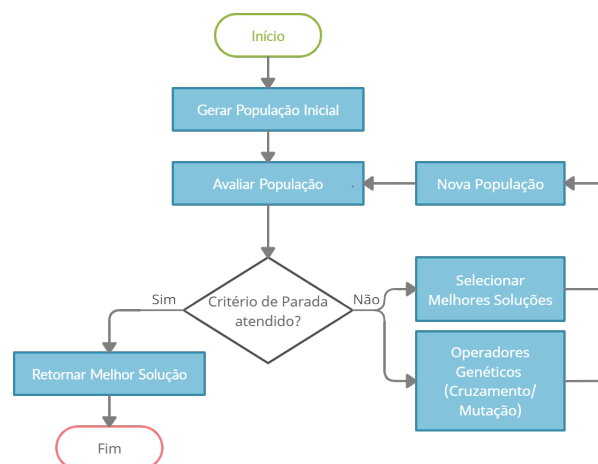


Figura 1. Resumo do processo de otimização do AG.

Desta forma, os AGs se mostram soluções eficientes para problemas complexos de otimização que envolvem uma expressiva quantidade de variáveis, através da maximização ou minimização de uma Função Custo (Gomes et al., 2015).

3. METODOLOGIA PROPOSTA

Para estudo da metodologia de gerenciamento de demanda em sistemas elétricos de Média Tensão (MT), foram realizadas simulações na rede IEEE 123 barras modificada com diferentes configurações de GD Fotovoltaica e banco de baterias, onde o regime de operação destas foi definido através do *script* desenvolvido (IEEE, 2014).

A fim de determinar os melhores parâmetros do SAE, para gerenciamento da curva de demanda, foi desenvolvido um *script* na linguagem de programação Python que aplica a otimização do AG e realiza as simulações das soluções candidatas através do OpenDSS, que atua como motor de cálculo. Para isso foi empregado a interface *py-dss*, que possibilita o acesso ao OpenDSS diretamente via Python, juntamente com algumas bibliotecas para o cálculo da Função Custo, tais como: *numpy*, *statistics* e *csv*.

A Figura 2 resume o funcionamento do código e a integração entre o AG e o OpenDSS. Para conseguir avaliar a aptidão de um Indivíduo usando a Função Custo, é preciso simular no OpenDSS a sua solução. O OpenDSS então retorna a Curva de Demanda na fonte, o carregamento do SAE, as perdas técnicas e os níveis de tensão nas barras das cargas, que são as informações necessárias para calcular a Função Custo.

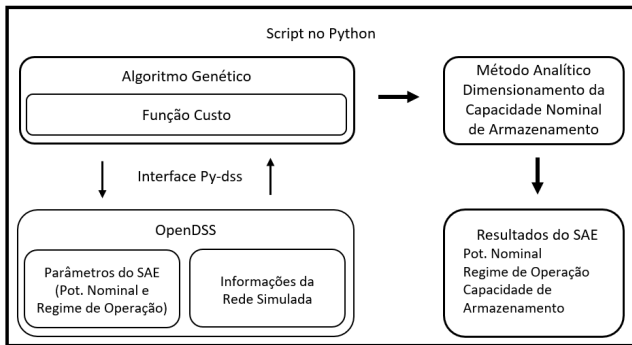


Figura 2. Resumo funcional do *script* desenvolvido.

3.1 Caracterização do Algoritmo Genético Desenvolvido

Para a resolução do problema proposto, foi utilizado um AG com representação inteira dos genes. Além disso, foi empregado o Cruzamento Binário com um único ponto e a seleção dos indivíduos por Classificação.

De forma geral, o AG desenvolvido tem como principal objetivo a definição da potência nominal e a curva de operação do SAE para minimizar a Função Custo (1).

A elaboração da Função Custo, definida por (1), foi feita com o objetivo de reduzir as variações de demanda sem, contudo, aumentar as perdas técnicas nem prejudicar os níveis de tensão da rede. Também foi levado em consideração que as baterias não admitem grandes variações em seu regime de operação e, portanto, a curva de despacho não poderia conter inclinações abruptas. Além disso, para que o regime de carga e de descarga do SAE seja sustentável por um longo tempo, levou-se em conta que o nível de carregamento da bateria ao fim do dia deveria se aproximar ao máximo do carregamento no início da simulação.

$$FC = \sigma(Pot) + \Delta Pe + \Delta V + \Delta L + \Delta Carr \quad (1)$$

na qual, $\sigma(Pot)$, é o desvio padrão da curva de demanda; ΔPe é a variação das perdas elétricas; ΔV , é a penalidade por violação de tensão; ΔL , é a penalidade para grandes variações no regime de operação do SAE; e, $\Delta Carr$, é a penalidade para carregamento do SAE na última hora do dia.

