

OTIMIZAÇÃO MULTI OBJETIVO COM ALGORITMOS EVOLUTIVOS - UMA APLICAÇÃO NO SECTOR ELÉTRICO

Álvaro Gomes e Carlos Henggeler Antunes

Deptº de Engenharia Electrotécnica e de Computadores, Universidade de Coimbra, Pólo II,
Pinhal de Marrocos, 3030-290 Coimbra, Portugal
INESC Coimbra, Rua Antero de Quental 199, 3000 Coimbra, Portugal
agomes@deec.uc.pt

Jorge Martinho

INESC Coimbra, Rua Antero de Quental 199, 3000 Coimbra, Portugal
jorgemartinho85@gmail.com

Eunice Oliveira

Escola de Tecnologia e Gestão, Instituto Politécnico de Leiria, 3411-901 Leiria, Portugal
INESC Coimbra, Rua Antero de Quental 199, 3000 Coimbra, Portugal
eunice@ipleiria.pt

RESUMO

O desenvolvimento dos sistemas de energia eléctrica e a sua evolução gradual para *smart-grids* tem levado a um crescente interesse na participação da demanda como ativo útil na operação e exploração eficientes dos sistemas. Neste cenário, a demanda é vista como um recurso com algum potencial de gestão e controlo. O principal desafio é a identificação das ações que alterem os padrões de consumo de electricidade de forma a atingir objetivos diversos, satisfazendo as necessidades dos consumidores em termos de serviços de energia, sem degradar a sua qualidade. Neste trabalho são apresentados os resultados da aplicação de um algoritmo genético multiobjetivo na identificação de ações de controlo. Dois tipos de ação são analisados: ações que interrompem exteriormente o funcionamento das cargas e ações que alteram o nível do serviço fornecido sem interromperem o seu funcionamento.

PALAVRAS CHAVE. Otimização em sistemas de energia. Algoritmos genéticos multiobjetivo. Ações de controlo disruptivo e não disruptivo.

ABSTRACT

The development of power systems and its gradual evolution to smart-grids has strongly contributed for the increasing attractiveness of demand management activities. In this new paradigm, demand is seen as a resource able to be actively used and capable of contributing for a more efficient functioning of power systems and also a higher penetration of renewables. In this work the results of using a multiobjective genetic algorithm in the identification of demand management actions are presented. Two different types of actions are considered: load shedding actions and changing the reference values of parameters determining the operation of some end-use loads. A comparison of disruptive and non-disruptive actions that can be used for an active utilization of controllable demand is made.

KEYWORDS. Optimization in power systems. Multiobjective genetic algorithms. Disruptive and non-disruptive load control actions.

1 Introdução

A mudança de paradigma trazida quer pela geração distribuída, quer pela natural evolução dos sistemas de energia no sentido das chamadas *smart-grids*, com uma integração cada vez maior das tecnologias da informação e comunicação, associada ao desenvolvimento tecnológico, permite que a busca da eficiência englobe também a demanda de energia elétrica, até aqui considerada praticamente inelástica (Mohsenian-Rad et al., 2010, Karangelos e Bouffard, 2012). Neste novo cenário, a demanda é vista como um recurso com algum potencial de gestão e controle, em que se procuram satisfazer as necessidades dos consumidores em termos de serviços de energia, sem degradar a sua qualidade, mas alterando os padrões de consumo de eletricidade por forma a atingir objetivos diversos. Podem pois encontrar-se cargas de utilização final que podem ser deslastradas durante breves instantes, com o objetivo principal de reduzir a ponta do diagrama de carga e/ou os custos de aquisição; cargas cujo funcionamento pode ser deslocado no tempo, tipicamente para períodos em que a energia é mais barata ou o seu funcionamento pode de alguma forma acarretar diminuição de custos; cargas cujos parâmetros podem ser alterados temporariamente, nomeadamente temperaturas de referência, diminuindo ligeiramente o nível de serviço fornecido (Pedrasa et al., 2009). Destes três tipos de ações, o controlo liga/desliga e os desvios de consumo são os mais usados e, no caso das cargas termostáticas, o controlo remoto automático liga/desliga é o mais implementado (Argiento et al. (2012), Gomes et al. (2004, 2007)). Para a aplicação deste tipo de controlo disruptivo é necessário conceber muito criteriosamente as ações de controlo, quer devido aos potenciais efeitos nocivos na qualidade do serviço fornecido - com a conseqüente diminuição da aceitação deste tipo de atividades - quer devido a eventuais efeitos de *payback* que se podem observar na potência pedida à rede quando a alimentação é restituída a este tipo de cargas. A variação das temperaturas de referência, desde que não muito brusca, poderá ser uma forma expedita de alterar a forma e amplitude da demanda com menores riscos de degradação da qualidade de serviço e de efeitos de *payback*. Assim, com estas ações de controlo não disruptivo, em conjunto com os chamados *smart-thermostat* e *energy management systems* locais poder-se-á estar na antecâmara da utilização em larga escala da gestão da demanda, garantidos que estejam os resultados obtidos. Este será uma passo essencial para se passar a comercializar serviços de energia e não kWh como até agora.

