

Faculdade de Engenharia da Universidade do Porto



**Distribuição otimizada dos aparelhos de corte
telecomandados numa rede de distribuição de
Média Tensão**

Paulo Marques de Sousa

Dissertação realizada no âmbito do
Mestrado Integrado em Engenharia Electrotécnica e de Computadores
Major Energia

Orientador: Prof. Dr. José Rui Ferreira
Co-Orientador: Eng. Nina Clemente

Julho de 2009

Resumo

Com a crescente dependência energética do mundo verifica-se a necessidade de desenvolver aplicações computacionais para melhor organização e optimização das soluções de diversos problemas. No âmbito do planeamento de redes da EDP Distribuição existe a necessidade de tomar decisões racionais para que a gestão do capital esteja assegurada.

Sendo assim, nesta dissertação, são apresentados os resultados de um trabalho desenvolvido na EDP Distribuição, com o objectivo de obter uma nova metodologia de localização de aparelhos de corte telecomandados numa rede de Média Tensão de modo a evitar a tomada de decisões de forma empírica em relação à colocação dos mesmos.

Para obter soluções optimizadas foi utilizada uma técnica baseada em Algoritmos Genéticos, recorrendo a métodos de Nicho, uma vez que estes permitem ultrapassar os problemas apresentados pela rápida convergência da população dos Algoritmos Genéticos e consequentemente a possibilidade de convergência rápida para óptimos locais incapacitando-o de atingir o óptimo global.

O presente trabalho inclui, o levantamento das funcionalidades actuais, uma revisão ao estado da arte em relação ao problema da optimização de localização dos aparelhos de corte numa rede radial de Média Tensão, integrando um capítulo sobre Metodologias de Optimização, o funcionamento dos Algoritmos Genéticos e a Metodologia e solução adoptada bem como os resultados obtidos.

Abstract

With the growing world's energy dependence, there is a need to develop computer applications to organize and optimize better the solutions to several problems. In the ambit of the network planning of the EDP Distribuição there is a need to make rational decisions so that the capital management is assured.

In this sense, this dissertation presents the results of a work developed at EDP Distribuição, with a goal of obtaining a new methodology for the location of reclosers in a average tension network, in the sense of avoiding the decision making process in an empirical way in regard to the allocation of the respective devices.

In order to obtain optimized solutions was used a Genetic Algorithm based technique, more concretely the Niching method, because these allowing to overcome the problems presented by a quick convergence of the genetic algorithm population and consequently the inability to present the global optimum, remaining the solution in the local optimum.

The following work includes the study of the actual functionality, a revision to the state of art in regard to the problem of the optimization of the cut devices in an average tension radial network, it includes a chapter regarding the optimization methodologies, the functioning of the genetic algorithms and the methodology and adapted solution as well as the results obtained.

Agradecimentos

A realização desta dissertação só foi possível devido à contribuição directa ou indirectamente de diversas pessoas, a quem pretendo, desta forma demonstrar o meu mais reconhecido agradecimento.

Aos meus pais, pela educação e oportunidade de que me deram de poder estudar e pelo acompanhamento ao longo da minha vida.

Ao meu irmão João por manter o silêncio em momentos importantes.

À Joana pelo carinho, conforto e motivação não só durante a realização desta dissertação como ao longo de todo o curso.

À EDP Distribuição por me dar a oportunidade de desenvolver este trabalho nas suas instalações e a todos os seus colaboradores que nunca rejeitaram qualquer tipo de ajuda, e que me acolheram com todo o carinho. Nomeadamente à minha orientadora Eng.^a Nina Clemente, ao Eng.º Hélder Fonseca, Eng.º Jorge Ribeiro, Eng.º Oliveira, Eng.º Quintino e também ao Sr. Carlos por ter partilhado o seu gabinete comigo na maior parte do tempo e me guiar no processo de integração.

Ao meu orientador Professor Dr. José Rui Ferreira pela disponibilidade, apoio e sinceridade prestada durante a realização do trabalho.

A toda a minha família e aos meus amigos nomeadamente ao Ricardo Moreira, Luís Moreira e Márcio Oliveira pela amizade e companheirismo ao longo do curso e em especial ao Tiago Fernandes pela sua preciosa e fundamental ajuda no trabalho desenvolvido.

A todos o meu sincero obrigado...

Índice

Abstract.....	v
Agradecimentos	vii
Índice	viii
Lista de figuras	x
Lista de tabelas	xii
Abreviaturas e Símbolos	xiii
Capítulo 1	1
Introdução	1
1.1 Enquadramento	1
1.2 Motivação	2
1.3 Objectivos.....	2
1.4 Calendarização.....	3
1.5 Estrutura da dissertação.....	3
Capítulo 2	2
Levantamento dos Equipamentos e Funcionalidades Actuais	2
2.1 Automatismo VT (voltage-time).....	2
2.2 Equipamentos Instalados na Rede	7
2.2.1 IAR (Interruptores Auto - Religadores).....	7
2.2.2 OCR1 (Órgão de Corte de Rede - Tipo 1)	8
2.2.3 OCR2 (Órgão de Corte de Rede - Tipo 2)	9
2.2.4 DAR (Disjuntor Auto - Religador).....	10
2.2.5 Comparação das características técnicas	11
2.3 Cadeia de Valor do TCMT (Telecomando de Média Tensão).....	12
2.3.1 Validação Técnico - Económica de TCMT.....	13
2.3.2 Validação do Local do Telecomando	14
Capítulo 3	15
Estado da Arte.....	15
3.1 Heurística para localizar interruptores ou IARs	16
3.1.1 Exemplo para localização de interruptores em redes radiais.....	18
3.2 Sistema de Colónia de Formigas (Ant Colony System)	21
3.2.1 Resultados e Análises	25
3.3 Multiple - Population Genetic Algorithm (MPGA)	27

3.4	Método Computacional	29
3.5	Resultados e Análises	29
Capítulo 4	14	
Métodos de Optimização	14	
4.1	Introdução.....	14
4.2	Inteligência Artificial.....	32
4.2.1	Simulated Annealing.....	32
4.2.2	Algoritmos Genéticos.....	34
4.2.3	Ant Colony Optimization.....	35
4.2.4	Particle Swarm Optimization (PSO).....	35
Capítulo 5	30	
Algoritmos Genéticos.....	30	
5.1	Introdução.....	30
5.2	Implementação.....	38
5.3	Operações Básicas de um AG simples	39
5.3.1	Inicialização.....	40
5.3.2	Cálculo da Aptidão.....	40
5.3.3	Seleccção	40
5.3.4	Cruzamento (“crossover”).....	41
5.3.5	Mutação.....	42
5.4	Escolha dos parâmetros do AG	42
Capítulo 6	43	
Métodos de Niching.....	43	
6.1	Introdução.....	43
6.2	Pré-seleccção	44
6.3	Crowding	44
6.4	Deterministic Crowding.....	45
6.5	Fitness Sharing	45
Capítulo 7	47	
Metodologia Implementada	47	
7.1	Porquê o método de Crowding?	47
7.2	Modelização do problema	52
7.3	Resultados e Análises	53
7.4	Dificuldades.....	56
Capítulo 8	48	
Conclusões e Trabalhos Futuros	48	
Referências	48	

Lista de figuras

Figura 2.1- Princípio de Funcionamento do Automatismo VT[1].	6
Figura 2.2- Exemplo de um IAR instalado na rede MT[1]	8
Figura 2.3 - OCR1 instalados na rede de MT e sinóptico mecânico de indicação de estado (aberto ou fechado) [1].	9
Figura 2.4- Exemplo de OCR2 instalados na rede MT[1].	9
Figura 2.5 - DAR instalado na rede de Média Tensão[1].	10
Figura 2.6 - Valores de referência de órgãos de TCMT instalados na rede de EDPD[1]..	11
Figura 2.7- Cadeia de valor do TCMT[1].	12
Figura 3.1- Representação de uma rede com n nós, cargas nodais $P_1...P_n$, n ramos com naturezas e comprimentos distintos e com diferentes taxas de avarias[2].....	16
Figura 3.2- Duas localizações possíveis para o interruptor automático, A e B.[2]	17
Figura 3.3- Rede radial a 15KV. Esquerda: comprimentos em m. Direita: cargas médias em KW.[2]	18
Figura 3.4- Intervalos [Esquerda, Direita] calculados para o valor da END, pela colocação de um único interruptor num qualquer dos ramos da rede (resultados em MWh/ano)[2].	19
Figura 3.5 - Rede radial com Geração Distribuída[4].....	21
Figura 3.6- Fluxograma correspondente ao método ACS (<i>ant colony system</i>)[4].	22
Figura 3.7- Rede de teste[4].....	25
Figura 3.8- Resultados sem geração distribuída[4].	25
Figura 3.9- Resultados com geração distribuída=0,5MW[4].	26
Figura 3.10- Resultados com geração distribuída=1MW[4].	26
Figura 3.11 - Estrutura do método MPGA[5].	28
Figura 3.12 - Parâmetros do AG das sub - populações[5].	29

Figura 3.13 - Resultados sem geração distribuída [5].	30
Figura 3.14 - Resultados com geração distribuída=0,5MW [5].	30
Figura 3.15 - Resultados com geração distribuída=1MW [5].	30
Figura 4.1 - Estado desordenado das moléculas da matéria em fusão.	33
Figura 4.2 - Estado desordenado das moléculas devido a um arrefecimento rápido.	33
Figura 4.3 - Estado ordenado das moléculas devido a um arrefecimento lento.	33
Figura 5.1- Estrutura básica de um AG simples [14]	39
Figura 5.2 - Resultado do cruzamento entre dois cromossomas[12].	41
Figura 7.1 - Gráfico da função $G(x)$ [12]	49
Figura 7.2 - Algoritmo do método determinístico de crowding [12].	51
Figura 7.3 - Representação de um indivíduo.	52
Figura 7.4 - Representação da rede em estudo extraída do software DPLAN.	53
Figura 7.5 - Esquema equivalente da rede de teste.	54
Figura 7.6 - Cálculo da rentabilidade do sistema para a Solução1	55
Figura 7.7 - Exemplo de uma rede	56

Lista de tabelas

Tabela 1.1 - Calendarização	3
-----------------------------------	---

Abreviaturas e Símbolos

ACS	Ant Colony System
AI	Inteligência Artificial
DAR	Disjuntor auto - religador
DG	Geração Distribuída
EDPD	Energias de Portugal Distribuição
END	Energia não distribuída
IAR	Interruptor auto - religador
IAT	Interruptor aéreo telecomandado
MT	Média Tensão
OCR1	Órgão de corte de rede tipo1
OCR2	Órgão de corte de rede tipo2
OCR3	Órgão de corte de rede tipo3
PSO	Particle Swarm Optimization
RND	Rede Nacional de Distribuição
SA	Simulated Annealing
TCMT	Telecomando de média tensão
TIEPI	Tempo de interrupção equivalente da potência instalada
VT	Voltage Time

Capítulo 1

Introdução

1.1 Enquadramento

As interrupções de distribuição de energia eléctrica na rede de distribuição impõem custos avultados à sociedade, quer por interrupção do fluxo normal das actividades económicas, quer por indisponibilidade momentânea do fornecimento a serviços primários, como serviços hospitalares, industriais ou utilizações domésticas.

Sendo natural uma certa susceptibilidade na avaria de qualquer elemento da rede, o alcance de uma maior fiabilidade e qualidade de serviço implica importantes investimentos por parte da empresa concessionária da rede, em novas linhas, transformadores, automatismo e telecomando da rede, entre outros na procura de uma rede “redundante¹”.