A capacidade nominal de armazenamento da bateria também é um parâmetro fundamental para o dimensionamento desse equipamento, contudo sua tentativa de otimização apresentou dificuldade de convergência, e por isso, ela foi definida analiticamente ao final das simulações do AG, conforme a Figura 2. Durante todo o processo de otimização pelo AG, a capacidade nominal de armazenamento foi definida em um valor constante suficientemente grande a fim de não agir como limitante na otimização, no que tange ao *State of Charge* (SOC). Essa parâmetro é então reavaliado analiticamente ao final do AG, segundo (3).

O critério de parada, para determinar a convergência do AG, foi a manutenção (sem observação de melhora) da aptidão da solução durante k gerações, sendo este definido como 20% do tamanho da população.

3.2 Características da Rede IEEE 123 Barras

O Sistema Elétrico base utilizado para realização das simulações foi o alimentador teste IEEE 123 barras, conforme visto na Figura 3, onde o ponto vermelho representa o barramento de conexão do SAE em todos os cenários estudados (barra 60).




Figura 3. Diagrama unifilar modificado do sistema IEEE 123 barras (IEEE, 2014).

O referido sistema opera com tensão nominal de 4,16 kV e possui cargas desequilibradas, reguladores de tensão e bancos de capacitores para correções de desvios nos níveis de tensão, cujos dados técnicos podem ser encontrados em IEEE (2014). No entanto, vale destacar que a Demanda Máxima é de 3.608,54 kW, obtida às 17 horas, e as Perdas Elétricas Totais são 2,32%.

3.3 Definição dos Cenários de Conexão dos SGDFV

Os cenários de geração distribuída do sistema foram definidos pela porcentagem de Prossumidores, ou seja, consumidores produtores de energia. Assim foram criados 5

cenários de simulação de GD Fotovoltaica conectada ao sistema, considerando 10%, 20%, 30%, 40% e 60% de Prossumidores.

A escolha de quais cargas se tornariam Prossumidores foi feita através da Seleção por Roleta. Essa técnica realiza o sorteio dos consumidores, porém considerando que cada um deles possui probabilidade de seleção proporcional ao seu consumo de energia. A Seleção por Roleta foi escolhida pois é um método que confere aleatoriedade sem negligenciar o fato que clientes com maior energia consumida possuem maiores chances de se tornarem Prossumidores, devido à indicação de maior poder aquisitivo e uma viabilidade técnico-econômica mais atrativa para o projeto de instalação do SGDFV.

Para definir a potência nominal máxima (P_{mpp}) dos painéis solares de cada Prossumidor, foi utilizado o método comercial de dimensionamento, que considera o consumo diário e a capacidade de geração no local, conforme (2). A energia consumida foi determinada pela integral da curva de carga (kW) específica de cliente, enquanto a capacidade de geração é dada pela área da curva de irradiação solar (p.u.).

$$P_{mpp} = \frac{E_C}{E_{PV}} \quad (2)$$

sendo: E_C , a energia consumida pelo cliente [kWh]; e, E_{PV} , a capacidade de geração solar [p.u. · h].

A Figura 4 indica a irradiação solar (p.u.) (Radatz, 2020), comum a todos os Prossumidores, bem como a curva de carga de consumo típica utilizada no estudo (IEEE, 2014).




Figura 4. Curva de irradiação solar e perfil de consumo.

3.4 Banco de Baterias

O objetivo do *script* desenvolvido é definir os melhores parâmetros para o funcionamento do banco de baterias, otimizando a curva de operação e a potência nominal e determinando analiticamente a capacidade nominal de armazenamento, após a otimização da curva de despacho e da potência nominal e convergência do AG, conforme Figura 2. A localização do banco de baterias também é um fator relevante no ajuste do sistema, no entanto sua otimização não foi objeto de estudo desse trabalho. Porém, conforme Wong et al. (2020), a redução das perdas elétricas é otimizada com a conexão da bateria próxima às cargas de maior potência. Desse modo, para a realização

das simulações, o SAE foi fixado no barramento 60 do alimentador IEEE 123 barras.

O dimensionamento analítico da capacidade nominal de armazenamento do SAE considera a variação da energia acumulada na bateria ao longo do dia, mantendo uma reserva de 30%. A capacidade de armazenamento foi definida conforme (3).

$$CapArm = \frac{SOC_{max} - SOC_{min}}{0,7} \quad (3)$$

na qual: $CapArm$ é a capacidade nominal de armazenamento estimada do SAE; SOC_{max} é a energia máxima medida no SAE ao longo do dia (kWh); e, SOC_{min} é a energia mínima medida no SAE ao longo do dia (kWh).

