

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO

Departamento de Engenharia Electrotécnica e de Computadores

UNIVERSIDADE DO PORTO  
Faculdade de Engenharia  
BIBLIOTECA  
N.º 19801-07  
CDU  
Data 28 / 3 / 1999

0.016452

ENG.

Int.

Co de V. de

ALGORITMOS GENÉTICOS NO  
PLANEAMENTO DA EXPANSÃO  
DE SISTEMAS DE DISTRIBUIÇÃO  
DE ENERGIA ELÉCTRICA

Luis Miguel Barbosa Proença

Licenciado em Engenharia Electrotécnica e de Computadores  
pela Faculdade de Engenharia da Universidade do Porto

Dissertação realizada sob a supervisão do  
Doutor Vladimiro Henrique Barbosa Pinheiro de Miranda  
Dissertação submetida para satisfação parcial dos  
requisitos do programa do curso de mestrado em  
Engenharia Electrotécnica e de Computadores  
(Área de especialização de Sistemas de Energia)

621.3(063)  
PROE/ALG

043 M

P957 a

Porto, Outubro de 1993

Dissertação realizada sob a supervisão do  
Doutor Vladimiro Henrique Barbosa Pinto de Miranda  
Professor Associado do Departamento de  
Engenharia Electrotécnica e de Computadores da  
Faculdade de Engenharia da Universidade do Porto

## Resumo

---

Esta dissertação apresenta os resultados de um projecto de investigação destinado ao desenvolvimento de métodos computacionais para o planeamento da expansão de sistemas de distribuição de energia eléctrica.

O estudo foi desenvolvido no INESC-Porto (Instituto de Engenharia de Sistemas e Computadores), constituindo esta dissertação o relatório final do projecto.

O estudo descreve e demonstra técnicas baseadas em algoritmos genéticos que podem ser usadas numa metodologia integrada de auxílio à decisão no planeamento de redes eléctricas. Apresenta-se ainda uma aplicação da referida abordagem ao problema da expansão de redes de gás.

## Abstract

---

This report describes the results of a research project aimed at developing computational methods for expansion planning of electric distribution systems.

This study was carried out at INESC-Porto, representing this thesis the final report of the project.

The study describes and demonstrates techniques based on genetic algorithms that may be used for decision making support in distribution network planning. This report also presents an application of the approach to the gas distribution planning problem

## **Palavras chave**

Algoritmos genéticos  
Sistema de distribuição  
Planeamento da expansão  
Modelização  
Optimização

## **Keywords**

Genetic Algorithms  
Distribution system  
Expansion planning  
Modelling  
Optimization

## Agradecimentos

---

Este estudo foi realizado no INESC-Porto com o apoio da JNICT, entidades às quais desejo agradecer o suporte financeiro e os meios postos à minha disposição, sem os quais a realização deste trabalho seria impossível.

Desejo ainda expressar os meus agradecimentos a todas as pessoas que contribuíram directa ou indirectamente para a realização deste trabalho. Particularmente, gostaria de agradecer ao Prof. Vladimiro Miranda pelo seu acompanhamento inspirador e ao Eng<sup>o</sup> João Vasco Ranito pela sua preciosa ajuda e aconselhamento, bem assim como pela cedência de *software* relacionado com os algoritmos genéticos.

O apoio contínuo dos meus colegas do Grupo IDEIA do INESC foi imensamente apreciado.

Por fim, um agradecimento especial ao meu pai pela revisão dos originais desta dissertação.

Porto, Outubro 1993

Miguel Proença

# Índice

---

	Pag.
<b>CAPÍTULO 1</b>	
Introdução .....	1.1
<b>CAPÍTULO 2</b>	
O planeamento da expansão de redes de distribuição de energia eléctrica	
2.1 Introdução.....	2.1
2.2 Classificação dos modelos .....	2.2
2.2.1 Horizonte de planeamento .....	2.2
2.2.2 Optimização dos subsistemas .....	2.3
2.2.3 Perdas de energia.....	2.3
2.2.4 Radialidade .....	2.4
2.2.5 Quedas de tensão .....	2.4
2.2.6 Outras considerações.....	2.5
2.2.7 Algoritmos e técnicas matemáticas utilizados.....	2.5
2.2.8 Análise multiobjectivo.....	2.5
2.2.9 Incertezas .....	2.6
2.2.10 Fiabilidade .....	2.6
2.3 Sumário dos modelos.....	2.7
2.4 Conclusões.....	2.9
<b>CAPÍTULO 3</b>	
Algoritmos genéticos	
3.1 Introdução.....	3.1
3.2 O mecanismo de evolução.....	3.1
3.3 Algoritmo genético canónico.....	3.2
3.3.1 Selecção.....	3.3
3.3.2 Cruzamento.....	3.3
3.3.3 Mutação.....	3.4
3.3.4 Parâmetros.....	3.4

3.4	Funcionamento de um algoritmo genético.....	3.4
3.5	Variações nos algoritmos genéticos.....	3.5
3.6	Vantagens dos algoritmos genéticos.....	3.6
3.7	Características especiais dos algoritmos genéticos.....	3.7
3.7.1	Variáveis de decisão discretas.....	3.7
3.7.2	Variáveis reais.....	3.7
3.7.3	Restrições.....	3.7
3.7.4	Problemas multiobjectivo.....	3.7
3.8	Aplicações dos algoritmos genéticos.....	3.8
3.8.1	Engenharia de controlo.....	3.8
3.8.2	Sistemas de energia.....	3.8
3.9	Conclusões.....	3.8

## CAPÍTULO 4

### Modelo de planeamento

4.1	Introdução.....	4.1
4.2	Representação do sistema de distribuição.....	4.1
4.2.1	Lista de símbolos.....	4.2
4.2.2	Subestações.....	4.3
4.2.3	Linhas potenciais.....	4.3
4.2.4	Linhas existentes.....	4.4
4.2.5	Reforços nas capacidades das subestações.....	4.5
4.3	Horizonte de planeamento.....	4.5
4.4	Custos de investimento.....	4.6
4.5	Restrições.....	4.6
4.6	Condições.....	4.7
4.7	Descrição do algoritmo.....	4.7
4.8	Resultados.....	4.7
4.9	Pré-processamento da rede.....	4.7
4.10	Algoritmo de codificação.....	4.10
4.10.1	Codificação directa.....	4.10
4.10.2	Processo de codificação.....	4.11
4.11	Avaliação das soluções.....	4.16
4.12	Função de adaptação ( <i>fitness function</i> ).....	4.17
4.13	Integração do algoritmo no contexto do planeamento.....	4.24
4.14	Conclusões.....	4.25

## **CAPÍTULO 5**

### **Exemplo ilustrativo**

5.1	Introdução.....	5.1
5.2	Metodologia geral .....	5.1
5.3	Dados do problema .....	5.1
5.3.1	Horizonte de planeamento .....	5.1
5.3.2	Sistema de distribuição.....	5.1
5.3.3	Processo genético.....	5.5
5.3.4	Resolução.....	5.5
5.4	Resultados obtidos.....	5.6
5.5	Análise dos resultados.....	5.10
5.6	Análise multiobjectivo .....	5.10
5.7	Evolução do processo genético.....	5.13
5.7	Conclusões.....	5.14

## **CAPÍTULO 6**

### **Algoritmos genéticos no planeamento da expansão de redes de distribuição de gás**

6.1	Introdução.....	6.1
6.2	Características do problema.....	6.1
6.2.1	Lista de símbolos .....	6.1
6.2.2	Qualidade nas pressões .....	6.2
6.2.3	Restrições.....	6.3
6.3	Modelo de planeamento .....	6.3
6.3.1	Condições .....	6.3
6.3.2	Codificação .....	6.4
6.3.3	Função de adaptação .....	6.4
6.3.4	Resultados do algoritmo .....	6.8
6.3.5	Integração no contexto do planeamento.....	6.8
6.4	Exemplo de aplicação.....	6.9
6.4.1	Conduitas.....	6.10
6.4.2	Nós de injeção.....	6.10
6.4.3	Consumos .....	6.10
6.4.4	Outros dados .....	6.11
6.5	Resultados .....	6.12
6.6	Análise dos resultados.....	6.15
6.7	Análise multiobjectivo .....	6.15

6.8 Conclusões.....	6.17
---------------------	------

**CAPÍTULO 7**

Conclusões e perspectivas de evolução do modelo .....	7.1
---	-----

**ANEXO A**

Genetic Algorithms in Optimal Multistage Distribution Network Planning

<b>BIBLIOGRAFIA .....</b>	<b>B.1</b>
---------------------------	------------

# Capítulo 1

## Introdução

O planeamento sistemático e eficiente da expansão de distribuição de energia eléctrica tem-se revelado de grande importância, tanto para as empresas distribuidoras como para os consumidores. O objectivo é o desenvolvimento de um sistema de distribuição que tenha em conta três objectivos fundamentais :

- Segurança,
- Economia,
- Qualidade de serviço.

Tendo em conta que cerca de 50% dos custos globais da electricidade derivam dos custos de distribuição, torna-se óbvio que, mesmo uma pequena melhoria na eficiência através de melhores métodos de planeamento da expansão, teria uma influência económica considerável.

O Problema do Planeamento da Distribuição (DPP - da literatura anglo-saxónica - *Distribution Planning Problem*) tem-se revelado um problema de resolução extremamente complexa especialmente devido às suas características multiobjectivo.

Muitos modelos destinados à resolução deste problema têm vindo a ser propostos ao longo dos últimos anos. Uma grande parte destes modelos são modelos estáticos, obtendo-se uma solução para um conjunto fixo de dados e para apenas um período de planeamento. Estudos em planeamento dinâmico, considerando a evolução nas cargas ao longo do tempo e conseqüentes alterações topológicas nas redes, não têm tido um sucesso definitivo quando aplicados a redes de tamanho real. Os modelos matemáticos em que se baseiam estas técnicas são ou demasiado pesados ou negligenciam determinados aspectos de projecto que os engenheiros de planeamento consideram importantes no desenho de sistemas de distribuição.

Mais ainda, a vasta maioria destes modelos obedecem ao princípio da obtenção da chamada "solução óptima". No entanto, mais recentemente, o objectivo de alcançar este conceito de óptimo tem vindo cada vez mais a ser posto em causa, favorecendo-se o uso de métodos multicritério e de algoritmos cujos resultados sejam um conjunto de possíveis boas soluções, em vez de uma solução óptima isolada.

Recentemente, tem vindo a ser desenvolvida uma nova e revolucionária técnica algorítmico-matemática baseada na evolução natural dos organismos, conhecida como **Algoritmos Genéticos**. Esta técnica, já com algumas aplicações conhecidas em diversas áreas nomeadamente em Sistemas de Energia, possui características inovadoras não partilhadas pelas metodologias clássicas até ao momento propostas.

Procurou-se, então, investigar a possibilidade de aplicação destes algoritmos no estudo do DPP. Este estudo foi dirigido no sentido de responder às seguintes perguntas:

- Podem os algoritmos genéticos adequadamente modelizar o DPP?
- Será possível desenvolver algoritmos computacionais eficientes para redes de tamanho real?
- Tem a abordagem genética uma *interface* fácil com métodos de ajuda à decisão multicritério?
- Terão os algoritmos genéticos algumas vantagens sobre técnicas propostas anteriormente?

Os capítulos seguintes demonstram que a resposta é positiva para todas estas questões. De facto, o modelo desenvolvido neste estudo permite analisar o problema numa perspectiva multiobjectivo, enquadrando-se facilmente no processo de tomada de decisão. E, ao contrário de muitos dos modelos propostos anteriormente, o modelo é suficientemente flexível para que diversas características e condições de ordem prática possam ser consideradas, nomeadamente :

- Inclusão de vários cabos na mesma vala, com as consequentes melhorias económicas.
- A possibilidade de desclassificação de uma linha num determinado estágio, permitindo o seu uso num estágio posterior.
- A possibilidade de gerar soluções com anéis abertos, no sentido de melhorar a fiabilidade do sistema de distribuição.
- A possibilidade de uma linha passar por um nó sem carga num determinado estágio no sentido de abastecer outro nó a jusante.
- A possibilidade de lidar naturalmente com factores de diversidade de cargas.
- Consideração de factores de qualidade de serviço como, por exemplo, quedas de tensão nos nós.

Um sumário do material apresentado em cada capítulo é dado em seguida.

O capítulo 2 apresenta uma introdução ao problema do planeamento da expansão de sistemas de distribuição de energia eléctrica. Não se pretendendo uma visão exaustiva sobre o problema, faz-se uma panorâmica geral sobre o "Estado da Arte" em algoritmos e modelos que têm vindo a ser desenvolvidos nos últimos anos.

No capítulo 3 revêem-se os algoritmos genéticos, apresentando-se conceitos, técnicas e exemplos de aplicação nomeadamente na área dos sistemas eléctricos.

No capítulo 4 propõe-se um modelo de planeamento destinado a resolver o problema do dimensionamento, época de construção e localização de subestações e da expansão da rede de distribuição, usando algoritmos genéticos. As vantagens da adopção desta nova abordagem ao problema são discutidas no contexto do planeamento, nomeadamente em conjugação com o uso de métodos de ajuda à decisão multicritério.

No capítulo 5 apresenta-se um exemplo ilustrativo de aplicação do modelo proposto. Neste capítulo apresentam-se também alguns resultados experimentais, sendo estes analisados numa perspectiva de pontuação e apreciação multicritério e, por fim, feito o seu enquadramento no processo de tomada de decisão.

O capítulo 6 demonstra a versatilidade da abordagem genética, apresentando uma aplicação completa ao problema da expansão de redes de distribuição de gás.

No capítulo 7 apresentam-se as conclusões do estudo, e referem-se as perspectivas de evolução do modelo.

## Capítulo 2

### O planeamento da expansão de redes de distribuição de energia eléctrica

#### 2.1 - Introdução

Com o rápido aumento do consumo de energia eléctrica, o problema do planeamento da expansão dos sistemas de distribuição tem-se revelado como um dos mais importantes para as companhias distribuidoras, tendo em conta os importantes investimentos que têm de ser feitos nessa área.

Os estudos de expansão são baseados no sistema existente, em previsões de consumos futuros, extensos cálculos económicos e eléctricos e na experiência e capacidade de julgamento do planeador. No entanto, o desenvolvimento de estudos mais elaborados com um número maior de projectos alternativos e o uso de modelos matemáticos e técnicas de optimização pode melhorar significativamente as soluções tradicionais atingidas pelos planeadores. Para um determinado sistema de distribuição, o nível de consumos presente é conhecido e os níveis futuros podem ser previstos para um estágio (geralmente, um ano) ou para vários estágios. Consequentemente, o problema genérico consiste em planear a expansão do sistema de distribuição (para um ou mais estágios, de acordo com a disponibilidade de dados e com a política da companhia distribuidora) no sentido de satisfazer os consumos, procurando maximizar os seguintes atributos:

#### a) Economia

Trata-se, neste caso, de minimizar custos que podem ser divididos em dois tipos fundamentais:

- Custos de investimento (construção ou reforço de linhas, subestações e transformadores)
- Custos de operação (por exemplo, perdas de energia)

#### b) Fiabilidade

Procura-se maximizar a fiabilidade do sistema de distribuição de energia, minimizando o corte de carga, traduzido em índices como, por exemplo, o valor anual de energia não fornecida.

#### c) Segurança

O sistema de distribuição deve funcionar de forma segura, quer para os consumidores, quer para os seus operadores. Este factor é de vital importância no planeamento destes sistemas. No entanto, a segurança é normalmente avaliada *a priori* e encarada como uma condição técnica.

#### d) Qualidade de serviço

Para além de aspectos relacionados com a fiabilidade do sistema, existem outros factores de qualidade importantes no planeamento dos quais se destacam:

- Impacto ambiental;
- Componente DC;
- Desvios de frequência;
- Assimetria do sistema trifásico;
- Presença de harmónicos e outros tipos de poluição na forma de onda;

- Flutuações no valor da tensão no consumidor.

Apesar de todos estes factores desempenharem um papel importante no planeamento de redes de distribuição, uma atenção especial será dada ao factor das quedas de tensão.

Como é sabido, o objectivo económico é, em geral, conflitual com os outros três. De facto, um melhor desempenho do sistema é geralmente atingido através de investimentos elevados. Por outro lado, investimentos baixos conduzem a uma fraca eficiência do sistema e, eventualmente, a elevados valores de corte de carga.

Não é difícil, então, compreender que nos encontramos perante um problema de elevada complexidade que deriva, fundamentalmente, de três factores:

- a) Trata-se de um problema multiobjectivo.
- b) Muitas das variáveis a considerar são discretas (variáveis de decisão do tipo: *construir/não construir ; reforçar/não reforçar*)
- c) Há a necessidade do período de planeamento ser dividido em várias fases (optimização temporal).

### **2.2 Classificação dos modelos**

Como consequência desta complexidade, o problema do planeamento da expansão da distribuição (DPP) é um problema de grandes dimensões mesmo para sistemas de médio porte. Por este motivo e, tendo em conta as limitações em termos de tempo e de espaço de memória dos computadores, a resolução directa e completa do DPP torna-se inviável para sistemas de dimensão real.

No sentido de ultrapassar esta limitação diversas abordagens ao problema têm vindo a ser propostas nos últimos anos. Estas abordagens, de um modo geral, distinguem-se entre si, por um lado, pelas metodologias e algoritmos utilizados e, por outro lado, pelas simplificações introduzidas nos modelos (especialmente em termos de opções de modelização).

Este ponto pretende fazer uma panorâmica geral sobre os modelos mais representativos desenvolvidos nos últimos anos, classificando-os de acordo com as suas características.

#### **2.2.1 Horizonte de planeamento**

O horizonte de planeamento pode ser dividido num ou em vários estágios. Em geral, um estágio corresponde a um ano no plano de expansão. Em relação ao horizonte de planeamento podemos dividir os modelos em dois tipos:

##### a) Modelos estáticos

A maior parte dos modelos consideram apenas um único estágio de planeamento (por exemplo: [Bac79], [Oli79], [Aok90], [Hin77], [Faw83]). Tais modelos são conhecidos como modelos estáticos. Frequentemente, em aplicações práticas, o algoritmo usado pode ver o planeamento da expansão como uma sequência de expansões anuais, de maneira a que cada expansão constitua um problema diferente. No entanto, este processo não conduz, necessariamente, a um óptimo global pois, em geral, soluções óptimas parciais não garantem a solução óptima global.

##### b) Modelos dinâmicos

Para ultrapassar o problema da optimização parcial foram desenvolvidos métodos mais complexos para resolver o problema da expansão da distribuição em vários estágios em vez de um único estágio. Estes modelos são conhecidos como modelos dinâmicos. É possível ainda distinguir os modelos dinâmicos de acordo com a metodologia utilizada:

- Metodologia pseudo-dinâmica - Esta metodologia considera a duração global do plano, ignorando os consumos reais nos estágios intermediários. Nesta metodologia, cada expansão anual é obtida por um processo de optimização por concatenação após a solução global ter sido atingida ([Sun82]).

- Metodologia dinâmica - Neste caso as decisões de construção são obtidas para cada estágio simultaneamente, no processo de optimização ([Kag93],[Gön86],etc.)

### 2.2.2 Optimização dos subsistemas

Para propósitos de planeamento, é comum dividir o problema global nos seguintes subproblemas, que são resolvidos sucessivamente:

a) Subproblema da determinação da capacidade óptima e/ou da localização óptima das subestações. Em determinadas abordagens, a formulação entra em linha de conta com a rede existente em termos de capacidade de transferência de carga ([Mas74], [Mas78], [Ada74], etc.) ou em termos de *cargaxdistância* ([Hlt76]) No entanto, a representação das linhas individualmente (ou seja, da rede em si) não é considerada. Esta simplificação conduz, geralmente, a resultados pouco aceitáveis do ponto de vista do planeamento.

b) Subproblema da determinação da localização e/ou capacidade óptima para as linhas de distribuição. Os modelos para a resolução deste subproblema entram em conta com a representação total da rede, sem considerar, no entanto, o problema anterior.

No entanto, sob um ponto de vista puramente matemático esta abordagem não conduzirá, necessariamente, a um óptimo global, pois cada subsistema é optimizado independentemente do outro.

Alguns modelos mais complexos, encaram o problema de uma forma global, ou seja, para todo o sistema de distribuição, resolvendo-o considerando a minimização do custo das linhas e subestações simultaneamente.

Estes modelos permitem, geralmente, obter a solução óptima para um único estágio. A complexidade da formulação matemática aumenta consideravelmente no planeamento multi-estágio, tornando-se o processo de resolução mais difícil, pois as decisões de construção de subestações e linhas num determinado estágio têm influência nas decisões nos estágios posteriores.

Podemos, portanto, dividir os modelos em dois grupos:

- O grupo mais geral de modelos, que procuram a solução do problema para cada um dos subsistemas ([Ada73], [Mas74], [Mas78], [Hlt76], etc.).

- O grupo de modelos que procuram a solução global do problema ([Kag93], [Gön86], [Nar91], etc.).

### 2.2.3 Perdas de energia

O custo relacionado com perdas de energia activa constitui a maior parcela facilmente contabilizável dos chamados custos variáveis de operação. Muitas vezes, e de acordo com o

custo capitalizado das perdas, é possível que a capacidade óptima da linhas seja determinada por condições económicas (de operação) em vez de limites térmicos.

Este custo é modelizado de várias maneiras e graus de precisão pelos diversos autores.

Basicamente, os modelos podem ser divididos em três grupos de acordo com a maneira de encarar este factor:

a) Os modelos que ignoram os custos relacionados com as perdas de energia ([Mas78], [Hlt76]).

b) O grupo mais geral de modelos, que encaram o custo das perdas de energia como um custo adicional nas linhas de distribuição e subestações ([Nar91], [Kag93], [Gön86], etc).

c) Os modelos que não incluem os custos das perdas na formulação mas, no entanto, calculam este custo *a posteriori*, na obtenção do custo global do sistema.

### 2.2.4 Radialidade

O planeador pode estar interessado em encontrar uma solução que possua características radiais dependendo da localização geográfica da rede e dos critérios da companhia distribuidora, normalmente relacionados com a segurança do serviço. Por questões de fiabilidade é comum as redes de distribuição (especialmente urbanas) apresentarem estruturas emalhadadas, sendo a operação do sistema feita radialmente. Assim são permitidas reconfigurações do sistema em caso de contingência (por exemplo, saída de serviço de uma linha ou transformador). A introdução de restrições relacionadas com a radialidade na formulação do DPP aumenta consideravelmente a complexidade do mesmo. Estas restrições introduzem, na maior parte dos casos, propriedades indesejadas no domínio do problema, nomeadamente a não convexidade e não conectividade. O DPP torna-se assim num problema de difícil tratamento através de metodologias tradicionais (por exemplo: programação inteira mista, programação dinâmica).

As soluções radiais apresentam, na maioria dos modelos que as incluem, uma estrutura topológica na forma de ramos arborescentes emanando de cada subestação.

Assim, numa parte considerável dos modelos revistos, as restrições de radialidade não são consideradas na formulação do problema. Outros modelos usam determinadas regras especiais ou métodos heurísticos nos seus algoritmos de modo a forçar a condição de radialidade da rede nas suas soluções [Hin77], [Faw83]. No entanto, estas regras heurísticas conduzem, geralmente, a soluções sub-óptimas. Por outro lado, alguns autores fazem referência à possibilidade de inclusão de restrições de radialidade nos seus modelos sem, no entanto, apresentarem exemplos de aplicação em sistemas de tamanho real [Kag90], [Gön86].

### 2.2.5 Quedas de tensão

O nível de tensão no consumidor é determinado pela tensão na subestação e pelas quedas de tensão nas linhas e transformadores, variando com flutuações nos níveis de consumo.

Normalmente, dividem-se as flutuações na tensão em dois grupos: flutuações rápidas e flutuações lentas. Do ponto de vista de planeamento de sistemas de distribuição estaremos apenas interessados nas flutuações lentas de tensão.

As flutuações lentas não podem ser notadas imediatamente, sendo causadas, principalmente, por variações graduais nos consumos e por flutuações na tensão nas subestações. Este tipo de flutuações tem um efeito considerável na eficiência e tempo de vida útil dos equipamentos dos consumidores.

Normalmente é imposto um limite máximo de desvio em relação à tensão nominal (queda de tensão) nas flutuações de tensão nas redes de distribuição.

As flutuações de tensão lentas têm, então, uma grande significância na qualidade de serviço e, conseqüentemente, são um factor a considerar no planeamento e na operação dos sistemas de distribuição.

A maior parte dos modelos revistos não incluem restrições relacionadas com as quedas de tensão no processo de optimização em si. Alguns deles verificam as quedas de tensão no decorrer do processo computacional, não as incluindo directamente na formulação do modelo [Hin77], [Faw83]. No entanto, é normal a verificação das quedas de tensão *a posteriori*, ou seja, depois do processo de optimização sendo, por vezes, feitos determinados ajustes (geralmente reforços nas linhas) no sentido de forçar as restrições [Bac79]. Modelos mais recentes incluem directamente estas restrições na formulação do modelo [Nar91], [Gön86], [Kag93].

### 2.2.6 Outras considerações

Os modelos de planeamento da distribuição poderão ainda possuir, entre outras, as seguintes capacidades:

- a) Determinação do percurso óptimo para as linhas de distribuição<sup>1</sup>.
- b) Determinação da capacidade óptima das linhas e subestações [Gön81], [Hin77].
- c) Consideração de custos fixos e variáveis para linhas e subestações [Faw83], [Gön81], [Gön86], [Kag90].
- d) Possibilidade de inclusão de duas ou mais linhas na mesma vala com os consequentes benefícios económicos<sup>2</sup> [Bur85].
- e) Determinação da política óptima de localização de seccionadores<sup>3</sup> [Mir91].

Naturalmente, a inclusão de qualquer destas capacidades nos modelos tornam, em vários graus, a formulação matemática mais complexa.

### 2.2.7 Algoritmos e técnicas matemáticas utilizadas

A técnica matemática básica na modelização do problema do planeamento da distribuição é a programação inteira mista. Esta técnica é particularmente adaptada a este problema pois as decisões de construir/não construir podem ser representadas com facilidade por variáveis inteiras binárias (0/1). No entanto outras técnicas têm sido utilizadas com algum sucesso nomeadamente:

- Programação dinâmica [Afu82], [Ada73];
- Técnicas de 'caminho mais curto' combinadas com algoritmos de transporte [Hlt76];
- Decomposição [Kag90], [Nar91].

Na maioria dos modelos revistos, determinados problemas práticos são resolvidos por algoritmos especiais como, por exemplo, Branch & Bound. É também comum, em modelos mais recentes, o uso de bibliotecas *standard* de programação matemática ([Gön81], [Kag90], etc.).

Para resolução de grandes problemas têm sido também usados algoritmos baseados em heurística, que procuram soluções aproximadas ([Aok90], [Nar91], [Bac79]). Foram também propostos algoritmos mistos, que procuram aproveitar o melhor de cada um dos tipos de algoritmos atrás citados.

---

<sup>1</sup>Este problema envolve um elevado nível de complexidade e, geralmente, é resolvido *a priori*.

<sup>2</sup>Esta possibilidade é dificilmente formulada num modelo convencional de programação linear: se tivermos duas variáveis booleanas  $a_1$  e  $a_2$  representando a existência de duas linhas  $L_1$  e  $L_2$ , a existência simultânea de  $L_1$  e  $L_2$  (que ocupariam a mesma vala, implicando uma redução de custo  $C$ ) será representada por  $a_1.a_2$  (Na função objectivo teríamos um termo  $-a_1.a_2.C$ ). Esta representação introduz imediatamente uma não linearidade na formulação. Em [Bur85] esta dificuldade é superada com alguma facilidade, pois este modelo utiliza técnicas de simulação e não um modelo de programação linear directo.

<sup>3</sup>Este problema é, só por si, um problema muito complexo. Normalmente é considerado *a posteriori*, ou seja, depois de obtida a solução para a rede de distribuição.

### 2.2.8 Análise multiobjectivo

A grande maioria dos modelos revistos ignora implícita ou explicitamente as características multiobjectivo do DPP. Modelos mais recentes [Kag93], correspondendo a uma evolução no sentido da aceitação dos princípios da análise multi-objectivo no planeamento de sistemas de distribuição procuram incluir explicitamente determinados aspectos importantes (economia, fiabilidade, impacto ambiental) simultaneamente no processo de optimização. Visto que, como já foi referido, estes objectivos são geralmente conflituais entre si, estes modelos apresentam como soluções não apenas um ponto óptimo, mas um conjunto de soluções não dominadas (ou conjunto eficiente ou conjunto óptimo de Pareto). Deste conjunto, a melhor solução de compromisso deve ser escolhida de uma forma automática (utilização de pesos) ou através de uma interacção do sistema com o agente de decisão.

### 2.2.9 Incertezas

Determinados factores que influenciam decisivamente a actividade de uma empresa não estão sob o seu controlo ou não podem ser previstos com exactidão: a isto designa-se como incertezas. Naturalmente, inerente a qualquer problema de engenharia está presente o conceito de incerteza. A modelização de incertezas pode ser probabilística, se o fenómeno for quantificável e se existir informação suficiente para uma análise deste género. Caso não haja informação suficiente ou esta for de natureza qualitativa ou subjectiva, as incertezas podem ser, por exemplo, representadas com recurso à teoria dos conjuntos imprecisos (*fuzzy sets*).

Nos estudos de planeamento a longo prazo de sistemas de distribuição, factores ligados à incerteza são extremamente relevantes (nomeadamente, incertezas na previsão de cargas). No entanto, na maioria dos modelos existentes estes factores são ignorados. Infelizmente, a solução óptima é muito sensível a previsões de carga variáveis. Alguns modelos ([Mir91], [Kag93], [Bur85]) sensíveis a este facto procuram, de alguma maneira, incluir este factor na sua formulação.

### 2.2.10 Fiabilidade

Uma das preocupações principais no planeamento de um sistema de distribuição é a sua fiabilidade. Índices de fiabilidade baixos resultarão em valores elevados de corte de carga, conduzindo a elevados custos indirectos de operação. Existe, portanto, cada vez mais a consciência que se torna necessário incluir este factor nos modelos de planeamento. Infelizmente, a questão da fiabilidade tem diversas vertentes e a sua formulação matemática directa é de elevada complexidade.