Globalmente, a EDP Distribuição prevê explorar os ganhos de fiabilidade com a instalação de telecomando, uma vez que ainda existe uma margem significativa de retorno para a sua utilização sabendo-se, no entanto, que o potencial de ganhos tende a diminuir progressivamente com a sua implementação.

Tendo em conta estes aspectos, a EDP Distribuição propôs a realização deste trabalho no qual se pretende desenvolver uma aplicação computacional para identificar uma solução optimizada para o problema de distribuição de aparelhos de corte telecomandados na rede de Média Tensão (MT).

¹ Na possibilidade de avaria de um qualquer elemento, este torna-se desnecessário/redundante para o correcto funcionamento do sistema. É usual a referência a uma rede com redundância “N-1”, sendo N o número de elementos que a compõem e 1 o elemento avariado.

1.2 Motivação

Até ao momento, apesar de já terem sido efectuadas tentativas para que se alterassem as metodologias, a identificação do melhor local para instalação dos aparelhos de corte telecomandados na rede de distribuição de Média Tensão (MT) segue um modelo empírico, no qual se adopta a “filosofia” de colocar os aparelhos sensivelmente a meio da rede de distribuição, de tal forma que um determinado incidente a jusante do mesmo não afecte os consumidores que estão a montante, garantindo assim que a rede não seja completamente colocada fora de serviço contribuindo deste modo para uma maior qualidade e fiabilidade de serviço.

O telecomando na rede de MT tem por objectivo a redução da Energia não Distribuída (END) e do Tempo de Interrupção equivalente da Potência Instalada (TIEPI) da Rede Nacional de Distribuição (RND), bem como, contribuir adicionalmente para o aumento da flexibilidade da rede MT.

1.3 Objectivos

O objectivo desta dissertação é então encontrar uma metodologia de optimização para a localização dos OCR's (órgão de corte de rede) telecomandados de modo a que seja minimizada a END (Energia não Distribuída) não descurando o factor da rentabilidade da solução.

Para tal, foi desenvolvido um método de optimização baseado em Algoritmos Genéticos sendo para tal desenhadas algumas funções em c++, que, se adicionaram a um Algoritmo Genético (Método de Crowding) já testado, para se atingir o objectivo proposto.

Dada a elevada quantidade de informação inerente a este tema, sentiu-se a necessidade de o subdividir em múltiplas tarefas, tais como:

- Análise da rede de MT (DPLAN);
- Indicadores de Qualidade de Serviço;
- Análise de metodologias de optimização existentes;
- Funcionalidades dos Algoritmos Genéticos;
- Métodos de Nicho;
- Cálculo de Energia não Distribuída (END) em redes de distribuição;
- Rentabilidade da solução.

1.4 Calendarização

Numa tentativa de realizar uma correcta gestão do tempo disponível para a realização deste trabalho, foi elaborado um esquema de calendarização, apresentado na Tabela 1.1.

Tabela 1.1 - Calendarização

ID	Nome das Etapas	Início	Fim	Duração					Abril				Maio				Junho							
					9	16	23	30	6	13	20	27	4	10	18	24	1	8	15	22	29			
1	Redes de Distribuição - O caso da EDP	09-03-2009	16-03-2009	1 semana																				
2	Princípios de Planeamento e aplicativos disponíveis	16-03-2009	30-03-2009	2 semanas																				
3	Conceitos básicos sobre TCMT	30-03-2009	06-04-2009	1 semanas																				
4	Análise de diferentes metodologias de TCMT	06-04-2009	20-04-2009	2 semanas																				
5	Critérios de condução e aplicativos disponíveis	20-04-2009	04-05-2009	2 semanas																				
6	Desenvolvimento de método de optimização	10-05-2009	29-06-2009	9 semanas																				
7	Elaboração do relatório	24-05-2009	29-06-2009	6 semanas																				

1.5 Estrutura da dissertação

Este documento está organizado em 8 Capítulos. No presente Capítulo, Introdução, descreve-se de uma forma sucinta os objectivos do trabalho o seu enquadramento, a motivação, a calendarização e estruturação da tese.

No segundo Capítulo, é feita uma abordagem às funcionalidades e equipamentos disponíveis na EDP bem como os seus automatismos.

No terceiro é feito um estudo sobre o “Estado da Arte” referindo-se a diversas metodologias existentes no âmbito da optimização de localização para aparelhos de corte bem como as suas características.

O quarto Capítulo comporta os diferentes Métodos de Optimização, demonstrando algumas das soluções possíveis para a realização do trabalho.

No quinto Capítulo é feita uma abordagem aos Algoritmos Genéticos (AG) e à forma como estes são estruturados, bem como a sua funcionalidade e características.

O sexto Capítulo introduz uma variante dos AG que se intitulam por métodos de Nicho. É então feita uma pequena abordagem a estes métodos e referidos alguns dos mais importantes, nomeadamente o Método de Crowding.

O sétimo Capítulo expõe toda a metodologia e estratégia adoptada na realização deste trabalho bem como os resultados obtidos.

Por fim, o oitavo Capítulo apresenta as principais conclusões e reflexões referentes ao trabalho realizado.

Capítulo 2

Levantamento dos Equipamentos e Funcionalidades Actuais

A inserção de órgãos de telecomando na rede eléctrica de média tensão da EDP Distribuição SA, remonta ao final da década de 90, com o objectivo de poder flexibilizar a sua exploração, quer em situação de avarias quer em manobras programadas.

Esta política de investimento está associada a uma inequívoca melhoria da qualidade de serviço prestada aos clientes e ao aumento da eficiência de meios disponíveis para gestão da rede. Segue-se então neste capítulo, alguns dos principais equipamentos e funcionalidades que existem actualmente na EDP. [1]

2.1 Automatismo VT (voltage-time)

Qualquer automatismo pressupõe a capacidade de controlar um processo, tomando decisões segundo uma programação prévia e sem intervenção humana.

A compreensão do funcionamento dos equipamentos instalados para telecomando da rede implica a compreensão do funcionamento do automatismo VT, que serviu de base à implementação dos mesmos.

Intrínsecamente associado ao automatismo VT, temos o automatismo de religação (ou função de religação), que se destina eliminar da rede AT e MT defeitos fugitivos ou semi-permanentes através de manobras sucessivas de ligar e desligar o disjuntor associado à linha, procurando assegurar a reposição de serviço sem intervenção do pessoal operador.

Esta função foi assegurada por relés electromagnéticos ou electrónicos denominados “religadores”, sendo que hoje em dia é assegurada pela RTU (remote terminal unit) ou pelos IED (intelligent electronic devices).

Existem diferentes programas de religação possíveis, constituindo diferentes ciclos de religação: a **religação rápida (RR)**, que comporta o disparo instantâneo do disjuntor (por acção da protecção associada), seguido de uma religação; e a **religação lenta (RL)**, que comporta o disparo do disjuntor e sua religação temporizados.

Combinando diferentes ciclos de religação, geram-se diferentes programas de religação possíveis, nomeadamente:

- Sem religação;
- 1 RL
- 2 RL
- 1 RR
- 1 RR + 1 RL
- 1 RR + 2 RL

A figura 2.1 serve então de base para a explicação do princípio de funcionamento do automatismo VT:




Figura 2.1- Princípio de Funcionamento do Automatismo VT[1].

Como se pode constatar através da figura anterior, tendo como referência um órgão de corte instalado na rede, na posição de fechado, a detecção de falha de tensão a montante do mesmo, (por abertura do disjuntor ou de outro órgão de corte), provoca o envio da ordem de abertura para o órgão, após o tempo t_0 (confirmação da falha de tensão).

Detectando-se o reposição de tensão é lançado um temporizador t1 (tempo de fecho), que ultrapassado provoca o fecho do órgão de corte. A partir desse instante, é lançado um temporizador t2 (tempo de vigilância) durante o qual, nova falha de tensão e consequente abertura do órgão de corte, provoca o bloqueio da função.

Para desbloquear a função de automatismo é necessário dar uma ordem de desbloqueio local ou à distância.

Caso não exista um programa com duas religações lentas associadas, o automatismo VT não irá desempenhar as suas funções. Este automatismo é também independente do regime de neutro associado à subestação, sendo por isso considerado “universal”.

2.2 Equipamentos Instalados na Rede

A instalação de órgão de telecomando tem acompanhado a evolução da indústria visando uma maior eficácia na delimitação de troços de rede com avaria, pela diminuição da extensão da rede a pesquisar.

2.2.1 IAR (Interruptores Auto - Religadores)

Os primeiros órgãos a serem instalados na rede de média tensão foram os IAR. Estes destinavam-se a colocar fora de serviço troços de linhas que devido às suas características fossem susceptíveis de ser causadoras de avarias.

O princípio de funcionamento baseia-se na função de automatismo VT descrita anteriormente. Quando ocorre o disparo do disjuntor da linha da subestação dá-se a actuação de uma bobine de falha de tensão e o IAR abre. Após a religação do disjuntor, um temporizador retarda o fecho do IAR, podendo verificar-se uma de duas situações:

- Se o disjuntor da linha voltar a disparar antes do IAR fechar, existe uma avaria a montante do IAR;
- Se o temporizador cumprir o tempo programado com a linha em tensão, o IAR liga; ao ligar, se o disjuntor na subestação não voltar a disparar, estamos perante um defeito fugitivo; se o disjuntor na subestação disparar, o IAR bloqueia na posição de aberto e temos uma avaria a jusante do IAR.

As primeiras unidades instaladas não eram providas de telecomando, pelo que após um ciclo de religações, era necessário mobilizar equipas de assistência à rede para confirmar o estado do órgão e pesquisar avarias a jusante, caso se confirmasse o bloqueio.

Investimentos posteriores permitiram criar condições de telecomando, a partir dos centros de condução, passando estes órgãos a serem designados por IART (interruptores auto-religadores telecomandados).



Figura 2.2- Exemplo de um IAR instalado na rede MT[1]

2.2.2 OCR1 (Órgão de Corte de Rede - Tipo 1)

O OCR1 é um dispositivo caracterizado por invólucro integralmente selado, contendo no seu interior hexafluoreto de enxofre que lhe confere qualidades excepcionais como meio dieléctrico e extintor do arco eléctrico. O seu nível de isolamento eléctrico consegue garantir a informação mecânica inequívoca do seu estado (aberto ou fechado) e a possibilidade de encravamento na posição de aberto, prescindindo assim da montagem de um seccionador associado.

Este aparelho deverá ser preferencialmente instalado nas fronteiras das linhas de média tensão (pontos de recurso da rede) uma vez que suporta uma menor corrente de curto-circuito do que o IAR, razão pelo qual devem ser evitadas manobras de fecho sobre defeitos.

É possível manobrar manual ou electricamente este órgão, sendo que as manuais podem ser feitas directamente através de uma vara de manobra fixa no apoio, até uma altura de 25 metros. Um sinóptico mecânico ligado directamente ao veio principal do aparelho indica claramente o seu estado (aberto ou fechado) e é visível para quem está no solo.

Quando intercalado com a rede na posição de fechado tem a possibilidade de ser dotado com três transformadores de corrente que sinalizam a passagem de defeito, enviando informação para o centro de condução, permitindo identificar o local da avaria.



Figura 2.3 - OCR1 instalados na rede de MT e sinóptico mecânico de indicação de estado (aberto ou fechado) [1].

2.2.3 OCR2 (Órgão de Corte de Rede - Tipo 2)

A designação deste OCR, tipo2, difere da anterior pelo facto de este suportar correntes de curto-circuito, possuindo características eléctricas muito semelhantes às do IAR.

