

GERENCIAMENTO PELO LADO DA DEMANDA UTILIZANDO ALGORITMOS GENÉTICOS EM SISTEMAS INDUSTRIAIS

VICTOR H. N. CORTEZ*, DÉBORA R. R. P. ARAUJO*, LEANDRO R. DE ARAUJO*

**Laboratório de Sistemas de Potência, Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora, Campus Universitário, Plataforma 5, Galpão 3 – São Pedro – Juiz de Fora – MG – Brasil - CEP: 36036-900*

E-mails: victor.cortez@engenharia.ufjf.br, debora.rosana@ufjf.edu.br,
leandro.araujo@ufjf.edu.br

Abstract — Big industries and industrial parks are one of the biggest energy consumers in a country and therefore it is of the electrical system's interest to encourage that the energy consumed by those industries is made efficiently. One of the ways to achieve this goal is to use a demand side management technique where loads can be shifted according to pre-determined objectives such as reducing the costs with electrical energy. In this paper a methodology for load shifting is presented for use in industrial systems utilizing a genetic algorithm.

Keywords — Demand Side Management, Industrial Systems, Load Shifting, Genetic Algorithms, Direct Load Control.

Resumo — Grandes indústrias e parques industriais estão entre os maiores consumidores de energia de um país e sendo assim é interessante do ponto de vista do sistema elétrico fazer com que a energia utilizada por estes consumidores seja consumida de forma eficiente. Uma das maneiras de se atingir este objetivo é através do Gerenciamento pelo Lado da Demanda onde se pode remanejar cargas de acordo com um objetivo pré-estabelecido, como por exemplo, a diminuição de custos com energia elétrica. Neste trabalho é apresentada uma metodologia para realocação de cargas em sistemas industriais com o auxílio de um algoritmo genético.

Palavras-chave — Gerenciamento pelo Lado da Demanda, Sistemas Industriais, Realocação de carga, Algoritmo Genético, Controle direto de carga.

1 Introdução

Os *smart grids* procuram ser uma evolução dos sistemas de potência integrando, por exemplo, tecnologias de detecção avançadas, métodos de controle e tecnologias de comunicação tanto na transmissão quanto na distribuição a fim de suprir energia elétrica de uma maneira mais inteligente e eficiente. Dentro desta questão, o gerenciamento pelo lado da demanda (GLD) (Rahman, 1993) é uma parte importante para o futuro dos *smart grids*.

O Gerenciamento pelo Lado da Demanda (GLD ou DSM, do inglês Demand Side Management) é o planejamento e a implementação de técnicas, que envolvem ações das concessionárias destinadas a influenciar os consumidores de forma a produzir alterações desejadas na curva de carga. Estas atividades englobam: gerenciamento de carga, conservação estratégica, eletrificação, geração de energia pelo lado do consumidor, substituição de equipamentos obsoletos por mais eficientes e estratégias para o crescimento da participação no mercado (Gellings, 1985).

Assim, o GLD se mostra importante para os sistemas mais inteligentes, já que fornece suporte para diversas áreas como o controle e gerenciamento do mercado de energia, planejamento da expansão e construção de infraestrutura, e gerenciamento de recursos energéticos descentralizados como energias renováveis e veículos elétricos.

O controle da demanda de energia pode reduzir o pico geral de demanda de carga, remodelar o perfil de demanda e aumentar a sustentabilidade de uma rede

reduzindo o custo total e as emissões de carbono de uma determinada área. O uso de estratégias eficientes de GLD pode potencialmente evitar a construção de uma infraestrutura de geração e/ou transmissão e/ou distribuição que poderia ficar subutilizada.

Deseja-se então com o GLD aumentar a eficiência geral do sistema, além da segurança e estabilidade maximizando a utilização da capacidade da infraestrutura existente e facilitando inclusive a integração de energias renováveis, devido ao maior controle.

Para auxiliar os engenheiros no desenvolvimento de sistemas que consideram o GLD e na posterior operação destes sistemas é interessante a utilização de programas computacionais, com metodologias adequadas para a implementação do GLD. Na literatura podem ser verificados trabalhos nesta linha, como por exemplo, (Logenthiran et al., 2012) e (Kinhekar et al., 2014).