Consequentemente, nos modelos desenvolvidos para o planeamento de redes de distribuição, os factores relacionados com fiabilidade têm sido, geralmente, ignorados. No entanto, alguns autores têm vindo a propor alguns modelos de planeamento, onde são integradas considerações relacionadas com a fiabilidade dos sistemas. Em [Mir91] propõe-se, depois de obtida uma solução radial óptima, a construção de linhas para o fecho de anéis (de acordo com determinados critérios técnicos e económicos) com vista a permitir reconfigurações da rede em caso de contingências, aumentando-se assim a fiabilidade da rede. No entanto, este procedimento não conduzirá necessariamente à estrutura emalhada óptima. Neste trabalho procura-se determinar, incluindo incertezas, a localização óptima de seccionadores e interligações com vista a melhorar a fiabilidade de um sistema de distribuição.

Constituindo um assunto tão vasto, não é possível, portanto, focar todos os aspectos relacionados com a fiabilidade. No entanto, fica claro que se deverá dar uma importância crescente a esta questão, nos modelos a serem desenvolvidos futuramente.

### 2.3 Sumário dos modelos

Neste ponto pretende-se dar uma perspectiva dos modelos mais significativos e que, de alguma maneira, marcaram a evolução do planeamento da distribuição, desenvolvidos nos últimos anos para a resolução do DPP.

Adams et al. em 1973 [Ada73] apresentam um modelo dinâmico para o planeamento de subestações utilizando programação dinâmica<sup>4</sup> e algoritmos de fluxo de cargas. No ano seguinte o mesmo autor [Ada74] apresenta um dos primeiros modelos dinâmicos para o estudo do planeamento da expansão de redes. Este modelo, baseado em programação inteira mista, foi utilizado para o estudo de sistemas de subtransmissão e não de sistemas de distribuição.

No mesmo ano Masud [Mas74] apresenta um modelo estático para o planeamento da localização de subestações. Em 1978 [Mas78] expande o modelo para o universo multi-temporal. Ambos os modelos consideram o sistema das linhas apenas em termos de transferência de cargas entre subestações que, como já foi referido é uma representação demasiado simplista da rede de distribuição.

Os modelos estáticos apresentados por Crawford e Holt em 1976 [Hlt76] procuram resolver o problema do planeamento do subsistema das subestações de distribuição através de técnicas que combinam algoritmos do tipo 'caminho mais curto' com algoritmos de transporte.

Em 1977 Hindi e Brameller [Hin77] propõe um modelo estático onde as condições de radialidade são impostas através de um interessante procedimento heurístico de abertura de anéis. Este modelo inclui um conjunto de opções de modelização bastante completo e resolve simultaneamente o problema do planeamento de subestações e o problema do planeamento das linhas de distribuição.

Em 1979, Backlund e Bubenko [Bac79] apresentam um dos modelos estáticos mais importantes desenvolvidos até hoje, aplicado com bastante sucesso na planificação de sistemas reais. O objectivo do modelo é o de determinar, com o auxílio do computador, a estrutura óptima hierárquica de um sistema de distribuição. Este modelo compreende duas fases: 1- uma planificação geral do abastecimento de energia a uma determinada área ; 2 - uma planificação detalhada da rede, baseada nos consumos dos utilizadores. Este modelo, utilizando metodologias heurísticas de optimização, possui as opções de modelização básicas nomeadamente quedas de tensão<sup>5</sup>, radialidade, perdas de energia etc.

No mesmo ano Oliveira e Miranda [Oli79] introduzem, pela primeira vez nos modelos de planeamento de sistemas de distribuição, aspectos relacionados com fiabilidade directamente na formulação da função objectivo.

Gönem e Foote em 1981 [Gön81] desenvolvem um modelo estático muito completo, baseado em programação inteira mista e usando sistemas *standard* de programação matemática. Este modelo inclui a maior parte das opções de modelização básicas. No

---

<sup>4</sup>Neste trabalho o algoritmo de optimização baseia-se na enumeração completa de todas as combinações possíveis de alternativas de expansão para as subestações.

<sup>5</sup>Neste modelo as quedas de tensão são calculadas *a posteriori*, ou seja, após a obtenção da rede. No caso de existirem violações das restrições, são efectuados os ajustes necessários (nos transformadores) de modo a se atingir a viabilidade.

entanto, considerações relacionadas com radialidade e quedas de tensão não são incluídas neste modelo. No ano seguinte, os mesmos autores apresentam um modelo completamente dinâmico [Gön82], mas do qual, no entanto, não se conhecem casos práticos de optimização multitemporal.

Como exemplo de uma metodologia pseudo-dinâmica refere-se o trabalho de 1982 de Sun et al [Sun82] que apresenta um modelo onde o planeamento global é dividido em duas fases: na primeira fase, um modelo estático é aplicado no sentido de se obter uma solução que satisfaça as condições correspondentes ao final do horizonte de planeamento, considerando o conjunto completo de componentes da rede (linhas, subestações, etc.) que seriam construídos durante o período do estudo. Em suma, nesta fase o período do estudo é utilizado com um estágio único. Na segunda fase, o modelo estático é aplicado a cada rede intermédia expandida do estágio precedente, sendo escolhidos componentes da rede do conjunto que foi seleccionado na primeira fase. Consequentemente, o procedimento de planeamento é baseado num processo de optimização por concatenação, não se obtendo, necessariamente, a solução óptima. Este modelo, baseado em programação inteira mista, não inclui restrições relacionadas com radialidade e quedas de tensão.

Em 1983 Fawzi et al. [Faw83] desenvolvem um modelo estático para a optimização do sistema global, onde são incluídas todas as opções de modelização básicas excepto o cálculo da dimensão óptima para as subestações. As condições de radialidade são impostas no processo computacional em si. Por seu lado, as quedas de tensão não são modelizadas directamente mas são verificadas no decorrer do algoritmo.

El Kady [Kad84] desenvolveu um modelo pseudo-dinâmico para o estudo do planeamento de sistemas de distribuição de energia para um estágio único correspondente ao horizonte de planeamento do problema. Depois de ser feito este estudo, a rede resultante é dividida heurísticamente em diversas sub-redes de menor dimensão (a divisão é feita de acordo com o julgamento do planeador). Em seguida, é efectuado um processo de optimização dinâmica no sentido de obter planos de expansão óptimos para cada uma das sub-redes. Naturalmente, e como é apontado por El-Kady no seu trabalho, este procedimento não é equivalente à optimização multitemporal da rede não particionada. Este modelo inclui diversas opções de modelização, nomeadamente: localização óptima de subestações, custo das perdas de energia. As restrições de radialidade neste modelo são forçadas pelo algoritmo utilizado. No que diz respeito às quedas de tensão, estas são verificadas apenas nas sub-redes atrás referidas.

Burkhardt et al [Bur85], conscientes do facto de que a solução do DPP é extremamente sensível às incertezas na previsão das cargas, mostram como converter os efeitos obscuros relacionados com estas incertezas (modelizadas de forma probabilística) numa lista clara de prioridades de medidas de construção. Este modelo, destinado a ser aplicado a sistemas de dimensão real, é baseado em técnicas de simulação aliadas a um grau elevado de interactividade com o agente de decisão. Neste modelo, foi também contemplada, pela primeira vez, a possibilidade da existência de duas linhas de distribuição partilhando a mesma vala.

Gönem e Ramirez-Rosado apresentam em 1986 [Gön86] um modelo multitemporal bastante completo, baseado em programação inteira mista, que resolve simultaneamente o problema da localização, dimensão e altura de construção de subestações de distribuição e o problema da expansão da rede. Este modelo inclui várias opções de modelização, nomeadamente perdas de energia e custo fixo e variável das linhas e subestações. Permite também a inclusão na formulação de restrições relacionadas com radialidade e quedas de tensão. No entanto a inclusão destas restrições parece limitar a utilização deste modelo a sistemas de pequenas dimensões.

Em 1990 Kagan e Adams [Kag90] apresentam um modelo baseado na técnica de decomposição de Benders e algumas das suas variantes. O modelo inclui a maior parte das opções de modelização básicas<sup>6</sup>. No entanto não são apresentados exemplos práticos de aplicação do modelo a sistemas de dimensão real.

Em 1991 Nara et al. [Nar91] propõem um método aproximado multiestágio baseado numa metodologia de decomposição pseudo-dinâmica destinado a resolver problemas de grande dimensão. O problema global ( $n$  estágios) é dividido em  $n$  problemas de um estágio que são resolvidos através de um algoritmo de optimização referido num trabalho anterior [Aok90]. Em seguida, os resultados destes subproblemas são coordenados minimizando a soma pesada dos custos de instalação e dos custos relacionados com violação de restrições. Um procedimento chamado de *'backward path'* coordena também os resultados dos subproblemas removendo itens desnecessários e reduzindo custos de instalação. Este método apresenta assim alguns resultados interessantes, de qualidade superior a outras metodologias pseudo-dinâmicas. Este modelo inclui directamente na sua formulação restrições relacionadas com radialidade e quedas de tensão mas não inclui o valor das perdas de energia na função objectivo. O algoritmo de resolução procura minimizar as perdas fazendo com que a tensão seja o mais elevada possível.

Em 1993 Kagan e Adams [Kag93] procuram resolver o DPP estendendo a capacidade de modelos existentes a uma análise multiobjectivo, incluindo incertezas. Neste trabalho o problema é formulado num enquadramento de programação matemática *fuzzy*. Este modelo permite representar objectivos múltiplos, dados imprecisos e várias opções de modelização incluídas em modelos anteriores [Kag 90]. A solução final é obtida com a participação do agente de decisão através de um *interface* adequado, procurando-se determinar a melhor solução de compromisso entre objectivos conflituais. No entanto, este modelo não inclui na sua formulação restrições relacionadas com radialidade e quedas de tensão. Por outro lado, a complexidade do procedimento limita a aplicação do modelo a sistemas de pequena dimensão.

### 2.4 Conclusões

Neste capítulo apresentou-se, em traços gerais, o problema do planeamento da expansão de sistemas de distribuição de energia eléctrica.

Ficou claro que este problema envolve uma elevada complexidade, quer ao nível da formulação, quer ao nível da resolução. Esta complexidade deriva fundamentalmente das suas características multiobjectivo e do facto de envolver um número elevado de variáveis (na sua maioria discretas). Surge ainda a necessidade de se efectuar uma análise multi-temporal, onde as decisões tomadas num determinado estágio se repercutem nos estágios posteriores. Por outro lado, a inclusão, na formulação, de diversas opções de modelização (radialidade, quedas de tensão, etc) aumenta consideravelmente a complexidade matemática do problema, introduzindo características normalmente consideradas indesejadas do ponto de vista de resolução, designadamente: não linearidade, descontinuidade, não conectividade e não convexidade. Estas características, aliadas ás limitações de capacidade de memória e processamento dos computadores, tornam este problema quase intratável usando metodologias e algoritmos de optimização tradicionais (programação dinâmica, programação inteira mista, decomposição, etc).

Foi ainda dada, neste capítulo, uma panorâmica geral sobre os modelos mais significativos desenvolvidos nos últimos anos destinados à resolução do DPP. Tornou-se,

---

<sup>6</sup>Neste modelo os autores indicam que é possível incluir restrições relacionadas com a radialidade na formulação do modelo mas não é apresentado nenhum exemplo onde estas restrições sejam consideradas.

desta maneira, evidente que, apesar da eficiência relativa de alguns destes modelos, nenhum deles se apresenta como um sucesso definitivo, ao ponto de o podermos considerar como um modelo padrão para a resolução deste problema. De facto, longe disso, todos os modelos revistos apresentam determinadas limitações e simplificações que, e para resumir, os condicionam da seguinte maneira:

- Por um lado, a não incluírem certas opções de modelação normalmente consideradas essenciais pelos engenheiros de planeamento, nomeadamente: radialidade, multi-temporalidade, fiabilidade, etc.

- Por outro lado, a inclusão destas opções, aumentando a complexidade matemática do problema, limita a aplicação do modelo a pequenos sistemas de teste, não permitindo a sua utilização em sistemas de tamanho real.

Estamos, portanto, ainda muito longe de um modelo 'global' onde sejam contemplados os diversos aspectos do problema de planeamento, bem assim como todas as opções de modelização. É mesmo um tal modelo exigirá, naturalmente, algum grau de interactividade com o agente de decisão/planeador.

Conclui-se, então, que se torna necessário procurar uma abordagem de alguma forma diferente das abordagens tradicionais. Esta nova abordagem deverá permitir lidar, com alguma facilidade, com funções objectivo '*mal comportadas*' e permitir um enquadramento fácil da solução numa análise multiobjectivo.

Nos capítulos seguintes procura-se estudar a exequibilidade da aplicação na resolução do DPP de uma técnica inovadora baseada na evolução natural conhecida como **Algoritmos Genéticos**.

## Capítulo 3

### Algoritmos genéticos

#### 3.1 Introdução

À primeira vista, os algoritmos genéticos são uma tentativa de implementar algum tipo de estratégias evolucionárias numa grande variedade de sistemas de informação.

A ideia do uso de métodos evolucionários em sistemas de aprendizagem automática surgiu nos anos 60 e foi discutida, por exemplo, em [Fog66]. [Bag67] usa o termo '*Algoritmo Genético*', mas apenas em 1975 [Hol75] a comunidade científica começa a considerar a utilização de algoritmos genéticos.

O conceito é atraente: durante um período superior a 4 biliões de anos a natureza produziu, aplicando o processo de evolução, organismos que nenhum engenheiro poderia sonhar em produzir. Estes organismos têm uma capacidade quase perfeita de adaptação a qualquer situação. Por outras palavras, a evolução conduziu-nos a soluções quase-óptimas para um sem número de problemas complexos.

O modelo do processo é bem conhecido: a teoria da evolução de Darwin. Hoje em dia existem computadores que permitem operar a velocidades infinitamente superiores à da natureza. Então porque não tentar imitar o processo natural?

Surgem então os algoritmos genéticos, que são aplicados principalmente a problemas de procura e optimização.

#### 3.2 O mecanismo de evolução

Ao tentarmos imitar a natureza, precisamos, em primeiro lugar, de falar sobre populações de indivíduos.

Cada um destes indivíduos define uma solução parcial ou potencial para o problema em consideração. Estes indivíduos podem representar funções aproximadas para resolução de um problema matemático, protótipos de agrupamentos num sistema de classificação, regras num sistema pericial, etc.

Os indivíduos são codificados em cadeias - os **cromossomas** - construídas sobre um determinado alfabeto (por exemplo o alfabeto binário {0,1}), de maneira a que sejam mapeados de forma única no domínio das variáveis de decisão. Todo o processo de procura toma lugar ao nível da codificação.

Uma vez calculada a representação no domínio das variáveis de decisão da população corrente, o desempenho de cada indivíduo é obtido de acordo com uma determinada função objectivo que caracteriza o problema a ser resolvido. A esta função damos o nome de **função de adaptação** ou '*fitness function*'.

Na medida em que esta função desempenha o papel de 'meio ambiente', ela estabelece a base para o processo de selecção. Por outras palavras, as soluções são classificadas por esta função de adaptação, que atribui melhores valores de adaptação a soluções melhores.

Cada indivíduo é então caracterizado pelo par

(cromossoma, adaptação)

---

#### Exemplo

Para ilustrar o conceito de indivíduo supunhamos que queríamos maximizar a função (inteira)

$$f(x) = 10 - (x - 2)^2$$

no intervalo [0,31].

Poderíamos simplesmente codificar  $x$  como um número binário usando 5 bits. Cada solução deveria ser avaliada pela função objectivo produzindo um valor. No nosso caso o cromossoma

00100 (correspondente a  $x=4$ )

receberia um valor de adaptação

$$f(00100) = 10 - (4-2)^2 = 6$$

O par

(00100,6)

representa, então, um indivíduo.

---

Passamos então ao estágio seguinte no processo evolutivo:

#### A reprodução

Neste estágio, o valor da adaptação de um indivíduo servirá para conduzir o processo de selecção. Indivíduos com um valor de adaptação elevado terão uma probabilidade superior de serem seleccionados para o próximo estágio evolutivo do que os indivíduos pior adaptados e, conseqüentemente, é esperado que a adaptação média desta geração intermédia de indivíduos seja superior.

Haverá, então, um número superior de cópias dos melhores indivíduos, apesar de haver a possibilidade de existirem cópias dos piores.

Este processo é realizado por um dos operadores genéticos conhecido como *operador selecção*.

Os diversos processos de implementação deste operador serão referidos no próximo ponto deste capítulo.

Os indivíduos seleccionados são então modificados através da aplicação de outros operadores genéticos de modo a se obter a próxima geração. Estes operadores genéticos manipulam directamente os genes que constituem o cromossoma, assumindo que determinados genes codificam, em média, melhores indivíduos do que outros. Estes operadores genéticos são divididos em duas categorias:

a) Recombinação. Este tipo de operador faz com que pares (ou grupos maiores) de indivíduos troquem informação genética entre si.

b) Mutação. A mutação provoca modificações na representação genética de um indivíduo de acordo com alguma regra probabilística.

### 3.3 Algoritmo genético canónico

Apesar de existirem diversas formas [Gre91] de algoritmos genéticos, referir-se-á apenas o **algoritmo canónico**. Isto significa que trataremos apenas com os três operadores genéticos básicos - selecção, cruzamento (ou *crossover*, uma forma de recombinação) e mutação. Os cromossomas utilizados são do tipo binário e de tamanho fixo. Os AG canónicos usam uma população de tamanho fixo, sem sobreposições, e cada

geração é criada pelo operador selecção e alterada pelos operadores cruzamento e mutação. A primeira população é gerada aleatoriamente.

### 3.3.1 Selecção

Este operador pode ser implementado de diversas maneiras. A técnica usada neste trabalho é conhecida como *torneio estocástico* [Gol91]. Esta implementação, particularmente adaptada a um futuro sistema distribuído, é muito simples:

Cada vez que queremos seleccionar um indivíduo para reprodução, escolhemos dois, aleatoriamente, e o melhor ganha com uma determinada probabilidade fixa (tipicamente 0.8). Este esquema pode ser melhorado, por exemplo, usando mais indivíduos no torneio [Gol91a] ou ainda considerando probabilidade de vitória proporcional, eventualmente conduzindo ao chamado *torneio de Boltzmann* [Gol91b], generalizando o paradigma do *simulated annealing*<sup>1</sup> [Kir83].

### 3.3.2 Cruzamento

O operador de recombinação de um AG canónico é chamado **cruzamento** (*crossover*).

Este processo é uma operação de recombinação aleatória mas, por outro lado, bem estruturada. O cruzamento simples pode ser dividido em dois passos. Primeiro, os indivíduos existentes são escolhidos aleatoriamente, com uma elevada probabilidade de cruzamento. Em segundo lugar, cada par de indivíduos cruza-se da seguinte maneira: uma posição inteira  $p$  ao longo do cromossoma é seleccionada de uma forma aleatória (linear) no intervalo  $[1, L-1]$ , sendo  $L$  o comprimento do cromossoma; dois novos cromossomas são criados trocando-se todos os bits (genes) entre as posições  $1$  e  $p$  inclusive. Para ilustrar este processo, consideremos dois cromossomas  $A$  e  $B$  de comprimento 7, retirados da população anterior e acasalados aleatoriamente. Supunhamos que o ponto de cruzamento obtido foi  $p=4$ . Do cruzamento resultante obtém-se duas novas *strings*  $A'$  e  $B'$ , de acordo com esta troca parcial.

Este processo é ilustrado na Fig 3.1.

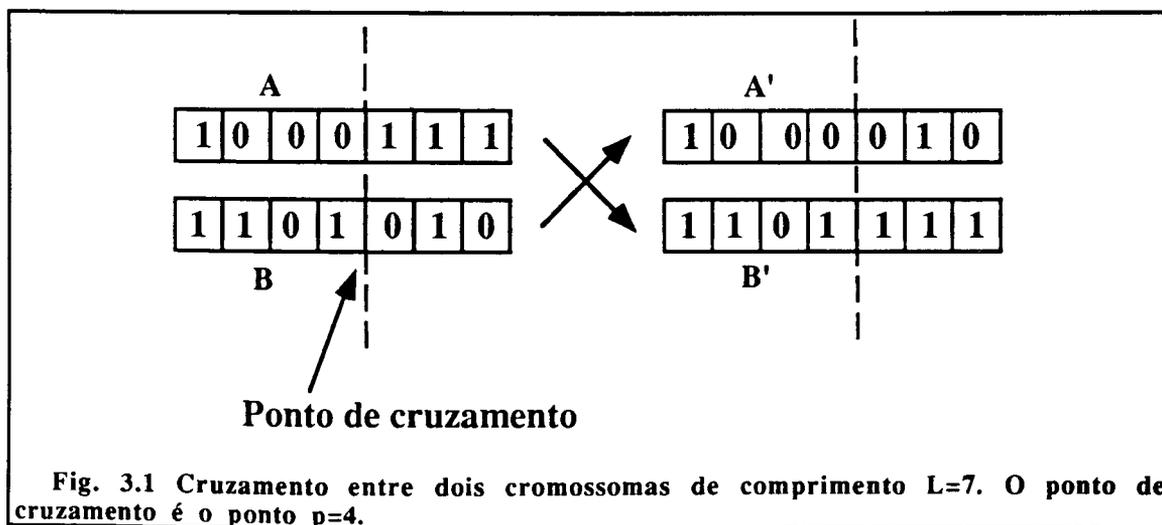


Fig. 3.1 Cruzamento entre dois cromossomas de comprimento  $L=7$ . O ponto de cruzamento é o ponto  $p=4$ .

<sup>1</sup>O *simulated annealing* é um procedimento estocástico que é aplicável a um vasto campo de problemas de procura e optimização. Resultados experimentais mostram que esta técnica é altamente eficiente quando aplicada a determinados problemas como, por exemplo, partição de gráficos e o problema do caixeiro viajante. Os AG podem ser considerados, de certa maneira, como uma generalização desta técnica.

O cruzamento permite a troca de material genético entre dois cromossomas 'pais', permitindo que genes benéficos de pais diferentes sejam combinados nos seus descendentes.

### 3.3.3 Mutação

No algoritmo canónico a mutação consiste em alterar cada bit individual do cromossoma com uma probabilidade muito baixa (Por exemplo,  $P_{mut} = 0.001$ ).

Os operadores selecção e cruzamento efectivamente procuram e recombina cromossomas existentes. No entanto, não criam nenhum material genético novo na população.

Assim, o operador mutação é usado no sentido de garantir que a possibilidade de se procurar num subespaço particular do espaço do problema nunca é nula, inibindo assim a tendência de terminarmos a procura num óptimo local, em vez de um óptimo global. No entanto, uma mutação demasiado elevada pode ter efeitos perniciosos. Uma probabilidade de mutação de 0.5 conduz sempre a uma procura aleatória, independentemente da probabilidade de cruzamento [Gol89].

### 3.3.4 Parâmetros

À semelhança de outros métodos estocásticos, os AG têm um determinado número de parâmetros como, por exemplo:

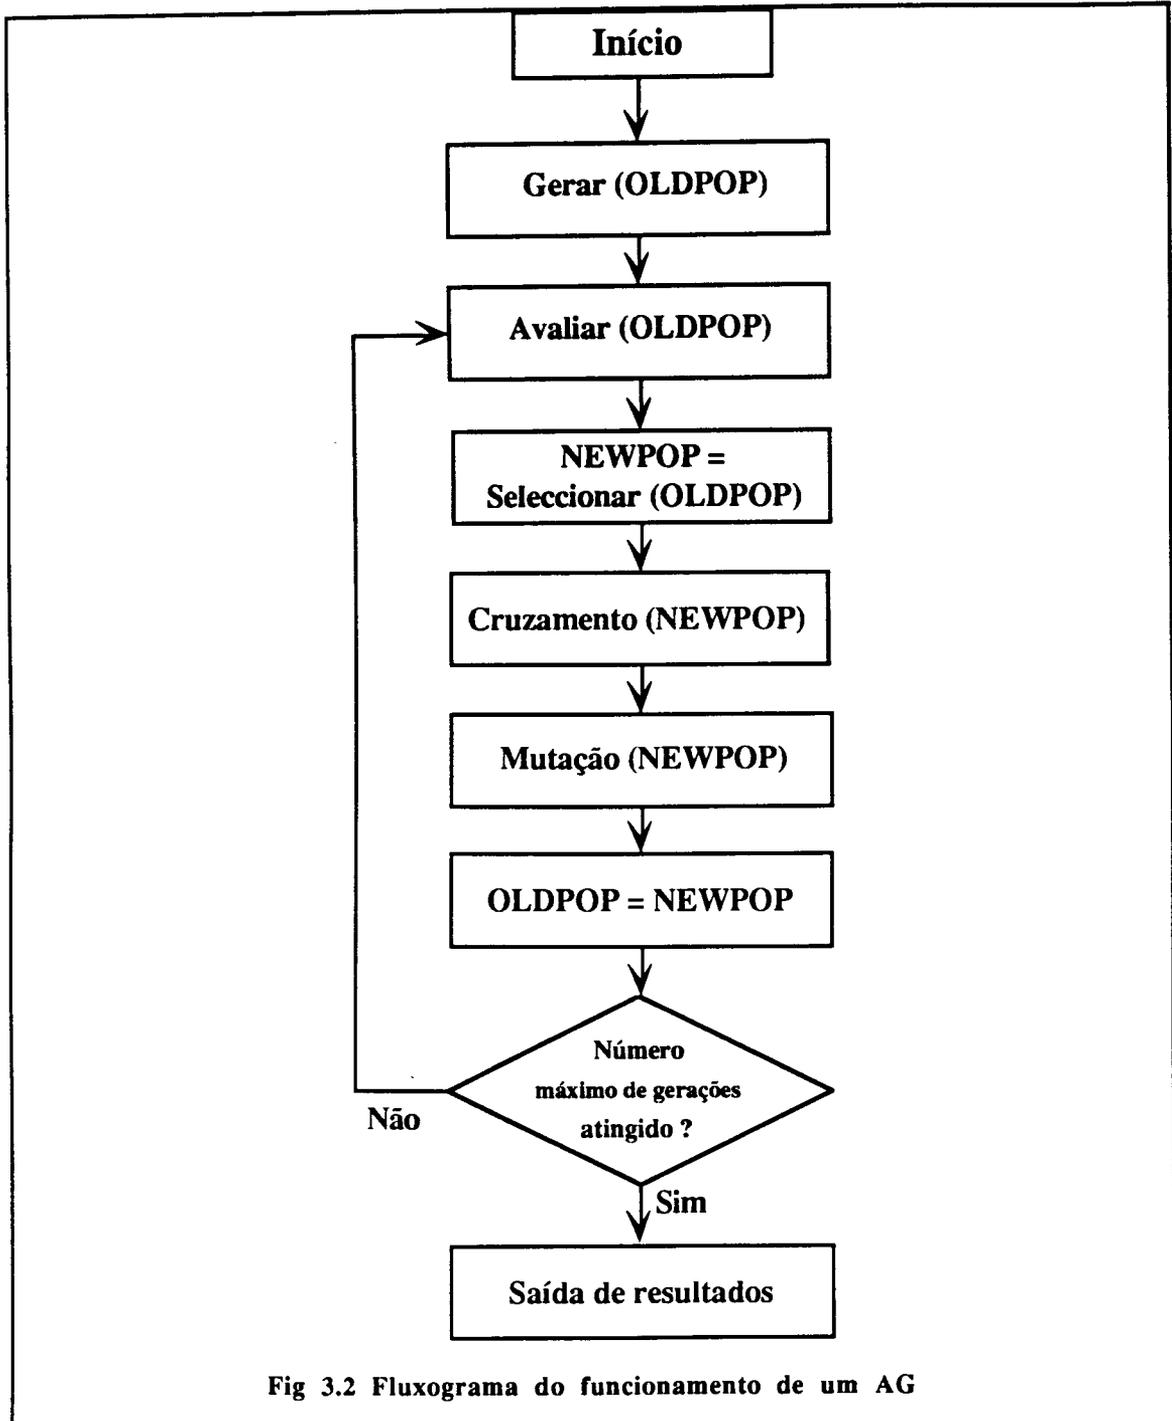
- Tamanho da população;
- Probabilidades das operações genéticas;
- Número de indivíduos no torneio, etc.

Estes parâmetros devem ser seleccionados com todo o cuidado, pois o desempenho dos AG depende intimamente dos valores utilizados. Usualmente são recomendados valores de população relativamente baixos, probabilidades de cruzamento elevadas e probabilidades de mutação baixas (e inversamente proporcionais ao tamanho da população). Em [Gol89] faz-se uma análise aprofundada da sensibilidade dos algoritmos em função dos parâmetros.

## 3.4 Funcionamento de um algoritmo genético

Um algoritmo genético canónico é um processo muito simples: primeiro geramos uma população inicial aleatoriamente, avaliamos-a e começamos a gerar novas populações aplicando os operadores genéticos atrás descritos. Este processo é ilustrado no fluxograma da fig 3.2.

Este comportamento muito simples esconde, no entanto, um processamento poderoso feito pelos AG. De facto, a combinação da selecção e do cruzamento leva à proliferação de indivíduos possuindo pequenos blocos de bits, fortemente acoplados, conduzindo a um bom desempenho. Estes blocos, usualmente chamados *schemata* [Hol75] são replicados através do processo de selecção e combinados ou separados pelo cruzamento. Consequentemente, os AG tendem a seleccionar indivíduos com um bom desempenho e recombinar alguns dos seus blocos constituintes., criando cada vez mais cópias de bons *schemata*, simplesmente pelo uso da selecção e do cruzamento. Este processo escondido é chamado *paralelismo implícito* porque o número de *schemata* processados por geração é tipicamente  $O(N^3)$  sendo  $N$  o tamanho da população. A comparação com o número de avaliações da função de adaptação  $N$  é muito favorável. Esta característica é distintiva dos Algoritmos Genéticos e conduz a elevados desempenhos dos mesmos.