Este aparelho possui uma distância entre pólos, na posição de aberto, que não lhe confere um nível superior de isolamento, podendo em presença de sobretensões acentuadas, verificarem-se escorvamentos entre os pólos. Necesita então de ter associado um seccionador que garanta o corte visível, em intervenções na rede.

De referir que, estes aparelhos são hoje em dia os mais utilizados na rede de MT, no entanto estão a ser feitos estudos de viabilidade para um novo tipo de OCR - tipo 3.



Figura 2.4- Exemplo de OCR2 instalados na rede MT[1].



Figura 2.5 - DAR instalado na rede de Média Tensão[1].

2.2.4 DAR (Disjuntor Auto - Religador)

O DAR é um aparelho aéreo que funciona de forma integrada com uma protecção e uma função de automatismo associada, e que tem a particularidade de promover um ciclo de religações após a detecção de um defeito. O DAR, contrariamente ao IAR, não necessita de “sentir” a ausência de tensão para abrir, mas sim, depende da protecção associada ou de uma ordem manual ou por telecomando.

Caso o ciclo de religações de cumpra e o defeito permaneça, o DAR fica na posição de aberto e com informação de bloqueio ao religador. Caso o defeito desapareça (defeito fugitivo), o DAR normaliza a alimentação das cargas a jusante[1].

2.2.5 Comparação das características técnicas

Depois de uma breve descrição de alguns dos aparelhos de corte existentes vai ser feita uma breve comparação das suas principais características, figura 2.6:

	IAR		OCR 1	OCR 2	DAR
Tensões estipuladas (kV)	17,5	36	12 / 17,5 / 36	15,5/27/38	15,5/27/38
Corrente nominal (A)	400	200	400	560	560
Frequência da rede (Hz)	50				
Poder de fecho (kA/v. pico)	31,5	20	20	30	21,5
Corrente de curta duração (kA/v. pico)	31,5	20	20	30	21,5
Tensão auxiliar de alimentação (V) [TT/ST]	120/-		120/230		
Mecanismo de fecho	actuadores eléctricos		actuadores mecânicos	actuadores magnéticos	actuadores magnéticos
Tempo de actuação	abertura (s)		1,800 - 13,000	4,800 - 9,800	0,030
	fecho (s)		3	2,100 - 6,100	0,040
Meio de corte	vácuo		8Fs	vácuo	vácuo
Meio isolante	vácuo		8Fs		disco
Peso (kg)	120		90	120	360/380/490

Figura 2.6 - Valores de referência de órgãos de TCMT instalados na rede de EDPD[1]..

Os valores dos tempos de actuação (abertura e fecho) correspondem a valores de referência dos tempos de actuação dos equipamentos que se encontram instalados na rede de MT da EDP Distribuição.

O OCR1, é o único que é dotado de encravamentos que possibilitam a sua montagem sem a necessidade de instalação de um seccionador associado, para garantir o corte aparentemente visível. Este facto, aliado ao seu pouco peso, faz do OCR1, o equipamento de mais fácil montagem e cujos custos são menores.

Contrariamente ao OCR1, os restantes tipos de equipamentos (IAR, OCR2 e DAR) necessitam da instalação de um seccionador adequado, para garantir o corte visível.

Para além destas diferenças, existe outra significativa, relativa ao nível de mecanismo de fecho que se prende com o facto de os OCR1 terem um considerável gasto de energia

associado, inerente à utilização de actuadores mecânicos, comparativamente aos actuadores magnéticos utilizados nos OCR2. Em situação de avaria e havendo falha de alimentação normal aos aparelhos, os OCR2 conseguem efectuar mais manobras de abertura e fecho, apoiados apenas nas baterias.

2.3 Cadeia de Valor do TCMT (Telecomando de Média Tensão)

O projecto de instalação de aparelhos de corte telecomandados visa rentabilizar e tornar mais eficiente a rede de distribuição, contribuindo para uma reposição de serviço mais célere em regimes perturbados, com a consequente melhoria dos índices de qualidade de serviço.

São várias as fases de um projecto de TCMT até à sua concretização. Na figura 2.7 destacam-se aquelas que poderão ser as mais relevantes para a compreensão do processo. Porém, irá ser abordada apenas uma das fases, dado que é a que diz directamente respeito ao trabalho em estudo.




Figura 2.7- Cadeia de valor do TCMT[1].

2.3.1 Validação Técnico - Económica de TCMT

A instalação de aparelhos para o telecomando da rede MT é validada com base numa análise técnico-económica, em que se calcula o ganho em energia não distribuída obtido com a sua inserção, comparando-o com o custo de investimento associado.

Para o cálculo da END (Energia não Distribuída) é considerada, a taxa média de avarias na linha, o seu comprimento, a potência que o novo OCR pode “defender”, e o tempo médio de reposição.

A fórmula de cálculo do ganho anual em END é definida por 2.1:

$$END = \lambda \times L \times t \times (P_{m\acute{a}x} \times f.u) \quad (2.1)$$

↓
Potência Média

Em que:

λ - Taxa de avarias (km/ano)

L- Comprimento do troço avariado (Km)

t- tempo médio ganho na reposição de serviço (h)

$P_{m\acute{a}x}$ - Potência de ponta não cortada (kW)

f.u- Factor de utilização de carga

O cálculo da END é inicialmente feito para o 1º ano em estudo, sendo depois generalizado para os anos seguintes através da afectação das taxas de crescimento das cargas das zonas em análise, isto é, consideram-se todos os parâmetros constante ao longo do período de estudo à excepção da potência não cortada, que vai aumentando com o crescimento de cargas.

De referir que a valorização dos ganhos em END é presentemente efectuada a 1,50 EUR/kWh[1].

2.3.2 Validação do Local do Telecomando

A validação do telecomando da rede aérea de média tensão deve no entanto ir para além de uma simples avaliação económica, sendo que esta deverá estar sempre presente. Por ser uma análise simulada, produzirá resultados próximos do óptimo, logo a sua adequação à realidade da rede carece de integrar outros factores. Fundamentalmente a validação do local de inserção do órgão para telecomando deve suportar-se em cinco factores de análise:

- Validação do local, suportada na análise benefício - custo;
- Análise da representatividade das cargas “defendidas” pela inserção do órgão;
- Validação do sinal de comunicação, porque sem este, não existe telecomando na rede;
- Extensões de rede significativas geográficas de difícil acesso;
- Acessibilidade ao local de instalação, garantida de forma eficiente, para serem possíveis acções de manutenção e manobras locais caso falhe o telecomando, sem necessitar de depender de terceiros.

Capítulo 3

Estado da Arte

Neste Capítulo, é feita uma pesquisa bibliográfica, onde serão abordados alguns exemplos de aplicações já desenvolvidas sobre a localização dos aparelhos de corte telecomandados na rede de distribuição.

Inicialmente, será dado um exemplo de um método que não necessita de recorrer a inteligência computacional.

Seguidamente será feita uma abordagem aos métodos computacionais usando inteligência computacional com especial ênfase para a utilização de Algoritmos Genéticos.

3.1 Heurística para localizar interruptores ou IARs

De acordo com [2], pode-se criar um modelo de decisão para uma rede radial com cargas nodais distintas e ramos de diversos tipos e comprimentos, tal como representa a figura 3.1. Considere-se que um aparelho de corte será sempre colocado no extremo montante de um ramo.

“Para facilitar a notação, adopta-se a seguinte notação, para qualquer variável $X(=\lambda,=P)$ distribuída entre os pontos a e b (incluindo todas as derivações ou ramais)”:




Figura 3.1- Representação de uma rede com n nós, cargas nodais $P_1...P_n$, n ramos com naturezas e comprimentos distintos e com diferentes taxas de avarias[2].

A energia média anual não fornecida E_0 numa rede sem interruptor é dada por:

$$E_0 = \lambda_1^n r P_1^n \quad (3.1)$$

e com um aparelho localizado no ramo $k-1/k$ é dada por:

$$E_s = \lambda_1^{k-1} r P_1^n + \lambda_k^n S P_1^n + \lambda_k^n r P_k^n \quad (3.2)$$

em que as parcelas representam respectivamente:

- A energia não fornecida em resultado de avarias na rede entre a subestação e o interruptor, cortando todos os consumidores, durante a reparação da mesma.
- A energia não fornecida em resultado de avarias na rede a jusante do interruptor, cortando todos os consumidores, durante o tempo de manobra daquele.

- A energia não fornecida em resultado de avarias na rede a jusante do interruptor, cortando todos os consumidores a jusante do interruptor, durante a reparação da mesma.

“Portanto, a melhor localização para um interruptor será onde a diferença $E_s - E_0$ for maximizada, dando:

$$\text{Max } E_s - E_0 = \lambda_k^n [rP_1^{k-1} - SP_1^n] \quad (3.3)$$

Esta é uma expressão muito simples, a ser calculada em cada nó montante de cada ramo da rede. Se $S \approx 0$, correspondendo a desprezar os tempos de manobra face aos tempos de reparação, a lógica de optimização é $\text{Max } \lambda_k^n P_1^{k-1}$ (3.4) que corresponde ao ponto onde o produto da taxa total de avarias da rede após o interruptor pela carga total antes do interruptor.

O “trade-off” entre não ter um interruptor e instalar um interruptor é dado, em €/MWh, por:

$$\tau = \frac{\text{custo do interruptor}}{E_s - E_0} \quad (3.5)$$

Se a rede radial tem características mais ou menos uniformes, tal como ser composta totalmente por linhas aéreas, pode admitir-se que a taxa de avarias por km é constante e igual a λ . Nesse caso, este valor pode ser posto em evidência e as taxas de avaria de cada troço podem ser substituídas pelos respectivos comprimentos L_k . Nesta situação, a busca resume-se ao ponto onde é máximo o produto do comprimento da rede após o interruptor pela carga total antes do interruptor”.

Isto justifica que, em situações como as da figura seguinte, a escolha correcta localize o interruptor na raiz das sub-árvores com cargas fracas e grandes comprimentos de linha [2].




Figura 3.2- Duas localizações possíveis para o interruptor automático, A e B.[2]

Obviamente, B é a melhor escolha, maximizando o produto da carga antes (10P) pelo comprimento após (10L), enquanto em A se obtém apenas PL.

Para decidir a localização de um segundo e 3º aparelho, pode seguir-se uma heurística de otimização local da seguinte forma:

- Encontrar o melhor local para o primeiro aparelho;
- Considerando esse local fixo, determinar a localização do segundo melhor aparelho de acordo com os mesmos princípios;
- Considerando os dois primeiros aparelhos fixos, determinar a localização do seguinte aplicando ainda os mesmos princípios.

Esta estratégia é independente dos valores das taxas de avaria e tempos de reparação.

3.1.1 Exemplo para localização de interruptores em redes radiais

“O exemplo seguinte baseia-se em incertezas de natureza intervalar, de forma a tornar claro e ajudar à compreensão dos conceitos. As técnicas utilizadas são todavia válidas quando se adoptam representações mais sofisticadas para as incertezas nos valores, como seja a utilização de números difusos”.




Figura 3.3- Rede radial a 15KV. Esquerda: comprimentos em m. Direita: cargas médias em KW.[2]

A figura anterior representa uma rede radial de 15KV, assinalando os comprimentos de cada ramo e as cargas nodais médias. Admitiremos que a taxa de avarias das linhas, por unidade de comprimento, é dada por um intervalo da forma $\lambda = [0.001, 0.011]/\text{km.ano}$, e que a estimativa de cargas está igualmente afectada de uma incerteza, representada pelo produto dos valores médios da figura pelo intervalo $[0.9, 1]$. Do mesmo modo, os tempos médios de reparação são admitidos como incertos, dados por um intervalo $r = [10, 20]\text{h}$.