Devido a importância do tema, neste trabalho o objetivo principal foi aplicar alguns métodos de GLD em um parque industrial composto por diferentes tipos de indústrias a fim de diminuir o custo geral com energia através de técnicas específicas e, se possível diminuir o pico de demanda do sistema aumentando assim a eficiência da rede. Mais especificamente pretende-se otimizar horários de funcionamento de diversos dispositivos e equipamentos em um parque industrial, com objetivo de diminuir os gastos com energia e o pico da demanda.

De maneira geral, dentro do GLD, no desenvolvimento de metodologias para melhorias nas curvas de carga, geralmente são utilizados a

programação linear e a programação dinâmica (Antunes et al., 2004, Martins et al., 1996) pela facilidade de uso e consistência dos resultados. Porém no caso específico do estudo proposto neste artigo, a dimensão do problema é muito grande e com muitas complexidades o que torna inviável o uso destes métodos.

Assim, a partir de algumas análises e estudos definiu-se que uma boa solução para resolver este problema seria o uso de um método heurístico, já que este tipo de solução se mostrou comprovadamente mais eficiente em problemas similares (Haupt and Haupt, 2004).

Em (Logenthiran et al., 2012), encontrou-se uma abordagem que foi utilizada com sucesso para resolver o problema tratado neste trabalho, logo esta referência é a base para estudo e aprimoramento neste trabalho.

Resumindo, neste trabalho foi desenvolvido um método baseado em algoritmos genéticos onde cargas que são passíveis de realocação (decididas de comum acordo entre a concessionária e os consumidores), são conectadas ou desconectadas em diferentes horas do dia a fim de encontrar uma utilização ótima que traga benefícios econômicos tanto para a concessionária quanto para os próprios consumidores. Verificou-se que esta estratégia apresentou bons resultados para auxiliar os engenheiros na tarefa de melhorar a eficiência energética de um sistema industrial utilizando GLD e com isso diminuir custos e o pico de demanda, e alguns resultados serão apresentados neste artigo.

2 Definições e Técnicas de GLD

Nesta seção serão apresentados alguns conceitos de GLD e técnicas comumente utilizadas, não só em sistemas industriais, mas em qualquer tipo de rede.

2.1. Tipos de programas de GLD

Os programas de GLD podem ser divididos em duas categorias; o GLD direto e o indireto (Garcia, 2002).

O GLD indireto é um programa que não permite o controle direto da carga. Nele o próprio consumidor remaneja sua demanda em resposta, por exemplo, a sinais de preço gerados pela concessionária. Esses programas provocam alterações na curva de carga mediante mudanças induzidas nos hábitos de consumo de energia elétrica (CAMARGO, 1996), como exemplo, as tarifas variáveis no tempo, incentivando os clientes a consumirem em horários fora de ponta; programas de educação do consumidor, procurando ensinar o cliente como conservar a energia; programas envolvendo publicidade e marketing para estimular os consumidores a conservar a energia e programas governamentais dando descontos em aparelhos modernos, mais eficientes (de menor consumo).

O controle de carga direto, DLC (do inglês, Direct Load Control), permite que a concessionária controle remotamente o funcionamento de determinados

aparelhos, determinando as cargas a serem desconectadas ou reduzidas, conforme condições especificadas em um contrato de interrupção com o consumidor, podendo ligar/desligar aparelhos específicos, fora e durante os períodos de pico de demanda e eventos críticos. O DLC é baseado em um acordo facultativo entre a concessionária e o cliente, onde este que participa do programa recebe uma compensação na conta de energia elétrica, ou seja, a conta de energia é reduzida (Strbac, 2008).

No Brasil ainda não há programas de controle direto de carga, e ainda são poucos significativos os esforços para sua implantação. Já nos Estados Unidos, a implantação de DLC, em 2012, foi a estratégia com maior impacto na redução de picos de demanda de consumo, reafirmando sua eficácia.