### 3.5 Variações nos AG

O algoritmo genético canônico tem sido melhorado de diversas maneiras para além das já referidas acima. Diferentes métodos de selecção foram propostos [Bak87] no sentido de reduzir erros estocásticos relacionados com a selecção por *roleta*. Em 1985 Baker [Bak85] propõe o sistema de *ranking* (ordenação) como alternativa à atribuição proporcional de adaptação, mostrando que assim se pode evitar a convergência prematura e acelerar a

procura quando a população se aproxima da convergência [Whi89]. Também foram propostos outros operadores de recombinação, nomeadamente o *crossover* múltiplo (mais do que um ponto de *crossover*) [Spe91].

O operador mutação tem-se mantido mais ou menos inalterado, mas o uso de cromossomas reais (não binários) requer o uso de operadores de mutação alternativos [Dav91]. Este factor motivou ainda o desenvolvimento de operadores não convencionais de recombinação, como por exemplo o chamado *crossover* intermédio [Bäc91].

Outros parâmetros também foram introduzidos tal como o de 'fosso de gerações' (*generation gap*). A abordagem geracional do algoritmo genético canónico implica populações que não se sobrepõem o que, como é sabido, não é o caso em sistemas naturais. O conceito de *generation gap*, estabelece quantos descendentes são produzidos em cada geração.

Os AG têm também vindo a ser aplicados em problemas de ordenação. Neste caso são usadas representações diferentes das binárias, requerendo operadores genéticos diferentes, como por exemplo o operador *inversão* (uma forma de mutação) e o *crossover* *cíclico* [Gol89].

Por outro lado, têm sido propostas diversas implementações de AG paralelos. Estas implementações são particularmente interessantes pelo seu desempenho excepcional.

Finalmente, alguns modelos genéticos implementam o conceito de isolamento geográfico (Ver, por exemplo, [Gor92]), que é um princípio importante na evolução natural. Estes modelos têm revelado comportamentos muito interessantes em termos de desempenho.

### 3.6 Vantagens dos Algoritmos Genéticos

Os AG apresentam diversas vantagens em relação às técnicas de optimização convencionais:

a) Visto que os AG desenvolvem a sua procura a partir de uma população de pontos e são baseados em regras de transição probabilísticas, é mais provável que converjam para óptimos globais do que as técnicas de optimização tradicionais. Estas são, na sua maioria, baseadas em métodos determinísticos de 'subida de encosta' que, por definição, encontrarão apenas óptimos locais.

b) As técnicas de optimização tradicionais requerem que as funções objectivo sejam '*bem comportadas*', o que restringe a sua aplicação.

Por seu lado, os AG toleram funções descontínuas, não convexas e ainda a existência de 'ruído' na função de avaliação. Os AG não necessitam, também, de qualquer informação sobre o gradiente da função objectivo.

c) Os AG não assumem da existência de qualquer informação *a priori* sobre o problema, além daquela necessária para definir o espaço das variáveis de decisão e o problema em si (ou seja, a função objectivo). No entanto, só é necessário definir esta informação sobre o espaço de procura.

d) Os AG são particularmente adaptados a processamento paralelo. O aumento da disponibilidade de poder de computação paralela que os AG podem, de facto, explorar, estimulou a procura de novos campos de aplicação da abordagem genética. Em meados dos anos 80 foram iniciados estudos de simulação e implementação em *hardware* dos AG.

e) Uma das grandes linhas de força dos AG é a falta de ligação com heurísticas específicas de um determinado domínio de aplicação.

Como nota final refere-se que, apesar das suas limitações, o poder dos métodos tradicionais é reconhecido - os AG deverão ser utilizados nos casos onde é impossível (ou muito difícil) obter soluções eficientes através das abordagens tradicionais.

### **3.7 Características especiais dos algoritmos genéticos**

Em problemas reais de engenharia determinados problemas práticos colocam-se na utilização dos AG. Este ponto refere alguns desses problemas e as estratégias utilizadas na sua resolução.

#### **3.7.1 Variáveis de decisão discretas**

Estas variáveis podem ser tratadas directamente através de codificação binária (ou mesmo n-ária) do cromossoma. Os AG, devido à sua estrutura natural, são particularmente adaptados a problemas com variáveis discretas e, em especial, variáveis binárias.

#### **3.7.2 Variáveis reais**

Os valores reais das variáveis podem ser aproximados com o grau de precisão requerida usando, por exemplo, uma representação binária em ponto fixo. É possível ainda representar variáveis reais em vírgula flutuante, expandindo assim a gama de valores representáveis.

#### **3.7.3 Restrições**

Muitos problemas de optimização estão sujeitos a determinado tipo de restrições. Os AG podem lidar com as restrições de duas maneiras. A mais eficiente é embeber directamente estas restrições na codificação dos cromossomas, eliminando à partida um conjunto de soluções inviáveis. Quando isto não é possível, a adaptação de indivíduos inviáveis deve ser calculada de acordo com uma função penalidade que assegure que estes indivíduos têm, de facto, uma adaptação baixa. A adaptação deve também reflectir a maior ou menor proximidade da solução ao domínio de viabilidade.

No entanto, funções penalidade apropriadas não são necessariamente fáceis de estabelecer, pois podem afectar consideravelmente a eficiência da procura genética.

#### **3.7.4 Problemas multiobjectivo**

Os problemas de engenharia raramente requerem a optimização de uma função com um objectivo único. Normalmente, há vários objectivos conflituais que devem ser optimizados simultaneamente.

Em muitos casos, a solução para problemas deste tipo é obtida combinando os diversos objectivos num único critério a ser optimizado, de acordo com uma *função de utilidade*. No entanto, em muitos casos, a função de utilidade não é conhecida antes do processo de optimização. O problema deve então ser tratado como um problema multiobjectivo, com objectivos não comumente mensuráveis. Desta maneira, um número de soluções pode ser encontrado. Estas soluções proporcionam ao agente de decisão um conhecimento aprofundado sobre as características do problema a ser optimizado, permitindo-lhe articular as suas preferências, antes de uma solução final ser escolhida. Ao contrário dos problemas de optimização com um objectivo único, a solução de um problema multiobjectivo é, em geral, um conjunto de pontos conhecido como conjunto óptimo de Pareto. Como foi referido no capítulo anterior, a obtenção deste conjunto nem sempre é uma tarefa fácil. Os algoritmos genéticos, mantendo uma população de soluções, podem pesquisar em paralelo soluções não dominadas. Esta característica torna os AG muito atraentes para a resolução de problemas multiobjectivo [Fon93].

### **3.8 Aplicações dos algoritmos genéticos**

Apesar de serem uma técnica relativamente recente, os AG têm aplicações em inúmeros campos do conhecimento e, em particular, da engenharia. Eles têm sido utilizados, quer isoladamente, quer em conjunção com outras técnicas inovadoras (redes neuronais [Mil90], fuzzy logic [Rod93], [Lin92], etc.).

Seria impossível, no entanto, citar todos os estudos baseados em AG. No entanto, terá algum interesse referir algumas aplicações particularmente interessantes no campo da engenharia de controlo e dos sistemas de energia.

#### **3.8.1 Engenharia de controlo**

Um dos campos onde os AG têm sido aplicados com um sucesso apreciável é o da engenharia de controlo. Neste campo, os problemas que se apresentam aos engenheiros possuem uma complexidade elevada e têm quase sempre características multiobjectivo. Os AG tornaram-se, então, numa ferramenta poderosa, em especial, quando usados em conjunto com outras ferramentas já existentes [Fle93].

De uma forma geral as aplicações de AG na engenharia de controlo podem ser divididos em duas áreas principais:

##### **a) Planeamento *off-line***

Neste caso os AG são utilizados *off-line* no processo de optimização, onde os indivíduos evoluem de uma população aleatória.

##### **b) Adaptação, aprendizagem e optimização *on-line*.**

Nas aplicações *on-line*, a avaliação directa de indivíduos mal adaptados poderia ter consequências graves. Os AG operam, normalmente, sobre modelos do sistema *on-line* e apenas influenciam indirectamente o controlo.

#### **3.8.2 Sistemas de energia**

Diversos estudos têm sido feitos no campo dos sistemas de energia com vista à resolução de diversos problemas utilizando uma abordagem genética. Muitos destes estudos podem-se integrar no campo da engenharia de controlo mas não se conhece, por enquanto, nenhuma aplicação no planeamento de sistemas de distribuição.

No sentido de mostrar a versatilidade da abordagem genética neste campo referem-se os seguintes trabalhos relacionados com sistemas de energia abordando diversos aspectos:

- Análise de redes eléctricas [Din92];
- Localização óptima de condensadores [Ajj91];
- Optimização de níveis de tensão [Hai91];
- Estudo da presença de harmónicos em sistemas de distribuição [Yan91];
- Observabilidade topológica de sistemas eléctricos [Mor91];
- Controlo de potência reactiva [Iba91];
- Resolução do problema do fluxo de cargas [Yin91].

### **3.9 Conclusões**

Os algoritmos genéticos, baseados na evolução natural dos organismos, possuem algumas vantagens consideráveis sobre as técnicas de optimização tradicionais. Estes algoritmos, exigindo um conhecimento mínimo sobre o problema a otimizar e não necessitando de funções objectivo 'bem comportadas', apresentam-se como uma técnica inovadora e apropriada para a resolução de problemas de elevada complexidade com os quais nos deparamos em diversos domínios, em particular no domínio da engenharia.

Esta nova abordagem é particularmente adaptada à optimização multiobjectivo e a problemas com variáveis de decisão discretas.

Todas as características dos AG mostram que estes apresentam um potencial enorme para o problema que se propôs abordar neste estudo - o problema do planeamento da expansão de sistemas de distribuição de energia eléctrica. A motivação em aplicar os AG à resolução do DPP deriva do facto de que são precisamente os pontos problemáticos na resolução do DPP, os pontos fortes dos AG.

Por estas razões, o estudo foi então dirigido para o desenvolvimento de um modelo para a resolução do DPP usando uma abordagem genética, de acordo com as técnicas apresentadas neste capítulo. Naturalmente, alguns problemas de ordem prática tiveram de ser ultrapassados, especialmente na codificação e na criação de um exemplo ilustrativo (o mais realista possível) da aplicação desta abordagem.

Os resultados deste estudo são apresentados nos capítulos seguintes.

## Capítulo 4

### Modelo de planeamento

#### 4.1 Introdução

No capítulo 2 demonstrou-se que o problema do planeamento da distribuição é um problema de elevada complexidade devido, entre outros factores, às suas características multiobjectivo e ao facto de se tratar de um problema discreto.

No capítulo 3 mostrou-se que os algoritmos genéticos estão particularmente adaptados à resolução deste tipo de problemas.

Estas duas considerações consistiram a motivação necessária para o desenvolvimento de um modelo de planeamento da expansão de sistemas de distribuição de energia eléctrica, baseado numa abordagem genética, tal como descrita no capítulo anterior.

O modelo deveria possuir as seguintes características gerais, correspondendo a objectivos bem claros:

- Permitir a análise multitemporal.
- Incluir o maior número possível de opções de modelização, não se tornando demasiado pesado, pois isso impedi-lo-ia de poder ser aplicado a sistemas de dimensão real.
- Ser, ao mesmo tempo, um modelo eficiente e uma ferramenta útil integrada num sistema global de ajuda à decisão no planeamento de sistemas de distribuição.
- Permitir integrar facilmente considerações relacionadas com a análise multicritério.
- Possuir a flexibilidade suficiente para permitir a sua aplicação a outros problemas de planeamento (redes de gás, sistemas hidrotérmicos, etc).

Ao desenvolver-se o modelo que se apresenta neste capítulo pretendeu-se apenas demonstrar a viabilidade de uma abordagem genética ao DPP. Não se trata, portanto, de um modelo exaustivo e, muito menos, de um sistema completo de planeamento. O objectivo principal do modelo é, simplesmente, constituir a base de tal sistema, a ser desenvolvido futuramente.

Por outro lado, a descrição completa do modelo, tornar-se-ia extremamente exaustiva devido ao número elevado e à complexidade dos algoritmos envolvidos. Por esta razão, os pontos seguintes descrevem apenas os pontos essenciais do modelo sem, no entanto, deixar de pormenorizar, quando tal se torne necessário para a compreensão das questões envolvidas.

#### 4.2 Representação do sistema de distribuição

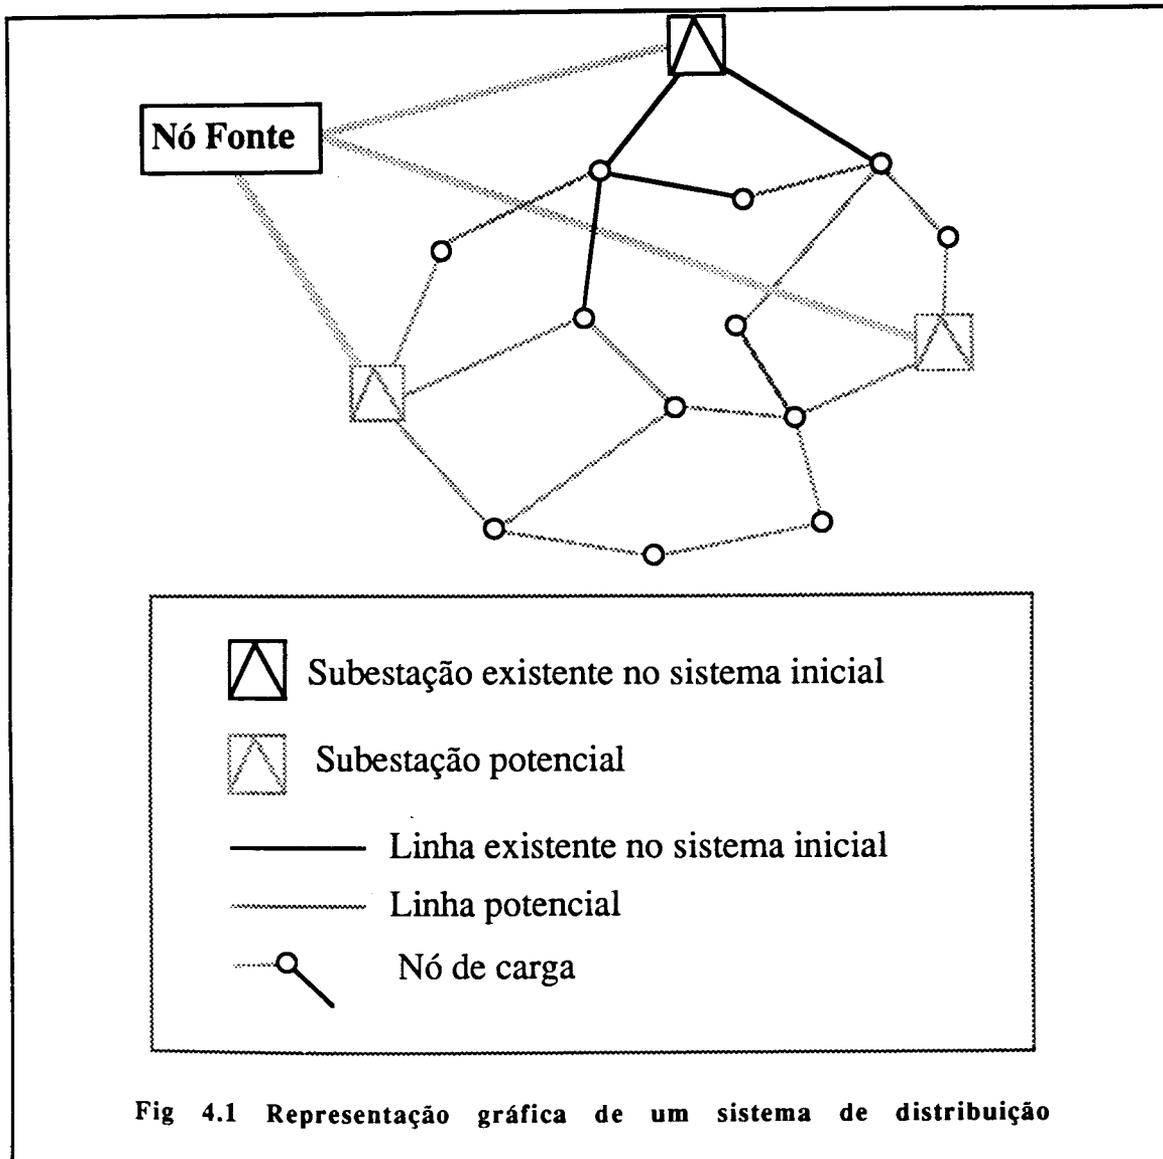
A representação gráfica de um sistema de distribuição consiste numa rede de nodos e arcos. Os nodos representam localizações existentes ou potenciais para as subestações e nós de consumo. Os arcos representam linhas de distribuição, que podem ser divididas em dois tipos:

- Linhas existentes (sistema inicial).
- Linhas potenciais (em projecto).

O fluxo de cargas nas linhas é permitido em qualquer direcção excepto entre o nó fonte e as subestações. Logo, como grafo orientado, as linhas são consideradas como dois arcos opostamente dirigidos.

As subestações são vistas como linhas ligadas ao nó correspondente à sua localização e a um nó fonte comum. Os nós de localização de uma subestação são considerados simultaneamente como nós de consumo.

Esta representação é ilustrada na fig. 4.1.



Posteriormente, a representação gráfica do nó fonte será ignorada, bem assim como as suas ligações às subestações.

Os pontos seguintes referem alguns aspectos relacionados com esta representação.

#### 4.2.1 Lista de símbolos

Apresentam-se em seguida uma lista das variáveis mais importantes do DPP.

### Variáveis do problema

- h** = horizonte de planeamento  
**e** = nº de estágios  
**n** = nº de linhas potenciais  
**j** = nº de subestações potenciais  
**r** = nº de reforços possíveis para as subestações.

### Variáveis de decisão

- $F_{is} = 1$  Se a linha potencial **i** é utilizada no estágio **s**  
 $F_{is} = 0$  Em caso contrário

- $S_{is} = 1$  Se a subestação potencial **i** é utilizada no estágio **s**  
 $S_{is} = 0$  Em caso contrário

- $E_{is} = 1$  Se a expansão de capacidade **i** de uma subestação é utilizada no estágio **s**.  
 $E_{is} = 0$  Em caso contrário

Estas variáveis definem completamente a rede ao longo do horizonte de planeamento. Será, no entanto, conveniente precisar os termos: utilizada, existente e construída.

Considera-se que uma linha é construída no primeiro estágio em que é utilizada<sup>1</sup>. Uma linha é considerada existente num determinado estágio **s**, quando tenha sido construída num estágio **j** tal que

$$j \leq s$$

Uma linha pode existir sem ser utilizada. As condições de radialidade serão impostas, obviamente, às linhas utilizadas e não às linhas existentes. Os custos são sempre calculados relativamente ao estágio em que os itens (linhas, subestações e reforços) são construídos.

#### 4.2.2 Subestações

Como já foi referido, as subestações são consideradas como linhas especiais entre o nó da subestação e o nó fonte. O custo destas linhas é o custo da construção da subestação (nulo, no caso de uma subestação existente) referido ao estágio em que esta é construída. A capacidade (e também a taxa de avarias) da linha que a representa são as mesmas da subestação, incluindo possíveis reforços.

#### 4.2.3 Linhas Potenciais

As linhas potenciais são linhas que poderão, ou não, existir (ou ser utilizadas) num determinado estágio. Estas linhas correspondem a um determinado projecto, ou seja, todos os dados relacionados com a sua construção (custos, capacidade, etc) são conhecidos *a priori*.

---

<sup>1</sup>Tal como o modelo foi formulado, não se considera ter interesse construir uma linha (ou subestação) num estágio onde não é utilizada. Isto deve-se ao facto de que o custo da construção de um determinado item é sempre menor num estágio posterior.

Se a capacidade da linha for encarada como uma variável de decisão<sup>1</sup> dever-se-á considerar  $k$  projectos para a linha, sendo  $k$  o número de valores de capacidade possíveis para a mesma. Cada um destes projectos terá uma variável de decisão correspondente. O modelo desenvolvido contempla assim a possibilidade da determinação da capacidade óptima das linhas.

#### Linhas na mesma vala

O modelo desenvolvido permite ainda considerar os benefícios económicos inerentes à possibilidade de duas linhas de distribuição partilharem a mesma vala. O princípio é simples: se duas linhas forem construídas no mesmo estágio e puderem partilhar a mesma vala, obteremos uma redução de custo correspondente. Normalmente uma condição deste género é muito difícil de incluir num modelo tradicional de programação matemática. No entanto, e como se verá mais adiante, este modelo permite a inclusão fácil desta condição graças ao tipo de abordagem proposto.

#### 4.2.4 Linhas existentes

As linhas existentes no sistema inicial podem ser encaradas de dois modos diferentes, de acordo com a estratégia geral definida pelo planeador do sistema:

a) O planeador pode fixar que as linhas existentes no sistema inicial serão obrigatoriamente usadas nos estágios posteriores. Neste caso não existirão variáveis de decisão correspondentes a estas linhas.

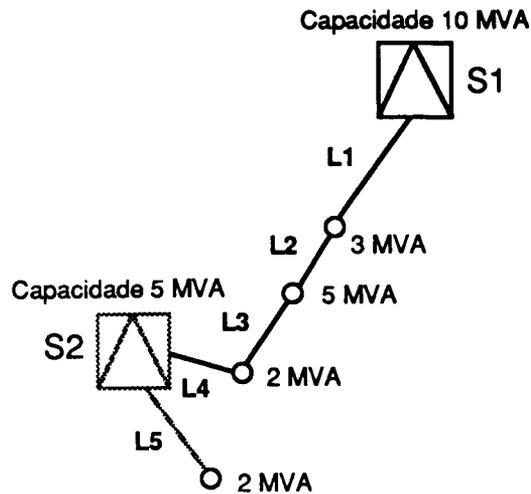
A solução nos estágios dentro do horizonte de planeamento incluirá necessariamente estas linhas.

b) O planeador pode, por outro lado, aceitar a desclassificação (e eventual reutilização) de linhas existentes no sistema inicial. Neste caso estas linhas serão vistas, pelo algoritmo, exactamente como linhas potenciais às quais serão atribuídos custos nulos. Esta possibilidade aumenta a complexidade do problema ao aumentar o número de variáveis de decisão.

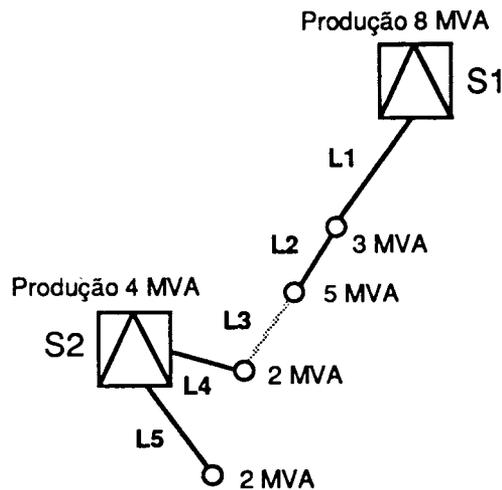
A implementação do modelo permite que qualquer uma destas abordagens seja utilizada. No entanto, apenas nalguns casos se torna interessante a utilização da possibilidade referida na alínea b). No exemplo 4.1 é apresentado um destes casos, onde se pode verificar que apenas permitindo a desclassificação de linhas existentes se pode chegar a uma solução viável.

---

<sup>1</sup>Em geral, num caso real de planeamento, apenas é considerada uma (no máximo duas) capacidade possível para as linhas de distribuição.

**Exemplo:**

Neste exemplo muito simples a subestação S2 deveria, obrigatoriamente, ser utilizada. No entanto uma das linhas existentes {L1,L2,L3,L4} deveria ser desclassificada, de modo a permitir uma solução radial. A desclassificação, por exemplo, da linha L3 conduziria ao sistema radial:

**4.2.5 Reforços nas capacidades das subestações**

O modelo permite considerar projectos de expansão nas capacidades das subestações. A cada um destes projectos corresponderá uma variável de decisão binária  $E_{is}$ . Se para uma determinada subestação forem considerados  $f$  projectos, deverão existir as correspondentes  $f$  variáveis  $E$ .

**4.3 Horizonte de planeamento**

Define-se um horizonte de planeamento  $h$  dividido em  $g$  estágios, que poderão ter uma duração de, por exemplo, um ano ou múltiplos.

A cada estágio corresponderá uma topologia da rede, de acordo com uma determinada realização das variáveis de decisão.

O modelo desenvolvido segue uma metodologia totalmente dinâmica, ou seja, as decisões de construção são obtidas simultaneamente no processo de decisão.

#### 4.4 Custos de investimento

O custo de uma linha corresponde ao custo total da construção da linha e, geralmente, é constituído por duas parcelas: um custo fixo (de instalação da linha) e um custo variável (dependendo do comprimento e da capacidade da linha). O custo de uma subestação ou de um reforço da capacidade inclui todos os componentes do custo associado ao estabelecimento destes itens, custo esse que é estimado previamente<sup>1</sup>. O custo capitalizado das perdas não está incluído no custo de cada um dos itens, pois será considerado separadamente<sup>2</sup>.

Todos os custos indicados referem-se ao estágio inicial. A construção de um determinado item tem custos menores se for efectuada o mais tarde possível no horizonte de planeamento  $h$ . Define-se uma taxa de actualização  $D_r$  (Discount Rate) que corresponde à economia percentual resultante do adiamento da construção de um item por um estágio. O valor desta taxa é definido de acordo com a política da companhia distribuidora; um valor típico em Portugal será da ordem de da ordem de 10%/ano. Este valor significa que, por exemplo, um item a que corresponda um custo

$C_1 = 100$  M\$ (milhões de escudos) para o estágio  $s = 1$

terá um custo  $C_2 = 100/1.1 = 90.9$  M\$ para o estágio  $s = 2$

e um custo  $C_3 = 100/1.1^2 = 82.6$  M\$ para o estágio  $s = 3$ .

#### 4.5 Restrições

Considera-se que o sistema de distribuição está sujeito às seguintes restrições:

a) Limites térmicos das linhas;

As linhas de distribuição estão sujeitas a um limite máximo de fluxo. Sendo  $f_{is}$  o fluxo na linha  $i$  num estágio  $s$  e  $f_{maxi}$  o valor máximo de fluxo na linha  $i$ , temos a seguinte restrição:

$$f_{is} \leq f_{maxi}$$

b) Limites nas quedas de tensão;

Define-se um valor máximo para a queda de tensão admissível percentual (em relação à tensão nominal). Este valor depende, naturalmente, do tipo de consumidor considerado. No entanto podemos considerar um valor limite global para as quedas de tensão com um valor típico na ordem de 8%. Este limite é geralmente considerado como um valor que em caso algum se deve ultrapassar.

Pode-se definir ainda um valor máximo preferível para as quedas de tensão (por exemplo, 5%). Isto leva-nos a uma análise de qualidade dos valores das quedas de tensão, que será referida mais adiante neste capítulo.

<sup>1</sup>Todos os custos são convertidos a custos anuais (ou à correspondente duração de um estágio), considerando o tempo de vida útil do equipamento.

<sup>2</sup>Seria possível tentar incluir os custos capitalizados das perdas directamente nos custos das linhas. A análise separada do valor das perdas activas dá, por outro lado, uma maior generalidade ao modelo.

### c) Limites na capacidade das subestações.

O valor da produção de uma subestação está sujeito a um limite máximo (correspondendo à capacidade da subestação). Em termos de modelo, isto corresponderá exactamente a considerar um limite de capacidade para o ramo do grafo que liga o nó de localização da subestação ao nó fonte. Um reforço na capacidade da subestação corresponderá a um reforço equivalente na capacidade desse ramo.

## **4.6 Condições**

Para o modelo de planeamento da expansão assume-se que:

- Um valor de carga de pico é considerado para cada estágio de expansão<sup>1</sup>. Para se poder avaliar as perdas e índices de fiabilidade é necessária alguma informação extra sobre as curvas de carga (como, por exemplo, o factor de carga).
- As localizações candidatas para a construção das linhas e subestações são conhecidas previamente, sendo os seus custos de instalação estimados.

## **4.7 Descrição do algoritmo**

O processo global de resolução do problema segue, resumidamente, os seguintes passos:

1 - Um conjunto de variáveis (Fis, Sis, Eis) é escolhido para representar uma solução multiestágio. Estas variáveis são codificadas num cromossoma.

2 - Uma população inicial é obtida aleatoriamente.

3 - É iniciado o processo genético, no qual cada solução é avaliada por uma função de adaptação. O primeiro passo desta função é a descodificação do cromossoma. Esta função inclui custos de investimento, custo das perdas de energia, qualidade dos valores das quedas de tensão e fiabilidade. A cada um destes atributos será atribuído um peso de acordo com os critérios do planeador. As restrições não incluídas na codificação serão tratadas através de funções de penalidade adequadas, de modo a que uma solução inviável tenha um valor de adaptação baixo.

4 - No final do processo, um conjunto de bons planos de expansão estará disponível.

## **4.8 Resultados**

A solução final representa uma lista de investimentos a serem efectuados em cada estágio. Esta solução dependerá, naturalmente, dos pesos escolhidos pelo planeador para cada um dos atributos a serem optimizados. Durante o processo genético, várias soluções não-dominadas serão encontradas, sendo apresentadas no final do algoritmo.

## **4.9 Pré-processamento da rede**

Tendo em conta determinadas características do DPP é feito um pré-processamento da rede, no sentido de optimizar o processo de resolução, diminuindo a dimensão do problema. Algumas linhas potenciais, devido à sua localização especial, podem não ser

---

<sup>1</sup>A previsão de cargas está fora do âmbito deste trabalho.