Com a aplicação do Método de análise de Monte Carlo e o cálculo para cada ramo $\lambda_k \cdot r_k \cdot P_k = 1$ conduz ao resultado apresentado na figura 3.4:




Figura 3.4- Intervalos [Esquerda, Direita] calculados para o valor da END, pela colocação de um único interruptor num qualquer dos ramos da rede (resultados em MWh/ano)[2].

“Pode-se observar que existem dois importantes locais candidatos à localização do aparelho de corte de seccionamento (admitindo junto do extremo montante de cada ramo). Os intervalos para a diminuição do valor da END devido à adição de um aparelho na rede são, para as duas localizações, A [2.493 , 5.796] e B [2.389 , 5.839] MWh/ano.

Embora sejam valores parecidos, notamos que a gama de incerteza para A está contida na gama encontrada para B. Esta, é já uma constatação interessante, mostrando que a simples consideração de intervalos em vez de simples números ocasiona a percepção de muito mais informação sobre as implicações de cada decisão”.

Se fosse aplicado o critério TDC² (Total Distance Criterion) a ambos os intervalos de END, com o parâmetro $\alpha=0.5$, obtinham-se os valores “colapsados” $A=4.125 > B=4.114$, com o significado de que a localização em A deveria ser preferida marginalmente.

Sendo assim, que valor de trade-off deverá ser encarado para que se possa tomar a decisão de instalar um aparelho?

Admita-se que o custo do aparelho e sua instalação tem uma incerteza traduzida por $[13000; 17000]$ €. Então, pode-se dividir a variação no investimento pela variação na END e obter:

$$\tau = \frac{[13000; 17000]}{[2.493; 5.756]} = [2259; 6819] \text{ €/MWh.year} \quad (3.6)$$

“Se por acaso a empresa adopta-se uma política para os investimentos em fiabilidade por forma a estimular uma eficiência no uso do capital superior a 8000€ por MWh (ou seja, que se deve gastar menos que 8000€ por cada MWh que se consegue reduzir de END), então a opção de introduzir o equipamento estaria bem justificada, independentemente do jogo das incertezas. Todavia, se o valor de trade-off de referência tiver sido fixado em 5000€, então aparece um risco associado à decisão - por outras palavras, há uma margem para um possível arrependimento de 1819€/MWh. Por outro lado, se a estimativa dos índices de fiabilidade e cargas tiver sido optimista e a estimativa dos custos tiver sido conservadora, então a opção pelo aparelho é claramente acertada. Que decidir?

Depende então da aversão ao risco. Para $\alpha=0.5$ (atitude neutral), o critério TDC coloca o trade-off para a decisão de instalar bem abaixo do limiar de 5000€, portanto, a decisão será de investir e correr os riscos [2]”.

² Com o intuito de incluir a influência da aversão ao risco na ordenação de números difusos, Saade propôs o critério TDC (Total Distance Criterion). No qual, para um número geral trapezoidal $[a,b,c,d]$, o valor “colapsado” A, dado pelo TDC é:

$$A = \alpha \frac{a+b}{2} + (1 - \alpha) \frac{c+d}{2} \quad (3.7)$$

Onde α é um parâmetro relacionado com a aversão ao risco - onde se pode atribuir maior ou menor importância pela adequada fixação do valor α no intervalo $[0,1]$.

3.2 Sistema de Colônia de Formigas (Ant Colony System)

Um conceito que tem vindo a ser mais utilizado na procura da melhor localização para instalação dos aparelhos de corte telecomandados é o sistema de Colônia de Formigas (ACS)[3]. Esta técnica simula o comportamento de um conjunto de agentes que cooperam para resolver um processo de optimização por meio de comunicações muito simples.

As formigas parecem conseguir encontrar o seu caminho (da colónia para uma fonte de comida e regresso, ou ao redor de um obstáculo) com relativa facilidade usando uma comunicação química através de ferómonas. Estas, depositam uma certa quantidade de ferómona no seu caminho, tornando esse caminho mais desejável para outras formigas.

No exemplo seguinte é abordado o problema de optimização englobando redes com geração distribuída (DG) avizinhand-se uma ligeira complicação no problema. Usualmente, é difícil localizar os pontos óptimos para a localização dos aparelhos de corte telecomandados sendo que, para isso propõem-se a utilização do ACS (ant colony system) para atingir este objectivo aumentando a fiabilidade do sistema.




Figura 3.5 - Rede radial com Geração Distribuída[4].

O algoritmo usado neste problema de otimização é apresentado no fluxograma seguinte e devidamente detalhado:




Figura 3.6- Fluxograma correspondente ao método ACS (*ant colony system*)[4].

- **Inicialização da produção das formigas:** As posições iniciais das formigas e os níveis de ferónomas são criados. O número de aparelhos de corte e de geradores distribuídos são especificados.
- **Avaliação da *fitness*:** É feita segundo (3.10) que significa o valor de *fitness* de cada cenário de localização do aparelho de corte de acordo com a fiabilidade do sistema.
- **Despacho:** As formigas são despachadas baseando-se no nível de ferónoma e na distancia. Como se pode ver em (3.11)(3.12), cada formiga escolhe o próximo movimento considerando os valores de τ_{ij} e η_{ij} .

- Se $q > q_0$, selecciona o próximo estado aleatoriamente com a seguinte probabilidade:

$$p_{ij}^k = \frac{[\tau_{ij}][\eta_{ij}]^{\beta}}{\sum_{u \in J_2^k} [\tau_{iu}][\eta_{iu}]^{\beta}} \quad (3.8)$$

- Se $q \leq q_0$, selecciona o próximo estado procurando o melhor perfil ferónoma-distância:

$$\text{Maximum: } [\tau_{ij}][\eta_{ij}]^{\beta} \quad (3.9).$$

O ferónoma de um caminho visitado pode ser dinamicamente ajustado usando (3.12).

Depois de algumas iterações todas as formigas completam a sua viagem e ao menor caminho encontrado por estas será permitido actualizar o seu ferónoma baseado na expressão (3.13) que corresponde à melhor configuração para os aparelhos de corte.

- **Critério de paragem:** O processo não termina até que o número de iterações atinja o valor especificado ou que o valor da função objectivo fique estagnado. O melhor caminho escolhido de entre todas as iterações corresponde ao desejado esquema de configuração dos aparelhos de corte, isto é, a solução óptima do problema[4].

$$C = W_{saift} \frac{saift}{saiftT} + W_{saidi} \frac{saidi}{saidiT} \quad (3.10)$$

para $q > q_0$:~

$$P_{ij}^{xy}(t) = \frac{[\tau_{ij}^{xy}(t)][\eta_{ij}^{xy}]^{\beta}}{\sum_{j \in \text{stagey}} [\tau_{ij}^{xy}(t)][\eta_{ij}^{xy}]^{\beta}} \quad (3.11)$$

para $q \leq q_0$:

$$\arg \max_{j \in \text{stagey}} \{[\tau_{ij}^{xy}(t)][\eta_{ij}^{xy}]^{\beta}\}$$

$$\tau_{ij}^{xy}(t+1) = [\rho \times \tau_{ij}^{xy}(t)] + \tau_{ij}^{xy(0)} \quad (3.12)$$

$$\tau_{ij}^{xy}(t+1) = [\tau_{ij}^{xy}(t+1)] + \frac{k_{pher}}{C(\Omega_k^{(t)})}, x, y \in \Omega_k^{(t)} \quad (3.13)$$

Legenda:

C - índice de fiabilidade

Wx - corresponde ao peso associado

XT - O parâmetro T corresponde ao valor alvo

τ_{ij}^{xy} - Intensidade do ferónoma do caminho

η_{ij}^{xy} - Redução do índice de fiabilidade (C) entre o caminho x e y

$C(\Omega_k^{(t)})$ - Avaliação da *fitness*

3.2.1 Resultados e Análises

O método anteriormente descrito, foi testado de acordo com rede que seguidamente se apresenta:




Figura 3.7- Rede de teste[4].

Os parâmetros usados para esta simulação encontram-se em [4]. Dos quais se obteve os seguintes resultados que são importantes de referir.

Number of reclosers	Reliability index value	Recloser locations
1	3.9560	8-9
2	2.8695	8-9, 30-31
3	1.9012	3-4, 30-31, 47-48
4	1.6042	3-4, 27e-28e 30-31, 47-48
5	0.9033	3-4, 11-12, 30-31, 47-48, 28e-65

Figura 3.8- Resultados sem geração distribuída[4].

Number of reclosers	Reliability index value	Recloser locations
1	3.5022	8-9
2	2.3341	8-9, 28-29
3	1.7432	8-9, 27-28, 50-51
4	1.1987	3-4, 30-31, 47-48, 66-67
5	0.7100	4-5, 10-11, 30-31, 47-48, 67-68

Figura 3.9- Resultados com geração distribuída=0,5MW[4].

Number of reclosers	Reliability index value	Recloser locations
1	3.3012	8-9
2	2.1455	8-9, 49-50
3	1.5066	4-5, 27e-28e, 47-48
4	1.034	8-9, 28-29, 36-37, 49-50
5	0.5988	3-4, 10-11, 30-31, 49-50, 67-68

Figura 3.10- Resultados com geração distribuída=1MW[4].

Pode então, com base nos resultados obtidos, observar-se que, para uma dada capacidade de geração distribuída a fiabilidade do sistema aumenta à medida que se aumentam o número de aparelhos de corte instalados.

Para um mesmo número de aparelhos, pode-se constatar que quanto mais geração distribuída existir maior será também a fiabilidade do sistema.

No caso da existência de apenas um aparelho para ser instalado, este deve colocar-se o mais próximo possível do centro da rede, para que, e assumindo que as cargas estão uniformemente distribuídas, seja alcançado um aumento da fiabilidade em cerca de 25%.

Aumentando o número de aparelhos disponíveis, alguns ramos tornam-se particularmente importantes para aumentar a fiabilidade do sistema. Veja-se por exemplo o ramo entre o barramento 47 e 48 que é um ponto crucial.

Com o método exposto (ACS) conseguiu-se provar que, tanto a localização dos aparelhos de corte como a selecção apropriada da capacidade de geração distribuída, são ambos muito importantes para se assegurar uma boa fiabilidade do sistema [4].

No entanto, existem algumas limitações que baixam a fiabilidade do referido método. Por exemplo, o ACS tem alguma dependência nos pontos iniciais e uma combinação eficiente dos diferentes parâmetros requerem algum tempo para se sintonizarem. Por sua vez, não tem qualquer tipo de limitação ao lidar com problemas de maior dimensão devido às suas características de procura estocástica. Pode demorar mais tempo para convergir devido à avaliação de várias soluções potenciais, porém este tempo não é tão extenso como nos métodos analíticos, uma vez que a eficiência computacional é relativamente insensível à complexidade e tamanho do sistema[5].

3.3 Multiple - Population Genetic Algorithm (MPGA)

Neste método utiliza-se também, para procura da localização óptima dos OCR's, os Algoritmos Genéticos (AG).

Segundo [5], os indivíduos que irão ser escolhidos para produzir a próxima solução são escolhidos com base em processos de selecção, que tem pesos através dos indivíduos mais fortes, introduzindo uma pressão selectiva na população caminhando para uma solução óptima.

As propriedades de convergência do AG tradicional, podem ser fortemente influenciadas pelos seus parâmetros:

- Probabilidade de crossover (pc) - Determina a taxa a que as novas soluções são introduzidas na população.
- Probabilidade de mutação (pm) - Para evitar que o Algoritmo fique preso num óptimo local. Para isso são introduzidos diferentes genes aleatoriamente na população.