2.3. Estratégias para moldar a curva de carga

Algumas das principais estratégias para moldar a curva de carga utilizadas neste trabalho estão mostradas na Figura 1 abaixo e descritas nas seções a seguir: deslocamento de carga, preenchimento de vales e redução do pico (Gellings, 1985).




Figura 1: Estratégias de GLD, adaptado de (Bellarmine and Turner, 1994)

2.3.1 Deslocamento da carga

Esta técnica de gerenciamento de carga incentiva os consumidores a deslocarem o consumo de energia elétrica do horário de pico para o horário fora do pico. É feito por meio de incentivos financeiros, impondo tarifas elevadas no horário de pico, com tarifas mais baixas nos momentos de menor carregamento do sistema, impulsionando assim a transferência de carga para esses horários.

2.3.2 Preenchimento de vales

Este método incentiva o cliente a consumir mais energia elétrica durante períodos em que a concessionária gera energia a custos mais baixos. Sua consequência pode ser a redução dos custos de serviço por distribuir os custos fixos de capacidade sobre uma base maior de venda de energia e também por diminuir custos médios de combustível.

2.3.3 Rebaixamento de pico

Uma das formas mais clássicas de gerenciamento de carga. Ele é definido como a redução da carga de ponta, conseguido geralmente através do controle direto de carga (desligamento de aparelhos através das concessionárias) e pela tarifação horária. Este método pode reduzir os custos da concessionária, visto que a necessidade de operar suas unidades de geração mais caras é reduzida e também por postergar investimentos na expansão da capacidade de geração, transmissão e distribuição.

3 Algoritmo Proposto

3.1. Considerações iniciais

Após analisar a teoria do GLD, em termos de desenvolvimento o problema proposto neste trabalho pode ser resumido em uma otimização dos horários de funcionamento de diversos dispositivos e equipamentos em um parque industrial, com objetivo de diminuir os gastos com energia e o pico da demanda.

Este problema não é de simples modelagem, pois deve ser considerada a necessidade de modelagem e de processamento de um grande número de dispositivos de diferentes tipos a fim de representar melhor a diversidade de cargas, de forma a obter melhores resultados. As cargas são de diversos tipos, e cada tipo de carga controlável tem uma característica de consumo específica, podendo ser necessário mantê-la ligada por diversas horas, sem possibilidade de desligamento.

Para solucionar este problema foi desenvolvida uma metodologia que tem como ponto de partida a curva de carga total da rede estudada, que compreende a alimentação de diversas indústrias (um parque industrial). Além disso, cada indústria, em parceria com a concessionária disponibiliza os dados de alguns equipamentos que podem ser realocados e suas características de funcionamento. Para simplificar a análise neste trabalho os equipamentos escolhidos tiveram as mesmas características em todas as indústrias. A relação de equipamentos utilizada pode ser observada na Tabela 1.

Tipo de Dispositivo	Consumo (kW)	Horas de uso	Quantidade de dispositivos
Aquecedor de água	12.5	4	39
Máquina de Solda	25	5	35
Ar condicionado	30	5	16
Forno a arco	50	6	8
Motor de indução	100	6	5
Motor de CC	150	3	6
Total			109

Tabela 1: Dispositivos e características de consumo (Logenthiran et al., 2012)

O algoritmo genético tem diversas vantagens em relação a algoritmos matemáticos tradicionais, fazendo com que o algoritmo proposto por este trabalho para resolver o problema de alocação horária de dispositivos em um parque industrial seja um algoritmo evolucionário heurístico, que não só se adapta facilmente ao problema como fornece uma solução eficiente e custo-efetiva (Yao et al., 2005).

A natureza flexível do algoritmo genético permite a implementação de características que modelam os padrões de demanda de consumidores baseado nos padrões de uso dos equipamentos, sendo assim, podemos avaliar qual o melhor horário para realocar cada equipamento. Na realidade certas cargas têm preferência sobre outras, o que pode ser levado em consideração pelo algoritmo para que essas cargas sejam realocadas nos horários apropriados, de acordo com sua importância.