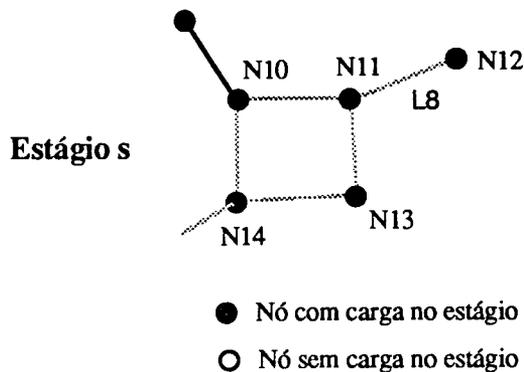
consideradas como variáveis de decisão. O pré-processamento segue os seguintes princípios gerais :

- Se uma linha potencial deve obrigatoriamente existir, à respectiva variável de decisão é atribuído o valor 1.
- Se uma linha potencial não necessita de existir em quaisquer circunstâncias num determinado estágio<sup>1</sup>, à respectiva variável de decisão é atribuído o valor 0.

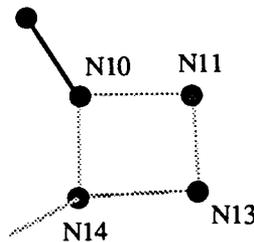
Para ilustrar esta técnica pode-se apresentar alguns exemplos :

a) Quando um determinado nó com carga está ligado apenas a uma linha.

A figura seguinte ilustra este caso. O nó N12 (com carga) está apenas ligado à linha potencial L8 no estágio s. Esta linha deverá obrigatoriamente existir e, conseqüentemente, deixará de ser considerada como linha potencial. À respectiva variável de decisão será atribuído o valor 1.



A rede pode ser simplificada<sup>2</sup> para :

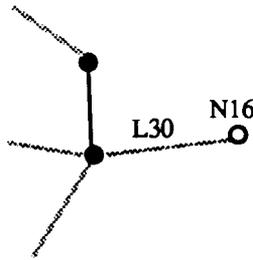


O nó N11 terá necessariamente de estar ligado a uma das duas linhas potenciais a ele ligadas.

b) Quando um nó sem carga está apenas ligado a uma linha potencial num determinado estágio, esta pode ser ignorada nesse estágio. A figura seguinte ilustra este caso.

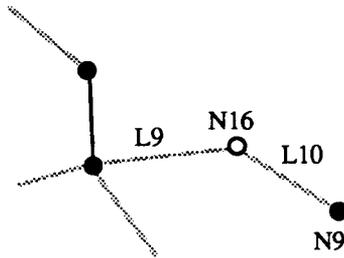
<sup>1</sup> Uma linha não necessita de existir num determinado estágio s quando não necessita de ser utilizada em nenhum estágio j com  $j \leq s$ .

<sup>2</sup> Esta simplificação é feita apenas em termos de variáveis de decisão e posterior codificação. Naturalmente, todos os cálculos efectuados sobre a rede incluirão estas linhas.

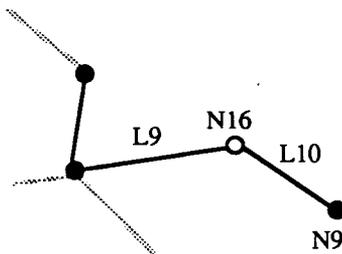


O nó N16 não possui carga neste estágio. A linha L30 pode ser eliminada, sendo atribuído o valor 0 à respectiva variável de decisão.

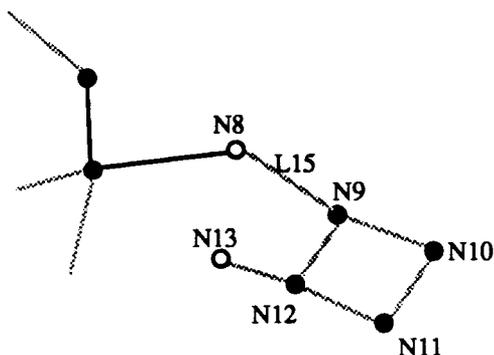
c) Quando a única via de fluxo a um nó com carga passa através de um nó sem carga, as linhas constituintes dessa via devem obrigatoriamente existir. Por exemplo, na situação seguinte



as linhas L9 e L10 deverão existir neste estágio de modo a que seja permitido o fluxo para o nó N9, passando a ser consideradas como linhas existentes. Às respectivas variáveis deverá ser atribuído o valor 1. A rede seria simplificada para :



d) À semelhança das alíneas anteriores, qualquer linha potencial que ligue a uma sub-rede com carga deverá ser eliminada do processo de decisão, sendo atribuído à respectiva variável o valor 1. A figura seguinte ilustra este caso. A linha L15 deverá necessariamente existir neste estágio pois a sub-rede N9-N13 possui nós com carga.



Alguns outros exemplos poderiam ser apresentados mas, de uma maneira geral o pré-processamento da rede segue os princípios gerais referidos acima.

O pré-processamento é efectuado antes do processo de optimização se iniciar, não tendo influência directa no algoritmo. As vantagens do pré-processamento são as seguintes:

- As variáveis de decisão cujo valor seja fixado pelo pré-processamento não são codificadas no cromossoma, diminuindo o seu tamanho.
- O processo de descodificação torna-se mais rápido.
- A eficiência da função de adaptação aumenta.

#### 4.10 Algoritmo de codificação

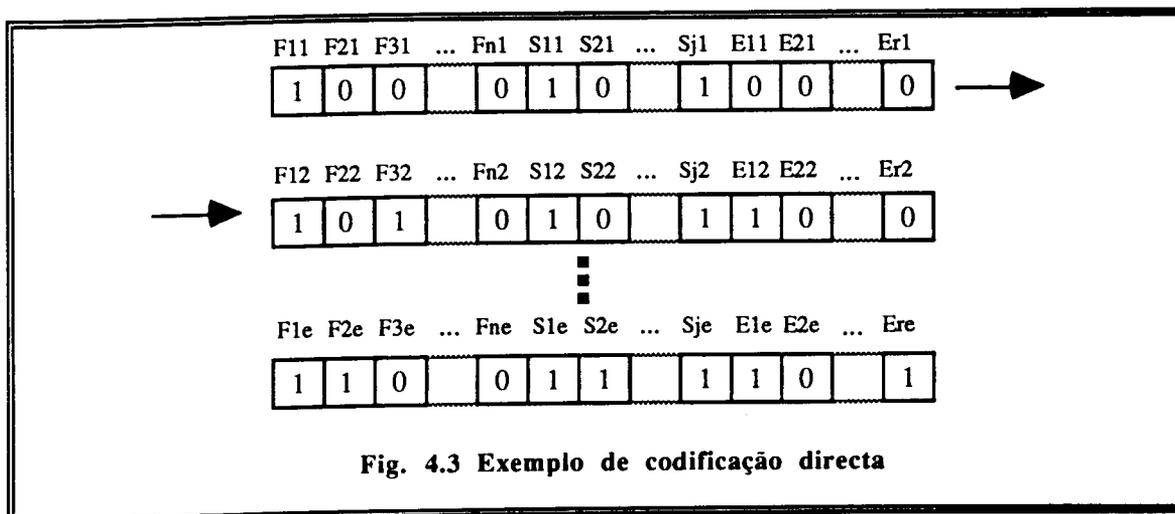
De acordo com a estratégia definida para a resolução do problema do planeamento, surge a necessidade de se encontrar uma representação (sob a forma de um cromossoma) para a rede, em cada um dos estágios.

##### 4.10.1 Codificação directa

A forma mais simples e imediata é a codificação directa das variáveis de decisão:

$F_{is}$ ,  $S_{is}$ ,  $E_{is}$

Para cada estágio, um determinado bit do cromossoma representaria directamente uma das variáveis binárias de decisão. A figura 4.3 mostra um exemplo de codificação directa.



Esta estratégia apresenta as seguintes vantagens gerais:

- A representação é directa, não havendo necessidade de descodificação, conduzindo a tempos inferiores na função de adaptação.
- Existe uma relação directa entre a representação topológica da rede e o cromossoma. Através de uma numeração adequada dos ramos, subestações e reforços, teríamos que, um determinado bloco de bits do cromossoma corresponderia directamente a uma determinada parte (ou região física) da rede.

No entanto, este tipo de representação conduz a uma percentagem demasiado elevada de soluções inviáveis topologicamente. Numa rede de dimensões reais, surgiriam um número elevado de soluções onde existiriam nós com carga, sem nenhuma ligação ou, por outro lado, soluções onde existiriam um número excessivo de linhas.

Este factor torna este tipo de codificação um pouco ineficiente.

#### 4.10.2 Processo de codificação.

Tornou-se, então necessário encontrar um novo processo de codificação que possuísse as seguintes características básicas:

- Deveria conduzir a um número mínimo de soluções inviáveis sob o ponto de vista topológico;
- O processo de descodificação deveria ser fácil e rápido;
- Não deveria conduzir a cromossomas de dimensões exageradas.
- Deveria possuir um nível razoável de relação física entre o cromossoma e a representação topológica da rede.
- Por fim, deveria permitir que todas as soluções viáveis tivessem uma representação correspondente num cromossoma.

O processo de determinar uma representação com estas características não foi, de modo algum, simples. Diversas possibilidades foram estudadas e testadas. Por fim, foi encontrado um processo de codificação que possui todas as características referidas acima.

Este processo baseia-se nas seguintes propriedades específicas do DPP:

- a) Cada nó com carga, num determinado estágio, deverá, obrigatoriamente, estar ligado a pelo menos uma linha.
- b) Um nó sem carga, num determinado estágio, poderá não ter ligações ou, alternativamente, possuir duas ou mais ligações no sentido de permitir o fluxo para outros nós da rede.
- c) Uma rede radial com  $n$  nós (com e sem carga) possui no máximo um número de linhas  $l$  tal que:

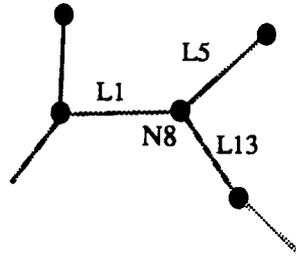
$$l \leq n-1$$

d) Uma subestação pode ser considerada como uma linha especial entre o nó fonte e o ponto onde a subestação está localizada. Do ponto de vista de codificação podem ser encaradas exactamente como linhas de distribuição.

A partir destes dados elaborou-se, então, um algoritmo de codificação que se pode sintetizar nos passos seguintes:

- 1 - Partindo do sistema inicial, para cada nó com carga não ligado a uma linha existente é estabelecida uma lista de linhas potenciais a ele ligadas.

Exemplo:



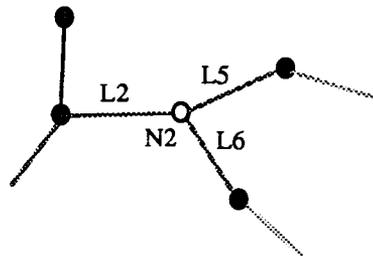
Para o nó N8 é estabelecida a lista N8(L1,L5,L13).

Como é fácil de compreender, pelo menos uma destas linhas na lista deverá existir, pois ao nó N8 foi atribuído um valor de carga não nulo.

2 - Para um nó sem carga não ligado a uma linha existente, o processo de obtenção da lista é idêntico. No entanto, acrescenta-se à lista a possibilidade deste nó não estar ligado a uma linha (ISOLADO).

Esta estratégia permite que, na solução, um nó sem carga esteja ligado a duas ou mais linhas no sentido de veicular carga para outros nós.

Exemplo:



Para o nó N2 é estabelecida a lista N2(L2,L5,L6,ISOLADO).

Neste caso, o nó N2 poderá estar ligado a uma das linhas na lista ou, simplesmente, desligado da rede.

3 - No final deste processo, obtemos um conjunto de listas, correspondentes a cada um dos nós não ligados a linhas do sistema existente. Este conjunto é previamente calculado e guardado em memória no sentido de facilitar o processo de descodificação que toma lugar na função de avaliação.

A codificação determinará, para cada um destes nós, uma e uma só entrada da lista correspondente<sup>1</sup>. Para isso, sendo  $t$  o número de entradas na lista, calcula-se o número  $b$  de bits  $b$  necessário para codificar uma entrada em cada uma das listas:

$$b = \log_2(t)$$

(arredondado para o inteiro imediatamente acima).

<sup>1</sup>É necessário, contudo, referir que esta codificação permite que um nó ligado ao sistema inicial seja ligado a uma linha que não pertença a este sistema.

Por exemplo, se o número de entradas numa lista for  $t=3$  ou  $t=4$ , o número de bits necessário para codificar esta lista é  $b=2$ . O exemplo indicado abaixo, mostra claramente esta codificação.

Exemplo:

Supunhamos uma lista correspondente a um nó N3:

**N3(L2,L4,L5,ISOLADO)**

O número de entradas na lista é  $t=4$ , logo o número de bits necessário para codificar esta lista é:

$$b = \log_2(4) = 2$$

Cada conjunto de bits corresponderia à seguinte situação do nó N3:

- (0,0) - Ligado à linha L2**
- (0,1) - Ligado à linha L4**
- (1,0) - Ligado à linha L5**
- (1,1) - ISOLADO**

Vejamos então outra situação:

**N8(L3,L6,L8)**  
( $b = 2$ )

As situações possíveis para o nó N8 são:

- (0,0) - Ligado à linha L3**
- (0,1) - Ligado à linha L6**
- (1,0) - Ligado à linha L8**
- (1,1) - INDEFINIDO**

A situação (1,1) fica, portanto, indefinida. Para evitar que uma solução deste tipo fosse imediatamente considerada inviável, decidiu-se que as situações indefinidas corresponderem a soluções definidas, pela ordem inicialmente estabelecida:

- (1,1) - Ligado à linha L3**

Poder-se-á pensar, no entanto, que este tipo de codificação irá criar uma certa *tendência* para uma determinada solução (neste caso para a construção da linha L3). Mas, do ponto de vista do algoritmo genético esta tendência é desprezável, pois, se a solução for fraca, o seu valor de adaptação será baixo, tendo poucas possibilidades de sobrevivência. Se, por outro lado, a solução for boa, esta tendência teve resultados positivos no processo genético, não constituindo assim um problema.

Em seguida, todos os bits são concatenados, formando um subcromossoma, correspondente a um determinado estágio no plano de expansão.

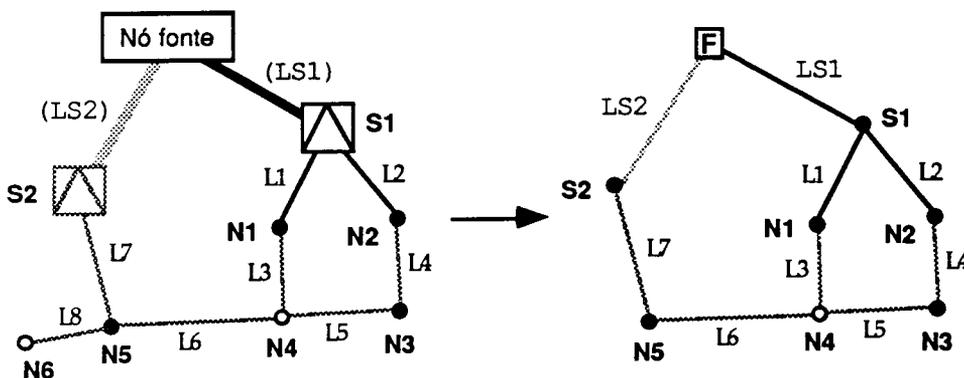
Este processo garante que todas as configurações topologicamente viáveis podem ser codificadas num subcromossoma e, ao mesmo tempo, assegura que o número total de linhas nunca excede o número total de nós menos um (condição de radialidade). Por outro lado, ao permitir que o número de linhas seja variável, o algoritmo de codificação contempla a possibilidade de um nó sem carga estar ou não ligado a uma linha que, como já foi referido anteriormente, é uma característica importante deste modelo.

4 - Por fim, as variáveis correspondentes a projectos de expansão da capacidade de subestações (E) são codificadas directamente no subcromossoma.

O exemplo seguinte demonstra o processo completo de descodificação<sup>1</sup> para um estágio.

### Exemplo:

A figura abaixo representa uma pequena rede de distribuição e, à direita, o seu equivalente do ponto de vista de codificação, num determinado estágio. Repare-se na linha L8, que foi eliminada pelo facto de o nó N6 não possuir carga neste estágio. Aos nós correspondentes às subestações S1 e S2 estão atribuídos valores de carga não nulos. Por fim, existe um plano de expansão para a subestação S1, a que corresponderá a variável  $E_{s1}$ .



O primeiro passo é o de estabelecer a lista de linhas obrigatórias para cada nó da rede não ligado ao sistema existente, calculando-se o número de bits total necessários à codificação da rede para um estágio.

N3	(L4,L5)	- 1 bit
N4	(L3,L5,L6,ISOLADO)	- 2 bits
N5	(L6,L7)	- 1 bit
S2	(L7,LS2)	- 1 bit
$E_{s1}$		- 1 bit
<b>Total</b>		<b>- 6 bits</b>

Portanto, para um problema multitemporal com  $e$  estágios seriam necessários **6.e** bits. A figura seguinte representa um possível subcromossoma para um determinado estágio:

<sup>1</sup>Nota: é importante reparar-se que o processo de codificação em si é absolutamente transparente do ponto de vista do algoritmo genético, pois está implícito no cromossoma. O único dado que o processo genético necessita relativamente à codificação é, evidentemente, o tamanho do cromossoma.

N3	N4	N5	S2	ES1
0	0	0	1	0

Este subcromossoma corresponde à construção das seguintes linhas:

L4 (de N3)

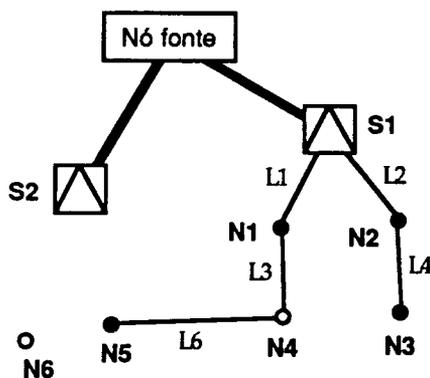
L3 (de N4)

L6 (de N5)

LS2 (de S2)

A expansão  $E_{S1}$  não é construída pois o respectivo bit tem o valor 0.

A rede correspondente é apresentada na figura seguinte:

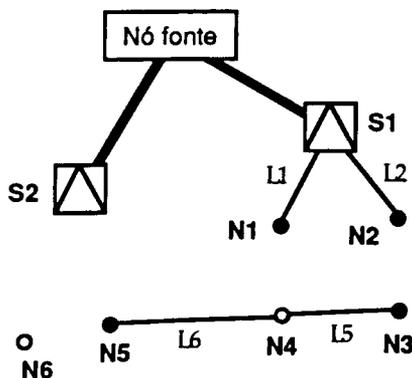


Como se pode verificar este subcromossoma corresponde a uma configuração viável (radial e conexas) da rede. Também é possível notar que o nó N4 apesar de não ter carga, está ligado a duas linhas, no sentido de veicular carga para o nó N5.

Por outro lado o subcromossoma:

N3	N4	N5	S2	ES1
1	1	0	1	0

não corresponde a uma solução topologicamente viável, como se pode constatar pela rede correspondente:



O cromossoma final será obtido pela concatenação dos sub-cromossomas correspondentes a cada um dos estágios dentro do horizonte de planeamento, codificandose, assim, completamente a topologia da rede para todo o plano de expansão.

Esta codificação foi, então, adoptada neste modelo, tendo em conta as suas vantagens consideráveis em relação a outras codificações. No entanto, é importante referir que se continuam a procurar algoritmos de codificação ainda mais eficientes.

#### **4.11 Avaliação das soluções**

Uma solução, como já foi referido, corresponde a um plano de expansão do sistema de distribuição.

Uma solução diz-se viável do ponto de vista topológico quando é radial e conexa em todos os estágios dentro do horizonte de planeamento.

Uma solução é considerada viável electricamente quando não existam violações nos limites de fluxo das linhas ou nos limites de quedas de tensão nos nós.

Uma solução viável é avaliada de acordo com os seguintes critérios:

1 - Custos de investimento - correspondem ao custo total do plano (somatório da construção dos diversos itens - linhas e subestações), capitalizado, em cada estágio, de acordo com a taxa de Discount Rate  $D_r$ .

2 - Perdas de energia activa - os custos de operação (perdas) é obtido pela soma capitalizada das perdas nos e estágios de planeamento.

3 - Fiabilidade - este critério é traduzido no valor esperado de energia não fornecida em cada um dos estágios dentro do horizonte de planeamento (ver ponto seguinte).

4 - Quedas de tensão - este critério é traduzido numa função de qualidade, que se referirá no próximo ponto.

Os custos relacionados com estes dois últimos critérios podem, ou não, ser capitalizados em cada estágio de acordo com a taxa  $D_r$  definida anteriormente.

Num modelo completamente dinâmico será mais correcto capitalizar estes custos, pois um investimento num determinado estágio corresponde a uma melhoria de qualidade num estágio posterior, onde os custos de investimento são inferiores (e, logo, seria possível aumentar a qualidade investindo menos). No entanto esta opção, apesar de absolutamente correcta, implica o aceitar um certo nível de degradação de qualidade ao longo do horizonte de planeamento.

No caso de o planeador decidir não utilizar os custos capitalizados correspondentes a estes dois últimos critérios, então estará a aceitar o princípio de minimização do valor esperado total da energia não fornecida (fiabilidade) ao longo de todo o horizonte de planeamento e de minimização da função de (não-)qualidade relacionada com as quedas de tensão. Neste caso e em relação a estes dois critérios, o modelo trai, parcialmente, os princípios de um modelo completamente dinâmico.

No modelo implementado e no exemplo de aplicação apresentado no capítulo 5, optou-se por utilizar o valor capitalizado tanto do índice de fiabilidade como do índice de qualidade nas quedas de tensão. No próximo ponto, para manter a generalidade, não se fará referência a este aspecto e, conseqüentemente, dever-se-á considerar os índices relativos a estes dois critérios capitalizados de acordo com a taxa de desconto  $D_r$ .

### **4.12 Função de adaptação (Fitness Function)**

Como já foi salientado, a função de adaptação procura avaliar uma solução codificada num cromossoma. Esta função deve reflectir tanto as propriedades desejadas como as indesejadas de uma solução potencial, premiando as primeiras e penalizando as segundas. No DPP as propriedades desejadas são, nomeadamente:

- Baixo custo de investimento;
- Baixo valor das perdas;
- Fiabilidade elevada.

Entre as propriedades indesejadas temos:

- Configurações não radiais;
- Violações nos limites térmicos das linhas;
- Violações nos limites das quedas de tensão.

No entanto, e como foi referido no capítulo anterior, a determinação de uma função de adaptação adequada nem sempre é um processo simples. Após diversos testes sobre diferentes tipos de funções de adaptação, foi implementada uma que basicamente pode ser dividida em quatro fases fundamentais que são as seguintes:

- 1) Descodificação do cromossoma.
- 2) Análise da rede do ponto de vista topológico.
- 3) Análise da rede do ponto de vista eléctrico.
- 4) Avaliação da solução.

O algoritmo geral seguido pela função de adaptação é ilustrado no fluxograma da figura 4.3. Cada uma das fases referidas será pormenorizada nos pontos seguintes:

#### **Fase 1 - Descodificação do cromossoma**

- O cromossoma é decodificado seguindo o algoritmo correspondente ao processo de codificação referido no ponto 4.10. São obtidas as variáveis de decisão **F**, **S** e **E**, ficando a rede completamente definida para cada um dos estágios dentro do horizonte de planeamento.

#### **Fase 2 - Análise topológica**

Depois de decodificado o cromossoma, pretende-se eliminar imediatamente soluções inviáveis do ponto de vista topológico. A fase 2, exigindo um tempo de computação muito reduzido, permite eliminar rapidamente estas soluções, atribuindo-lhes um valor muito baixo de adaptação.

Pretendem-se soluções radiais e conexas em todos os estágios. Se a solução não possuir estas características, a função de adaptação termina retornando um valor inversamente proporcional ao somatório (estendido ao número de estágios) do número de nós com carga sem ligação ao nó fonte. Pretende-se que as soluções que possuam um número superior

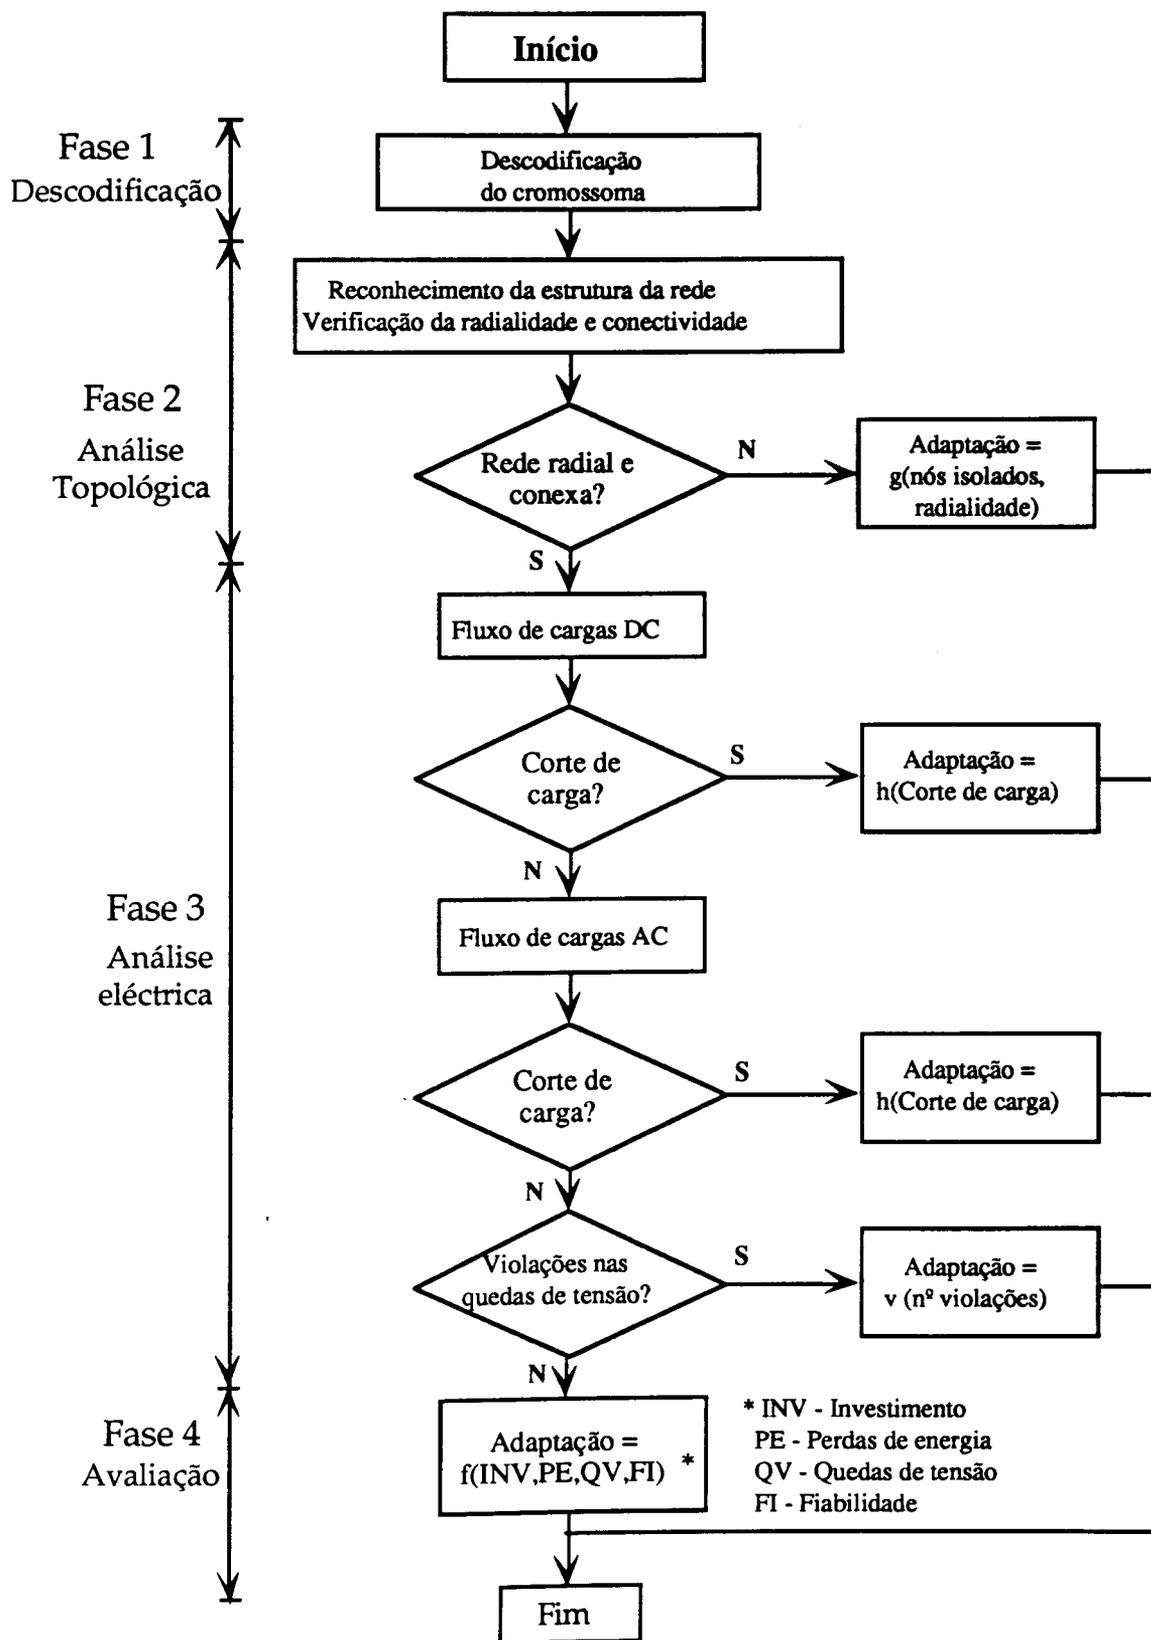


Fig 4.3 Esquema da função de adaptação

destes nós tenham um valor inferior de adaptação, encaminhando, assim, o algoritmo genético no sentido de soluções viáveis do ponto de vista topológico. Por outro lado, a não radialidade da rede é também penalizada com valores muito baixos da função de adaptação. A função de adaptação FA é então calculada a partir de uma função  $g()$  tal que:

$$FA = g(\text{número de nós com carga não ligados ao nó fonte, radialidade})$$

Simultaneamente, é feito o reconhecimento da estrutura da rede no sentido de facilitar cálculos posteriores (análise eléctrica). Este processo revelou-se muito eficiente no decorrer dos testes efectuados sobre o modelo.