Passamos, pois, de um cenário em que tipicamente se procurava minimizar custos com a geração (sobretudo de energia ativa), perdas, desvios de tensão e frequência, desvios nas interligações, interrupções e manobras de correção, para um cenário em que também se procura maximizar a integração das renováveis e de novas cargas (por exemplo, o veículo elétrico) ao mesmo tempo que se procura minimizar os seus potenciais impactos adversos, maximizar lucros dos fornecedores/retalhistas, e minimizar custos de aquisição por parte do consumidor, pontas na rede de distribuição (De Jonghe et al., 2012; Farahani et al, 2012). Em geral dir-se-ia que além das questões de qualidade e fiabilidade, cada entidade potencialmente interessada nestas atividades terá objetivos diversos que quererá realizar. Num cenário de *smart grid* é possível, numa perspectiva de operação global eficiente de todo o sistema, englobar todo o sistema desde a geração à demanda.

A utilização dinâmica de algumas cargas como recurso controlável pode ser usada com objetivos diversos para as diferentes entidades potencialmente interessadas. Por exemplo, do ponto de vista dos consumidores o objetivo principal será reduzir os custos com a aquisição da energia ou maximizar a integração de outros recursos (armazenamento, geração local, por exemplo); para os fornecedores o interesse será tipicamente o aumento dos seus lucros (através da utilização da diferença de preços entre a energia no mercado grossista e os preços de venda aos clientes finais, ou tirando partido da demanda variável para otimizar as contratações de capacidade) ou como ferramenta de marketing para captar novos clientes ou manter os existentes; do ponto de vista dos SEE pode ser usada como ferramenta de otimização do seu funcionamento (melhorar fator de carga, minimizar pontas, reduzir perdas, minimizar impactos ambientais, lidar com restrições de capacidade, etc.) ou como forma de aumentar a eficiência do mercado de energia (potencialmente contribuindo para reduzir o poder de mercado e/ou mitigando

incrementos bruscos nos preços da energia).

Tipicamente pretende-se tirar partido das características de algumas cargas que as tornam passíveis de serem controladas e alterar quer a amplitude, quer a forma da demanda, através de estratégias de controlo adequadas. Todavia, a identificação destas estratégias de gestão é um problema difícil, quer devido ao número de eixos de avaliação que normalmente são utilizados (devido ao carácter potencialmente conflituoso dos múltiplos objetivos em presença), quer devido à sua natureza combinatória, que resulta do facto de ser necessário identificar ações diversas, por exemplo padrões ligado/desligado, a aplicar aos diferentes grupos de cargas.

No que se refere à gestão da demanda, a identificação e a seleção das ações de gestão são etapas cruciais, e esforços nesse sentido podem ser encontrados na literatura. Todavia, quase todos os trabalhos se focam na parte da seleção, relegando a parte da identificação e pesquisa para um plano secundário, baseando-se sobretudo na experiência acumulada ou em dados empíricos eventualmente recolhidos em experiências piloto para identificar um conjunto de alternativas das quais depois uma é selecionada. Todavia, sendo essencial que as ações de gestão/controlo permitam atingir os objetivos em jogo sem degradar a qualidade do serviço fornecido a níveis que poriam em causa a continuidade da sua aplicação e sem causarem danos nas cargas, facilmente se percebe quão importante esta etapa é para o bom sucesso de qualquer programa de gestão da demanda. Os algoritmos genéticos, ao trabalharem com populações, são particularmente adaptados para estes problemas combinatórios multiobjetivo (MO) onde se pretende, numa primeira fase, caracterizar uma frente de soluções não dominadas.

Neste trabalho apresentam-se os resultados da utilização de um algoritmo genético (AG) na pesquisa e identificação de ações de gestão da demanda (mais especificamente *Demand Response -DR-*, na terminologia anglo-saxónica). Na secção 2 é feita uma breve introdução ao problema da identificação de ações DR, sendo na secção 3 abordada a respectiva concepção. Os resultados da utilização do algoritmo na identificação de dois tipos diferentes de ações de gestão da demanda são apresentados na secção 4. A secção 5 contém algumas conclusões acerca do trabalho apresentado.

2 O problema da identificação de ações de DR

Os algoritmos genéticos fazem parte de um conjunto de ferramentas de pesquisa e otimização adequadas para problemas multiobjetivo complexos, sobretudo de natureza combinatória pois, ao trabalharem em cada iteração com um conjunto de potenciais soluções para o problema, podem dar uma visão abrangente do espaço em que está a decorrer a pesquisa. Uma função de avaliação e operadores que permitam selecionar, recombinar e introduzir alterações nas soluções são os instrumentos necessários para replicar a evolução natural. O facto de disponibilizarem em cada iteração um conjunto de soluções, que podem representar diferentes regiões do espaço de pesquisa, torna os AGs particularmente atrativos no quadro de um processo de otimização MO, permitindo caracterizar a fronteira não dominada (e conseqüentemente fazer perceber os compromissos a estabelecer no quadro da seleção de uma solução final a implementar, envolvendo explícita ou implicitamente as preferências do agente de decisão - AD).

Nos AGs, cada indivíduo da população é avaliado de acordo com o seu desempenho (*performance*) face a cada um dos objetivos, podendo ainda outros fatores ser levados em conta. Com base nessa avaliação, são escolhidos probabilisticamente alguns indivíduos para serem os progenitores da geração seguinte, aos quais são aplicados os operadores recombinação e mutação e depois construída a nova população. O operador mutação permite que haja introdução de novo material genético nos descendentes. Ao combinar vários indivíduos, os algoritmos genéticos usam o historial da população para gerar as novas soluções. Os operadores recombinação e mutação permitem percorrer o espaço de pesquisa, ao trazerem novas soluções / indivíduos para a população. Como forma de garantir a convergência e acelerar a pesquisa sobretudo para regiões do espaço de pesquisa que sejam interessantes para o AD, os AGs têm habitualmente comportamentos elitistas e são alimentados, sempre que possível, com informação que possa ser útil no processo evolutivo.