De acordo com [5], quanto maior for (pc) e (pm), melhor é o rendimento das novas soluções em cada geração. No entanto, o melhor modelo genético é destruído facilmente e a taxa de convergência será lenta.

Quanto menor forem os referidos parâmetros pode-se atingir um melhor modelo genético, porém podem não introduzir as suficientes diferenças e o sistema convergir para um mínimo local.

O tamanho da população não pode ser muito pequeno pois pode não reter as diversas variedades genéticas no processo de geração para geração.

Por outro lado, uma população muito extensa pode ter um número proibitivo de funções de avaliação, abrindo o algoritmo.

Sendo assim, recorrendo a [5] o **MPGA** apresenta as seguintes características:

- As soluções óptimas podem ser procuradas através de várias populações ao contrário do AG tradicional em que trata apenas uma população;
- A população pode ser dividida em:
Qualidade - (pc) e (pm) baixos de modo a manter o modelo estável dos melhores indivíduos e manter a capacidade de procura local do MPGA.
Normal - os parâmetros são utilizados para equilibrar a procura local e global.
Pobre - (pc) e (pm) elevados para aumentar a capacidade de procura dos melhores indivíduos e fortalecer a capacidade de procura global.
- Depois de cada população concluir o seu próprio processo evolutivo e depois de várias gerações evolutivas alguns indivíduos trocam entre cada tipo de população de modo a evitar uma convergência prematura, mantendo a diversidade de indivíduos em cada uma das três populações. Além disso, esta troca entre populações aumenta o espaço de solução.
- Os melhores indivíduos da denominada população “pobre” são trocados com os piores na “normal”, e os melhores desta são trocados com os piores da denominada população de “qualidade”.




Figura 3.11 - Estrutura do método MPGA[5].

3.4 Método Computacional

O processo do método computacional para o algoritmo proposto é descrito de seguida e de acordo com [5]:

- O problema da localização do órgão de corte de rede (OCR) é codificado usando representação binária. O tamanho do cromossoma representa as possíveis localizações do OCR sendo que 1 representa que existe aparelho de corte e 0 o oposto;
- Seguidamente é inicializado o cromossoma de forma aleatória;
- A avaliação de todos os cromossomas é feita segundo a o índice de fiabilidade do sistema correspondendo à fórmula (3.10). Esta função de avaliação permite dividir a população em três;
- São usados diferentes parâmetros (Figura 3.12) para as três populações e a sua evolução é simultaneamente satisfeita para obter um novo grupo de soluções;
- A troca de indivíduos entre populações é feita quando o número de iterações é um número inteiro múltiplo da taxa de migração;
- No final, são guardados na “quintessence population” os melhores indivíduos das três populações em cada evolução da geração. Para manter a estabilidade da quantidade de indivíduos, este são ordenados de acordo com a sua avaliação (*fitness*) e os piores são eliminados;
- O processo de optimização não pára até que o número de iterações atinja o número especificado.

3.5 Resultados e Análises

Utilizando novamente a mesma configuração de rede do método anterior (Figura 3.7), segundo os parâmetros descritos em [5] e introduzindo um novo factor que se apresenta na Figura 3.12:

Control Parameters	Quantity Population	Normal Population	Poor Population
P_c	0.4	0.6	0.8
P_m	0.02	0.05	0.10

Figura 3.12 - Parâmetros do AG das sub - populações[5].

Os seguintes resultados são importantes de referir:

Number of Reclosers	Reliability Index Value	Recloser Locations
1	3.9560	8-9
2	2.8695	8-9,30-31
3	1.9012	3-4,30-31 47-48
4	1.6042	3-4,27e-28e 30-31,47-48
5	0.9033	3-4,11-12 30-31,47-48, 28e-65

Figura 3.13 - Resultados sem geração distribuída [5].

Number of Reclosers	Reliability Index Value	Recloser Locations
1	3.5022	8-9
2	2.3341	8-9,28-29
3	1.7432	3-4,27-28 50-51
4	1.1987	3-4,30-31 47-48,66-67
5	1.7100	4-5,10-11 30-31,47-48 67-68

Figura 3.14 - Resultados com geração distribuída=0,5MW [5].

Number of Reclosers	Reliability Index Value	Recloser Locations
1	3.3012	8-9
2	2.1455	8-9,49-50
3	1.5066	4-5,27e-28e 47-48
4	1.034	8-9,28-29 36-37,49-50
5	0.5988	3-4,10-11,30-31,49- 50,67-68

Figura 3.15 - Resultados com geração distribuída=1MW [5].

De notar que os resultados obtidos neste método são iguais aos resultados obtidos pelo método da colónia de formigas pelo que, este apesar de introduzir uma nova variante, dividindo a população em três sub-populações, em nada influencia o resultado final.

Portanto, todas as conclusões tiradas no método anterior são válidas para este.

Isto deve-se fundamentalmente ao facto de a função de avaliação ser a mesma nos dois métodos.

Capítulo 4

Métodos de Optimização

4.1 Introdução

A procura do óptimo e das melhores soluções que conduzem a uma maior fiabilidade, à maximização do investimento e dos lucros e minimização do risco constituem alguns dos factores de maior importância no sector económico e empresarial.

Sendo assim, os Métodos de Optimização oferecem não só um cenário de desenvolvimento sofisticado sob o ponto de vista técnico-científico com perspectivas I&D na área da Matemática Aplicada, mas também um enquadramento para os problemas de Engenharia em que existem requisitos de desempenho elevados. Estes colocam-se cada vez mais à medida que o desenvolvimento tecnológico acelera e a competitividade entre processos e produtos aumenta.

Ao permitirem formulação que envolvem directamente critérios de desempenho, bem como restrições de mais variada natureza que traduzem o funcionamento físico dos sistemas, os objectivos e as condições a que estão sujeitos, os paradigmas tratados nos Métodos de Optimização revelam-se de extrema importância prática sobretudo quando inseridos num contexto adequado.

4.2 Inteligência Artificial

As tradicionais aproximações são baseadas em métodos de programação matemática. Em muitos casos as formulações matemáticas têm que ser simplificadas para obter as soluções devido à sua capacidade limitada para avaliar problemas de planeamento reais.

Sendo assim, os métodos baseados em Inteligência Artificial apresentam grande vantagem pelo facto de serem relativamente versáteis para suportar várias restrições qualitativas que prevalecem no problema planeamento.

Alguns métodos de IA são aplicados em problemas como: Simulated Annealing, Algoritmos Genéticos, Ant Colony Optimization Method, Particle Swarm Optimization Method[7].

4.2.1 Simulated Annealing

O *Simulated Annealing* (SA) é baseado nos resultados da termodinâmica. Tal como o próprio nome indica, o algoritmo explora uma analogia entre o modo como um metal arrefece e tende para uma estrutura cristalina de energia mínima e a procura por um mínimo num sistema qualquer.

O SA é usualmente referido como a mais antiga das metaheurísticas e é seguramente um dos primeiros algoritmos a incorporar uma estratégia para evitar mínimos locais. As origens deste algoritmo encontram-se na mecânica estatística (algoritmo de Metropolis) e este foi primeiro apresentado como um algoritmo de pesquisa para problemas combinatórios por Kirkpatrick [9]. A ideia fundamental é a de permitir que a pesquisa possa evoluir para soluções de pior qualidade do que a solução actual, a fim de escapar de óptimos locais. Neste algoritmo a probabilidade de fazer um tal movimento é diminuída à medida que a procura é realizada.

O princípio base do *Simulated Annealing* está relacionado com a seguinte observação física do comportamento da matéria. Considerando que um material é levado à sua temperatura de fusão, então as suas moléculas ficam num estado muito desordenado e agitam-se livremente como é ilustrado na figura (4.1).




Figura 4.1 - Estado desordenado das moléculas da matéria em fusão.

Se arrefecermos bruscamente a amostra, o nível de energia baixa rapidamente e as moléculas vão encontrar-se num estado ainda muito desordenado no qual o nível de energia é muito superior ao de um cristal perfeito. Este estado, dito amorfo, está representado na Figura (4.2) sendo menos estável que o estado ordenado na Figura (4.3).




Figura 4.2 - Estado desordenado das moléculas devido a um arrefecimento rápido.

Contrariamente, se arrefecermos a amostra de forma lenta e gradual, as moléculas adquirem uma estrutura cristalina estável que tem um nível de energia mais reduzido como apresentado na Figura (4.3).




Figura 4.3 - Estado ordenado das moléculas devido a um arrefecimento lento.

Sendo assim, a maior vantagem do SA resulta da possibilidade de evitar mínimos locais, particularmente nos casos em que as técnicas tradicionais de otimização falham: o

algoritmo emprega, para isso, uma pesquisa aleatória que, por vezes, aceita vizinhos cuja energia seja mais elevada. Ou seja, em algumas iterações, o SA aceita degradar a função de avaliação em vez de a reduzir. Entretanto, uma característica interessante deste está associada ao facto de a probabilidade de se aceitar um vizinho de maior energia decresce com o tempo, o que se implementa com um parâmetro, a temperatura, que decresce ao longo do processo iterativo [8].

4.2.2 Algoritmos Genéticos

Os Algoritmos Genéticos (AGs) apresentam características que garantem eficácia em procedimentos de busca, sendo utilizados na resolução de problemas complexos, incluindo-se numa família mais vasta que é a dos algoritmos evolucionários. Os óptimos resultados apresentados em problemas de busca e optimização fazem dos AG uma excelente alternativa aos métodos tradicionais de resolução de problemas de optimização.

Os AGs diferem dos métodos tradicionais de procura e optimização principalmente em quatro aspectos:

- Os AGs trabalham com uma codificação do conjunto de parâmetros e não com os próprios parâmetros;
- Os AGs trabalham com uma população e não com um único ponto;
- Os AGs utilizam informações relativas ao custo associado a uma solução e não derivadas ou outro conhecimento auxiliar;
- Os AGs utilizam regras de transição probabilísticas e não determinísticas.

No capítulo seguinte (capítulo 5) irá ser demonstrado com mais pormenor o funcionamento dos Algoritmos Genéticos.

4.2.3 Ant Colony Optimization

Esta técnica, como já foi anteriormente exemplificada (capítulo 3), simula o comportamento de um conjunto de agentes que cooperam para resolver um problema de optimização por meio de comunicações muito simples. As formigas encontram o seu caminho (da colónia para uma fonte de comida e regresso, ou ao redor de um obstáculo) com relativa facilidade. Diversos estudos permitiram descobrir que esta capacidade é o resultado da comunicação química entre as formigas através de ferómonas e um fenómeno emergente causado pela presença de muitas formigas.

Caso cada formiga não considere o rasto de ferómonas deixadas por ela mesma relativamente à trajectória que efectua, movimentar-se-ia com uma regra probabilística ambiciosa local, que provavelmente conduziria a uma má solução final.

No caso de se considerar o efeito da presença simultânea de muitas formigas, então cada uma contribui com uma parte da distribuição do rasto de ferómonas. Bons conjuntos de nós serão então seguidos por muitas formigas e que assim, receberão uma grande quantidade de ferómonas que lhes indicará quais os melhores nós para desta forma seguirem uma boa trajectória [3].

4.2.4 Particle Swarm Optimization (PSO)

Optimização por enxame de partículas (PSO - *Particle Swarm Optimization*) é um método relativamente recente. Deve-se à iniciativa de James Kennedy e Russel Eberhart [15] e veio a mostrar-se competitiva relativamente a outras meta - heurísticas. A PSO trabalha com um conjunto de soluções de um problema a otimizar, que se designa como partículas, que evoluem no espaço das alternativas.