Outra grande vantagem do uso do algoritmo genético é a habilidade de trabalhar com um grande número de dispositivos controláveis de diversos tipos diferentes. O tamanho do problema apenas afeta o tamanho dos cromossomos do algoritmo genético. A flexibilidade do algoritmo genético se mostra como uma das principais vantagens do algoritmo proposto.

3.2. Metodologia proposta

Nesta seção serão descritos os parâmetros e funções considerados no desenvolvimento da ferramenta proposta. Como foi dito na seção anterior, desejamos conseguir uma configuração ótima dos equipamentos para reduzir o custo total de energia elétrica a partir da curva de carga original e dos equipamentos passíveis de realocação.

Inicialmente são coletados os dados da curva de carga da rede e das tarifas praticadas pela concessionária naquela região. Em seguida são definidos os equipamentos que podem ser realocados e suas características de funcionamento. Para tanto é necessário que as indústrias e a concessionária cheguem a um acordo quanto aos equipamentos

podem ser utilizados para este fim e seus horários de funcionamento. Os dados dos equipamentos estão mostrados na Tabela 1 apresentada anteriormente.

Em seguida devem ser definidas as condições de contorno, e colocar algumas restrições necessárias ao funcionamento do mesmo. As restrições utilizadas neste trabalho foram organizadas de forma que a carga total da rede permaneça constante durante as 24 horas do estudo, ou seja, cada equipamento retirado de algum horário deverá ser alocado em outro horário.

Definiu-se que a população inicial neste trabalho seria gerada aleatoriamente contendo 200 cromossomos. Cada cromossomo contém diversas variáveis de decisão, que por sua vez correspondem aos equipamentos que desejamos realocar e a hora em que eles devem ser realocados. Cada cromossomo encontrado através do processo de evolução é uma potencial solução para o problema. Como foi dito anteriormente, esta população é aleatoriamente inicializada e cada gene é inicializado entre os limites inferiores e superiores definidos para ele. Para exemplificar, seja o cromossomo exemplo da Figura 2 a seguir: neste caso cada índice de X corresponde ao dispositivo e à hora do dia. Portanto x_{32} corresponde a quantos dispositivos do tipo 3 estão conectados na hora 2. No caso do problema abordado são contemplados 6 diferentes tipos de dispositivo e um período de estudo de 24 horas.




Figura 2: Exemplo de um cromossomo

Finalmente definiu-se a função objetivo que é gerada a partir das tarifas operadas pela concessionária na região. O objetivo principal é de minimizar o custo e, portanto a função objetivo é inversamente proporcional às tarifas.

A função de aptidão (Fitness) definida para avaliar cada cromossomo, em cada etapa das gerações do AG, de forma que o algoritmo busque boas configurações de dispositivos, para alcançar uma curva de carga final o mais perto possível da curva objetivo é dada na equação a seguir:

$$Aptidão = \frac{1}{1 + \sum_{t=1}^{24} (Carga(t) - Objetivo(t))^2} \quad (1)$$

Onde:

- A variável Carga que se encontra na função de aptidão pode ser dividida em três partes. A primeira é a carga prevista do parque industrial, a segunda representa as cargas conectadas pelo algoritmo em cada instante de tempo e a terceira corresponde às cargas desconectadas em cada hora. Ou seja, Carga, é à soma da curva de carga original com os dispositivos conectados naquele horário do dia menos os dispositivos desconectados no mesmo horário.

- A variável Objetivo depende do objetivo do programador, por exemplo, se o objetivo principal for a redução de custos, como neste trabalho, é montada uma curva inversamente proporcional às tarifas horárias praticadas durante o dia e assim têm-se uma curva final.

Com essa função de aptidão assim definida, o algoritmo deve alocar os equipamentos de forma a minimizar a diferença entre essas duas curvas dentro das possibilidades apresentadas pelas restrições do problema.

Assim, cada cromossomo é avaliado, sendo aqueles com melhor aptidão os que representam melhores soluções para o problema.

Resumidamente, enquanto o algoritmo progride, novas populações de cromossomos são geradas a partir das populações antigas através de operadores genéticos.