4. RESULTADOS

Nesta seção serão apresentados resultados que irão possibilitar a análise da eficiência do AG, bem como a análise do regime de operação do SAE e respectivos impactos na rede, frente aos diversos cenários simulados.

4.1 Análise da Eficiência do Algoritmo Genético

Serão apresentados indicadores que possibilitaram a aferição da eficiência do Algoritmo desenvolvido, através da análise dos resultados obtidos com a variação de alguns parâmetros do AG, bem como a alteração dos índices de penetração de Geração Fotovoltaica no sistema estudado.

Foram feitas 15 simulações para cada um dos 6 cenários definidos, através da variação dos parâmetros Elitismo, População e Probabilidade de Mutação, considerando um percentual fixo de Prossumidores de 20%, conforme a Tabela 1.

Estes cenários possibilitaram analisar a variação dos indicadores: valor da Função Custo (mínimo, média, máximo e desvio padrão), tempo de simulação (média) e número de simulações (média), de modo a permitir a determinação da melhor configuração dos parâmetros do AG para a resolução específica do problema estudado.

Como pode ser visto na Tabela 1, é notório que a variação dos parâmetros de configuração do AG interfere diretamente no valor da Função Custo e no esforço computacional necessário para convergência do *script*, medido através do tempo de cada otimização do AG e do número de simulações realizadas no OpenDSS, sendo este último o produto da População pelo número de gerações.

Considerando os resultados indicados, observa-se que o Caso 4 apresenta o menor valor mínimo e baixo valor médio para a Função Custo, ao mesmo tempo em que dispõe do melhor valor de eficiência de processamento. Desta forma, este caso foi o escolhido para realização das análises posteriores, sendo o AG configurado com Elitismo de 20%, Tamanho da População de 80 indivíduos e uma Probabilidade de Mutação de 24%.

4.2 Análise do Regime de Operação do SAE

Considerando a configuração indicada no item 4.1, Caso 4, serão apresentados resultados referentes ao Regime de

Tabela 1. Análise da eficiência do AG.

Caso	Parâmetros do AG			Resultados					
	Elitismo	População	Prob. de mutação	Custo		Tempo de Simulação Média	Número de simulações		
				Min	Máx		Média	Desv. Padrão	Média
1	10%	80	18%	29,68	37,81	33,04	2,34	1,40	14.901,33
2	10%	120	18%	30,02	37,23	33,12	1,86	2,12	20.600,00
3	20%	80	16%	29,11	49,81	34,75	4,77	1,63	16.154,67
4	20%	80	24%	28,97	36,97	32,66	2,14	1,41	14.226,66
5	20%	80	32%	30,27	36,16	32,43	1,41	1,65	16.206,67
6	40%	50	18%	33,14	37,80	35,29	1,60	1,75	40.581,33
7	40%	120	12%	31,20	52,39	36,51	6,20	3,02	30.720,00

Operação do SAE otimizado pelo AG. Seguindo o modelo do tópico anterior, foram considerados 5 cenários com a variação do percentual de Prossumidores, conforme tabela 2.

Estes cenários possibilitaram analisar a variação da Potência Nominal (kW) e Capacidade de Armazenamento (kWh) do SAE, bem como o valor da Função Custo do AG, cujo objetivo foi identificar o melhor dimensionamento do SAE, frente ao aumento do número de prossumidores conectados à rede.

Como pode ser visto na Tabela 2, em geral, o aumento do número de SGDFV e o conseqüente aumento do nível de penetração fotovoltaica, produzem um crescimento na potência nominal e capacidade de armazenamento ótima, bem como o aumento do valor da Função Custo. Por outro lado, a Tabela 3 mostra que as perdas técnicas totais sofrem uma redução, devido ao incremento da penetração fotovoltaica, haja vista que a bateria dimensionada ampliou a capacidade de hospedagem do sistema.

Tabela 2. Resultados da otimização do SAE.

Caso	Cenário GD-PV		Armazenador			Função Custo
	Pross. (%)	Pot. Inst. (kWp)	Pot. Nom. (kW)	Cap. de Arm. (kWh)	Perdas Totais (kWh)	
1	10	1508,5	800	5561,7	1466,2	30,98
2	20	2002,3	900	6726,1	1976,8	29,11
3	30	3190,4	1600	10379,9	2803,9	32,65
4	40	4298,4	2400	16198,7	4440,5	36,89
5	60	6354,1	3300	26856,6	6947,8	50,73

As curvas de despacho do SAE indicadas na Figura 5, descrevem os Regimes de Operação otimizados para cada caso simulado. É importante ressaltar que valores positivos indicam o descarregamento do SAE, representando fornecimento de potência para a rede, ao passo que valores negativos retratam o carregamento do SAE, ou sejam absorção de potência da rede. Desta forma, o SAE realiza o controle de Demanda do sistema IEEE 123 barras, através da compensação entre a potência requerida pelo

Tabela 3. Análise de indicadores elétricos.