Segundo [11], estas partículas movem-se sob a influência de três vectores aos quais se dá o nome de inércia, memória e cooperação. O primeiro vector impele a partícula numa direcção idêntica à que ela vinha seguindo, o segundo atrai a partícula na direcção da melhor posição até ao momento ocupada pela partícula durante a sua vida. O terceiro atrai a partícula na direcção do melhor ponto do espaço até ao momento descoberto pelo enxame.

Na PSO, ao contrário de outros algoritmos evolucionários, não há competição entre partículas ou auto - adaptação das suas características.

Capítulo 5

Algoritmos Genéticos

5.1 Introdução

Os problemas de otimização são baseados em três pontos principais: a codificação do problema, a função objectivo que se deseja maximizar ou minimizar e o espaço de soluções associado. Pode-se imaginar um problema de otimização como uma caixa preta com n botões, onde cada botão é um parâmetro do problema, e uma saída que é o valor da função objectivo, indicando se um determinado conjunto de parâmetros é bom ou não para resolver o problema.

Os algoritmos genéticos são uma família de modelos computacionais inspirados na evolução, que incorporam uma solução potencial para um problema específico numa estrutura semelhante à de um cromossoma e aplicam operadores de selecção e “crossover” a essas estruturas de forma a preservar informações críticas relativas à solução do problema. Normalmente os AG's são vistos como optimizadores de funções, embora a quantidade de problemas para o qual os AG's se aplicam seja bastante abrangente.

Uma das vantagens de um algoritmo genético é a simplificação que eles permitem na formulação e solução de problemas de optimização. AG's simples normalmente trabalham com descrições de entrada formadas por cadeias de bits de tamanho variável, como por exemplo AG's usados para Programação Genética. AG's possuem um paralelismo implícito decorrente da avaliação independente de cada uma dessas cadeias de bits, ou seja, pode-se avaliar a viabilidade de um conjunto de parâmetros para a solução do problema de optimização em questão[13].

5.2 Implementação

Inicialmente, existe a necessidade de definir os elementos ou indivíduos e agrupá-los a um conjunto que se chama população.

Cada indivíduo deverá ser representado por um código genético - cromossoma - que normalmente é definido por uma cadeia de elementos binários (0,1) que associa de forma única um indivíduo a um ponto no domínio das variáveis de decisão. Cada elemento (posição) do cromossoma denomina-se por gene. Cada gene pode tomar o valor 0 ou 1, ao valor do gene chama-se alelo.

Além da informação genética o indivíduo deverá também possuir uma medida da sua qualidade ou adaptação ao meio designada por função de adaptação ou *fitness function*.

Considerando agora o problema como sendo um problema de optimização, temos que um indivíduo deve ser representado pelo par:

(cromossoma, adaptação)

Em que o cromossoma possui a codificação binária das variáveis de decisão e a adaptação o valor da função objectivo para as variáveis de decisão codificadas no cromossoma.

Os indivíduos de uma população irão reproduzir-se, com base em mecanismos genéticos que irão ser descritos posteriormente, dando origem a uma nova população de indivíduos.

Para uma melhor percepção do descrito apresenta-se um pequeno exemplo em que se considera o problema de maximização da seguinte função:

$$f(x_1, x_2) = 10 - x_1 + (15 - x_2)^2 \quad (4.1)$$

Com $x_1, x_2 \in [0, 31]$. As variáveis x_1 e x_2 podem ser codificadas cada uma como um número binário usando 5 bits. O cromossoma de um indivíduo pode ser por exemplo:

01100 01010 (correspondente a $x_1=12$ e $x_2=10$)

A este cromossoma corresponde um valor de adaptação de:

$$f(01100, 01010) = 10 - 12 + (15 - 10)^2 = 2 \quad (4.2)$$

O par, (0110001010, 23) representa, então um indivíduo.

Segundo [5], “Os AG’s têm por objectivo encontrar o óptimo, ou seja, por defeito considera-se que se pretende maximizar a função de adaptação. Este tipo de formulação é genérica visto que para minimizar uma função bastará multiplicar a função pretendida por -1”.

5.3 Operações Básicas de um AG simples

A estrutura básica do algoritmo genético é mostrada na figura abaixo:




Figura 5.1- Estrutura básica de um AG simples [14]

Com referência ao diagrama da figura 4.1, observa-se que cada iteração do algoritmo genético corresponde à aplicação de um conjunto de quatro operações básicas: cálculo de aptidão, selecção, cruzamento e mutação. No fim destas operações cria-se uma nova população, chamada de geração que, espera-se, representa uma melhor aproximação da solução do problema de optimização que a população anterior. A população inicial é gerada atribuindo-se aleatoriamente valores aos genes de cada cromossoma.

A aptidão bruta de um indivíduo da população é medida por uma função de erro, também chamada função objectivo do problema de optimização. A aptidão bruta é em seguida normalizada (aptidão normalizada), para permitir um melhor controlo do processo de selecção. Como critérios de paragem do algoritmo em geral são usados a aptidão do melhor indivíduo em conjunto com a limitação do número de gerações. Outros critérios podem envolver, por exemplo, um erro abaixo de um valor especificado pelo projectista para um determinado parâmetro do problema.

5.3.1 Inicialização

Uma população de n indivíduos é gerada aleatoriamente. Cada um dos indivíduos da população representa uma possível solução para o problema, ou seja, um ponto no espaço de soluções.

5.3.2 Cálculo da Aptidão

Geralmente a aptidão do indivíduo é determinada através do cálculo da função objectivo, que depende das especificações de projecto. Neste trabalho, cada indivíduo é uma entrada para uma ferramenta de análise de desempenho, cuja saída fornece valores que permitem ao algoritmo genético o cálculo da aptidão do indivíduo. Ainda nesta fase, os indivíduos são ordenados de acordo com a sua aptidão.

5.3.3 Selecção

Existem vários mecanismos de selecção. Em todos eles o valor da adaptação de um indivíduo é fundamental. O mecanismo utilizado neste trabalho é conhecido como torneio estocástico.

Esta técnica consiste no seguinte:

Cada vez que se pretende seleccionar um indivíduo, são escolhidos dois aleatoriamente, sendo que o que possui melhor adaptação ou *fitness* ganha com uma determinada probabilidade fixa (normalmente 0,8). Este método é melhorado à medida que aumenta o número de indivíduos no torneio.

Outro mecanismo de selecção frequentemente utilizado é o da selecção com base na probabilidade de selecção de cada indivíduo calculada por:

$$ps(i) = \frac{f(i)}{\sum_{j=1}^n f(j)} \quad (4.3)$$

Em que $f(i)$ e $f(j)$ representam o valor da adaptação do indivíduo i e j respectivamente.

Após o cálculo das probabilidades (ps) são seleccionados os n indivíduos com probabilidades mais elevadas.

5.3.4 Cruzamento (“crossover”)

Os indivíduos seleccionados na etapa anterior passam à fase de cruzamento (*crossover*) ou recombinação. Os n indivíduos são aleatoriamente emparelhados formando $n/2$ pares. Cada indivíduo possui uma determinada probabilidade de cruzamento (pc) o que significa que pode ou não ocorrer cruzamento. No caso de não ocorrência de cruzamento, os indivíduos passam à fase de mutação sem sofrerem qualquer alteração. Caso se dê o cruzamento ele processa-se da seguinte forma: uma das $L-1$ posições do cromossoma é seleccionada aleatoriamente, sendo L o comprimento do cromossoma, os dois cromossomas são cortados pela posição seleccionada (p) e trocam entre si as partes compostas pelos genes de p a $L-1$ dando origem a dois novos cromossomas que posteriormente seguirão para a fase seguinte.

Na figura 5.2 será exemplificado este processo:




Figura 5.2 - Resultado do cruzamento entre dois cromossomas[12].

Supondo-se então a existência de dois cromossomas de comprimento 10, sendo a posição de cruzamento, aleatoriamente sorteada, a posição 7. Os dois “pais” irão trocar os genes correspondentes às posições seleccionadas dando origem a dois novos “filhos”.

5.3.5 Mutaç o

A opera o de muta o   utilizada para garantir uma maior diferencia o do espa o de estados e evitar que o algoritmo gen tico convirja muito cedo para m nimos locais. A muta o provoca como que uma descontinuidade no processo evolutivo, permitindo o aparecimento de novo material gen tico que poder  proporcionar o aparecimento de indiv duos melhor adaptados. No entanto, o valor da probabilidade de muta o (p_{mut}) n o dever  ser muito elevado de forma a evitar situa es de busca aleat ria.

5.4 Escolha dos par metros do AG

Al m da forma como o cromossoma   codificado, existem v rios par metros do algoritmo gen tico que podem ser escolhidos para melhorar o seu desempenho, adaptando-o  s caracter sticas particulares de determinadas classes de problemas. Entre eles os mais importantes s o:

- o tamanho da popula o;
- o n mero de gera es;
- a probabilidade de *crossover*;
- a probabilidade de muta o;

A influ ncia de cada par metro no desempenho do algoritmo depende da classe de problemas que se est  a tratar. Assim, a determina o de um conjunto de valores otimizado para estes par metros depender  da realiza o de um grande n mero de testes. Na maioria dos casos, os valores encontrados est o na faixa de 60% a 65% para a probabilidade de *crossover* e entre 0,1% e 5% para a probabilidade de muta o. O tamanho da popula o e o n mero de gera es dependem da complexidade do problema de optimiza o e devem ser determinados experimentalmente. No entanto, deve ser observado que o tamanho da popula o e o n mero de gera es definem directamente o tamanho do espa o de busca a ser coberto.

Capítulo 6

Métodos de Niching

6.1 Introdução

Os AG tradicionais rapidamente provocam a convergência sua população, tornando todos os seus elementos idênticos. No caso de problemas mais complexos, em que existem vários óptimos locais pode suceder que o AG tradicional não consiga determinar o óptimo global, dada a rápida convergência da população, correspondendo a solução encontrada a um óptimo local. Com o objectivo de ultrapassar este problema foram desenvolvidas alterações aos AGs tentando evitar que todos os elementos da população se tornassem idênticos. Surgiram então AG incluindo **métodos de *Niching***. Estes algoritmos mantêm a diversidade dos elementos na população criando diferentes nichos, cada um correspondendo a uma solução do problema. A existência de nichos provoca também algum atraso na convergência do AG facilitando, no entanto, a identificação de uma melhor solução [12].

Inúmeros métodos têm sido implementados para induzir nichos e espécies em AGs. Entretanto, existem pelo menos dois problemas identificados quanto à questão do niching, são eles: Um modelo de abstracção simples do nicho e a formação/manutenção das espécies.

Na natureza, quando um ambiente se torna “cheio” de um determinado tipo de organismo, indivíduos são forçados a partilhar os recursos disponíveis. Sendo assim, podemos concluir que a necessidade de partilhar é uma consequência natural de ambientes contendo superpopulação e conflitos. Seguidamente, serão apresentados alguns exemplos dos métodos de *niching* e posteriormente evidenciado qual o método escolhido para a realização deste trabalho.

6.2 Pré-selecção

A dissertação de Cavicchio (1971), foi um dos primeiros trabalhos a estudar a indução de nichos e o comportamento das espécies em AGs (Mahfoud, 1992). Especificamente, introduziu um mecanismo chamado pré-selecção. Neste esquema, um descendente substitui um dos seus pais, se o seu *fitness* exceder o do pai de pior *fitness*. Desta forma a diversidade é indirectamente mantida na população porque indivíduos tendem a substituir indivíduos similares (um de seus pais).

Como vantagens apresenta a simplicidade na implementação e custo computacional reduzido, bem como o facto de manter, segundo Cavicchio, maior diversidade na população, mesmo com aglomerados relativamente pequenos.