Como em boa parte dos problemas do mundo real, também no problema de

identificação de ações de controlo de cargas o processo de tomada de decisão envolve potencialmente múltiplos aspectos de avaliação, quer porque diferentes agentes de decisão terão objetivos diversos, quer porque o problema em análise envolve intrinsecamente múltiplos objetivos na sua avaliação. Independentemente do nível a que está a ser executado e dos ADs envolvidos, o estudo terá necessariamente que ser informado com os dados exigidos em cada uma das vertentes da avaliação. Neste trabalho, o enfoque principal será dado à avaliação quantitativa dos impactos das diferentes medidas em termos de alteração dos níveis de potência e energia. Isto implica que a caracterização dos impactos deverá ser ao mesmo tempo pormenorizada, dando idêa do potencial individual de cada ação ou medida, e precisa, no sentido de ser baseada numa adequada quantificação dos impactos. Uma correta identificação e quantificação dos impactos das ações nas suas diferentes vertentes (econômica, energética e ambiental) são essenciais para a sua avaliação. Para isso, pode ser necessário simular os cenários físicos que se pretendem analisar e fazer repercutir sobre eles as ações pretendidas. O recurso a modelos adequados, que sintetizem a demanda ao nível de agregação pretendido, tendo como base a modelação de algumas utilizações finais de eletricidade, e cuja estrutura e parametrização possibilitem a simulação das ações, permite responder a essa necessidade (Molina-Garcia et al., 2010; Gomes et al., 2009). A avaliação adequada dos impactos a diferentes níveis de agregação da demanda e, portanto, segundo o interesse de diferentes potenciais agentes econômicos existentes nos diversos ramos de atividade no mercado da energia elétrica, ficará dessa forma salvaguardada. Aquando da implementação prática de tais medidas procede-se, em geral, à implementação de programas piloto para a caracterização das ações ou usa-se o conhecimento adquirido. No estudo de caso aqui apresentado, de forma a proceder à avaliação das diferentes soluções recorre-se à utilização de modelos que permitam reproduzir adequadamente a demanda a ser controlada. Os chamados modelos fisicamente baseados (MFB) são muito interessante neste contexto pois permitem reproduzir a demanda das cargas controláveis sem e com a aplicação das ações de controlo. A utilização conjunta dos AGs e MFBs tem produzido resultados muito interessantes (Gomes et al., 2007, 2009; Molina-Garcia et al., 2012).

Em termos de gestão integrada de recursos, a satisfação parcial da variação da demanda com base no controlo do funcionamento das cargas requer, por um lado, que as cargas selecionadas para controlo sejam agrupadas de acordo com algum critério e, por outro, que sobre as cargas de um mesmo grupo sejam aplicadas as mesmas ações de corte. No controlo de cargas, cada estratégia de controlo tem subjacente a organização do despacho das cargas controláveis. O despacho da carga controlável consiste no envio de uma ordem de deslastre / restabelecimento de alimentação ou uma alteração da parametrização a uma ou mais parcelas (grupos de cargas) da carga total sob controlo. As inúmeras alternativas de organização possíveis tornam este problema combinatório particularmente difícil.

Como eixos de avaliação do mérito de soluções alternativas incluem-se as reduções da demanda máxima, avaliadas a diferentes níveis de agregação da demanda (neste estudo são considerados dois níveis: uma sub-estação, SE, e dois postos de transformação, PT1 e PT2); não impor demasiado desconforto ao consumidor final, para ter níveis de aceitação adequados; procurar aumentar os lucros; contribuir para a redução das perdas. Ao englobar um vasto conjunto de objetivos, conjuntamente com a possibilidade de avaliação a diferentes níveis de agregação, o modelo será potencialmente útil para qualquer entidade que exerça a função de comercialização, tipicamente com a compra por grosso e venda a retalho, independentemente da estrutura do sector. A formalização matemática pode ser consultada em Gomes et al. (2004, 2007). De referir que o modelo foi adaptado, neste trabalho, para poder identificar também as ações de controlo que passam pela variação da temperatura de referência, sendo esta uma perspectiva nunca antes explorada com este modelo.

3 Concepção de medidas de gestão da demanda

O problema da identificação de medidas de DR passa pela identificação dos cortes ou das variações da temperatura de referência a aplicar a cada grupo de cargas durante o período de controlo. Em termos algorítmicos, o processo de identificação de soluções para este problema,

com a utilização conjunta dos MFB e de um AG, decorrerá da seguinte forma: o AG identifica um conjunto de indivíduos, codificação de potenciais soluções, que são depois decodificados em estratégias de controlo a aplicar, cada uma delas, a todas as cargas. De seguida, os MFB reproduzem a demanda das cargas quando são aplicadas essas estratégias de controlo previamente identificadas. Os resultados da simulação das demandas são utilizados pelo AG para avaliar o desempenho de cada indivíduo, continuando o AG o seu curso normal (seleção, recombinação e mutação), obtendo uma nova população que irá ser decodificada num novo conjunto de estratégias de controlo. Este processo iterativo repete-se até que uma qualquer condição de paragem seja verificada.