### Fase 3 - Análise eléctrica

Se a solução for viável do ponto de vista topológico (fase 1) é analisada sob o ponto de vista eléctrico. Esta análise consiste em dois passos distintos, que se referem em seguida:

1) É efectuado um **fluxo de cargas DC**<sup>1</sup> para cada um dos estágios, dando como resultado o valor da carga total não fornecida devido a violações nos limites térmicos das linhas e dos limites da capacidade das subestações. Se o valor do corte de carga for nulo, a função de adaptação passa a 2). Em caso contrário, a função de adaptação retorna um valor inversamente proporcional ao valor do somatório dos cortes de carga em todos os estágios, no sentido de encaminhar o algoritmo genético no sentido de soluções viáveis sob o ponto de vista eléctrico. A função de adaptação (FA) é calculada através de uma função  $h()$  tal que:

$$FA = h(\text{energia não fornecida}) \text{ e } h() > g() \text{ (em todo o domínio)}^2$$

Este passo é importante, pois permite filtrar muito rapidamente (um fluxo de cargas DC numa rede radial é um processo muito simples) soluções onde exista corte de carga, atribuindo-lhes um valor de adaptação baixo.

2) É efectuado um **fluxo de cargas AC**, para cada um dos estágios, baseado num algoritmo descrito em [Mir83], aplicado a sistemas equilibrados. Este algoritmo iterativo foi desenvolvido para redes radiais, permitindo o ajuste da precisão dos resultados de acordo com o critério do planeador. Por este motivo é particularmente adaptado ao problema presente.

Como resultado deste procedimento teremos os seguintes valores:

- Correntes nas linhas;
- Tensões nos nós;
- Perdas activas de energia nas linhas;

No caso de este procedimento detectar violações nos limites térmicos das linhas ou na capacidade das subestações (que não tenham sido detectados no passo anterior), a função de avaliação termina retornando um valor, à semelhança do passo anterior, proporcional ao somatório dos cortes de carga nos vários estágios:

---

<sup>1</sup> Antes dos cálculos do fluxo de cargas (DC ou AC) é possível afectar os valores das cargas de coeficientes que reflectam factores de diversidade nas curvas de carga. Esta característica distingue, mais uma vez, esta abordagem das metodologias tradicionais.

<sup>2</sup> Esta condição é necessária no sentido de garantir que as soluções (topologicamente viáveis) avaliadas por  $h()$  na fase 3 tenham um valor de adaptação superior a qualquer solução (topologicamente inviável) avaliada por  $g()$  na fase 2.

**FA = h(energia não fornecida)**

Em caso contrário, procede-se à verificação dos valores de tensão nos nós. Se algum valor de tensão num nó estiver fora dos limites impostos (por exemplo, se a queda de tensão for superior a 8%), a solução é imediatamente considerada inviável do ponto de vista eléctrico. A função de adaptação termina e retorna um valor proporcional ao número de violações, sendo mais penalizadas as soluções onde existam mais violações destas restrições. Este valor é obtido através de uma função  $v()$ , tal que :

**FA = v(número de violações) e  $v() > h()^1$  (em todo o domínio)**

Se não existirem violações às restrições de queda de tensão, estaremos perante uma solução viável para todos os estágios dentro do horizonte de planeamento. Pode-se, então, passar à fase seguinte da função de adaptação, que consiste na avaliação da solução.

#### **Fase 4 - Avaliação da solução**

Neste ponto da função de adaptação, só estão presentes soluções viáveis sob o ponto de vista eléctrico e topológico podendo-se, então, avaliar a qualidade da solução obtida. A versatilidade deste modelo está precisamente neste ponto, pois é possível avaliar a solução da forma que se mostrar mais adequada e de acordo com os critérios do planeador.

Neste trabalho decidiu-se avaliar a solução de acordo com os seguintes critérios (entre parentesis o índice correspondente):

- Custos de investimento (INV)
- Custos de operação/perdas (PE).
- Fiabilidade (FI).
- Qualidade dos valores de tensão dos nós (QV).

O valor final da adaptação (FA) de uma solução será obtido através de uma função  $f()$  dependente de cada um dos critérios acima assinalados:

**FA = f(INV,PE,QV,FI) e  $f() > v() > h() > g()$  (em todo o domínio)**

O processo de cálculo desta função a partir de cada um dos critérios referidos será analisado com algum pormenor nos pontos que se seguem.

#### Custos de investimento (INV)

O valor dos custos de investimento é obtido, como foi referido num ponto anterior, através do somatório dos investimentos para todos os estágios dentro do horizonte de planeamento, capitalizados de acordo com um valor de *discount rate* fixo. Estes custos incluem:

- Linhas de distribuição;
- Subestações;
- Reforços nas subestações.

O valor deste índice é então calculado de acordo com a seguinte expressão:

<sup>1</sup>Esta condição é necessária no sentido de garantir que as soluções avaliadas por  $v()$  tenham um valor de adaptação superior a qualquer solução avaliada por  $h()$  (existência de corte de carga).

$$INV = \sum_{i=1}^e \sum_{j=1}^k \frac{C_j}{\left(1 + \frac{D_r}{100}\right)^{i-1}} \quad \text{sendo:}$$

<b>e</b>	número de estágios
<b>k</b>	número de itens construídos
<b>C<sub>j</sub></b>	custo do item j referido ao primeiro estágio
<b>D<sub>r</sub></b>	taxa de actualização (%)

O índice INV corresponde, portanto, ao custo global de investimento do plano de expansão.

- Linhas na mesma vala

Se duas linhas que possam partilhar uma vala forem construídas no mesmo estágio<sup>1</sup>, ao custo global de investimento será subtraído o valor correspondente ao benefício económico de tal facto, tal como foi referido no ponto 4.2.2. Este procedimento é muito simples e constitui uma das grandes vantagens deste tipo de abordagem.

#### Perdas (PE)

O valor da potência activa de perdas nas linhas é obtido a partir do fluxo de cargas AC efectuado na fase anterior da função de adaptação. O valor do índice PE é obtido através do somatório do valor das perdas em todos os estágios dentro do horizonte de planeamento. Os valores das perdas são capitalizados de acordo com o valor de *discount rate* definido anteriormente.

$$PE = \sum_{i=1}^e \sum_{j=1}^{l_i} \frac{p_{ji}}{\left(1 + \frac{D_r}{100}\right)^{i-1}}$$

<b>p<sub>ji</sub></b>	potência de perdas na linha j no estágio i.
<b>e</b>	número de estágios.
<b>l<sub>i</sub></b>	número de linhas existentes no estágio i.
<b>D<sub>r</sub></b>	taxa de actualização (%)

#### Fiabilidade (FI)

A fiabilidade de um sistema de distribuição pode ser avaliada de diversas maneiras. Em geral este factor é traduzido em índices como por exemplo:

- EPNS (Expected Power Not Supplied) - valor esperado da potência não fornecida.
- LOLP (Loss Of Load Probability) - Probabilidade de perda de carga.
- ENS (Energy Not Supplied) - Energia não fornecida.

<sup>1</sup>De acordo com os critérios do planeador pode-se incluir a possibilidade das linhas serem construídas em estágios diferentes. Num caso geral, os benefícios económicos serão diferentes para o caso de as linhas serem construídas no mesmo estágio ou em estágios diferentes.

Neste modelo, o índice de fiabilidade FI de uma solução é avaliado através do cálculo do valor esperado da potência não fornecida (EPNS) para a situação em questão (pico de carga) para os  $g$  estágios dentro do horizonte de planeamento. Este cálculo leva em linha de conta a existência de anéis abertos<sup>1</sup> no sistema.

No entanto, é impossível calcular um valor exacto da fiabilidade de um sistema de distribuição sem ter em conta a localização da aparelhagem de seccionamento na rede. Sendo este um problema, em si mesmo, muito complexo [Mir83], procurou-se obter um valor aproximado para o EPNS através de um esquema que se descreve em seguida:

a) É calculado um majorante  $U_f$  para o valor de EPNS assumindo que não há aparelhagem de seccionamento incluída no sistema. Neste caso, todos os cortes se processam a nível das subestações. Consequentemente, não são permitidas reconfigurações da rede em caso de contingência.

O processo de cálculo deste valor para cada um dos estágios é muito simples: obtém-se o valor esperado da energia cortada (entrando em linha de conta com o tempo médio de retoma de serviço) para cada saída de serviço de uma linha de distribuição. Este valor é, simplesmente, o valor da potência não fornecida à saída da subestação correspondente. Em caso de saída de serviço de uma subestação, o valor esperado da energia não fornecida é obtido imediatamente.

b) É calculado um minorante  $L_f$  para o valor de EPNS assumindo que todas as linhas da rede estão equipadas de aparelhagem de seccionamento em ambas as extremidades, permitindo o isolamento das linhas em caso de contingência e retoma do serviço (tomando em conta a capacidade das linhas).

O processo de cálculo deste valor é mais complexo do que o anterior. Em caso de uma determinada linha (ou subestação) sair de serviço é necessário verificar as possibilidades de reconfiguração, colocando em serviço linhas que poderão veicular carga para os nós afectados. Em seguida é calculado o valor de EPNS tendo em conta os tempos médios de reparação e as capacidades das linhas.

Por fim o valor do índice de fiabilidade para um estágio  $i$  ( $FI_i$ ) é calculado através da seguinte expressão:

$$FI_i = EPNS = \alpha U_f + (1-\alpha)L_f$$

sendo  $\alpha \in [0,1]$  definido como o "coeficiente de seccionamento", cujo objectivo é simular o efeito de uma solução de compromisso na política de localização de aparelhagem de corte.

Os valores  $\alpha=1$  e  $\alpha=0$  corresponderão, respectivamente, ao caso onde não existe aparelhagem de seccionamento e ao caso em que a rede é completamente seccionável. No entanto, a escolha de um coeficiente adequado, é deixado ao critério do planeador.

Este processo é efectuado para cada estágio, sendo o valor final do índice FI obtido pelo somatório capitalizados índices para cada um dos estágios.

É importante notar que o valor deste índice, calculado a partir do valor da potência não fornecida numa situação específica, é apenas uma medida do valor anual da energia não fornecida devido a saídas de serviço de linhas e subestações. Para um cálculo mais realista deste valor seria necessário possuir um conhecimento superior sobre características da rede e dos consumos, nomeadamente alguma informação relacionada com diagramas de carga. No entanto, para efeitos de planeamento, esta aproximação é perfeitamente razoável.

### Quedas de tensão (OV)

<sup>1</sup>Estes anéis devem a sua existência, num determinado estágio, a linhas desclassificadas em estágios anteriores. Estas linhas servirão assim para fechar anéis no caso de contingência.

Existem várias maneiras de avaliar a qualidade de um sistema de distribuição de acordo com o critério das quedas de tensão [Jor85]. Em geral esta qualidade depende de vários factores, nomeadamente do tipo de consumidores em questão. Neste modelo, reflectindo a enorme versatilidade desta abordagem, qualquer método de avaliação é implementável. No entanto, far-se-á referência ao processo utilizado nos testes efectuados sobre o modelo.

Este processo é muito simples e resume-se da seguinte maneira:

a) Se o valor da queda de tensão, num determinado nó  $j$  no estágio  $i$  for inferior a um determinado valor (p. ex. 5%) o índice de qualidade  $Q_{ij}$  relativo a este nó recebe o valor 0 (zero).

b) Por outro lado, se este valor se situar no intervalo entre aquele valor e o limite superior aceitável<sup>1</sup> (p. ex. [5%,8%]), o valor do índice  $Q_{ij}$  será calculado pelo quadrado do desvio deste valor em relação ao limite inferior daquele intervalo.

O índice global  $QV$  será calculado pelo somatório dos índices capitalizados de cada um dos nós para todos os estágios dentro do horizonte de planeamento.

$$QV = \sum_{i=1}^e \sum_{j=1}^{N_i} \frac{Q_{ij}}{\left(1 + \frac{D_r}{100}\right)^{i-1}} \text{ sendo:}$$

- $e$  número de estágios
- $N_i$  número de nós com carga no estágio  $i$ .
- $Q_{ij}$  índice de qualidade da queda de tensão do nó  $j$  no estágio  $i$ .
- $D_r$  taxa de actualização (%)

### Cálculo de $f()$

Como já foi referido, o valor da adaptação  $FA$  de uma solução  $x$  será calculada a partir dos índices referidos nos pontos anteriores ( $INV$ ,  $PE$ ,  $FI$ ,  $QV$ ) através de uma função linear  $f(x)$ :

$$f(x) = M - c_1.INV - c_2.PE - c_3.FI - c_4.QV$$

sendo as constantes  $c_n > 0$  fixadas externamente. Estas constantes representam pesos estimados de acordo com a política global da companhia distribuidora [Jor85].

No sentido de garantir que  $f(x) > v(x) > h(x) > g(x)$ , será necessário somar uma constante elevada  $M$  à função  $f(x)$ , pois, como já foi referido, trata-se de um problema de maximização. Pela mesma razão, as constantes  $c_n$  são afectadas de sinais negativos.

### 4.12 Resultados do processo genético

Um dos resultados de um algoritmo genético é o indivíduo com o maior valor da função de adaptação encontrado até ao fim do processo genético. É importante notar que esta solução poderá não corresponder ao óptimo global do problema, pois um algoritmo

<sup>1</sup>Neste ponto não existirão nós com um valor de queda de tensão superior a este limite.

genético não garante que este valor seja atingido. No entanto, é de esperar uma solução muito próxima da solução óptima. Esta solução, para o processo genético  $g$  será designada por  $O_g$ .

Por outro lado, ao longo deste processo vão surgindo um conjunto de soluções interessantes (incluindo várias soluções não dominadas) que vão sendo guardadas pois podem, eventualmente, ser consideradas como boas soluções de compromisso numa análise final. Este conjunto designar-se-á como  $S_g$ .

Teremos então como resultado final do processo genético um conjunto de soluções  $A_g$ :

$$A_g = \{O_g\} \cup S_g$$

#### 4.13 Integração do algoritmo no contexto do planeamento

O passo final do planeamento é a escolha de uma solução a que corresponde um plano de expansão do sistema de distribuição. A determinação desta solução pode ser feita de duas maneiras, dependendo do maior ou menor conhecimento do planeador das características do seu problema. Por outras palavras, a estratégia de determinação final de uma solução depende da capacidade do planeador estabelecer com segurança e exactidão o valor dos pesos a atribuir a cada um dos índices (ou seja, a cada um dos critérios), o que corresponde a duas situações bem distintas:

1 - Se o valor dos pesos  $c_n$  puder ser estabelecido previamente com precisão, a solução final da execução do processo genético  $g$  corresponderá à melhor solução encontrada para a concretização escolhida dos pesos  $Q_g$ . Portanto, esta será considerada como a solução do problema. No entanto, é sempre interessante ao planeador do sistema analisar soluções próximas (no domínio das soluções) desta solução final. No exemplo de aplicação do modelo no capítulo seguinte apresenta-se um caso onde a solução é obtida por este processo.

2 - Por outro lado, se tal não for possível, o planeador tem ao seu dispor a possibilidade de determinar um plano de expansão através do processo que se descreve:

Através da variação de pesos dentro de limites pré-estabelecidos e da execução do processo genético o número de vezes necessário, obter-se-á um número elevado de soluções  $O_n$  correspondendo às melhores soluções de cada processo  $n$  mais um conjunto  $S_n$  de soluções que foram sendo guardadas. O conjunto destas soluções será designado por  $T$ .

Apesar de através deste processo se obter uma amostra da região convexa das soluções, os algoritmos genéticos possuem o poder de descobrir um número elevado de soluções dentro da região não convexa do domínio.

Pela eliminação de soluções dominadas de  $T$  obtém-se finalmente um conjunto muito representativo, embora não completo, do domínio das soluções eficientes.

A partir deste momento o planeador / agente de decisão tem ao seu dispor um conjunto de métodos de ajuda à decisão [Mat88] que lhe permitirão escolher a solução mais conveniente do conjunto (normalmente muito extenso) de soluções eficientes, obtidas por este processo. Um dos métodos de auxílio à decisão mais adequados a este propósito é descrito em [Mat88] e [Mat92] e conhecido por *Método das Amplificações Sucessivas* (MAS). Este método fornece ao planeador um meio que lhe permite aproximar-se progressivamente da solução preferida, à custa de decisões parciais que respeitam os seus limites na capacidade de processamento. O método baseia-se numa representação do conjunto de alternativas (neste caso,  $T$ ) através dos pontos característicos de macro-soluções, em número não superior ao limite aceitável ao planeador / agente de decisão, mas mantendo uma perspectiva global sobre o problema. Este método permite ao planeador

seleccionar a(s) macro-solução(s) que lhe pareça(m) mais promissora(s), o que lhe permite a amplificação sucessiva da sua zona de preferência mais forte, à custa de uma redução progressiva do conjunto de alternativas, até à obtenção de um pequeno conjunto final de soluções. O planeador pode então escolher neste conjunto a sua solução preferida. Será interessante então, ao planeador, estudar os *trade-off* entre esta solução final e as soluções adjacentes (as soluções restantes no conjunto), no sentido de tomar a decisão mais adequada na escolha do plano de expansão para o sistema de distribuição. No exemplo apresentado no capítulo seguinte refere-se uma aplicação deste método na escolha de uma solução de planeamento.

Por outro lado, no sentido de tomar uma decisão mais esclarecida, o planeador poderá ainda aprofundar mais alguns pontos na análise destas soluções, como por exemplo:

- Política de seccionamento;
- Análise de incertezas;
- Robustez e exposição.

Compreende-se, então, que a abordagem descrita é facilmente integrada num contexto global de planeamento, onde o planeador tem um papel importante na tomada de decisão. Esta é, provavelmente, a característica mais importante da metodologia apresentada neste capítulo.

#### **4.14 Conclusões**

Neste capítulo apresentou-se um modelo para a resolução do problema do planeamento da expansão de sistemas de distribuição de energia eléctrica.

Este modelo, baseado numa abordagem genética, possui, como principal vantagem em relação às metodologias tradicionais, uma versatilidade notável. Esta característica traduz-se numa grande liberdade na escolha do tipo de avaliação de uma solução por parte do planeador.

Por outro lado, esta abordagem permite incluir no modelo diversas opções dificilmente formuláveis nos modelos tradicionais, nomeadamente:

- Radialidade;
- Quedas de tensão;
- Fiabilidade;
- Benefícios económicos resultantes da inclusão de linhas na mesma vala;
- Permitir que uma linha passe por um nó sem carga;
- Inclusão de factores de diversidade nas cargas.

Ficou também claramente demonstrado que a metodologia descrita tem potencialidades consideráveis na análise multiobjectivo do DPP, permitindo determinar um conjunto extenso de soluções incluindo soluções eficientes (incluindo algumas soluções na superfície não convexa do domínio) através de um processo de variação de pesos.

Além disso, o modelo apresenta flexibilidade suficiente para permitir, por um lado, a sua expansão no sentido da inclusão de outras opções de modelização e, por outro lado, a sua aplicação a outros problemas de planeamentos semelhantes. Estes poderão ser, por exemplo, o planeamento de sistemas de transmissão de energia eléctrica ou de redes de distribuição de gás.

Após a formulação completa do modelo, o passo seguinte consistiu na sua implementação prática, afinação e calibração e, por fim, alguns testes sobre o mesmo. O

próximo capítulo apresenta e analisa os resultados da aplicação do modelo a um sistema de dimensão real.

## Capítulo 5

### Exemplo ilustrativo

#### 5.1 Introdução

A abordagem proposta no capítulo anterior foi aplicada a diversos problemas em sistemas de teste de pequena e média dimensão, com excelentes resultados. Foram também feitos testes em sistemas de grande porte para um único estágio, tendo sido, igualmente, muito boa a qualidade dos resultados obtidos. Por fim, procurou-se aplicar o modelo a um problema multiestágio, sobre um sistema de grande dimensão, sendo os resultados deste teste apresentados neste capítulo.

Assim, nos pontos seguintes apresentam-se os dados relativos a este sistema de teste, bem assim como os parâmetros genéticos e outros dados específicos do algoritmo. Em seguida, são mostrados os resultados obtidos e, finalmente, é feita uma análise aprofundada destes resultados, integrando-os no contexto global do planeamento.

#### 5.2 Metodologia geral

A metodologia seguida na resolução do problema que se descreve em seguida não é, essencialmente, diferente da metodologia descrita no capítulo anterior. No entanto, é conveniente clarificar a estratégia de resolução deste problema.

Numa primeira fase optou-se pela determinação de apenas uma solução, partindo-se do princípio de que os coeficientes  $c_n$  (pesos de cada um dos critérios) poderiam ser estabelecidos com algum grau elevado de certeza (ver ponto 4.13). Assim, a solução do problema será a melhor solução encontrada no fim de um único processo genético.

Numa segunda fase optou-se pela determinação de um conjunto de soluções eficientes alternativas, através de uma técnica de variação dos pesos  $c_n$ . Deste conjunto de soluções não-dominadas seria escolhida, através de algum método de auxílio à decisão multicritério, a solução mais interessante para o planeador. Os resultados obtidos nesta fase serão apresentados nos últimos pontos deste capítulo.

Para finalizar, resta referir que o algoritmo de optimização foi implementado em linguagem C numa Workstation NEXT, usando software genético referido em [Ran93].

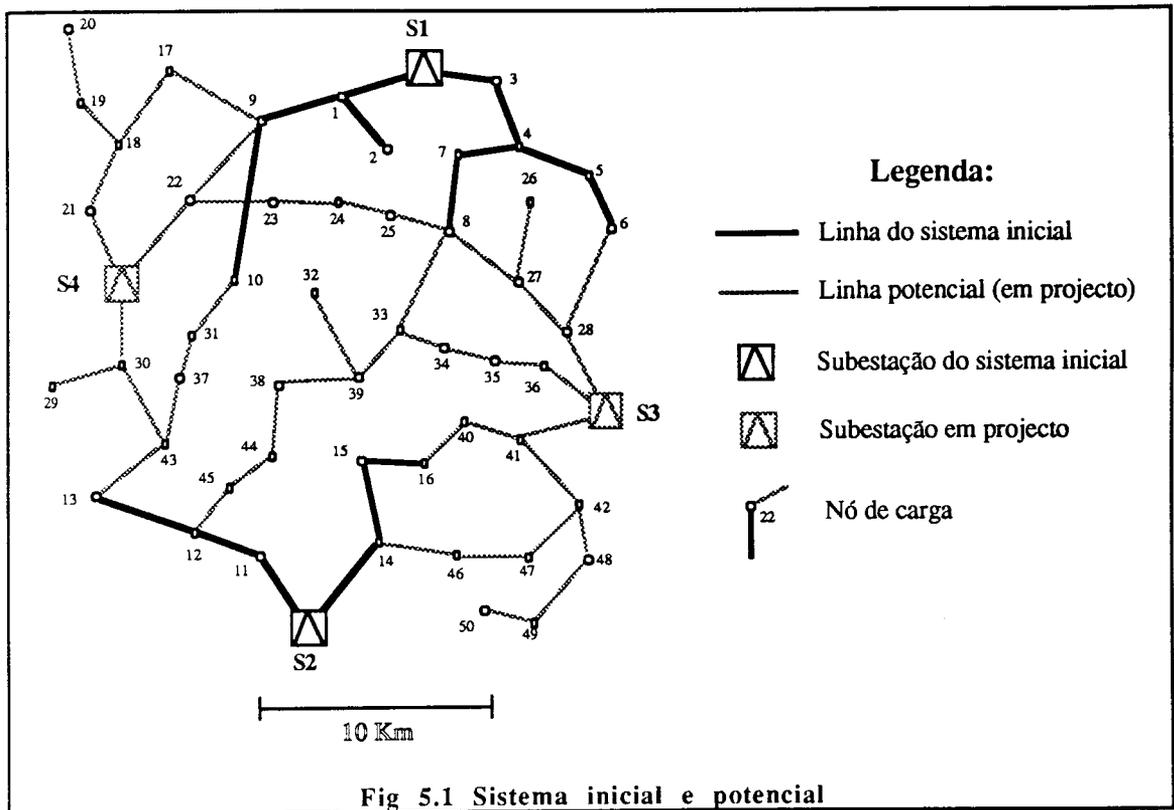
#### 5.3 Dados do problema

##### 5.3.1 Horizonte de planeamento

O exemplo foi desenvolvido para um horizonte de planeamento de **3 anos** dividido em **3 estágios** de expansão. O objectivo é determinar um plano de expansão para este horizonte, ou seja, determinar quais os itens a ser construídos e em que estágio essa construção terá lugar. Como a metodologia desenvolvida é completamente dinâmica, as decisões de planeamento são tomadas simultaneamente para todo o horizonte de planeamento.

##### 5.3.2 Sistema de distribuição

O modelo foi aplicado ao sistema de distribuição representado na fig. 5.1, constituído por 54 nós de consumo, 16 linhas e 2 subestações no sistema inicial e, por fim, 45 linhas e 2 subestações em projecto. De acordo com a representação referida no capítulo anterior, as linhas a cheio representam o sistema radial inicial e as linhas sombreadas as localizações possíveis para a construção de linhas ou subestações para a expansão do sistema.



Cargas

A tabela 5.1 apresenta os valores das cargas nos nós para os 3 estágios de expansão (valores em MW).

Nó	E1	E2	E3	Nó	E1	E2	E3	Nó	E1	E2	E3
S1	2.0	2.6	3.4	15	1.0	1.2	1.4	33	1.8	2.3	2.9
S2	0.8	0.9	1.0	16	1.3	1.5	1.9	34	0.9	1.0	1.2
S3	0.6	0.7	0.8	17	0.5	0.6	0.7	35	-	-	0.9
S4	0.3	0.4	0.5	18	0.9	1.0	1.2	36	0.2	0.2	0.3
1	3.3	3.8	4.2	19	1.0	1.2	1.4	37	1	1.6	2.1
2	1.1	1.3	1.5	20	0.5	0.7	0.8	38	-	-	1.1
3	0.4	0.5	0.7	21	0.5	1.6	1.8	39	0.8	0.9	1.0
4	1.4	1.9	1.1	22	0.5	1.0	1.1	40	1	1.2	1.4
5	2	2.3	2.6	23	0.5	0.9	1.0	41	0.3	0.5	0.9
6	0.6	0.7	0.7	24	0.5	0.4	0.5	42	-	-	1.2
7	0.2	0.5	1.0	25	0.6	0.8	0.9	43	-	-	1.3
8	1.5	1.7	1.9	26	-	0.8	1.2	44	0.5	1.0	1.4
9	1.9	2	1.2	27	-	1.2	1.5	45	0.5	0.7	0.8
10	2	2.4	2.9	28	0.4	0.5	0.7	46	-	1.6	1.8
11	0.2	0.3	0.3	29	0.6	0.9	1.4	47	0.5	0.5	1.0
12	1.0	1.6	1.8	30	2	2.3	2.6	48	0.5	0.6	0.8
13	0.9	1.0	1.1	31	0.6	0.7	0.7	49	-	0.6	0.5
14	0.8	0.9	1.0	32	-	1.5	1.7	50	-	-	0.8

Tabela 5.1 Cargas nos nós

Factor de carga

No sistema de teste é considerado um factor de carga constante para todas as cargas:

$$\cos \phi = 0.9$$

Carga total

A tabela seguinte apresenta as cargas totais (em MVA) para os três estágios de expansão.

Estágio 1	45.0 MVA
Estágio 2	63.0 MVA
Estágio 3	79.5 MVA

Tabela 5.2 Cargas totais nos 3 estágios

Subestações

No sistema inicial existem duas subestações designadas por S1 e S2. Existem ainda duas subestações em projecto S3 e S4. As capacidades destas subestações, bem assim como os reforços possíveis nas capacidades iniciais e custos respectivos (referidos ao primeiro estágio de expansão) são apresentados na tabela 5.3. A taxa de avarias (em avarias por ano) é apresentada na última coluna. Este valor será utilizado nos cálculos de fiabilidade.

Subestação	Capacidade inicial (MVA)	Capacidade em projecto (MVA)	Custo referente ao estágio E1 (M\$)	Taxa de avarias (avarias.ano <sup>-1</sup> )
S 1	16.7	16.7 (expansão)	100 (expansão)	0.001
S 2	16.7	13.3 (expansão)	80 (expansão)	0.0012
S 3	-	22.2	200	0.0011
S 4	-	22.2	240	0.0013

Tabela 5.3 Dados relativos às subestações

O tempo médio de reparação é considerado igual para todas das subestações:

$$\text{TMR} = 0.01 \text{ ano}$$

Linhas

A tabela 5.4 apresenta os custos de construção das linhas destinadas à expansão do sistema. Este custo, em geral, é calculado através da seguinte fórmula:

$$C_i = C_f + l_i \cdot C_{v_i} \text{ sendo:}$$

- $C_i$  custo da linha  $i$ ;
- $l_i$  comprimento da linha  $i$  (km);
- $C_f$  custo fixo de construção de uma linha;
- $C_{v_i}$  custo variável de construção da linha  $i$ .

No sistema de teste o custo fixo de uma linha é considerado nulo, sendo o custo variável considerado igual para todas as linhas:

$$Cv_i = 4 \text{ M\$/km}$$

Todos estes custos (em milhões de escudos) são referidos ao primeiro estágio de expansão e capitalizados para os outros estágios de acordo com a já referida taxa de actualização. São também indicados os nós extremos (indicados por A e B) destas linhas. As linhas L0-L3 são linhas fictícias que ligam o nó fonte às subestações S1-S4. Os custos destas linhas para as subestações S3 e S4 correspondem ao custo de construção destas subestações. As linhas L4-L19 pertencem ao sistema inicial, sendo os seus custos, por definição, nulos.