A desvantagem reside no facto de que uma selecção seja realizada antes do seu processo efectivo[14].

6.3 Crowding

O método de *crowding*, proposto por De Jong em 1975, é uma generalização do método de pré-selecção realizada por Cavicchio. Neste método, novos indivíduos substituem os indivíduos existentes de acordo com a sua similaridade na população sobreposta. Especificamente, um novo indivíduo é comparado a outro pertencente a uma sub-população escolhida aleatoriamente, cujo tamanho é determinado por um factor de *crowding*. O indivíduo com mais alta similaridade (na comparação bit-a-bit) é substituído pelo novo indivíduo.

Novos indivíduos (n) passam a fazer parte da população, pela substituição de indivíduos similares; os procedimentos de selecção e de reprodução ocorrem normalmente. A substituição de indivíduos por outros similares tende a manter a diversidade dentro da população e reservar espaço para uma ou mais espécies. O método de *crowding* tem sido usado em várias aplicações de aprendizagem de máquinas e sistemas de classificação e não é um método a partir do qual a população atinge uma nova “mistura” de espécies, mas sim trabalha por manter a diversidade da mistura pré-existente.

A vantagem reside no facto deste método ser capaz de manter a diversidade inicial mesmo sabendo que não promove uma alta diversidade.

Apresenta desvantagens em termos de habilidade para o *niching*. Descendentes competem com os seus pais segundo regras determinísticas.

Segundo Mahfoud (1992), nas experiências com este algoritmo, o número de picos encontrados após as evoluções não é superior a dois[14].

6.4 Deterministic Crowding

Mahfoud (1992) aponta que erros de substituição estocástica de indivíduos causam a dificuldade para o algoritmo de *crowding* original manter mais que dois pontos de máximo.

O método de *crowding* tem sucesso na manutenção da diversidade em algumas situações, mas, erros estocásticos são introduzidos pelo baixo factor de *crowding* e por outros factores que forçam o método a gradualmente fixar o valor de algumas posições (bits) de indivíduos.

Deterministic crowding trabalha com casamento (*matching*) aleatório de todos os elementos da população em cada geração até conseguir $n/2$ pares, onde n é o tamanho da população. Cada par de pais é submetido ao *crossover*, seguido do operador mutação originando dois descendentes. Os dois descendentes competem com os seus pais pela inclusão na população.

As vantagens são o facto de reduzir os erros estocásticos, em comparação com o método de *crowding* original. É também um método que no geral é bom para resolver problemas de todos os níveis de complexidade [14].

6.5 Fitness Sharing

Fitness sharing trabalha através da redução de função de avaliação de elementos idênticos na população. Este método impõe uma pressão para a diversidade através da função *fitness*. No cálculo da função, os indivíduos não podem usar o seu valor de *fitness* sozinho, eles devem partilhá-lo com os indivíduos que estejam próximos. Especificamente, a nova *fitness* de um indivíduo é igual à sua *fitness* original dividida pela sua *nich count*. A *nich count* de um indivíduo é a soma dos valores da função de sharing entre ele e cada indivíduo na população (incluindo o próprio). A função de sharing é uma função entre dois elementos da população, que retorna 1 se os elementos forem idênticos, zero se eles ultrapassarem algum *threshold* de não similaridade; e um valor intermédio para níveis intermédios de similaridade. O *threshold* de não similaridade indica a distância máxima permitida para ocorrer um sharing distinto de zero (Mahfoud, 1993).

A analogia com um problema de optimização é que a localização de cada ponto máximo representa um nicho e, a capacidade de partilhar a *fitness* associada a cada nicho pode encorajar a formação de sub - populações estáveis em cada máximo. *Sharing* é baseado no princípio de que o valor da *fitness* dentro do nicho é finito e deve ser partilhado entre todos os indivíduos que o ocupam. Consequentemente, a *fitness* atribuída a cada indivíduo será inversamente proporcional ao número de indivíduos no mesmo nicho.

Neste método, quando a população começa a convergir para múltiplos picos, o *crossover* entre diferentes picos pode ser inconsequente. Deb (1989) mostrou que com uma restrição

que evite este problema era possível era possível melhorar o método, proibindo então a combinação de indivíduos de diferentes picos consegue-se melhorar a performance.

Sharing pode ser implementado usando qualquer método de selecção, ainda que a selecção *stochastic remainder* tenha sido a mais popular nas primeiras implementações do método.

De notar que, *fitness sharing* é um método computacionalmente caro, que requer a computação de N^2 medidas de distância entre pares de indivíduos, onde N é o número de indivíduos da população.

A maior desvantagem deste método é a necessidade de especificação do σ_{share} que requer o conhecimento do número de picos no espaço. Têm sido desenvolvidos procedimentos para determinar este parâmetro, como por exemplo no trabalho de Deb & Goldberg em 1989, porém este trabalho assume uma distribuição uniforme de pontos, o que não é real em muitas aplicações. Um problema fundamental é: onde estão os nichos? Como decidir se dois indivíduos estão no mesmo nicho, e se devem ter o valor das suas *fitness* partilhados? Para fazer isso com precisão é necessário saber onde estão os nichos e o seu tamanho. Obviamente não podemos conhecer os nichos previamente, caso contrário não teríamos um problema para resolver. A abordagem inicial Goldberg & Richardson (1987) assume que se dois indivíduos estão próximos, dentro de uma distância conhecida como raio do nicho, então os seus valores de *fitness* devem ser partilhados. Desta forma é medida a distância ao longo de uma única dimensão, o espaço de codificação de parâmetros. O valor do raio de sharing (σ_{share}) é o mesmo para todos os indivíduos, desta forma todos os pontos de valor devem ser aproximadamente equidistantes (Darwe & Yao, 1995). Para estabelecer o σ_{share} é necessário conhecer há priori a distância entre os pontos óptimos e as suas *fitness*. Algo que só acontece após o AG realizar a procura no espaço de soluções candidatas e que até então permanece desconhecida. Estas últimas limitações implicam que este método tenda a falhar na procura de todos os pontos óptimos caso estes não estejam equidistantes e não tiverem o mesmo valor de *fitness* ou se a distância estimada entre eles estiver incorrecta. Para solucionar estes problemas algumas alternativas podem ser adoptadas, como, por exemplo, não adoptar um σ_{share} fixo.

Apesar das limitações citadas anteriormente, os AGs com selecção proporcional e *fitness sharing* têm tido sucesso para resolver problemas de funções multimodais [14].

Capítulo 7

Metodologia Implementada

7.1 Porquê o método de Crowding?

Como foi devidamente explicado nas secções anteriores, os algoritmos genéticos (AG) tradicionais têm uma convergência relativamente rápida, após ter sido encontrada uma boa solução.

A rápida convergência da população limita o aparecimento de cromossomas diferentes quando se dá o cruzamento, pois o código genético dos pais é igual. Só a mutação altera o código genético - apenas um bit e com uma probabilidade muito baixa de tal suceder (pelas razões apresentadas no Capítulo 5). Esta mecânica dos AG tradicionais leva a que em problemas complexos possa ocorrer a convergência para óptimos locais.

Para ultrapassar este tipo de problemas desenvolveram-se AG com base em métodos de nicho, nomeadamente, o algoritmo genético baseado no método determinístico de *crowding*. Este método permite manter a diversidade da população, tornando possível, além da obtenção de uma melhor solução final, a obtenção de várias outras boas soluções.

Relativamente ao AG tradicionais as diferenças situam-se nos operadores genéticos, principalmente ao nível da selecção, e no método de inserção de um novo indivíduo na população.

No método determinístico de *crowding* os indivíduos de uma população são aleatoriamente emparelhados em $n/2$ pares de indivíduos, sendo n o número de indivíduos da população. Estes pares de indivíduos (pais) são sujeitos ao operador cruzamento, seguido da mutação, originando dois novos indivíduos (filhos). Cada um dos filhos vai competir então com o pai mais próximo entrando o vencedor para a nova população.

Segundo [12], esta medida de proximidade pode ser calculada recorrendo à distância de Hamming quando se usa directamente o cromossoma. No entanto os resultados obtidos podem ser de pior qualidade devido a erros de substituição. Estes erros ocorrem sempre que a distância entre pais e filhos não é correctamente avaliada, levando a que um filho substitua um pai indevidamente.

Para melhor se observar esta situação e recorrendo exemplo descrito em [12], em que temos uma função $G(x)$:

$$G(x) = \begin{cases} \frac{8x}{127} + 10 & 0 \leq x < 127 \\ \frac{x}{16} + 10 - \frac{255}{16} & 127 \leq x \leq 255 \end{cases} \quad x \text{ inteiro} \quad (7.1)$$




Figura 7.1 - Gráfico da função $G(x)$ [12].

Esta função tem então dois máximos localizados em 0 (00000000) e 255(11111111).

Considerem-se os seguintes cromossomas pais 00111110 e 11000001. Ocorrendo o cruzamento no segundo bit obtêm-se então dois cromossomas filhos 00000001 e 11111110. A distância de Hamming entre pais e filhos é dada por:

distância1 (00111110, 00000001)=6

distância2 (11000001, 11111110)=6

distância3 (00111110, 11111110)=2

distância4 (11000001, 00000001)=2

Como,

$$\text{distância1} + \text{distância2} > \text{distância3} + \text{distância4} \quad (7.2)$$

Então o cromossoma 11111110 vai competir com o pai 00111110 e o cromossoma 00000001 vai competir com o pai 11000001. No entanto, calculando a distância euclidiana verificou-se que a conclusão anterior estava errada, isto é os filhos estão a competir com o pai errado. Com efeito:

- decodificando os cromossomas obtém-se

$$\text{distância1} (62, 1)=61$$

$$\text{distância2} (193, 254)=61$$

$$\text{distância3} (62, 254)=192$$

$$\text{distância4} (193, 1)=192$$

Assim,

$$\text{distância1} + \text{distância2} < \text{distância3} + \text{distância4} \quad (7.3)$$

Logo, o pai 00111110 deverá competir com o filho 00000001 e o pai 11000001 deverá competir com o filho 11111110. Este exemplo comprova o que havia sido dito anteriormente, que a distância de Hamming pode originar erros de substituição de pais por filhos.

Na Figura 7.2 apresenta-se o algoritmo do método determinístico de *crowding* com base em [12].

Repetir para as g gerações

Para contador = 1 até metade do n° de indivíduos da população faça

- seleccione aleatoriamente dois indivíduos (p1 e p2) sem os substituir
- aplique o operador cruzamento para obter dois novos indivíduos (f1 e f2)
- aplique o operador mutação (f'1 e f'2)
- se $[distância(p1, f'1) + distância(p2, f'2)] \leq [distância(p1, f'2) + distância(p2, f'1)]$ então

 início

 se $adaptação(f'1) > adaptação(p1)$ então

 substitua p1 por f'1

 se $adaptação(f'2) > adaptação(p2)$ então

 substitua p2 por f'2

 fim

senão

 início

 se $adaptação(f'2) > adaptação(p1)$ então

 substitua p1 por f'2

 se $adaptação(f'1) > adaptação(p2)$ então

 substitua p2 por f'1

 fim

Figura 7.2 - Algoritmo do método determinístico de crowding [12].

No Algoritmo são representados os quatro blocos constituintes do método de crowding:

- Selecção aleatória de indivíduos da população para cruzamento;
- Cruzamento dos indivíduos para obtenção de dois indivíduos (filhos);
- Aplicação da mutação aos dois novos indivíduos;
- Determinação da proximidade entre pais e filhos, e obtenção da adaptação de cada filho segundo a função de avaliação (END). Uma vez encontrada a relação de proximidade entre pais e filhos, é escolhido um indivíduo de cada par (pai, filho) para transitar para a geração seguinte em função do valor da função de avaliação.