Para permitir lidar com eventuais níveis de reserva que o AD tenha para cada um dos objetivos, é dada a possibilidade ao AD de especificar esses níveis, que são levados em conta na função de avaliação penalizando a *fitness* dos indivíduos que os violem.

Cada estratégia de controlo define os intervalos de tempo em que se verificam cortes de alimentação às cargas ou alteração da sua parametrização, durante todo o período de controlo (24 horas). A sua representação no AG é feita à custa de uma *string* binária, em que os “1” representam os períodos de tempo em que há cortes/variação da temperatura de referência.

Uma das formas de alimentar o processo de pesquisa com informação que eventualmente possa acelerar o processo ou veicular preferências do AD relativamente ao espaço de pesquisa é recorrendo aos operadores genéticos. No AG foi implementada uma probabilidade de mutação adaptativa que é calculada como o resultado das contribuições de cada função objetivo (FO). Cada contribuição pode, se o AD o entender, ser ponderada de forma diferente. Como a representação das soluções recorreu ao alfabeto binário, em que um “1” representa um corte e um “0” representa um não corte, podem ocorrer duas diferentes mutações “1” → “0” e “0” → “1”. Para o caso dos objetivos cuja informação varia ao longo do período de simulação e de geração para geração, a probabilidade de mutação é modulada entre 0 e um valor máximo pré-definido pelo utilizador de acordo com o desempenho do indivíduo nos diferentes objetivos. Relativamente às FO cuja informação disponível não é variável ao longo do tempo a respectiva contribuição para a probabilidade de mutação varia entre dois extremos. No caso dos lucros está-se perante uma situação intermédia: a informação varia de intervalo de tempo para intervalo de tempo, mas não varia de simulação para simulação uma vez que se estão a usar previsões de 24 horas. A probabilidade de mutação a aplicar a cada indivíduo pode ser diferente, possibilitando desta forma que o meio ambiente influencie a taxa de mutação. Para além disso, também a mutação de cada gene pode também ser diferente de outros genes no mesmo cromossoma (indivíduo). A fig. 1 representa as duas taxas de mutação nos dois níveis de agregação da demanda (PT1 e PT2, e SE) em que os impactos das ações são avaliados.

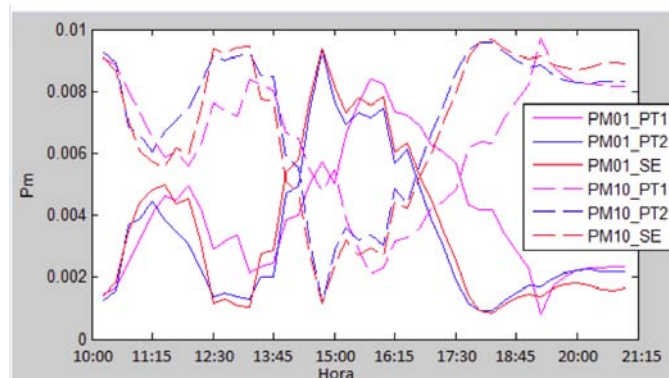


Fig. 1 - Probabilidade de mutação (0→1 e 1→0 nos dois níveis de agregação)

O *crossover* implementado é de dois pontos, ou seja, o AG identifica aleatoriamente dois pontos através dos quais se dá a troca entre os pais para originar os filhos. Estes dois pontos respeitam sempre a integridade de um padrão de corte, ou seja, os padrões de corte dos grupos de cargas nunca são interrompidos.

4 Estudo ilustrativo

No caso de estudo apresentado procura reduzir-se a potência máxima numa subestação (SE) e em dois postos de transformação de distribuição (PT1 e PT2), ao mesmo tempo que se procura diminuir o fator de perdas (FP) e maximizar os lucros (L) com a venda de electricidade. Pretende-se também minimizar o desconforto imposto aos consumidores, através de duas funções objetivo que medem o tempo máximo (MI) e o tempo total (NM) que a temperatura nos locais condicionados ultrapassa os valores de conforto. Para tal controlam-se 500 equipamentos de condicionamento ambiente distribuídos da forma que apresenta na tabela 1. Os diagramas diários de carga típicos são apresentados na fig. 2, e a demanda das cargas sob controlo na fig. 3. De acordo com os objetivos e com a forma dos diagramas de carga achou-se suficiente identificar cortes apenas no período 10:00h – 21:00h. Desta forma reduz-se o esforço computacional imposto pelos MFB. Na tabela 1 são apresentadas algumas características dos grupos de cargas sob controlo. De referir a necessidade de ter em consideração quer considerações sobre a localização geográfica das cargas que relacionadas com as suas características, uma vez que uma mesma estratégia de controlo é aplicada a todos os equipamentos de ar condicionado (ACs) de um mesmo grupo. A tabela 1 mostra o número de equipamentos de cada grupo, a potência de cada equipamento e as temperaturas de referência dos termostatos que controlam o funcionamento dos ACs [BMmin - BMmax].

A demanda na SE e nos dois PTs denota uma forte presença do sector dos serviços. A ponta máxima é de 7394,3 kW na SE e de 821 kW e 643,8kW respectivamente no PT1 e PT2. De realçar a duração do período de ponta no PT1.