Caso	Cenário GD-PV Prossumidores (%)	Desvio Padrão da Demanda do Sistema	Perdas (%)
1	10	27,67	1,96
2	20	27,31	1,64
3	30	30,11	1,45
4	40	37,48	1,38
5	60	57,98	1,06

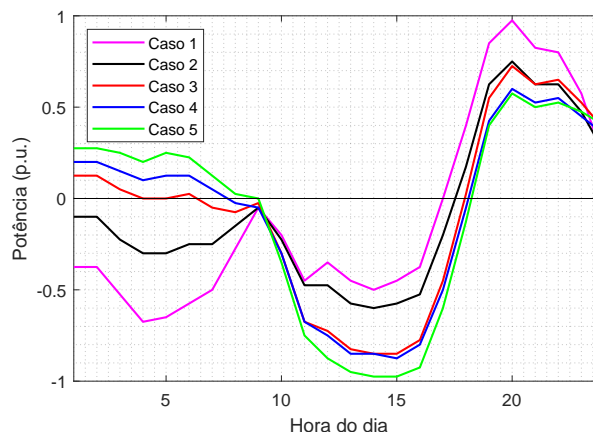


Figura 5. Curva de despacho do SAE.

sistema e energia fornecida pelos SGDFV. Observa-se que aproximadamente a partir das 9 horas as curvas de despacho apresentam comportamento semelhante para todos os casos considerados, carregando o SAE quando há excesso de geração e descarregando durante o período em que a GD reduz sua produção e não é suficiente para alimentação das cargas.

A partir das otimizações realizadas e dos parâmetros do SAE obtidos no tópico 4.2, pode-se alcançar melhorias no sistema IEEE 123 barras, tais como suavização da curva de demanda e redução das perdas elétricas, conforme a Tabela 3.

A Figura 6 evidencia que a GD Fotovoltaica sem a presença de SAE produz um afundamento da Demanda no intervalo de geração solar e esse fato é mais acentuado pelo aumento do percentual de SDGFV. Nos casos com 40% e 60% de Prossumidores, conforme a queda da irradiação, é verificado um crescimento abrupto da potência requerida, ocasionando o fenômeno da “Curva de Pato” (Wong et al., 2020). Nos casos mencionados há ainda a ocorrência de fluxo reverso de potência com energia sendo exportada pela rede.

Por outro lado, em todos os cenários com a presença de SAE, o fenômeno da “Curva de Pato” foi mitigado, observando-se variações discretas entre a potência mínima e máxima requerida pelo sistema. No entanto, é importante ressaltar que para valores elevados de penetração, é requerida baterias com Potência Nominal e Capacidade de Armazenamento elevadas considerando a demanda na rede.

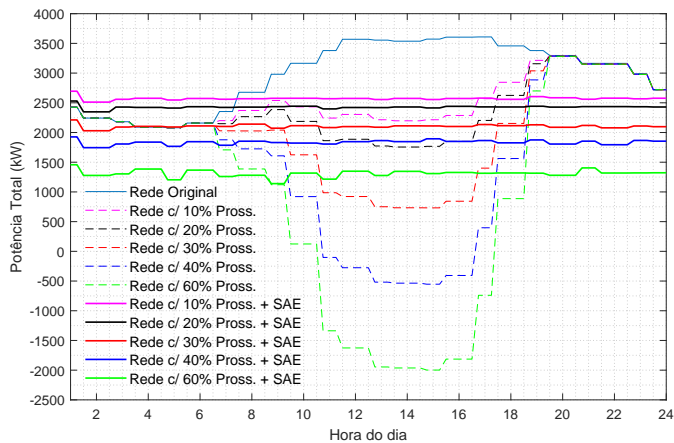


Figura 6. Otimização das curvas de demanda.

A otimização foi determinada pelo desvio padrão entre os valores de Potência despachada pela fonte ao longo das 24 horas do dia, tornado a curva de demanda significativamente mais *Flat*, em todos dos cenários simulados.