Linha	Nó A	Nó B	Custo	Linha	Nó A	Nó B	Custo
L0	Fonte	S1	-	L1	Fonte	S2	-
L2	Fonte	S3	200	L3	Fonte	S4	240
L4	S1	1	-	L5	S1	3	-
L6	3	4	-	L7	4	7	-
L8	4	5	-	L9	7	8	-
L10	5	6	-	L11	1	9	-
L12	1	2	-	L13	9	10	-
L14	S2	14	-	L15	14	15	-
L16	15	16	-	L17	S2	11	-
L18	11	12	-	L19	12	13	-
L20	19	20	10.6	L21	18	19	9.8
L22	17	18	13.0	L23	9	17	17.0
L24	18	21	11.4	L25	S4	21	9.0
L26	S4	22	14.6	L27	9	22	17.0
L28	22	23	14.6	L29	23	24	9.0
L30	24	25	9.0	L31	25	8	9.0
L32	8	27	14.6	L33	27	26	12.2
L34	27	28	9.8	L35	6	28	17.0
L36	S4	30	9.8	L37	30	29	11.4
L38	30	43	13.8	L39	43	37	9.0
L40	37	31	7.4	L41	31	10	9.0
L42	13	43	12.2	L43	12	45	9.0
L44	45	44	9.0	L45	44	38	12.2
L46	38	39	13.0	L47	39	32	15.4
L48	39	33	9.0	L49	33	8	17.0
L50	33	34	7.4	L51	34	35	9.0
L52	35	36	9.0	L53	S3	36	11.4
L54	S3	28	13.0	L55	S3	41	13.8
L56	41	40	9.8	L57	40	16	9.8
L58	41	42	13.8	L59	42	48	9.0
L60	48	49	13.0	L61	49	50	9.0
L62	42	47	11.4	L63	47	46	11.4
L64	46	14	13.0	-	-	-	-

Tabela 5.4 Dados relativos às linhas de distribuição

Dados eléctricos das linhas

A tabela 5.6 apresenta os dados eléctricos e outros dados relacionados com a fiabilidade das linhas.

<b>Resistência</b>	<b>0.3 <math>\Omega</math>/km</b>
<b>Indutância</b>	<b>0.3 <math>\Omega</math>/km</b>
<b>Capacidade máxima</b>	<b>20 MVA</b>
<b>Taxa de avarias</b>	<b>0.01 avarias.ano<sup>-1</sup>.km<sup>-1</sup></b>
<b>Tempo médio de reparação</b>	<b>0.003 ano</b>

**Tabela 5.5 Dados relativos às linhas de distribuição**

Outros dados

Tensão nominal	<b>15 KV</b>
Limite máximo para as quedas de tensão	<b>8%</b>
Limite preferível para as quedas de tensão	<b>5%</b>

**Tabela 5.6 Outros dados**

**5.3.3 Processo genético**

Os dados seguintes referem-se aos parâmetros mais importantes utilizados no processo genético. Os estudos efectuados sobre diversos modelos de teste demonstraram que estes valores conduziam a um bom desempenho dos algoritmos genéticos.

População	<b>50</b>
Probabilidade de cruzamento	<b>0.8</b>
Probabilidade de mutação	<b>0.004</b>
Número de gerações	<b>300</b>

**Tabela 5.7 Dados relativos ao processo genético**

**5.3.4 Resolução**

A tabela seguinte apresenta alguns parâmetros respeitantes à metodologia referida no capítulo anterior.

Coefficiente de seccionamento

O valor do coeficiente de seccionamento, utilizado no cálculo do índice de fiabilidade, para o sistema de teste é:

$$\alpha = 0.2$$

Este valor do coeficiente de seccionamento indica que os pesos a atribuir, respectivamente, ao minorante e ao majorante do valor esperado da potência não fornecida são de **80%** e **20%**.

### Coeficientes $c_n$ (pesos)

O valor retornado pela função de adaptação para uma solução viável X é obtido através de uma uma função  $f(x)$ , de acordo com os 4 índices (INV,QV,FI,PE).

$$f(x) = M - c_1 \cdot \text{INV} - c_2 \cdot \text{PE} - c_3 \cdot \text{FI} - c_4 \cdot \text{QV}$$

Nos testes efectuados sobre o sistema foram utilizados os seguintes valores:

$c_1$	1.0
$c_2$	5.0
$c_3$	500
$c_4$	0.5

Estes valores foram calculados através de análises de *trade-off* entre o investimento e os outros atributos do problema, no sentido de se obterem soluções equilibradas. O valor elevado do peso atribuído ao critério fiabilidade está relacionado com dois factores fundamentais:

- 1- O valor do índice de fiabilidade toma, em geral, valores da ordem das milésimas.
- 2- Os custos (directos e indirectos) da energia (ou potência) não fornecida são normalmente muito superiores ao custo da energia fornecida (na ordem das 100 vezes<sup>1</sup>).

Naturalmente, estes valores poderiam variar de acordo quer com a sensibilidade e conhecimento prévio do planeador/agente de decisão em relação às características do seu problema, quer com outros critérios económicos da companhia distribuidora.

O valor da constante M foi fixado em  $M=3000$ .

### 5.4 Resultados obtidos

O resultado de um processo genético correspondente aos valores dos parâmetros acima indicados é um plano de expansão para o sistema de distribuição apresentado. Este plano corresponde à solução com um valor superior da função de adaptação (ou seja, com um custo global inferior). As figuras 5.2a a 5.2c representam este plano de expansão. Nestas figuras, uma subestação enquadrada representa a construção de uma expansão da capacidade desta subestação. Uma linha a sombreado representa uma linha que existe num determinado estágio, mas que não é utilizada. No entanto, estas linhas podem ser utilizadas para fechar anéis em caso de saída de serviço de outra linha. Os cálculos de fiabilidade (valor esperado da potência não fornecida) prevêm esta possibilidade. Por fim, um nó sombreado corresponde à não existência de consumo nesse estágio. Entre parentesis indicam-se os valores da potência à saída das subestações.

Esta solução apresenta algumas características interessantes, que se indicam:

- 1 - No primerio estágio, os nós 42 e 43 não possuem consumo. No entanto, a rede passa por estes nós no sentido de existir fluxo para outros nós do sistema.
- 2 - A linha 41-42 é construída no primeiro estágio, desclassificada no segundo e, por fim, reclassificada no último estágio.

<sup>1</sup>A relação entre os pesos dos critérios fiabilidade/perdas corresponde precisamente a este valor.

3 - Note-se, ainda, a reorganização da rede após a entrada em serviço da subestação S3 no segundo estágio.

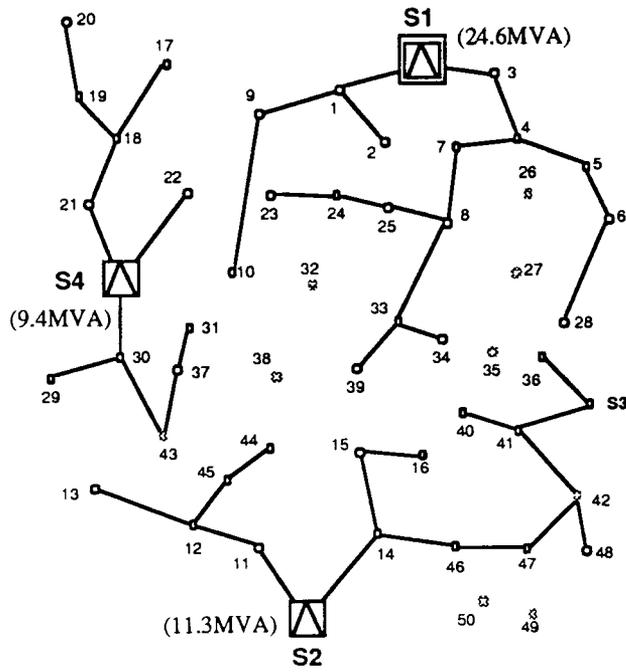


Fig 5.2a Solução para o primeiro estágio

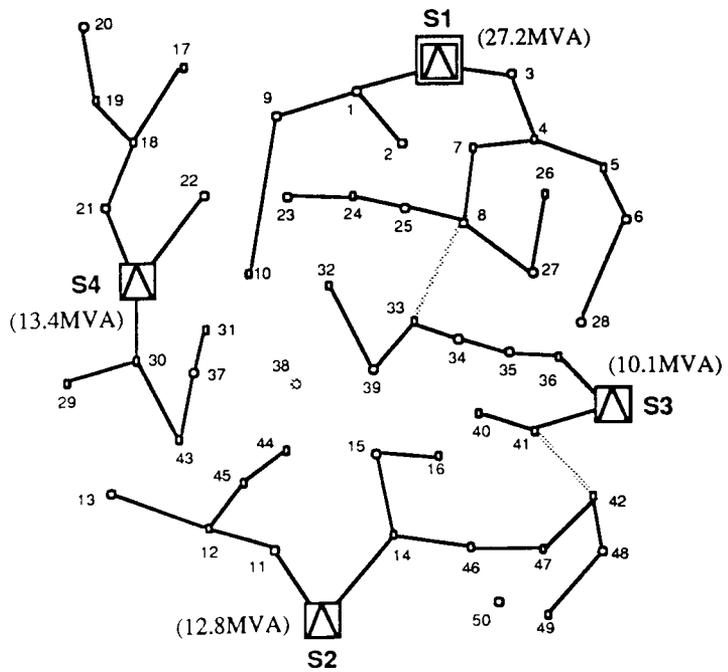


Fig 5.2b Solução para o segundo estágio

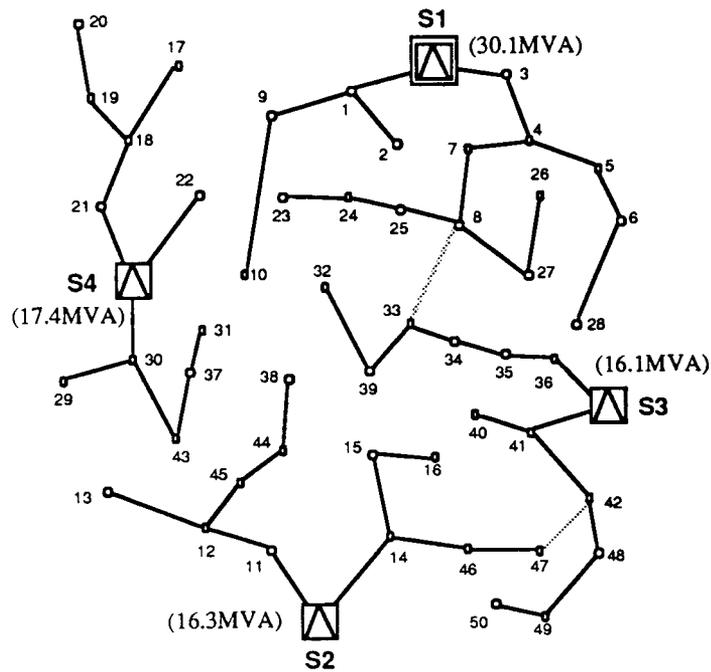


Fig 5.2c Solução para o terceiro estágio

Tensões nos nós

A tabela seguinte apresenta os valores percentuais das quedas de tensão nos nós do sistema nos 3 estágios de expansão (em relação à tensão nominal). A tensão nos nós onde estão localizadas as subestações corresponde, como ficou estabelecido, à tensão nominal. Os valores sombreados correspondem a quedas de tensão superiores ao limite preferível para as mesmas (5%). Um X indica que uma subestação está em serviço ligada a este nó e, conseqüentemente, a sua tensão corresponde à tensão nominal.

Nó	E1	E2	E3	Nó	E1	E2	E3	Nó	E1	E2	E3
S1	X	X	X	15	1.30	1.45	1.55	33	4.34	1.94	2.45
S2	X	X	X	16	1.38	1.54	1.66	34	4.39	1.61	2.07
S3	2.46	X	X	17	0.63	0.82	0.95	35	-	1.14	1.51
S4	X	X	X	18	0.60	0.78	0.90	36	2.47	0.63	0.85
1	0.9	1.04	1.05	19	0.69	0.89	1.04	37	0.68	0.95	1.41
2	0.98	1.12	1.15	20	0.71	0.93	1.08	38	-	-	1.73
3	1.45	1.52	1.72	21	0.31	0.42	0.49	39	4.38	2.11	2.65
4	2.61	2.71	3.11	22	0.04	0.07	0.08	40	2.44	0.27	0.81
5	2.88	3.01	3.47	23	4.34	4.33	5.10	41	2.39	0.21	0.74
6	2.94	3.10	3.57	24	4.31	4.29	5.05	42	2.12	1.82	1.11
7	3.41	3.43	4.01	25	4.24	4.19	4.94	43	0.58	0.81	1.25
8	4.12	4.03	4.75	26	-	4.28	5.11	44	0.66	1.00	1.67
9	1.36	1.56	1.59	27	-	4.23	5.04	45	0.64	0.96	1.50
10	1.64	1.90	2.00	28	2.98	3.14	3.64	46	1.47	1.51	1.45
11	0.27	0.39	0.57	29	0.36	0.49	0.76	47	1.81	1.68	1.51
12	0.57	0.83	1.24	30	0.32	0.43	0.67	48	2.14	1.90	1.26
13	0.64	0.91	1.33	31	0.71	0.98	1.44	49	-	1.94	1.40
14	1.05	1.16	1.19	32	-	2.23	2.78	50	-	-	1.44

Tabela 5.9 Valor percentual das quedas de tensão nos nós

Índice de qualidade de quedas de tensão (QV)

Os valores seguintes representam os índices de qualidade das quedas de tensão QV (valor capitalizado) para os três estágios de expansão. Este índice toma um valor muito próximo de zero, pois as quedas de tensão nos três estágios de expansão se mantêm, em geral, dentro dos limites preferíveis.

QV1	QV2	QV3	QVtotal
0.00	0.00	0.01	0.01

Tabela 5.10 Índice de qualidade das tensões

Custos de investimento

Os valores apresentados na tabela seguinte representam os custos totais de investimento (valores capitalizados) em milhões de escudos para os 3 estágios de expansão, bem assim como o valor do custo global de investimento.

Estágio 1	Estágio 2	Estágio 3	Total (INV)
646.2	248.3	17.3	911.8

Tabela 5.11 Custos de investimento.

Perdas de energia

O valor dos índices de perdas de energia activa (PE) são apresentados na tabela seguinte. Estes valores constituem apenas uma medida do valor esperado da energia anual de perdas, pois correspondem ao valor da potência activa de perdas numa situação de pico de carga. Como já foi referido no capítulo anterior, para o cálculo exacto do valor da energia não fornecida num determinado estágio, seria necessário possuir informação suplementar sobre o sistema nomeadamente relacionado com o diagrama diário de cargas. No entanto, este índice servirá posteriormente para comparação entre as diversas soluções.

Estágio 1	Estágio 2	Estágio 3	Total (PE)
0.33	0.41	0.43	1.17

Tabela 5.12 Índice de perdas de energia activa.

Índice de fiabilidade

Os valores apresentados na tabela seguinte são os índices de fiabilidade FI correspondentes ao valor esperado (capitalizado) da potência de pico não fornecida nos três estágios de expansão. Tal como foi referido no capítulo anterior e à semelhança do índice de perdas de energia activa, este índice é apenas uma medida do valor anual da energia não fornecida e deve ser usado com cuidado na comparação entre os vários planos de expansão.

Estágio 1	Estágio 2	Estágio 3	Total (INV)
0.0126	0.0090	0.0137	0.0353

Tabela 5.13 Índice de fiabilidade.

### 5.4 Análise dos resultados

Os resultados obtidos no teste sobre o sistema apresentado mostram que é possível obter um plano de expansão claro e equilibrado, num compromisso muito aceitável entre os diversos critérios a ser otimizados. Assim, nesta solução, os valores de quedas de tensão estão praticamente sempre dentro dos limites preferíveis, as perdas de energia activa não tomam valores exagerados e os fluxos nas linhas estão, em geral, longe do limite máximo. Além disso, esta solução apresenta uma fiabilidade bastante elevada, permitindo algumas reconfigurações do sistema em caso de contingência (linha 33-8 no 2º e 3º estágio, linha 41-42 no 2º estágio e linha 42-47 no 3º estágio).

Ficou assim demonstrado que este tipo de metodologia pode conduzir a soluções muito interessantes do ponto de vista de planeamento. No entanto, será sempre interessante encontrar e analisar algumas soluções alternativas, enquadrando a solução anterior neste processo. É sobre este assunto que se debruçam os pontos seguintes.

### 5.5 Análise multiobjectivo

Nos testes anteriores, a solução obtida e apresentada nos pontos anteriores corresponde, como já foi referido, à melhor solução encontrada para um único processo genético. Esta solução corresponde a uma concretização dos valores dos coeficientes  $cn$  referidos anteriormente. Através da variação aproximada destes parâmetros em torno daqueles pontos obtemos um elevado conjunto de soluções eficientes. Estas soluções são apresentadas na tabela 5.13 e graficamente nas figuras 5.3 a 5.5.

#### Soluções eficientes

A tabela seguinte apresenta algumas soluções eficientes obtidas através do algoritmo descrito acima seleccionadas a partir de um conjunto muito vasto de soluções não-dominadas que seria fastidioso apresentar por completo. Como se pretende minimizar todos os atributos, nenhuma alternativa é dominada. A solução apresentada anteriormente é indicada a sombreado.

Solução	INV	PE	FI	QV
1	1065	1.45	0.0264	32.3
2	796	1.59	0.0484	7.6
3	911.8	1.15	0.0353	0.01
4	996.5	0.94	0.0290	0.03
5	976.0	1.38	0.0310	15.76
6	1019.5	1.27	0.0276	8.81
7	993.9	1.37	0.0285	2.05
8	1011.5	1.28	0.0276	8.81
9	902.1	1.54	0.0420	53.2
10	897.7	1.32	0.0362	53.2
11	895.0	1.39	0.0378	53.2
12	916.0	0.96	0.0357	0.00
13	925.2	0.92	0.0346	0.00
14	985.1	1.41	0.0286	2.05
15	912.0	1.04	0.0362	1.04
16	936.0	0.96	0.0315	0.00

Tabela 5.13 Soluções eficientes

Ao longo dos diversos testes efectuados concluiu-se que, em geral, as soluções tendem a se agrupar em *clusters* mais ou menos bem definidos. Esta tendência pode ser observada nos gráficos das figuras 5.3 a 5.5.

### Investimento versus Fiabilidade

A figura seguinte apresenta o conjunto de soluções eficientes num espaço bi-atributo - **Investimento versus índice de fiabilidade** - ambos a ser minimizados, pois o índice de fiabilidade FI é, como já foi referido, uma medida do valor esperado da energia não fornecida. A solução apresentada nos pontos anteriores é indicada por uma seta.

A partir do gráfico fica claro que investimentos superiores conduzem a melhores soluções do ponto de vista de fiabilidade.

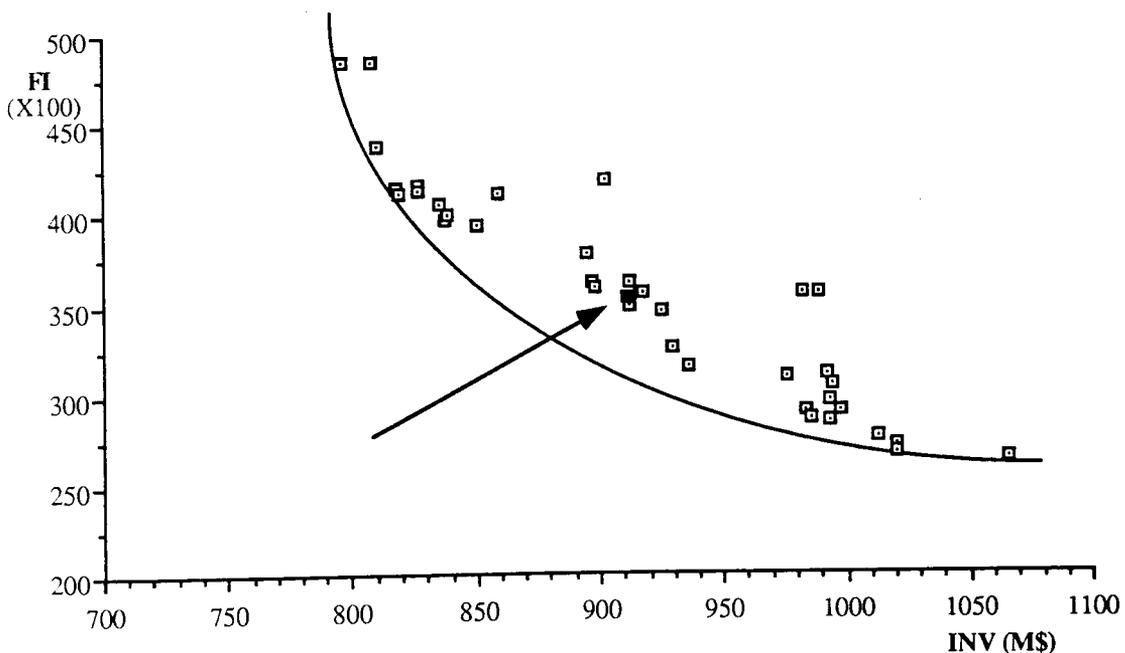


Fig 5.3 Investimento versus índice de fiabilidade.

Neste gráfico foi também desenhada uma aproximação convexa da superfície do domínio de soluções não dominada. Podemos verificar que um elevado número de soluções eficientes se encontram em zonas não convexas da superfície não dominada. Estas soluções seriam dificilmente encontradas a partir de métodos de optimização tradicionais através da adição pesada de atributos. No entanto, estas soluções poderiam ser consideradas como boas soluções de compromisso pelo planeador (veja-se, por exemplo, a solução apresentada anteriormente).

### INV versus QV e INV versus PE

Os gráficos seguintes apresentam duas projecções de parte do domínio de soluções eficientes nos planos INV/QV e INV/PE. Mais uma vez se pode compreender que a fronteira do conjunto de soluções eficientes não apresenta características convexas. Uma das vantagens principais da abordagem genética é precisamente a capacidade de obter soluções fora da superfície convexa do domínio não dominado.

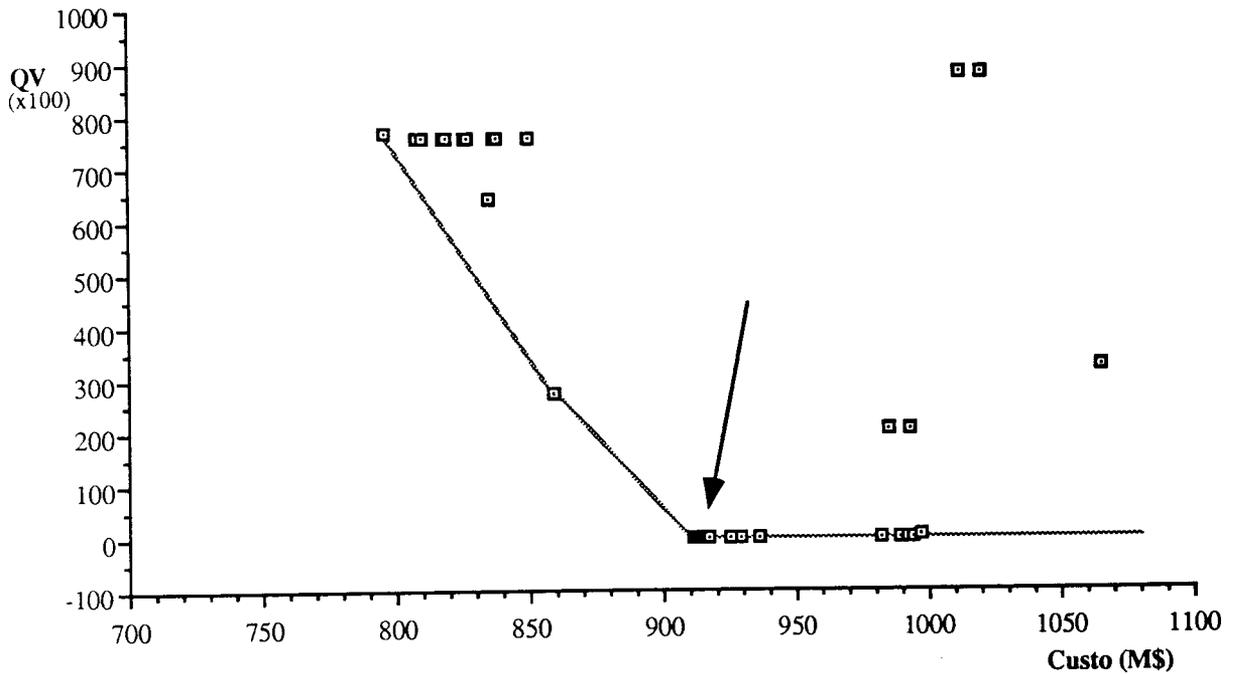


Fig 5.4 Investimento *versus* qualidade das tensões.

No gráfico anterior pode-se verificar que a partir de um determinado valor de custo (aproximadamente 910 M\$) as soluções eficientes neste espaço bi-atributo possuem um valor nulo de índice de qualidade de quedas de tensão. Este facto deve-se, evidentemente, ao processo de cálculo do índice QP. Repare-se também na existência de algumas soluções dentro do domínio não convexo das soluções não dominadas.

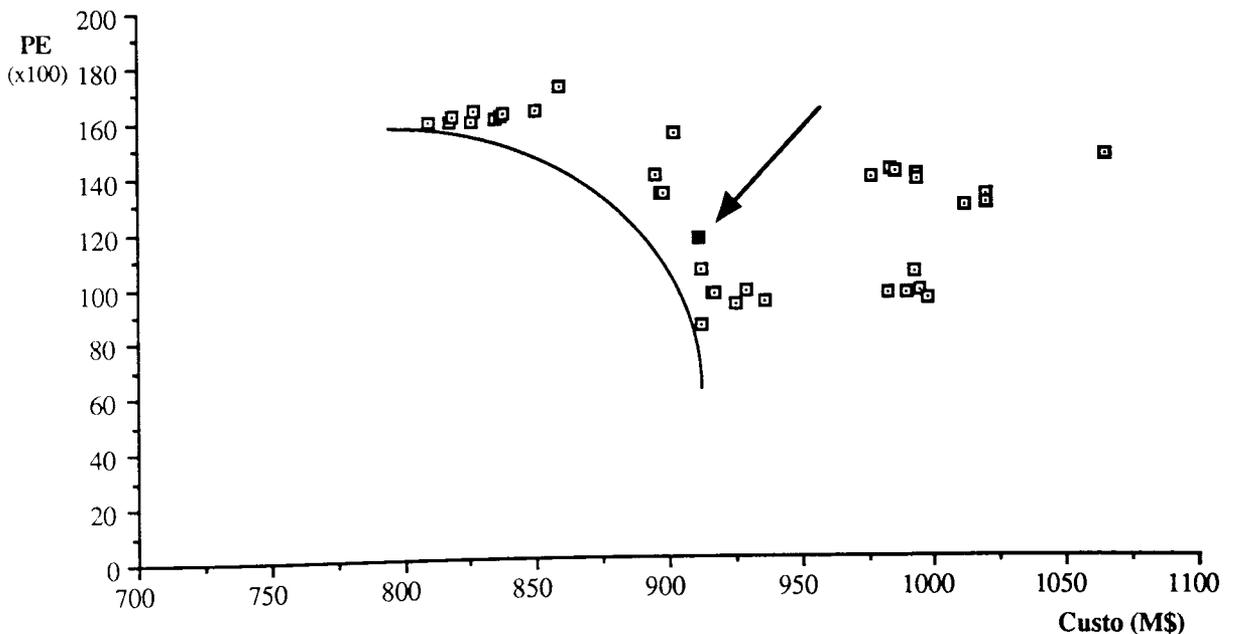


Fig 5.5 Investimento *versus* índice de perdas.

No gráfico da fig. 5.5 pode-se verificar que não existe uma relação muito acentuada entre investimentos superiores e valores menores de perdas de energia. Este facto reflecte a pequena influência atribuída ao factor perdas de energia no custo global para sistema de teste. No entanto, a utilização de um peso superior poderia inverter esta situação. Repare-se também na convexidade da superfície não dominada (da qual uma aproximação foi desenhada sobre o gráfico).

### Escolha de uma solução

Neste ponto, o planeador possui informação suficiente sobre o problema para, de forma esclarecida, escolher uma solução de expansão para o sistema de distribuição em causa. A utilização de metodologias de auxílio à decisão multiobjectivo (nomeadamente, o método das amplificações sucessivas referido no capítulo anterior) seria particularmente adequada para este fim, devido ao elevado número de alternativas existentes.

Outra vantagem desta metodologia seria a possibilidade de fazer uma análise mais aprofundada e individual das soluções mais promissoras deste conjunto. Esta análise poderia incidir sobre aspectos relacionados, por exemplo, com a capacidade de adaptação de cada um dos planos a incertezas e variações no cenário de consumos.

### 5.7 Evolução do processo genético

A figura 5.6 apresenta a evolução típica da melhor solução de sempre e da mediana da geração do processo genético na resolução do DPP através do modelo proposto. O processo genético evolui de acordo com a função de adaptação descrita no capítulo 4, podendo-se distinguir as seguintes zonas que são indicadas no gráfico:

Zona A - Soluções inviáveis topologicamente

Zona B - Soluções inviáveis em termos de satisfação dos consumos.

Zona C - Soluções inviáveis em termos de quedas de tensão.

Zona D - Soluções viáveis.