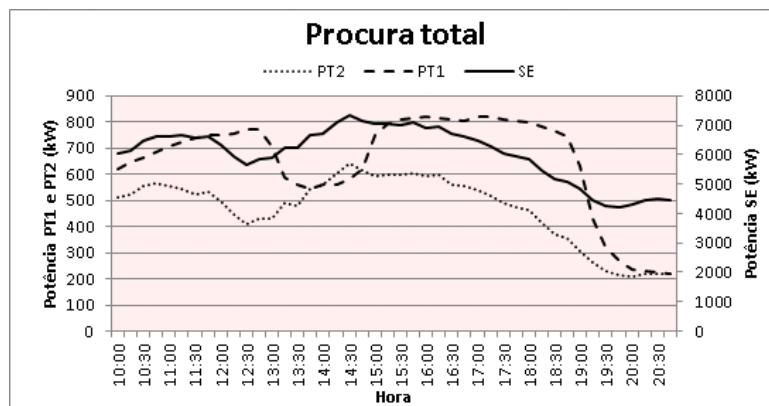


Fig. 2 - Diagrama de carga do PT1, PT2 e SE.

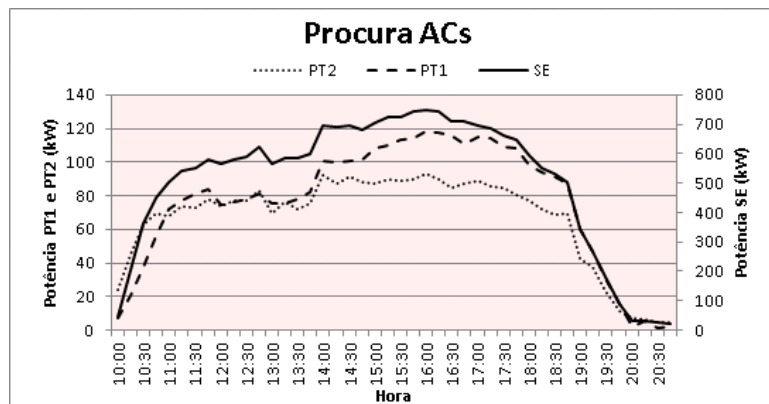


Fig. 3 - Demanda das cargas controláveis localizadas no PT1, PT2 e SE.

Tabela 1 - Características dos grupos de cargas sob controle.

Grupo	Nº de ACs	Potência (kW)	BMmin (°C)	BMmax (°C)	PT/SE
1	15	1,6	22,5	23	PT2
2	20	2,8	23	23,5	PT1
3	30	2,7	22,5	23	SE
4	20	4	23	23,5	SE
5	25	1,6	23,5	24	SE
6	20	1,4	23,5	24	SE
7	35	2,4	22	22,5	SE
8	20	2,4	23	23,5	SE
9	20	4	22,5	23	PT1
10	30	3,8	23	23,5	SE
11	15	1,8	23,5	24	PT2
12	25	8	22	22,5	SE
13	30	2,4	23,5	24	SE
14	20	3,4	22,5	23	PT2
15	30	2,4	23,5	24	SE
16	25	1,6	23,5	24	SE
17	10	2,4	23	23,5	PT1
18	15	1,4	23,5	24	PT1
19	15	1,8	23,5	24	PT2
20	15	1,6	22,5	23	PT1
21	10	1,8	23,5	24	PT2
22	15	1,4	23,5	24	PT1
23	20	1,4	23,5	24	SE
24	20	2,4	23	23,5	SE

4.1 Resultados com cortes de alimentação

Na tabela 2 são apresentadas algumas características do AG.

Tabela 2 - Configuração da simulação e pesos usados no cálculo da PM.

Soluções	Iterações	Início	Fim	Integração	Prob. Mutação máxima	
30	5200	10h01m	21h00m	1 minuto	0,002	
Pesos usados na agregação das contribuições de cada objetivo para calcular a probabilidade de mutação						
PT1	PT2	SE	FP	L	NM	MI
0,3	0,3	0,3	0,1	0,1	0,1	0,1

A tabela 3 apresenta os resultados de algumas soluções identificadas pelo AG, que caracterizam a frente ótima de Pareto, incluindo os valores das FO e a variação em relação à situação sem ações de controle. A negrito encontram-se identificados os melhores valores para cada FO.

Na fig. 4 são apresentados os diagramas de carga das melhores soluções nos diferentes níveis de agregação assim como a comparação com os diagramas de carga iniciais. Refira-se mais uma vez a duração da “ponta” no PT1 torna difícil reduzir o seu valor com recurso a apenas seis grupos perfazendo um total de 95 cargas (107 kW em média de carga controlável durante o período de ponta), tendo ainda sido possível uma redução de 8,7kW (8 % da potência controlável). A principal dificuldade é conseguir baixar a potência máxima sem que o efeito de *payback* se verifique. É necessário ter em atenção que os grupos de cargas cuja variação da demanda é avaliada no PT1 é também avaliada na SE, tornando o problema ainda mais complexo. Com as cargas que foram selecionadas para controle foi possível reduzir a potência máxima dos diagramas sem alterar drasticamente os lucros com a venda da energia.