5. CONCLUSÃO

Analisando os resultados obtidos nas simulações realizadas, pode-se afirmar que a metodologia desenvolvida utilizando AG para a otimização da Curva de Demanda de redes elétricas com a presença de SGDFV e SAE *On-Grid*, se mostrou bastante eficaz e viável do ponto de vista de esforço computacional.

Além disso, a combinação de SGDFV e SAE centralizado se mostrou uma solução bastante adequada do ponto de vista elétrico, bem como pela óptica operacional, visto que o SAE conseguiu complementar o fornecimento de energia, também nos momentos em que não há irradiação solar disponível para geração fotovoltaica. Apesar disso, é importante ressaltar que, no caso estudado de bateria centralizada, a operação desse equipamento é feita pela concessionária de energia, que também é responsável por arcar com os custos envolvidos.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado da Bahia (FAPESB) pelo financiamento por meio do programa PIBIC / UFBA - FAPESB, bem como ao suporte do Grupo de Sistemas Elétricos de Potência Integrado (G-SEPI) da Escola Politécnica da UFBA.

REFERÊNCIAS

ANEEL (2012). Resolução normativa nº 482.
 ANEEL (2015). Resolução normativa nº 687.
 Babacan, O., Torre, W., and Kleissl, J. (2017). Siting and sizing of distributed energy storage to mitigate voltage impact by solar pv in distribution systems. *Solar Energy*, 146, 199–208.
 EPE (2021). Plano decenal de expansão de energia 2030.
 Gomes, F.M., Pereira, F.M., Silva, M.B., and Marins, F.A.S. (2015). Aplicação da meta-heurística algoritmo genético na otimização de problemas com múltiplas respostas. *Encontro Nacional de Engenharia de Produção ENEGEP*.

HassanzadehFard, H. and Jalilian, A. (2018). Optimal sizing and location of renewable energy based dg units in distribution systems considering load growth. *International Journal of Electrical Power & Energy Systems*, 101, 356–370.
 Howlader, H.O.R., Furukakoi, M., Matayoshi, H., and Senjyu, T. (2017). Duck curve problem solving strategies with thermal unit commitment by introducing pumped storage hydroelectricity renewable energy. In *2017 IEEE 12th International Conference on Power Electronics and Drive Systems (PEDS)*, 502–506. doi:10.1109/PEDS.2017.8289132.
 IEEE (2014). IEEE 123 node test feeder. <http://site.ieee.org/pes-testfeeders/files/2017/08/feeder123.zip>. Acessado: 06-04-2021.
 Jannesar, M.R., Sedighi, A., Savaghebi, M., and Guerrero, J.M. (2018). Optimal placement, sizing, and daily charge/discharge of battery energy storage in low voltage distribution network with high photovoltaic penetration. *Applied energy*, 226, 957–966.
 Julianto, P., Soeprijanto, A., and Mardijah (2020). Dynamic economic load dispatch by introducing compressed air energy storage for solving duck curve. In *2020 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, 129–134. doi:10.1109/ISITIA49792.2020.9163698.
 Kacejko, P. and Pijarski, P. (2021). Optimal voltage control in mv network with distributed generation. *Energies*, 14(2), 469.
 Kazmi, S.A.A., Shahzad, M.K., and Shin, D.R. (2017). Multi-objective planning techniques in distribution networks: A composite review. *Energies*, 10.
 Meirinhos, J.L., Rua, D.E., Carvalho, L.M., and Madureira, A.G. (2017). Multi-temporal optimal power flow for voltage control in mv networks using distributed energy resources. *Electric Power Systems Research*, 146, 25–32.
 Radatz, P.e.a. (2020). *OpenDSS PVSsystem and InvControl Element Models*. EPRI.
 Sedghi, M., Ahmadian, A., and Aliakbar-Golkar, M. (2015). Optimal storage planning in active distribution network considering uncertainty of wind power distributed generation. *IEEE Transactions on Power Systems*, 31(1), 304–316.
 Wong, L.A., Ramachandaramurthy, V.K., Walker, S.L., and Ekanayake, J.B. (2020). Optimal placement and sizing of battery energy storage system considering the duck curve phenomenon. *IEEE Access*, 8, 197236–197248.
 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.
 Zad, B.B., Hasanvand, H., Lobry, J., and Vallée, F. (2015). Optimal reactive power control of dgs for voltage regulation of mv distribution systems using sensitivity analysis method and pso algorithm. *International Journal of Electrical Power & Energy Systems*, 68, 52–60.
 Zheng, Y., Dong, Z.Y., Luo, F.J., Meng, K., Qiu, J., and Wong, K.P. (2013). Optimal allocation of energy storage system for risk mitigation of discos with high renewable penetrations. *IEEE Transactions on Power Systems*, 29(1), 212–220.