Neste trabalho foi utilizado o crossover de um único ponto e mutação. Sabe-se que uma taxa de crossover alta pode levar a uma convergência mais rápida para a solução, e por outro lado altas taxas de mutação podem resultar em perdas de boas soluções de gerações anteriores e fazer com que o algoritmo pare antecipadamente, em ótimos locais. Neste trabalho as taxas foram encontradas experimentalmente para o problema, sendo elas: crossover (0,8) e mutação (0,1).

Além disso, foi considerado o elitismo para evitar a perda de boas soluções que possam surgir prematuramente. E a reprodução neste trabalho foi baseada na técnica de torneio.

O algoritmo termina quando o número de gerações estipulado (no caso foram consideradas 200 gerações) é alcançado ou quando a diferença entre os valores das funções de aptidão não variem por valores maiores do que a tolerância por 50 gerações. O fluxograma do AG está mostrado na Figura 3 a seguir:




Figura 3: Fluxograma do AG

4 Resultados das simulações

O parque industrial utilizado como exemplo neste artigo é o mesmo analisado por (Logenthiran and Srinivasan, 2011) para que possam ser feitas melhores comparações em relação aos resultados obtidos pelas duas abordagens.

O parque possui 7 barras, com diferentes cargas com a demanda máxima totalizando 3MW, sendo que a maior parte delas está localizada na barra 2 com pouco mais de 1,6MW. A rede opera em uma tensão de 410 V e as conexões entre as barras possuem 0,003 pu de resistência e 0,01 pu de reatância e tem 5km de comprimento.

Uma representação esquemática do parque industrial está representada a seguir na figura 4:




Figura 4: Parque industrial utilizado, adaptado de (Logenthiran and Srinivasan, 2011)

Os equipamentos a serem realocados estão especificados na Tabela 1 mostrada na seção anterior.

Neste sistema industrial proposto, a realocação de equipamentos a fim de alcançar o menor custo para o consumidor foi simulada diversas vezes, a fim de verificar se os resultados entregues pelo algoritmo proposto se mostraram corretos.

Os resultados da simulação mostram que a estratégia de GLD conseguiu um resultado satisfatório diminuindo tanto o custo total quanto o pico de carga do sistema. Além disso, podemos destacar que o algoritmo proposto conseguiu gerenciar efetivamente um grande número de cargas controláveis de diversos tipos.

Os resultados encontrados pelo algoritmo proposto foram bastante semelhantes aqueles apresentados para o mesmo problema em (Logenthiran et al., 2012). As melhorias encontradas podem se dar devido à programação em si do algoritmo ou possivelmente à alguns parâmetros utilizados em cada caso.

O resumo da otimização pode ser observado na Figura 5, onde a curva vermelha representa a demanda apresentada pelo parque industrial durante um dia típico e a curva azul é a curva proposta pelo algoritmo para realocar os equipamentos durante o dia e assim

modificar a demanda esperada com o objetivo de diminuir os custos.

Também podemos observar a evolução da média dos indivíduos e do melhor indivíduo durante as gerações na Figura 6 verificando assim a convergência do algoritmo.




Figura 5: Resultados da otimização




Figura 6: Evolução da média e do melhor indivíduo à cada geração

Como pode ser observado na Tabela 2 a seguir, sem a utilização do GLD o custo diário de energia neste parque industrial era de \$5712,00. Com o uso desta estratégia, conseguimos reduzir o custo para \$5088,41 acarretando em uma redução de pouco mais de 10% no custo operacional. Apesar de não ser o objetivo principal da otimização observou-se também o pico de demanda em cada caso. Assim como nos custos, a redução também foi significativa caindo de 2727,30 kW para 2287,53 kW o que acarretou em uma redução de pouco mais de 16%.

Assim, atingiu-se o objetivo de diminuição de custos para os consumidores. E ainda, essa diminuição no pico de demanda, como já foi comentado anteriormente neste trabalho, pode ser extremamente vantajosa para a concessionária diminuindo custos com gerações mais caras e trazendo benefícios ao planejamento da expansão das redes como um todo.