No caso do PT2, com 5 grupos e 75 cargas, apresentando uma potência controlável de cerca de 90 kW no período de ponta, conseguiu-se uma redução de 38,9 kW (43% da potência

controlável). Sendo uma ponta muito localizada foi possível usar uma percentagem muito elevada da carga controlável para reduzir a ponta no PT2.

Tabela 3 - Algumas soluções calculadas pelo AG.

PT1		PT2		SE		FP	Lucros		MI	NM
kW	Redução (%)	kW	Redução (%)	kW	Redução (%)		€	Aumento (%)		
814,87	-1,06	616,33	-4,49	7438,01	0,59	0,68	1074,17	0,23	13	64
827,73	0,50	674,73	4,56	7686,21	3,95	0,63	1080,78	0,85	14	479
838,00	1,75	606,44	-6,02	7206,34	-2,54	0,72	1068,27	-0,32	14	308
827,27	0,45	614,38	-4,79	7016,70	-5,10	0,76	1064,15	-0,71	14	456
815,80	-0,95	623,60	-3,36	7443,14	0,66	0,67	1074,28	0,24	0	0
827,13	0,43	616,71	-4,43	7406,27	0,16	0,68	1073,37	0,15	6	15
830,87	0,88	616,71	-4,43	7405,47	0,15	0,68	1073,34	0,15	10	34
815,80	-0,95	623,60	-3,36	7446,87	0,71	0,67	1074,38	0,25	1	3
829,80	0,75	674,73	4,56	7673,01	3,77	0,63	1080,03	0,78	14	360
817,47	-0,74	619,73	-3,96	7394,67	0,01	0,68	1073,17	0,13	12	85
822,73	-0,11	617,93	-4,24	7381,61	-0,17	0,69	1072,73	0,09	5	41

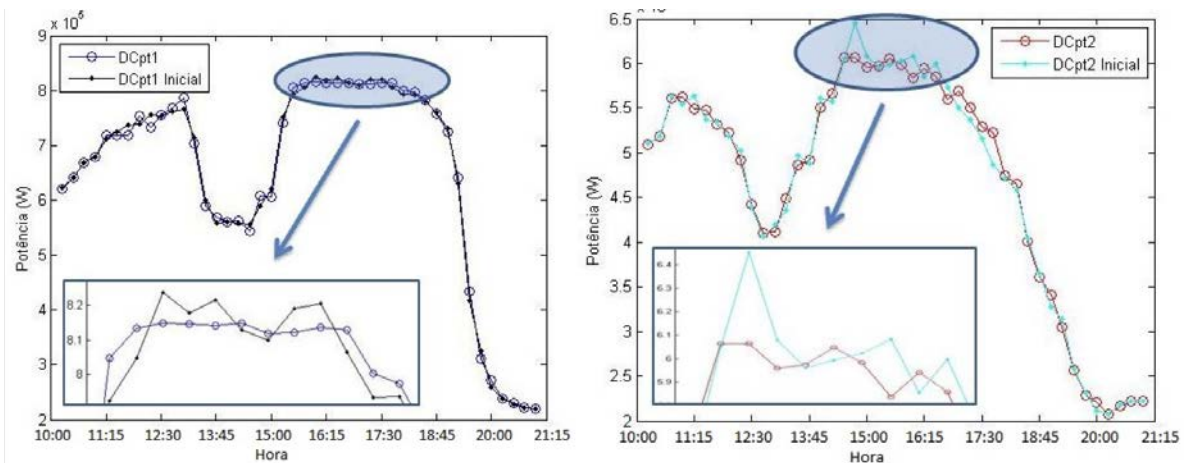


Fig. 4 - Diagrama de carga inicial e final da solução 1 para o PT1 e para a solução 3 para o PT2

Conclui-se, assim, que o AG identifica padrões de corte de alimentação que conseguem reduções bastante significativas no máximo dos diagramas de carga sem impor muito desconforto aos consumidores. A menor redução, é a nível do PT1, mas facilmente se verifica que o diagrama de carga do PT1 é um diagrama de difícil manuseamento pois apresenta 5 horas em que o pico máximo pouco varia. Mesmo nestas condições, o AG conseguiu identificar a solução apresentada na fig. 4 que ilustra que a solução final preenche o pequeno vale cortando, assim, os picos mais elevados nesse período de tempo. Ao nível da demanda mais agregada (fig. 5) o AG foi capaz de identificar soluções que permitem atingir reduções da demanda máxima superiores a 5%.

A fig. 6 mostra um exemplo de uma estratégia de controlo, com todos os períodos de interrupção de alimentação aplicados a cada um dos grupos de cargas identificados em cada uma das “linhas”. Nota-se que os grupos alimentados a partir do PT1 têm tendência a apresentar cortes mais estendidos ao longo da tarde.




Fig. 5 - Diagrama de carga inicial e final da solução 4 para a SE.




Fig. 6 - Padrões de corte de uma das estratégias de controle identificada pelo AG.

4.2 Resultados com variação da banda-morta do termostato

No contexto da aplicação de ações disruptivas, percebe-se o cuidado que deve ser colocado na constituição dos grupos de cargas, pois uma mesma estratégia é aplicada a todas as cargas do grupo, por forma a não degradar demasiado a qualidade do serviço fornecido, dado que uma estratégia pode ser adequada para umas cargas e completamente desadequada para outras. Com a aplicação de ações não disruptivas conseguem-se resultados semelhantes aos obtidos com cortes de alimentação sem os impactos negativos em termos de conforto dos utilizadores. O uso de ações de controlo não disruptivas poderá passar a ser prática comum com a disseminação das tecnologias como os *smart-thermostat* se os resultados obtidos forem encorajadores. A ideia é que variações ligeiras e temporárias em torno da temperatura de referência usada pelos termostatos das cargas podem levar a alterações razoáveis do consumo sem colocar em causa o conforto dos consumidores. Na tabela 4 são apresentadas algumas características do AG.