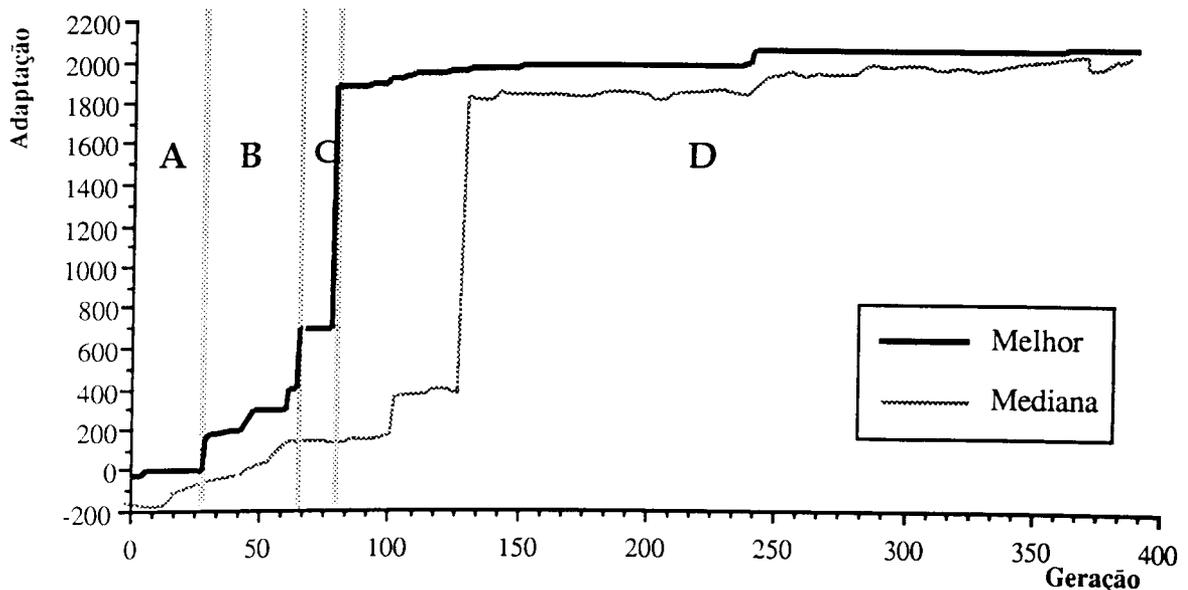


Fig 5.6 Evolução típica de um processo genético.

Analisando o gráfico, pode-se verificar que o algoritmo genético atinge rapidamente (menos de 80 gerações) a região de soluções viáveis, sendo a convergência também rápida.

Nota: É comum, em alguns processos genéticos deste tipo, não existir a zona C. Isto acontece quando a primeira solução encontrada (viável em termos de satisfação de consumos) não viola os limites de queda de tensão.

### Tempos de corrida

O tempo médio de CPU de um processo genético para os dados indicados nos pontos anteriores é aproximadamente  $t = 280$  s. Este valor não pode ser considerado exagerado pois durante o processo genético são encontradas e testadas várias soluções viáveis. No entanto, uma implementação otimizada dos algoritmos conduzirá, provavelmente, a tempos de corrida ainda menores. Num futuro próximo, a implementação de soluções paralelas diminuirá radicalmente estes valores.

## 5.8 Conclusões

Os resultados obtidos pela aplicação do método descrito neste trabalho confirmam a relevância da abordagem genética e o valor de ter uma ferramenta poderosa como este modelo no auxílio ao planeamento da distribuição. Isto é particularmente correcto quando se trata de um problema de grandes dimensões, onde um rápido aumento nos consumos implica um número elevado de possíveis investimentos e, conseqüentemente, um número elevado de estratégias de expansão possíveis. De facto, este modelo permite obter, num tempo reduzido, uma solução ou, eventualmente, um conjunto de soluções eficientes que, enquadradas convenientemente num processo de decisão multicritério, facilitam substancialmente a tarefa do planeador. Assim, através da combinação adequada de algoritmos genéticos e métodos de auxílio à decisão multiobjectivo, resultarão benefícios económicos consideráveis, com uma diminuição de custos quer na expansão dos sistemas quer no planeamento em si (atendendo à diminuição de engenheiros.hora envolvidos).

Não restam, portanto, dúvidas que esta abordagem será retida para trabalhos futuros e, provavelmente, aperfeiçoada na base da experiência e de novas técnicas no campo dos algoritmos genéticos. A introdução de novas opções de modelização e um melhoramento no interface com o planeador será, também, uma das direcções a seguir.

Todos os aspectos relacionados com a evolução do modelo serão equacionados de uma maneira mais desenvolvida no capítulo 7. O próximo capítulo apresenta uma aplicação do modelo a redes de distribuição de gás.

## Capítulo 6

### Algoritmos genéticos no planeamento da expansão de redes de distribuição de gás

#### 6.1 Introdução

Nos capítulos anteriores ficou demonstrado que o problema do planeamento da distribuição de energia eléctrica (DPP) pode ser eficientemente resolvido através duma metodologia baseada em algoritmos genéticos. Por outro lado, esta abordagem mostrou possuir uma grande flexibilidade, sugerindo a sua aplicação na resolução de outro tipo de problemas de planeamento. Neste capítulo, e precisamente no sentido de mostrar a versatilidade do modelo, apresenta-se uma aplicação do mesmo ao problema do planeamento de redes de distribuição de gás. Como se poderá constatar, a metodologia seguida é, em diversos aspectos, idêntica à seguida na resolução do DPP.

#### 6.2 Características do problema

O problema do planeamento da distribuição de gás apresenta diversas facetas e seria quase impossível incluí-las todas num modelo de planeamento. Consequentemente, o modelo que foi desenvolvido é um modelo simplificado, não deixando, no entanto, de constituir uma ferramenta interessante no planeamento destes sistemas. Este modelo foi desenvolvido para redes de **alta pressão** (pressões superiores a **7 bar**) apresentando, no entanto, generalidade suficiente para ser aplicado a qualquer tipo de rede de distribuição.

O problema consiste, genericamente, em planear a expansão de um sistema de distribuição de gás para um ou mais estágios, no sentido de satisfazer os consumos, minimizando os custos de investimento. Procura-se ainda maximizar a qualidade de serviço, traduzida em índices relacionados com, por exemplo, quedas de pressão. Este último factor será referido mais adiante.

Um sistema de distribuição de gás é representado como uma rede de nodos e arcos. Os nodos representam localizações existentes ou potenciais para nós de injeção ou nós de consumo e os arcos representam condutas existentes no sistema inicial ou condutas potenciais. Tal como no DPP, os nós de injeção, correspondentes às subestações, estão ligados a um nó fonte comum. Do ponto de vista do modelo, estes nós correspondem a condutas (potenciais ou existentes) entre o nó de injeção e o nó fonte. Em todos os outros aspectos (excepto os que irão ser referidos mais adiante) existe um paralelismo entre o DPP e este problema. A figura 6.1 ilustra a representação de um sistema deste tipo.

##### 6.2.1 Lista de símbolos

- e número de estágios
- h horizonte de planeamento
- c número total de condutas
- i número total de nós de injeção
- k número total de nós de consumo
- $D_r$  Taxa de actualização (*discount rate*)

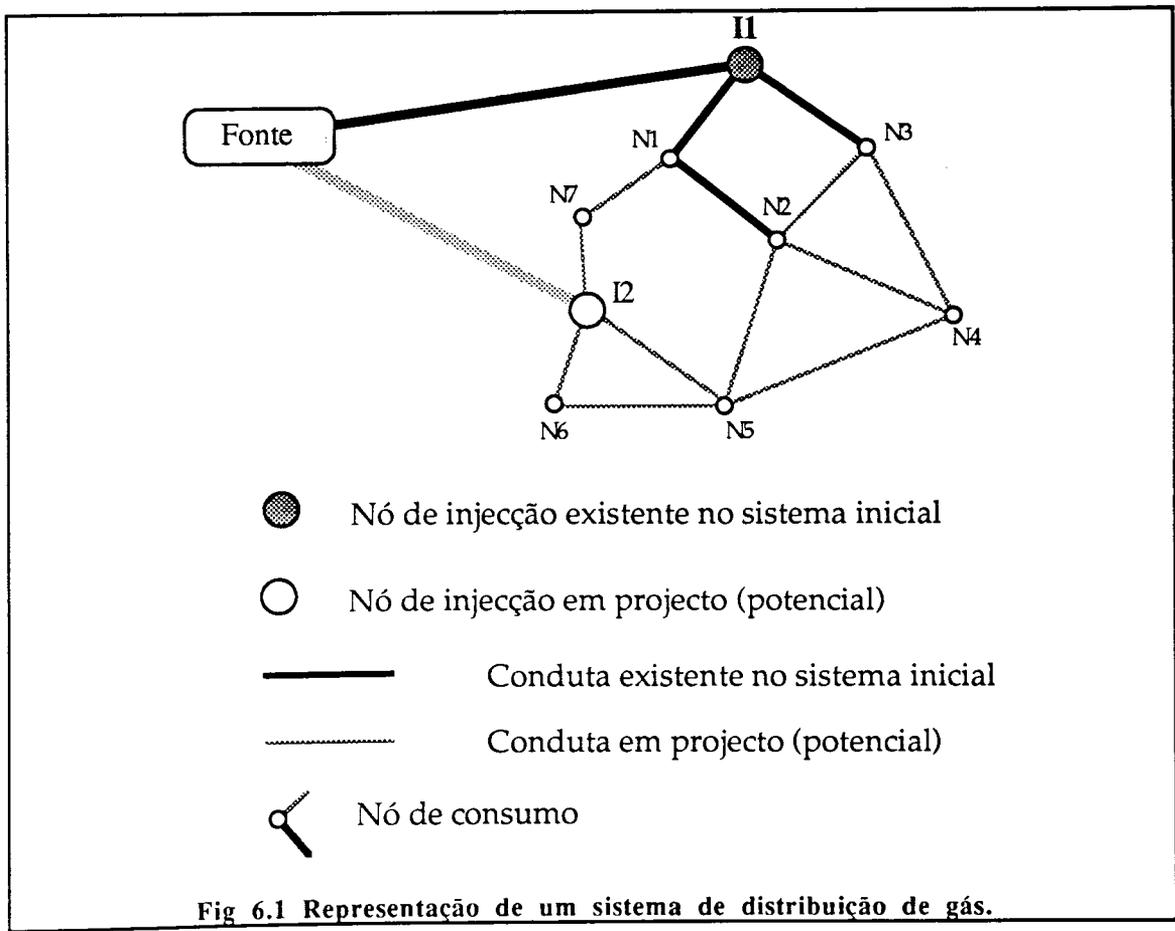
Variáveis de decisão:

$F_{is} = 1$  Se a conduta potencial  $i$  é utilizada no estágio  $s$   
 $F_{is} = 0$  Em caso contrário

$S_{is} = 1$  Se o nó de injeção potencial  $i$  é utilizado no estágio  $s$   
 $S_{is} = 0$  Em caso contrário

$E_{is} = 1$  Se a expansão de capacidade  $i$  de um nó de injeção é utilizada no estágio  $s$ .  
 $E_{is} = 0$  Em caso contrário

Estas variáveis definem completamente a rede de distribuição de gás ao longo do horizonte de planeamento.



**6.2.2 Qualidade nas pressões.**

Neste modelo, o único critério considerado para além do relacionado com os custos de investimento, é o critério de qualidade nas quedas de pressão nos nós de consumo. O objectivo é ter os valores de pressão nos nós de consumo o mais próximo possível da pressão nominal da rede. O índice de qualidade de pressões **QP** deverá reflectir este

objectivo e, tal como os índices de qualidade no DPP, é capitalizado de acordo com a taxa de actualização  $D_r$ . Este aspecto será referido num ponto posterior.

### 6.2.3 Restrições

O problema está sujeito às seguintes restrições:

a) Limites na queda de pressão nos nós de consumo.

É estabelecido um limite inferior para a pressão num nó de consumo. Este limite pode variar com o tipo de nó. No entanto, neste modelo foi estabelecido apenas um limite para todos os nós de consumo. Sendo  $p_{ij}$  a pressão no nó  $i$  no estágio  $j$  e  $P_{\min}$  o limite inferior para as pressões, temos a seguinte restrição:

$$p_{ij} \leq P_{\min} \quad \text{para } i=1..c, j=1..e$$

Nota: Havendo uma relação directa entre os caudais na conduta e as quedas de pressão nos seus extremos, aquele fica automaticamente limitado por esta restrição.

b) Limites na capacidade dos nós de injeção.

Os nós de injeção estão sujeitos a um limite superior na sua capacidade. Sendo  $O_i$  a capacidade máxima de um nó de injeção  $i$  e  $I_{ij}$  a injeção desse nó num estágio  $j$  temos a seguinte restrição:

$$I_{ij} \leq O_i \quad \text{para } i=1..c, j=1..e$$

## 6.3 Modelo de planeamento

O modelo de planeamento da expansão de sistemas de distribuição de gás é, em muitos aspectos, semelhante ao modelo desenvolvido para o DPP, sendo a estratégia geral praticamente idêntica. Para isso é feita uma correspondência directa entre:

- Conduitas - Linhas de distribuição;<sup>1</sup>
- Nós de injeção - Subestações;
- Nós de consumo de gás - Nós de consumo de energia eléctrica;
- Reforços na capacidade dos nós de injeção - Reforços nas subestações.

O pré-processamento da rede é efectuado seguindo o mesmo algoritmo do modelo para o DPP.

As diferenças fundamentais encontram-se ao nível da função de adaptação, onde as soluções apenas são avaliadas segundo dois critérios (investimento e qualidade de pressões). Assim, os pontos seguintes apenas pretendem resumir os pontos fulcrais deste modelo.

### 6.3.1 Condições

No modelo parte-se dos mesmos princípios que no modelo de resolução do DPP:

---

<sup>1</sup>É também contemplada a possibilidade de duas condutas partilharem a mesma vala, com a consequente diminuição de custo.

- É considerado apenas um valor de pico para os consumos sendo, no entanto, possível incluir factores de diversidade de consumos na formulação do modelo.

- Todos os custos e localizações candidatas à construção de condutas e nós de injeção são conhecidos *a priori*.

### 6.3.2 Codificação

A codificação usada neste modelo é exactamente igual à usada no modelo de resolução do DPP. Isto deve-se ao facto de esta codificação se ter mostrado extremamente eficiente para a representação de problemas deste género. A codificação permite, tal como no DPP, a uma conduta passar por um nó sem consumo num determinado estágio. Também é permitida a desclassificação (e eventual reclassificação) de condutas.

### 6.3.3 Função de Adaptação

A função de adaptação deve reflectir tanto as propriedades desejadas como as indesejadas de uma solução. Numa rede de distribuição de gás as propriedades desejadas são:

- Baixo custo de investimento.
- Qualidade elevada nas quedas de pressão (quedas de pressão baixas)

As propriedades indesejadas são:

- Configurações não conexas.
- Violações nos limites de caudal nas condutas.
- Violações nos limites inferiores de pressão nos nós de consumo.

Tratando-se de um problema de maximização, a função de adaptação retorna um valor superior para melhores soluções.

Como já foi referido, esta função apresenta algumas diferenças em relação ao modelo apresentado no capítulo 4. Ela pode ser dividida em quatro fases fundamentais:

Fase 1 - Descodificação.

Fase 2 - Análise topológica.

Fase 3 - Verificação das restrições.

Fase 4 - Avaliação da solução.

A descrição de cada uma destas fases será feita em seguida. O algoritmo geral é apresentado na figura 6.2.

#### Fase 1 - Descodificação.

Como já foi referido num ponto anterior, o algoritmo de codificação/descodificação é igual ao seguido no modelo apresentado no capítulo 4.

Neste ponto são obtidas as variáveis **F**, **S** e **E** que definem completamente a topologia da rede para os e estágios de expansão.

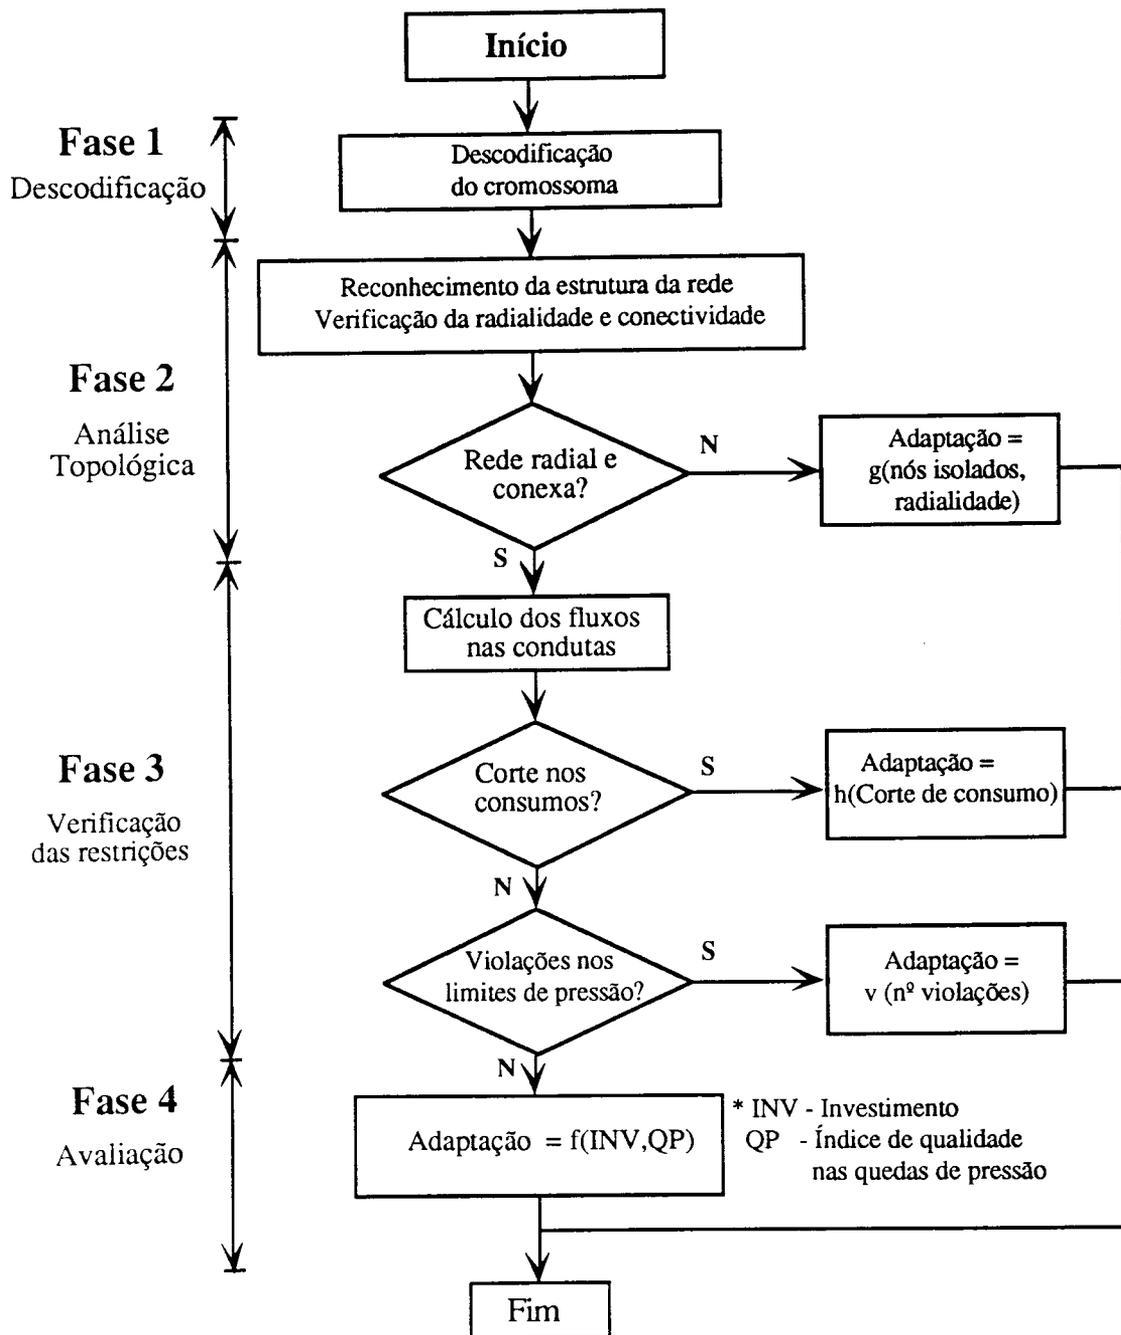


Fig 6.2 Esquema da função de adaptação

**Fase 2 - Análise topológica.**

Esta fase, à semelhança do modelo descrito para o DPP permite eliminar soluções inviáveis do ponto de vista topológico atribuindo-lhes um valor de adaptação muito baixo, calculado através da função g():

$$FA = g(\text{n}^\circ \text{ de nós com consumo não ligados ao nó fonte, radialidade})$$

### Fase 3 - Verificação das restrições.

Esta fase apresenta algumas diferenças em relação ao modelo do DPP.

Em primeiro lugar é efectuado o cálculo do caudal nas condutas, através de um algoritmo muito simples e rápido de caudal em redes radiais. Depois procede-se à verificação de restrições em dois passos:

a) Verificação dos limites de caudal nas condutas. Se houver violações nestes limites, a função de adaptação de uma solução  $x$  termina retornando um valor inversamente proporcional ao consumo não satisfeito. Este valor é calculado através da função  $h()$ :

$$FA = h(\text{consumos não satisfeitos}) \text{ e } h() > g() \text{ (em todo o domínio)}$$

b) No caso de não haver violações nos limites de caudal nas condutas, são calculadas as pressões nos nós através da equação 'A' de Panhandle, formulada para redes de alta pressão, que relaciona o caudal numa conduta com as pressões nos seus extremos [Osi87]:

$$Q_n = 7.57 \times 10^{-4} \frac{T_n}{P_n} \sqrt{\frac{(p_1^2 - p_2^2) \cdot D^5}{fSLTZ}}$$

sendo:

$Q_n$	caudal na conduta (m <sup>3</sup> /h)
$T_n$	temperatura nominal (°K)
$P_n$	pressão nominal (bar)
$D$	diâmetro interno da conduta (m)
$p_1, p_2$	pressões nos extremos das condutas (bar)
$Z$	factor de compressibilidade do gás (adimensional)
$S$	peso específico do gás (N/m <sup>3</sup> )
$L$	comprimento da conduta (m)
$E$	factor de eficiência da conduta (adimensional)

Para o gás natural, o factor de fricção  $f$  é dado por:

$$\sqrt{\frac{1}{f}} = 14.94 E \left( \frac{SQ_n}{D} \right)^{0.073}$$

Assumindo  $Z=0.95$ ,  $T = 288K$  e  $S = 0.589$ , obtemos a relação entre as pressões nos extremos da conduta e o caudal:

$$p_1^2 - p_2^2 = K Q_n^{1.854}$$

onde:

$$K = 18.43 \frac{L}{E^2 D^{4.854}}$$

Se não houver violações nos limites de pressão nos nós de consumo, a função de adaptação passa à fase 4. Em caso contrário, a função termina retornando um valor proporcional ao número de nós onde existem violações, procurando-se encaminhar o

algoritmo genético no sentido de uma solução viável. Este valor é calculado através de uma função  $v()$ :

**FA =  $v(n^o$  de nós onde existem violações nos limites inferiores de pressão)**

#### Fase 4 - Avaliação da solução.

A última fase consiste na avaliação de uma solução viável  $X$ . Esta solução corresponde a um plano de expansão para os  $e$  estágios dentro do horizonte de planeamento  $h$ .

A solução será avaliada através de uma função  $f(X)$  a partir de dois índices correspondentes aos dois critérios de avaliação já referidos:

- Custos de investimento (INV)
- Qualidade nas pressões nos nós de consumo (QP)

Estes dois índices são calculados da seguinte forma:

##### Custos de investimento

Tal como no modelo referido no capítulo 4, os custos de investimento são calculados através da soma capitalizada dos custos correspondentes à construção de cada um dos itens (condutas, nós de injeção, aumento da capacidade nos nós de injeção). Ao índice INV é atribuído o valor destes custos. Temos assim a seguinte expressão para o cálculo deste índice:

$$INV = \sum_{i=1}^e \sum_{j=1}^k \frac{C_j}{\left(1 + \frac{D_r}{100}\right)^{i-1}}$$

sendo:

- |       |  |
|-------|--|
| $e$   | número de estágios                             |
| $k$   | número de itens construídos                    |
| $C_j$ | custo do item $j$ referido ao primeiro estágio |
| $D_r$ | Taxa de actualização (%)                       |

##### Qualidade nas pressões nos nós de consumo.

O índice de qualidade de pressão  $q_{ij}$  para cada nó de consumo  $i$  num estágio  $j$  é calculado através do desvio quadrático da pressão  $p_{ij}$  em relação à pressão nominal  $P_n$ :

$$q_{ij} = (P_n - p_{ij})^2 \text{ para } i=1..k$$

O índice de qualidade  $Q_j$  para um estágio  $j$  é obtido pelo somatório dos índices de qualidade para cada um dos nós de consumo:

$$Q_j = \sum_{i=1}^k q_{ij} \text{ para } j=1..e$$

O índice de qualidade global de uma solução QP é obtido pela soma capitalizada dos índices correspondentes aos  $e$  estágios de planeamento:

$$QP = \sum_{j=1}^n \frac{Q_j}{(1 - D_r)^{j-1}}$$

sendo,  $D_r$  a taxa de actualização considerada para este problema.

### Cálculo de $f(X)$

A função de adaptação FA é calculada, para uma solução viável  $x$ , através da função  $f(x)$  de acordo com a seguinte expressão:

$$FA = f(x) = M - INV - c.QP$$

sendo  $c > 0$  uma constante calculada externamente. Esta constante é uma medida da importância atribuída ao factor qualidade das pressões. Pode ser calculado através de análises de *trade-off* - a companhia distribuidora deverá decidir qual o valor que está disposta a pagar (em termos de investimento suplementar) por um incremento no valor do índice de qualidade QP.

No sentido de garantir que  $f() > v() > h() > g()$ , é necessário somar uma constante elevada  $M$  à função  $f(X)$ , pois, como já foi referido, trata-se de um problema de maximização. Pela mesma razão, a constante  $c$  é afectada de um sinal negativo.

### 6.3.4 Resultados do algoritmo

O resultado final do processo genético para uma determinada realização da constante é o indivíduo encontrado com o valor superior de adaptação. Como foi referido no modelo anterior, este indivíduo pode, eventualmente, não constituir a solução óptima para o problema.

Se variarmos o valor da constante  $c$  dentro de valores pré-determinados, encontraremos necessariamente várias soluções, pois estaremos a atribuir pesos diferentes aos critérios de investimento e de qualidade de pressões. Se apenas estivermos interessados em minimizar o investimento, podemos atribuir a  $c$  o valor nulo. Este caso, bastante comum no planeamento de redes de gás, corresponde ao aceitar qualquer valor de pressão nos nós de consumo até ao limite máximo determinado. Obteremos assim a melhor solução do ponto de vista de custos de investimento.

### 6.3.5 Integração no contexto do planeamento

Surge, finalmente, o problema de determinar a melhor solução para a expansão do sistema de distribuição. Neste momento existem duas opções, de acordo com a capacidade do planeador estabelecer com segurança o valor da constante  $c$ :

a) Se o planeador puder atribuir, com um elevado grau de certeza, um valor à constante  $c$  (ou seja, os pesos aos dois critérios) a solução final de um processo genético corresponderá ao plano de expansão procurado.

b) Em caso contrário ou se, por alguma razão, o planeador desejar uma análise mais aprofundada do conjunto de soluções, poderá optar pela estratégia que a seguir se descreve em dois passos:

1- Variar o valor da constante  $c$  num intervalo pré-estabelecido. Guardar todas as soluções eficientes encontradas.

- 2 - Escolher a solução mais interessante dentro do conjunto de soluções não-dominadas. Para isso o planeador tem várias opções, nomeadamente:
- Pesquisa através de métodos de auxílio à decisão multicritério (ver capítulo 4).
  - Métodos gráficos e/ou análises de *trade-off* (ver exemplo de aplicação).

Por outro lado, o planeador pode ainda utilizar este conjunto para uma segunda análise mais aprofundada de cada uma das soluções eficientes.

#### 6.4 Exemplo de aplicação

O algoritmo descrito neste capítulo foi programado em linguagem C numa Workstation NEXT, usando o software genético apresentado em [Ran93].

Esta metodologia foi aplicada ao problema representado na figura 6.3. Trata-se de um problema de planeamento multitemporal (3 estágios) de um sistema de distribuição de gás de alta pressão (30 bar) constituído por 50 nós de consumo, 4 nós de injeção/consumo, 16 condutas existentes e 45 condutas potenciais.

As capacidades previstas para os nós de injeção e outros dados complementares do problema são apresentados nas tabelas seguintes.

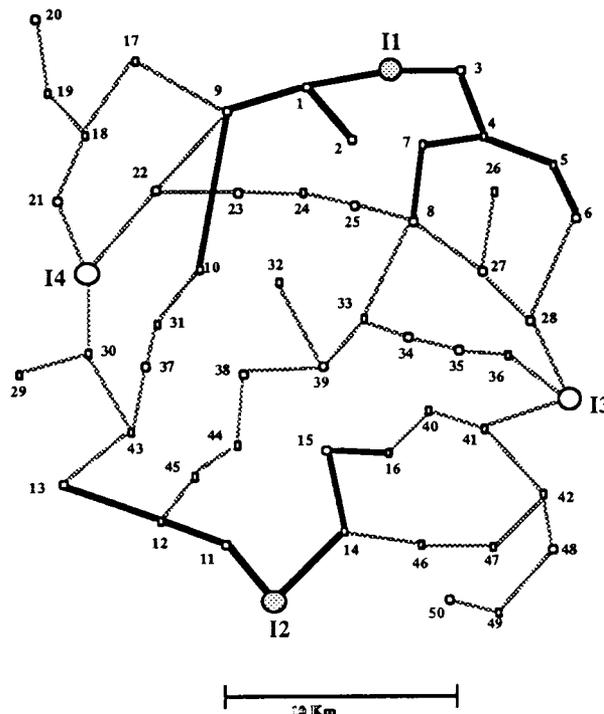


Fig 6.3 Sistema inicial

- |                            |                  |
|----------------------------|------------------|
| * Horizonte de planeamento | $h = 3$ anos     |
| * Número de estágios       | $e = 3$          |
| * Taxa de actualização     | $D_r = 10\%/ano$ |

##### 6.4.1 Condutas

###### Diâmetro interno

O valor do diâmetro interno nas condutas existentes e em projecto são indicados em seguida. Apenas é considerado um valor possível de diâmetro para cada conduta em projecto.