7.2 Modelização do problema

A resolução deste problema consiste no desenvolvimento de um programa, baseado no algoritmo de Crowding previamente desenvolvido, que realiza a optimização da distribuição de órgãos de corte telecomandados (OCR's) na rede de distribuição de Média Tensão de modo a evitar tomadas de decisão de forma empírica em relação às respectivas localizações. Pretende-se assim, obter soluções optimizadas tendo em conta que estas devem contribuir para um aumento do ganho em Energia não Distribuída, um aumento dos níveis de qualidade de serviço, não esquecendo que se devem ter em consideração os factores económicos, sendo que, deve ser um investimento rentável.

Sendo assim:

- Inicialmente criou-se a população que seriam os n indivíduos, sendo que cada indivíduo corresponde a um cromossoma que é codificado com 0 e 1 consoante a existência ou não de OCR's, figura 7.3. O tamanho do cromossoma representa as possíveis localizações para os OCR's.




Figura 7.3 - Representação de um indivíduo.

- Seguidamente é inicializado o cromossoma de forma aleatória;
- Desenvolvimento do processo genético (selecção, cruzamento, mutação), no qual, cada solução (cromossoma) é avaliada por uma função de avaliação que consta em (2.1) correspondente à Energia não Distribuída (END), e que neste trabalho se pretende minimizar;
- No final do processo estarão disponíveis as melhores soluções correspondentes aos melhores locais para a localização dos OCR's que proporcionam uma maior rentabilidade;

- Os operadores genéticos selecção, cruzamento e mutação foram descritos no Capítulo 5. Na resolução do problema proposto para o operador selecção foi utilizado o torneio estocástico com uma probabilidade de 0,8 do melhor ganhar. Para a probabilidade de cruzamento e mutação foram utilizados valores típicos de 0,8 para o cruzamento e de 0,01 para a mutação.

7.3 Resultados e Análises

Com o objectivo de testar o Algoritmo implementado extraiu-se uma pequena saída de uma determinada saída de uma subestação da rede de distribuição de Média Tensão (Fig.7.4).




Figura 7.4 - Representação da rede em estudo extraída do software DPLAN.

Ainda que pequena, esta rede possui 110 ramos o que torna um pouco confuso o processo de teste. Para uma melhor compreensão é então necessário reduzir o “alvo” para que se possa efectuar manualmente o cálculo da Energia não Distribuída comparando-a com o valor obtido pelo método computacional e averiguando a sua veracidade.

Sendo assim, na Figura 7.5 está representado digamos que um “esquema equivalente”:

Nó XX4WFVBEHH4OEPOXCT62XSSZPA




Figura 7.5 - Esquema equivalente da rede de teste.

Vai então fazer-se a análise de duas soluções, para que se compare com o método computacional de modo a confirmar se o cálculo da END está a ser feito de forma adequada. De relembrar que o objectivo era diminuir a END pelo que a solução corresponde ao ponto óptimo deste exemplo.

Solução1: 0100 - que corresponde à inserção de um OCR no troço representado por 2.

$$END = \lambda \times L \times t \times P_{\text{máx}} \times f.u =$$

$$= 0,1 * L2 * t * P2 * 0,57 = 0,1 * 2,187 * 1,6667 * 317,1 * 0,57 = 65,88 \text{ kWh} \quad (7.4)$$

Constantes

Confrontando com o valor obtido através do método computacional podemos observar que, para aquela codificação do cromossoma (0100) o valor de **END = 65,89 kWh**. Portanto, são valores aproximadamente iguais, o que comprova a viabilidade deste método para esta solução.

E em termos de cálculo para a taxa de rentabilidade do sistema?

Para a Solução 1 temos que:

$$\text{Ganho_END} = \text{END}_{\text{total}} - \text{END}(1) = 5096\text{kWh} - 65,88\text{kWh} = 5030 \text{ kWh} \quad (7.5)$$

Assim, o $\text{Ganho_END} = 5030 \text{ kWh}$ no caso de ocorrência de um defeito no ramo 2, e que corresponde à energia que se salvaguarda com a introdução do OCR (de notar que se considera que a instalação do OCR é sempre feita no início do ramo).

Podemos então observar qual a rentabilidade do sistema a partir da solução do programa, que nos devolve uma taxa de rentabilidade máxima e que apresenta, para este exemplo, o valor de **3,464** que se confirma com os cálculos efectuados na folha de cálculo:

Ganho (kWh)	5030	Investimento (€)	Ganho END (kWh)	Ganho (€)	Ganho Actualizado(€)
nº OCR	1				
preço/OCR	15000	0	15000		
custo kWh END (€)	1,5	1	0	5030	7545
tx. Cres. Cargas	3%	2	0	5181	7771
tx. Actualização	10%	3	0	5336	8004
		4	0	5496	8245
		5	0	5661	8492
		6	0	5831	8747
		7	0	6006	9009
		8	0	6186	9279
		9	0	6372	9558
		10	0	6563	9845
		$\Sigma =$	15000		51938
		B/C =	3,46	p.u. se ≥ 1 é rentável	

Figura 7.6 - Cálculo da rentabilidade do sistema para a Solução1

O problema, neste caso, seria se o defeito ocorre-se num dos outros ramos, algo que traria graves problemas de abastecimento aos consumidores uma vez que toda a rede ficaria fora de serviço. Daí, não ser adequado avaliar a inserção de um OCR na rede apenas pela sua rentabilidade, mas também devido à carga que consegue manter em serviço após ocorrência de uma avaria num determinado ramo.

7.4 Dificuldades

Os problemas do programa verificaram-se quando tentamos obter o mínimo de END com a totalidade da rede correspondente à saída da subestação.

A END continua efectivamente a minimizar à medida que se aumentam as gerações e os indivíduos, porém retorna sempre um resultado que é inviável na medida em que o número de OCR's é muito superior ao permitido (~4 ou 5 por saída).

Exemplificando:

Com,

```
gpsize = 10;      /* Population size */
gpmut  = 0.0075;   /* mutation prob. */
ngngers = 10;      /* n. of generations */
gpwin  = 0.8;      /* prob of best winning */
```

Obteve-se uma END=9,93kWh, algo que seria de extremo agrado se não fosse a solução de cerca de 44 OCR's, o que inviabiliza totalmente a solução.

Alterando o parâmetro **ngngers** para **100** obteve-se, para END=8,46kWh, portanto minimizou o resultado porém o número do OCR ainda fica muito longe do permitido apresentando-se cerca de 42 OCR's.

Sendo assim, supõem-se que o problema ocorre o programa se depara com as situações em que os troços de rede divergem:




Figura 7.7 - Exemplo de uma rede

Nestas situações, supondo que existe um OCR em L2 e outro em L3, o programa não consegue analisar um dos troços. Continua a procura e tenta encontrar as soluções num dos ramos mas o outro não é analisado, deparando-se com o mesmo problema sempre que ocorra outra situação do género.

Capítulo 8

Conclusões e Trabalhos Futuros

A presente dissertação teve como principal motivação a procura de uma metodologia computacional para localização óptima de aparelhos de corte telecomandados na rede de distribuição de Média Tensão.

Não pretendendo com este trabalho obter uma solução que resolva todos os problemas inerentes à localização óptima deste tipo de aparelhos, mas simplesmente dar um pequeno contributo na procura deste objectivo, pondera-se que a utilização de Algoritmos Genéticos possa fornecer alguns resultados que garantam e justifiquem a aposta neste desenvolvimento.

De uma forma geral, os temas abordados permitem identificar que é possível encontrar esta solução, porém tal como havia sido inicialmente previsto, não é um processo de fácil resolução, quer pelas diversas características da rede de distribuição, quer pela variedade de situações que são necessárias considerar, quer mesmo pelo tempo disponível para a realização deste trabalho.

Como trabalhos futuros, propõem-se o desenvolvimento e resolução de alguns erros existentes no programa bem como uma nova perspectiva que englobe redes de distribuição em anel, uma vez que neste trabalho são abordadas apenas as redes radiais.

Referências

- [1] EDP - Energias de Portugal, “Definição de critérios de Instalação, Operação e Condução TCMT”, QST2010 Sub-Projecto 7.2.1, Dez 2008.
- [2] Vladimiro Miranda, “Fiabilidade em Sistemas de Potência - Uma Introdução”, versão 2.1, Março 2009.
- [3] M. Dorigo & T. Stützle, “Ant Colony Optimization”, MIT Press, 2004.
- [4] Lingfeng Wang & Chanan Singh, “Reliability - Constrained Optimum Placement of Reclosers on Distributed Generators in Distribution Networks Using an Ant Colony System Algorithm”, IEEE Transactions on Systems, MAN, and Cybernetics - Part C: Applications and Reviews, Vol.38, No.6, Nov 2008.
- [5] Zhang Li, Xu Yuqin, and Wang Zengping, “Research on Optimization of Recloser Placement of DG - enhanced Distribution Networks”, IEEE document, Abril 2008.
- [6] S. Nosaki, F. A. Fernandes, R. Torrezan, “Optimization in the application of Reclosers”, IEEE document, Jun 1997.
- [7] Felix Wu, Zheng Yen, Yunhe Hou, Yixin Ni, “Applications of AI Techniques to Generation Planning and Investment”, IEEE document.
- [8] E. Aarts e J. Korst, " Simulated Annealing and Boltzmann Machine", John Wiley, 1989.
- [9] S. Kirkpatrick, C. D. Gelatt, M. P. Vecchi, “Optimization by Simulated Annealing”, Science, vol. 220, no. 4598, pp. 671-680, 1983.
- [10] A. Abdulwhab, R. Billinton, A. A. Eldamaty, S. O. Faried, “Electric Power Components and Systems Maintenance Scheduling Optimization Using a Genetic Algorithm (GA) with a Probabilistic Fitness Function”, Power Systems Research Group, University of Saskatchewan, Saskatoon, Canada, 2004, disponível em: <http://www.informaworld.com/smpp/title-content=t713399721>, ultimo acesso em Maio 2009.

- [11]Vladimiro Miranda, “Computação Evolucionária - Uma introdução” versão 2.0, Mar 2005.
- [12]José Rui Ferreira, “Avaliação da Estabilidade de Tensão com Cenários de Injecção Imprecisos e Identificação de procedimentos de Controlo”, Tese de Doutoramento, 1999.
- [13]Márcio Nunes de Miranda, “Algoritmos Genéticos: Fundamentos e Aplicações”. Disponível em: <http://www.gta.ufrj.br/~marcio/genetic.html>, último acesso em Maio de 2009.
- [14] Deborah R. Carvalho & Alex A. Freitas, “Uma revisão de métodos de Niching para Algoritmos Genéticos”, Disponível em: <http://www.utp.br/tuiuticienciaecultura/FACET/FACET%2029/PDF/Art%207.pdf>, último acesso em Maio 2009.
- [15] Kenney,J. Eberhart, R.C (1995), “Particle Swarm Optimization”, IEEE document
- [16]Matthew Wall, “GAlib: A C++ Library of Genetic Algorithm Components”, versão 2.4, Ago 1996.
- [17]Entidade Reguladora dos Serviços Energéticos, “Relatório da qualidade de Serviço 2007, Transporte, Distribuição e Comercialização da Energia Eléctrica em Portugal, Dez 2008, Disponível em: <http://www.erse.pt/pt/Paginas/home.aspx>, último acesso Abr 2009.
- [18]EDP- Energias de Portugal, “Guia Técnico do Planeamento”, Ago 1995.
- [19]EDP- Energias de Portugal, “Plano de Desenvolvimento da rede de Distribuição (2009-2011)