Tabela 4 - Configuração da simulação efetuada e distribuição dos pesos no cálculo da PM.

Soluções	Iterações	Início	Fim	Duração	Prob. mutação máxima	
30	5200	10h01m	21h00m	1 minuto	0,004	
Pesos usados na agregação das contribuições de cada objetivo para calcular a probabilidade de mutação						
PT1	PT2	SE	NC	L	NM	MI
0,3	0,3	0,5	0,05	0,05	0,05	0,05

Tabela 5 - Algumas soluções calculadas pelo AG.

PT1		PT2		SE		FP	Lucros		MI	NM
kW	(redução) (%)	kW	(redução) (%)	kW	(redução) (%)		€	(aumento) (%)		
823,60	0,00	645,33	0,01	7394,07	0,00	0,68	1071,72	0,00	0	0
830,20	0,80	603,24	-6,52	7347,34	-0,63	0,69	1071,63	-0,01	0	0
808,47	-1,84	631,16	-2,19	7284,61	-1,48	0,70	1070,07	-0,15	0	0
853,40	3,62	615,20	-4,66	7078,94	-4,26	0,75	1065,85	-0,55	0	0
868,93	5,50	672,60	4,23	7753,34	4,86	0,62	1082,31	0,99	0	0
821,07	-0,31	610,98	-5,32	7471,61	1,05	0,67	1075,64	0,37	0	0
861,80	4,64	613,40	-4,94	7127,14	-3,61	0,74	1066,99	-0,44	0	0
826,40	0,34	623,22	-3,42	7417,41	0,32	0,68	1074,09	0,22	0	0

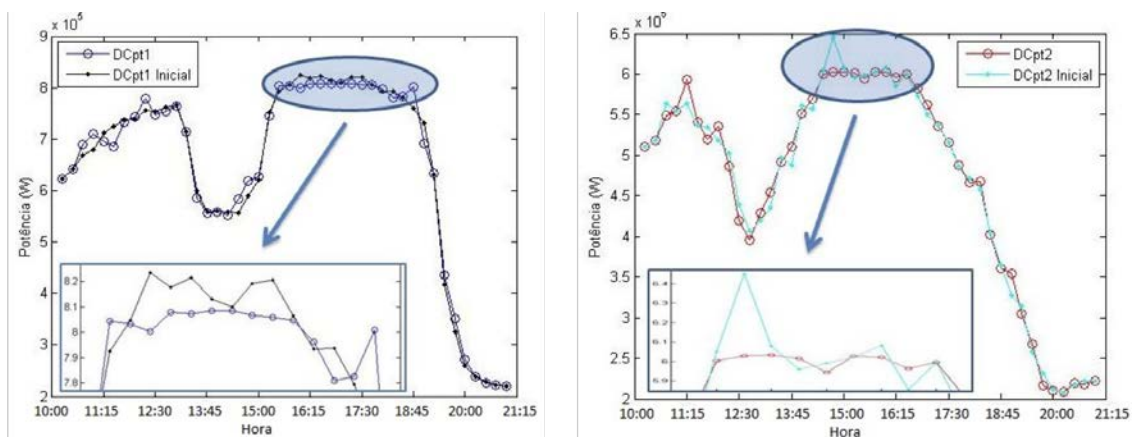


Fig. 7 - DC no PT1 e no PT2 - original e com variação da temperatura de referência

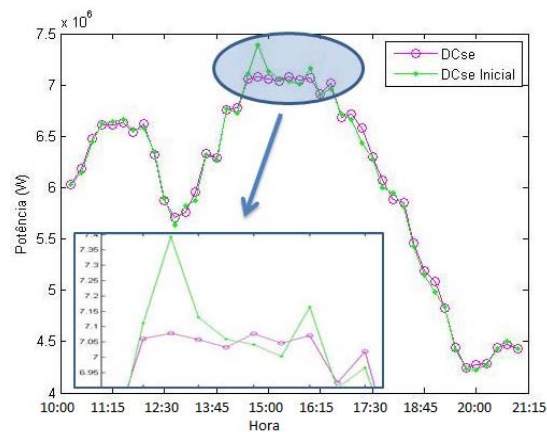


Fig. 8 - DC na SE - original e com variação da temperatura de referência.

Os resultados obtidos para este modelo são apresentados na tabela 5 e nas figs. 7 e 8. Os resultados obtidos com os dois diferentes tipos de ações de controlo são semelhantes em termos de redução da potência, fator de perdas e lucros. Todavia, as ações não disruptivas tendem a não impor desconforto aos utilizadores finais dos serviços de energia, para além daquele que advém da alteração temporária da temperatura de referência (sempre em torno de $\pm 1^\circ\text{C}$). Não sendo uma estratégia com presença comum nas atividades de gestão da demanda, deverá sempre que possível ser avaliada a sua implementação em substituição de ações disruptivas as quais, interrompendo o serviço de energia fornecido, podem provocar algum desconforto aos utilizadores.