Tipo de análise	Sem GLD	Com GLD	Economia	Redução Percentual (%)
Custo (\$)	5712,00	5088,41	623,59	10,92
Pico de demanda (kW)	2727,30	2287,53	439,77	16,12

Tabela 2: Análise de custo e redução do pico de demanda

5 Conclusões

O GLD tem potencial para fornecer muitos benefícios para todo o sistema, particularmente para a distribuição e para sistemas industriais. Este trabalho apresenta uma estratégia de GLD que é uma técnica geral baseada em realocação de carga que foi matematicamente formulada como um problema de minimização e posteriormente implementada em um algoritmo evolutivo especialmente desenvolvido para resolver o problema. As simulações realizadas com este algoritmo mostram que é possível utilizar um grande número de dispositivos controláveis de diversos tipos e com isso alcançar tanto reduções de custo significativas quanto reduções no pico de demanda do sistema. Com relação ao trabalho de (Logenthiran et al., 2012) como já foi dito, o exemplo proposto foi reproduzido a fim de se ter uma base comparativa para os resultados encontrados. As modificações tanto na função objetivo quanto no algoritmo genético proporcionaram resultados que apesar de parecidos com os encontrados pelo trabalho base trazem uma melhora em relação à economia de energia e em relação ao pico de demanda.

Agradecimentos

Os autores deste trabalho agradecem ao CNPq, FAPEMIG, Capes, INERGE e PPEE pelo apoio e incentivo prestado a esta pesquisa

Referências Bibliográficas

- Antunes, C. H., Martins, A. G. and Brito, I. S. (2004) 'A multiple objective mixed integer linear programming model for power generation expansion planning', *Energy*, 29(4), pp. 613-627.
- Bellarmine, G. T. and Turner, M. C. (1994) 'Energy conservation and management in the US', *Energy conversion and management*, 35(4), pp. 363-373.
- CAMARGO, C. C. d. B. (1996) 'Gerenciamento pelo lado da demanda: metodologia para identificação do potencial de conservação de energia elétrica de consumidores

- residenciais', *Florianópolis: Programa de Pós-graduação em Engenharia de Produção da Universidade Federal de Santa Catarina*.
- Garcia, O. (2002) 'Integração de Técnicas de Gerência de Redes ao Gerenciamento de Cargas em Redes de Distribuição Elétrica', *Revista Eletrônica de Sistemas de Informação* ISSN 1677-3071 doi: 10.5329/RESI, 1(1).
- Gellings, C. W. (1985) 'The concept of demand-side management for electric utilities', *Proceedings of the IEEE*, 73(10), pp. 1468-1470.
- Haupt, R. L. and Haupt, S. E. (2004) *Practical genetic algorithms*. John Wiley & Sons.
- Kinhekar, N., Padhy, N. P. and Gupta, H. O. (2014) 'Multiobjective demand side management solutions for utilities with peak demand deficit', *International Journal of Electrical Power & Energy Systems*, 55, pp. 612-619.
- Logenthiran, T. and Srinivasan, D. (2011) 'Multi-agent system for market based microgrid operation in smart grid environment', *Department of Electronics and Computer Science, National University of Singapore*.
- Logenthiran, T., Srinivasan, D. and Shun, T. Z. (2012) 'Demand side management in smart grid using heuristic optimization', *Smart Grid, IEEE Transactions on*, 3(3), pp. 1244-1252.
- Martins, A. G., Coelho, D., Antunes, H. and Clímaco, J. (1996) 'A Multiple Objective Linear Programming Approach to Power Generation Planning with Demand-Side Management (DSM)', *International Transactions in Operational Research*, 3(3-4), pp. 305-317.
- Rahman, S. (1993) 'An efficient load model for analyzing demand side management impacts', *Power Systems, IEEE Transactions on*, 8(3), pp. 1219-1226.
- Strbac, G. (2008) 'Demand side management: Benefits and challenges', *Energy policy*, 36(12), pp. 4419-4426.
- Yao, L., Chang, W.-C. and Yen, R.-L. (2005) 'An iterative deepening genetic algorithm for scheduling of direct load control', *Power Systems, IEEE Transactions on*, 20(3), pp. 1414-1421.