É apresentado na fig. 9 um exemplo de ação de controlo, identificada pelo AG, através da variação da temperatura de referência imposta a cada um dos grupos de cargas. Para cada grupo há indicação dos instantes de tempo em que a temperatura aumentou 1°C (parte superior da linha) ou diminuiu 1°C (parte inferior da linha). De notar que com a aplicação de uma estratégia deste tipo, quando se faz variar a temperatura do termostato $+1^\circ\text{C}$ o nível do serviço varia ligeiramente temporariamente levando a uma diminuição da potência pedida à rede e do consumo de energia nesse período de tempo em que a temperatura foi aumentada. De referir que este tipo de ação deve ser temporário, ou seja, parte-se do princípio que o termostato está regulado para a temperatura desejada e as variações são efetuadas por períodos de tempo pequenos. Deixando o AG variar a temperatura nos dois sentidos permite-se que sejam identificadas situações em que se faz “armazenamento” de frio no espaço em períodos de menor demanda (aumentando o funcionamento dos ACs), o que evita que o equipamento seja colocado tanto tempo em funcionamento nos períodos mais críticos.

5 Conclusões

O algoritmo genético multiobjetivo implementado funciona adequadamente para a identificação de ações que permitem alterar os padrões da potência de forma a alcançar os objetivos pretendidos, quer com a aplicação de cortes de alimentação, quer com a variação da temperatura de referência. Este desempenho deve-se sobretudo à forma como foram implementados os operadores *crossover* e mutação. Ao permitir que o operador mutação alimente o processo evolutivo com os resultados obtidos até então acelera-se a convergência e melhora a qualidade dos resultados obtidos. Foram obtidas soluções em que facilmente se observa a adaptação do algoritmo genético ao problema, ou seja, a existência de um número maior ou menor cortes de alimentação em determinadas horas do dia. O operador *crossover* “respeita” a integridade dos padrões de cortes de alimentação, o que contribui para melhorar os resultados.

Relativamente ao tipo de ações identificadas conclui-se que com ações não disruptivas se conseguem resultados semelhantes aos conseguidos com as ações liga/desliga sem os potenciais inconvenientes em termos de desconforto provocado aos utilizadores. Este tipo de

ação tem potencial de aplicação em larga escala em cenários de *smart-grids* e com sistemas locais de gestão de energia, permitindo aumentar significativamente a resposta da demanda a estímulos diversos, sejam de variação de preços, sejam outro tipo de sinais vindos da rede ou do sistema local de gestão.




Fig. 9 - Variação da temperatura de referência imposta aos diferentes grupos de cargas.

Agradecimentos

Este trabalho de pesquisa e desenvolvimento beneficiou do apoio dos projectos MIT/SET/0018/2009 e PEst-C/EEI/UI0308/2011.

Referências

- Argiento, R.; Faranda, R.; Pievatolo, A.; Tironi, E.** (2012), Distributed Interruptible Load Shedding and Micro-Generator Dispatching to Benefit System Operations, *IEEE Trans. on Power Systems*, 27 (2), 840 - 848 .
- De Jonghe, C.; Hobbs, B.F.; Belmans, R.** (2012), Optimal Generation Mix With Short-Term Demand Response and Wind Penetration, *IEEE Trans. on Power Systems*, 27 (2), 830 - 839.
- Farahani, V.; Vahidi, B.; Abyaneh, H.A.** (2012), Reconfiguration and Capacitor Placement Simultaneously for Energy Loss Reduction Based on an Improved Reconfiguration Method, *IEEE Trans. on Power Systems*, 27 (2), 587 - 595.

Gomes, A.; Henggeler Antunes, C.; Gomes Martins, A. (2004), A multiple objective evolutionary approach for the design and selection of load control strategies, *IEEE Trans. Power Systems*, 19 (2), 1173-1180.

Gomes, A.; Henggeler Antunes, C.; Gomes Martins, A. (2007), A multiple objective approach to electric load management using an interactive evolutionary algorithm, *IEEE Trans. Power Systems*, 22 (3), 1004-1011.

Gomes, A.; Henggeler Antunes, C.; Gomes Martins, A. (2009), Physically-based load demand models for assessing electric load control actions, PowerTech, IEEE Bucharest 2009.

Karangelos, E.; Bouffard, F. (2012), Towards Full Integration of Demand-Side Resources in Joint Forward Energy/Reserve Electricity Markets, *IEEE Trans. on Power Systems*, 27 (1), 280 - 289.

Mohsenian-Rad, A.; Wong, V.W.S.; Jatskevich, J.; Schober, R.; Leon-Garcia, A. (2010), Autonomous Demand-Side Management Based on Game-Theoretic Energy Consumption Scheduling for the Future Smart Grid, *IEEE Trans. on Smart Grid*, 1 (3), 320-331.

Molina-Garcia, A.; Kessler, M.; Fuentes, J.A.; Gómez-Lázaro, E. (2012), Probabilistic Characterization of Thermostatically Controlled Loads to Model the Impact of Demand Response Programs, *IEEE Trans. on Power Systems*, 26 (1), 241 – 251.

Pedrasa, M.; Spooner, T.D.; MacGill, I.F., (2012), Scheduling of Demand Side Resources Using Binary Particle Swarm Optimization, *IEEE Trans. on Power Systems*, 24 (3), 1173 - 1181.