$\phi = 400 \text{ mm}$

para as condutas: 4, 5, 14, 17, 25, 26, 36, 53, 54, 55

$\phi = 200 \text{ mm}$

para as outras condutas

### Eficiência

A eficiência de uma conduta pode variar com o tempo e com outros aspectos como, por exemplo, a frequência de limpeza da mesma. Para simplificar (em termos de planeamento é aceitável), considerou-se um valor fixo para a eficiência das condutas  $E_i = 0.8$ .

### Custos

A tabela 6.1 apresenta os custos (em milhões de escudos) correspondentes à construção de cada conduta para o primeiro estágio -  $C_1$  (são também indicados os nós correspondentes aos extremos das condutas A e B). O custo de uma conduta é calculado a partir do comprimento e diâmetro da mesma. Às condutas existentes no sistema inicial corresponde, por definição, um custo nulo.

Cond.	Nó A	Nó B	$C_1$	Cond.	Nó A	Nó B	$C_1$
-	-	-	-	4	11	1	-
5	11	3	-	6	3	4	-
7	4	7	-	8	4	5	-
9	7	8	-	10	5	6	-
11	1	9	-	12	1	2	-
13	9	10	-	14	12	14	-
15	14	15	-	16	15	16	-
17	12	11	-	18	11	12	-
19	12	13	-	20	19	20	11.9
21	18	19	10.8	22	17	18	16.2
23	9	17	21.6	24	18	21	14.0
25	14	21	13.4	26	14	22	19.5
27	9	22	21.6	28	22	23	16.7
29	23	24	10.8	30	24	25	10.8
31	25	8	10.8	32	8	27	16.7
33	27	26	12.9	34	27	28	11.8
35	6	28	21.6	36	14	30	13.4
37	30	29	15.1	38	30	43	19.9
39	43	37	10.8	40	37	31	9.7
41	31	10	10.8	42	13	43	12.9
43	12	45	10.8	44	45	44	10.8
45	44	38	12.9	46	38	39	21.0
47	39	32	17.2	48	39	33	10.8
49	33	8	9.7	50	33	34	10.8
51	34	35	10.8	52	35	36	10.8
53	13	36	14.6	54	13	28	18.3
55	13	41	19.5	56	41	40	11.8
57	40	16	11.8	58	41	42	16.2
59	42	48	10.8	60	48	49	16.2
61	49	50	10.8	62	42	47	14.0
63	47	46	14.0	64	46	14	16.2

Tabela 6.1 Dados relativos às condutas

### 6.4.2 Nós de injeção

A tabela 6.2 apresenta os valores iniciais de capacidade (e possíveis expansões) para os nós de injeção I1 e I2, bem assim como as capacidades para os nós de injeção em projecto I3 e I4. Os custos dos reforços de I1 e I2 e da construção de I3 e I4 são apresentados na coluna da direita.

Nó de injeção	Capacidade inicial (m <sup>3</sup> /s)	Capacidade em projecto (m <sup>3</sup> /s)	Custo para o estágio 1 (M\$)
I1	15	15	100 (reforço)
I2	15	12	80 (reforço)
I3	-	20	200
I4	-	18	180

Tabela 6.2 Dados relativos aos nós de injeção

### 6.4.3 Consumos

A tabela seguinte apresenta os dados relativos aos consumos nos nós (em m<sup>3</sup>/s) em cada um dos estágios de expansão (E1, E2, E3).

Nó	E1	E2	E3	Nó	E1	E2	E3	Nó	E1	E2	E3
I1	-	1.6	1.8	I2	0	0.9	1.0	I3	-	0.7	0.8
I4	-	0.4	0.5	1	3.3	3.8	4.2	2	1.1	1.3	1.5
3	0.4	0.5	0.7	4	1.4	1.9	1.1	5	2.0	2.3	2.6
6	0.6	0.7	0.7	7	0.2	0.5	1.0	8	1.5	1.7	1.9
9	1.9	2.0	1.2	10	2.0	2.4	2.9	11	0.2	0.2	0.3
12	1.0	1.6	1.8	13	0.9	1.0	1.1	14	0.8	0.9	1.0
15	1.0	1.2	1.4	16	1.3	1.5	1.6	17	-	0.6	0.7
18	0.9	1.0	1.2	19	1.0	1.2	1.4	20	0.5	0.7	0.8
21	0.5	1.6	1.8	22	0.5	1.0	1.1	23	0.5	0.9	1.0
24	0.5	0.4	0.5	25	0.6	0.8	0.9	26	-	0.8	1.2
27	-	-	1.5	28	0.4	0.5	0.7	29	0.4	0.9	1.1
30	2.0	2.3	2.6	31	-	0.7	0.7	32	-	1.5	1.7
33	1.5	1.7	1.9	34	0.9	1.0	1.2	35	0.1	0.4	0.9
36	-	-	0.3	37	1.0	1.6	2.1	38	0.9	1.0	1.1
39	0.8	0.9	1.0	40	1.0	1.2	1.4	41	0.3	0.5	0.9
42	-	-	1.2	43	-	-	1.3	44	0.5	1.0	1.4
45	0.5	0.7	0.8	46	0.5	1.6	1.8	47	-	-	1.0
48	0.5	0.6	0.8	49	0.5	0.6	0.5	50	0.5	0.7	0.8

Tabela 6.3 Consumos nos nós

### 6.4.4 Outros dados

A tabela seguinte apresenta alguns dados relativos aos testes efectuados sobre o exemplo, incluindo parâmetros respeitantes ao processo genético.

Peso atribuído ao índice QP	$c = 0.01$
População	$p = 50$
Probabilidade de <i>crossover</i>	$P_c = 0.8$
Probabilidade de mutação	$P_m = 0.04$
Número de gerações	$g = 350$

Tabela 6.4 Outros dados

## 6.5 Resultados

Após a execução de um processo genético, foi obtido um plano de expansão final que corresponde à solução com um valor superior da função de adaptação (ou seja, a um custo global inferior). Este plano é apresentado nas figuras 6.4 a 6.6, nas quais um nó de injeção enquadrado representa uma expansão na sua capacidade e uma linha a sombreado representa uma conduta que não é utilizada no estágio em questão.

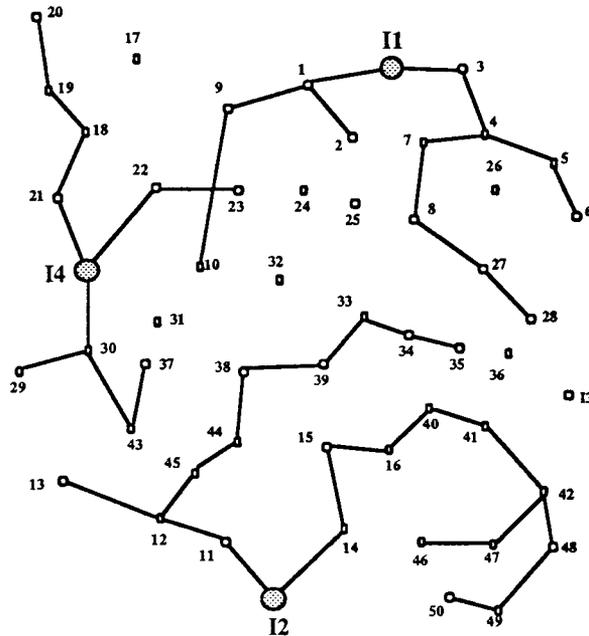


Fig 6.4 Solução para o 1º estágio

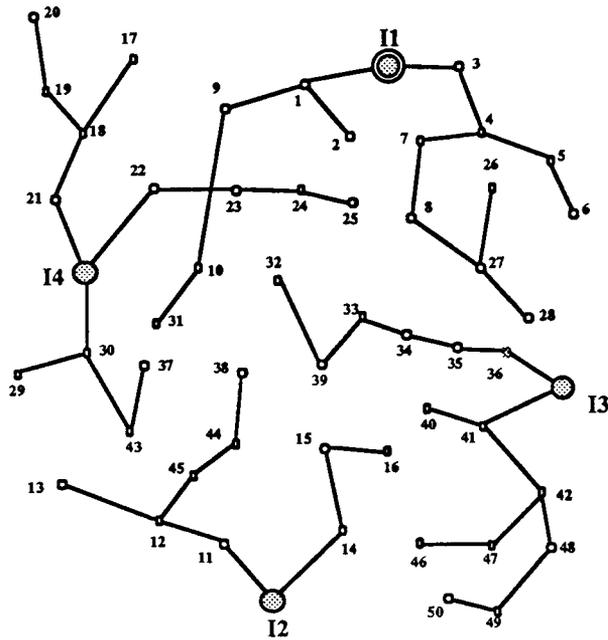


Fig 6.5 Solução para o 2º estágio

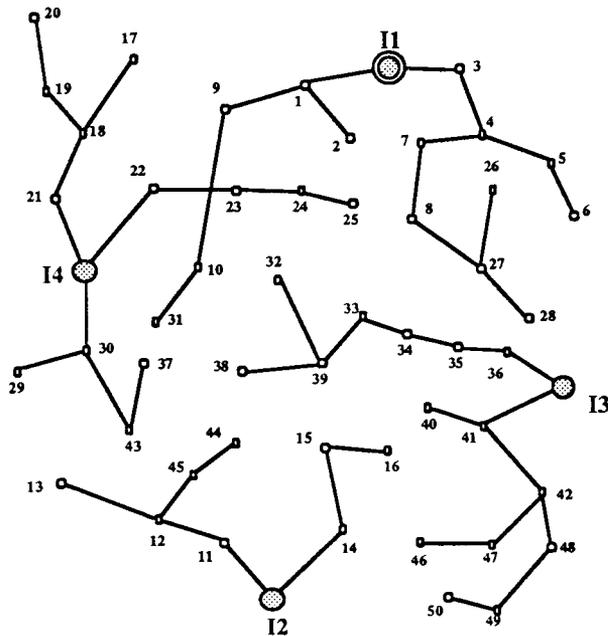


Fig 6.6 Solução para o 3º estágio

Pressões nos nós

A tabela 6.5 apresenta os valores das pressões (em bar) nos nós da rede nos três estágios de expansão. A sombreado é representado o maior valor de queda de pressão (24.8 bar no nó 26, estágio 3, a que corresponde uma queda de pressão de 20.9% em relação à pressão nominal).

Nó	P <sub>1</sub>	P <sub>2</sub>	P <sub>3</sub>	Nó	P <sub>1</sub>	P <sub>2</sub>	P <sub>3</sub>	Nó	P <sub>1</sub>	P <sub>2</sub>	P <sub>3</sub>
1	29.93	29.90	29.90	2	29.89	29.84	29.82	3	29.96	29.93	29.89
4	29.07	28.3	27.29	5	28.85	28.01	26.93	6	28.84	27.99	26.91
7	28.94	27.94	26.16	8	28.82	27.66	25.31	9	29.39	29.00	29.09
10	29.10	28.34	28.23	11	29.96	29.98	29.98	12	28.58	29.18	29.24
13	28.54	29.14	29.19	14	29.94	29.98	29.97	15	29.00	29.74	29.62
16	28.41	29.67	29.51	17	-	29.62	29.50	18	29.82	29.64	29.52
19	29.77	29.55	29.40	20	29.76	29.54	29.39	21	29.99	29.98	29.97
22	29.99	29.99	29.99	23	29.90	29.83	29.78	24	29.87	29.80	29.74
25	29.86	29.78	29.72	26	-	27.57	24.80	27	28.82	27.59	24.85
28	28.81	27.59	24.83	29	29.98	29.95	29.92	30	29.99	29.98	29.96
31	-	28.33	28.21	32	-	28.23	26.64	33	26.37	28.46	27.10
34	26.34	28.83	27.80	35	26.34	29.37	28.77	36	-	29.98	29.95
37	29.92	29.81	29.4	38	27.04	28.89	26.70	39	26.53	28.33	26.76
40	28.14	29.93	29.87	41	28.00	29.97	29.93	42	27.85	29.58	28.81
43	29.94	29.87	29.50	44	27.52	28.92	29.08	45	28.01	29.02	29.13
46	27.83	29.42	28.47	47	27.84	29.50	28.58	48	27.79	29.49	28.64
49	27.75	29.43	28.64	50	27.74	29.42	28.62	I1	o	o	o
I2	o	o	o	I3	X	o	o	I4	o	o	o

Tabela 6.5 Pressões nos nós da rede

Fluxos nas condutas

A tabela 6.6 apresenta os valores de fluxo (em m<sup>3</sup>/s) nas condutas de distribuição para os três estágios de expansão.

Cond	F1	E2	E3	Cond	E1	E2	E3	Cond	E1	E2	E3
4	8.3	10.2	10.5	5	6.5	8.9	11.4	6	6.1	8.4	10.7
7	2.1	3.5	6.3	8	2.6	3.0	3.3	9	1.9	3.0	5.3
10	0.6	0.7	0.7	11	3.9	5.1	4.8	12	1.1	1.3	1.5
13	2.0	3.1	3.6	14	6.4	3.6	4.3	15	5.6	2.7	3.3
16	4.6	1.5	1.9	17	7.3	5.5	5.4	18	7.1	5.3	5.1
19	0.9	1.0	1.1	20	0.5	0.7	0.8	21	1.5	1.9	2.2
22	-	0.6	0.7	23	-	-	-	24	2.4	3.5	4.1
25	2.9	5.1	5.9	26	2.1	3.1	3.5	27	-	-	-
28	1.6	2.1	2.4	29	1.1	1.2	1.4	30	0.6	0.8	0.9
31	-	-	-	32	0.4	1.3	3.4	33	-	0.8	1.2
34	0.4	0.5	0.7	35	-	-	-	36	3.4	4.8	7.1
37	0.4	0.9	1.1	38	1.0	1.6	3.4	39	1.0	1.6	2.1
40	-	-	-	41	-	0.7	0.7	42	-	-	-
43	5.2	2.7	2.2	44	4.7	2.0	1.4	45	4.2	1.0	-
46	3.3	-	1.1	47	-	1.5	1.7	48	2.5	2.4	3.8
49	-	-	-	50	1.0	4.1	5.7	51	0.1	5.1	6.9
52	-	5.5	7.8	53	-	5.5	8.1	54	-	-	-
55	-	5.2	8.4	56	2.3	1.2	1.4	57	3.3	-	-
58	2.0	3.5	6.1	59	1.5	1.9	2.1	60	1.0	1.3	1.3
61	0.5	0.7	0.8	62	0.5	1.6	2.8	63	0.5	1.6	1.8

Tabela 6.6 Fluxos nas condutas de distribuição

Fluxos nos nós de injeção

Nó de injeção	Fluxo E1 (m <sup>3</sup> /s)	Fluxo E2 (m <sup>3</sup> /s)	Fluxo E3 (m <sup>3</sup> /s)
I1	14.80	20.70	23.70
I2	13.70	10.00	10.70
I3	X	11.40	17.30
I4	8.40	13.40	17.00

Tabela 6.7 Fluxos nos nós de injeção

Custos

Os custos de investimento (INV) para os 3 estágios (valor capitalizado em milhões de escudos) e o custo global são apresentados na tabela seguinte:

Custo Estágio 1	Custo Estágio 2	Custo Estágio 3	Custo total
569.6	346.4	0.0	916

Os índices de qualidade QP para cada um dos estágios:

QP Estágio 1	QP Estágio 2	QP Estágio 3	QP total
125.37	56.04	173.72	355.13

Portanto, o custo total do plano de expansão do sistema de distribuição de gás, capitalizado a custos do primeiro estágio de expansão, é de  $C=916$  M\$, sendo o índice de qualidade de quedas de pressão (QP) igual a 355.1.

O valor de  $f(x)$  para esta solução:

$$f(x) = M - INV + c.QP = 916 + 0.01 \times 355.1 = M - 919.5$$

O valor da função de adaptação para a solução final toma então o valor de (para  $M=3000$ ):

$$FA = 3000 - 919.5 = 2080.5$$

6.6 Análise dos resultados

O resultado de um processo genético consistiu de um plano de expansão claro e equilibrado, onde as quedas de pressão e caudais nas condutas se mantêm dentro de níveis razoáveis. Este tinha sido definido como o principal objectivo do planeamento da expansão do sistema de distribuição de gás. Esta solução constituiria, portanto, um conjunto de decisões interessante, a considerar no planeamento.

Pode-se ainda salientar alguns pontos interessantes nesta solução:

- No terceiro estágio não são feitos investimentos, pois o sistema construído nos estágios anteriores permite satisfazer os consumos.

- A conduta entre os nós 38 e 39 foi utilizada no 1º estágio, sendo desclassificada no segundo e reclassificada no último estágio. Neste estágio, no sentido de se manter a radialidade da solução, a conduta 38-44 foi retirada da rede.

- O nó 36 não tem consumo até ao terceiro estágio. No entanto, foram construídas condutas passando por este nó no 2º estágio de modo a ligar o nó de injeção I3 ao nó 35. Outros nós nestas condições são os nós 27, 42 e 43 nos primeiro e segundo estágios.

### Tempos de corrida

O tempo médio de CPU gasto por um processo genético (para os dados genéticos indicados anteriormente) é aproximadamente  $t_m = 210$  s.

### Evolução do processo genético

A figura 6.8 apresenta a evolução da melhor solução (de sempre) para o processo genético referido nos pontos anteriores. Neste caso o número de gerações utilizado foi  $g=360$ . Na figura pode-se observar que, a partir da 20ª geração, a melhor solução entrou na zona da viabilidade topológica e que, aproximadamente, a partir da 40ª geração as soluções entraram na zona das soluções viáveis em termos de pressões nos nós.

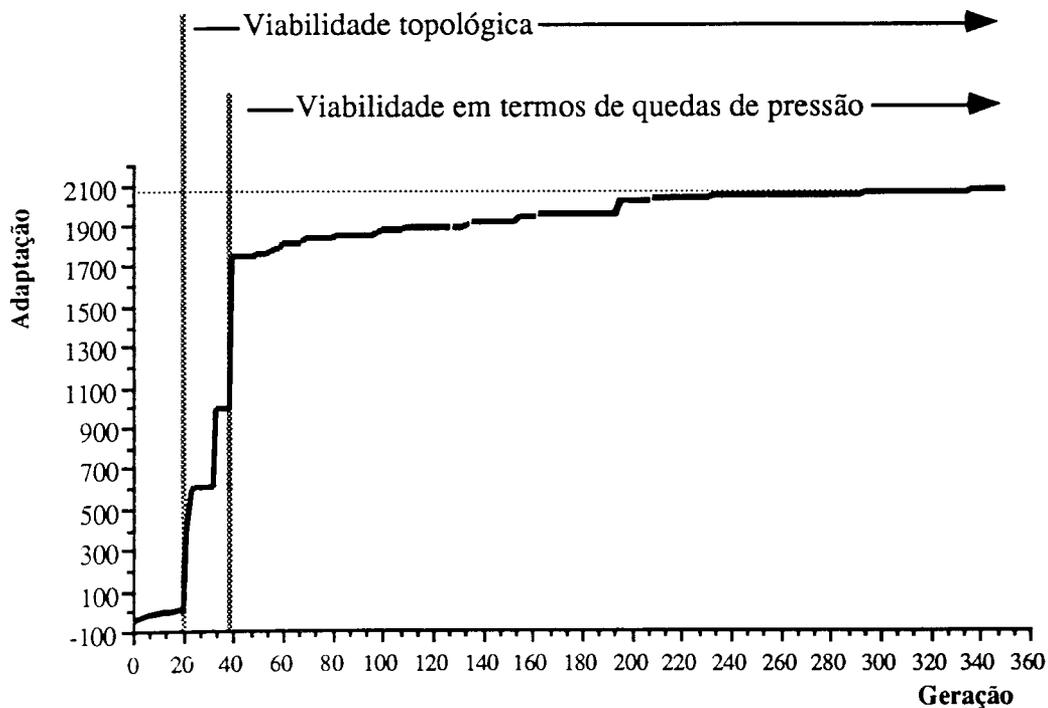


Fig 6.8 Evolução do processo genético

## 6.7 Análise multiobjectivo

A solução apresentada nos pontos anteriores corresponde à melhor solução encontrada no decorrer de um único processo genético para um único valor do parâmetro  $c$  (peso do índice QP).

Neste ponto, pretende-se obter um conjunto de soluções eficientes através da variação daquele parâmetro dentro do intervalo:

$$c \in [0.0; 0.1]$$

É preciso notar que, como foi referido num ponto anterior, não se pode garantir que este conjunto de soluções percorra toda a fronteira não dominada das soluções.

Mas, apesar de tudo, os resultados obtidos foram, de certa maneira, surpreendentes pelo facto de terem sido encontradas apenas duas soluções não dominadas. Isto deveu-se a, por um lado, as condições impostas ao sistema serem muito restritivas e, por outro lado, se ter encontrado uma solução a que corresponde um valor do índice de qualidade nas pressões QP muito baixo. Como o seu custo de investimento é igualmente muito bom, esta solução domina todas as outras soluções encontradas excepto a solução apresentada acima, que possui um custo de investimento inferior.

As duas soluções eficientes encontradas foram:

Solução	Investimento	QP
Sol1	916.0 M\$	355.5
Sol2	922.0 M\$	77.8

O facto de apenas terem sido encontradas duas soluções eficientes facilitaria, neste caso, o trabalho do planeador/agente de decisão. A escolha final de uma solução dependeria apenas do valor que estaríamos dispostos a pagar por uma melhoria no índice de qualidade nas pressões. Posto noutros termos: estará a companhia disposta a investir mais 6 milhões de escudos no sentido de obter uma melhoria no índice de qualidade

$$\Delta QP = 277.7 ?$$

Se a resposta for positiva o planeador deveria optar pela solução Sol2 e, em caso contrário, pela solução Sol1 (apresentada nos pontos anteriores).

Se, noutro sistema, surgissem um número mais elevado de soluções eficientes, uma análise semelhante pode ser feita e, obviamente, a solução escolhida depende do valor de *trade-off* investimento/qualidade determinado pelo planeador.

## 6.7 Conclusões

Nos capítulos anteriores foi demonstrado que uma metodologia baseada numa abordagem genética constitui uma ferramenta muito útil no auxílio ao planeamento de redes de distribuição de energia eléctrica. Este facto constituiu a motivação principal para o estudo apresentado neste capítulo, onde se refere uma aplicação desta metodologia ao planeamento da expansão de redes de distribuição de gás.

A principal vantagem da aplicação desta abordagem a este problema é, provavelmente, a capacidade de lidar com muita facilidade com as características discretas e claramente não-lineares das redes de distribuição de gás (em particular, a relação entre a pressão nos nós e o caudal nas condutas.) Essa capacidade foi concretizada nos excelentes resultados obtidos, mostrando que esta metodologia é claramente superior às metodologias tradicionais de optimização. O modelo apresenta ao planeador, como resultado final, um conjunto de decisões de investimento claro e ordenado, permitindo-lhe, ao mesmo tempo, ganhar algum

conhecimento sobre as características do seu problema através de análises de *trade-off* qualidade/investimento.

Por outro lado, este estudo constitui um avanço significativo no planeamento de redes de gás ao abrir perspectivas interessantes para a evolução do modelo no sentido da criação de um sistema integrado, onde outras opções de modelização (especialmente relacionadas com a qualidade de serviço) e vários outros aspectos importantes do planeamento seriam contemplados. Entre esses aspectos podem-se destacar:

- Análise de incertezas nos consumos;
- Impacto ambiental;
- Fiabilidade do sistema;
- Segurança;
- Interactividade com o planeador.

Existe, portanto, um forte empenho em prosseguir esta investigação no sentido do desenvolvimento de metodologias ainda mais eficientes baseadas nas possibilidades abertas por este estudo.

## Capítulo 7

### Conclusões e perspectivas de evolução do modelo

Nesta dissertação foram apresentados os resultados de um trabalho destinado a desenvolver métodos computacionais, baseados em algoritmos genéticos, para a resolução do problema do planeamento da expansão de sistemas de distribuição de energia eléctrica. Foi, assim, desenvolvido um algoritmo baseado nesta nova abordagem. No sentido de demonstrar a flexibilidade deste algoritmo, apresentou-se também uma aplicação ao planeamento de redes de gás.

Os resultados obtidos demonstram claramente que a abordagem genética ao problema do planeamento é viável, apresentando diversas vantagens em relação às técnicas tradicionais.

De facto, nenhum dos modelos de planeamento baseados em técnicas convencionais de programação matemática constitui um sucesso definitivo na resolução do DPP. Apesar de os algoritmos existentes serem consideravelmente eficientes, a dimensão do problema ainda limita a optimização de redes de tamanho real num tempo de computação comportável, especialmente quando todas as opções de modelização estão representadas. No sentido de ultrapassar este problema, o número de opções de modelização é usualmente restringido para permitir a utilização de métodos de optimização eficientes. Nestas condições são ignoradas diversas opções consideradas essenciais pelos engenheiros de planeamento como por exemplo:

- Optimização dinâmica.
- Inclusão de restrições de radialidade.
- Análise multiobjectivo.

Ficou demonstrado neste trabalho que, utilizando uma abordagem genética, não se torna necessário restringir as opções de modelização, pois a avaliação das soluções é sempre feita *a posteriori*, não sendo necessário funções objectivo 'bem comportadas'. De facto, o modelo apresentado permite a representação de não-linearidades, difíceis de incluir em métodos convencionais de programação matemática. Estas não linearidades derivam do carácter não linear das funções objectivo e restrições do problema e da natureza discreta de diversos aspectos do DPP. Nalguns casos estas características do problema podem-nos conduzir a domínios não convexos e, mesmo, não contínuos. Os AG têm precisamente a capacidade de trabalhar em ambientes 'difíceis', podendo detectar facilmente mínimos locais ou mesmo 'ilhas de soluções'.

Mais ainda, os AG permitem a obtenção de um conjunto de soluções (em vez de uma solução única), permitindo ao planeador executar um conjunto de valiosos exercícios de comparação e de análises de *trade-off*. Isto permitir-lhe-á ganhar um conhecimento mais profundo sobre o problema, ajudando-o a tomar decisões de uma forma mais esclarecida.

Por fim, provou-se que os AG apresentam um potencial enorme no sentido da aplicação de métodos de ajuda à decisão multicritério ao DPP. Este é, sem dúvida, um dos passos mais importantes no sentido de um melhor planeamento da distribuição.

As perspectivas abertas por esta nova abordagem constituem a motivação principal para a continuação da investigação neste campo. O estudo apresentado nesta dissertação constitui uma base para uma investigação futura, investigação essa que será dirigida de acordo com os seguintes vectores fundamentais:

a) Utilização de sistemas de processamento massivamente paralelo.

Os AG, devido às suas características específicas, são altamente paralelizáveis. Cada indivíduo (ou solução potencial para o problema) pode ser avaliado separadamente e em paralelo. Assim, o tempo de computação diminuirá drasticamente, permitindo a utilização de populações maiores e de funções de adaptação mais elaboradas. Como consequência, poderemos planear redes cada vez maiores em horizontes de planeamento mais alargados. Será também possível incluir no problema mais opções de modelização (por exemplo, análise do impacto ambiental). Por fim, será possível analisar diversos cenários em paralelo, avaliando as soluções de acordo com os índices de robustez e exposição.

b) Análise multicritério

As características multiobjectivo do DPP já foram, por várias vezes, salientadas ao longo desta dissertação. A investigação futura procurará explorar todas as vertentes deste problema complexo, no sentido de encontrar as metodologias mais adequadas na ajuda à decisão ao planeador dos sistemas. O objectivo é proporcionar ao agente de decisão/planeador a possibilidade de tomar as decisões adequadas, na posse dum conjunto de informação o mais abrangente possível. Nesta linha de ideias, será importante desenvolver algoritmos que permitam obter um determinado número de soluções interessantes, representantes de todo o espaço de decisão não dominado. É precisamente neste estágio que se desenrola o estudo presente.

c) Introdução de factores ligados à incerteza

Num modelo global de planeamento da distribuição, não será possível ignorar factores ligados à incerteza. Uma das vertentes fundamentais da investigação futura passará necessariamente pelo estudo de factores de risco, exposição e robustez dos planos de expansão.

d) Aplicação a outros problemas de planeamento e operação.

Neste estudo ficou demonstrada a flexibilidade dos modelos e algoritmos apresentados. Existe, assim, um forte empenho em estudar a viabilidade da aplicação destes modelos a outros problemas de planeamento e operação, nomeadamente:

- Problema do planeamento da operação de sistemas hidrotérmicos.
- Problema da expansão de sistemas de transporte de energia.

e) Investigação sobre outros tipos de algoritmos genéticos.

Como foi referido num dos capítulos da dissertação, existe um número elevado de técnicas e estratégias diferentes no campo dos algoritmos genéticos. Um dos pontos fundamentais dos estudos a desenvolver no futuro será, naturalmente, a comparação destas estratégias, no sentido de encontrar a mais adequada à resolução dos problemas em estudo e, em particular, do DPP.

f) Validação dos resultados

Devido às características inovadoras do modelo desenvolvido, nomeadamente a introdução de opções de modelização inéditas, tornou-se impossível estabelecer qualquer tipo de comparações com metodologias tradicionais de optimização. De facto, todas as tentativas de procurar resolver o DPP (formulado de forma equivalente à apresentada nesta dissertação) usando, por exemplo, sistemas *standard* de programação matemática

revelaram-se infrutíferas devido ao incomportável tempo de cálculo. No entanto e apesar das dificuldades, continua-se a procurar estabelecer termos de comparação entre os dois tipos de metodologias no sentido de uma validação mais aprofundada dos resultados obtidos nesta dissertação.

Por fim e para concluir, refira-se que a meta do estudo desenvolvido é o desenvolvimento de um sistema global integrado para o planeamento de sistemas de energia (em particular de distribuição) onde metodologias baseadas em algoritmos genéticos terão, necessariamente, um lugar de destaque.

# ANEXO A

---

**Genetic algorithms in optimal multistage distribution network  
planning.**

# GENETIC ALGORITHMS IN OPTIMAL MULTISTAGE DISTRIBUTION NETWORK PLANNING

Vladimiro Miranda      J. V. Ranito      L. M. Proença  
INESC - Inst. de Engenharia de Sistemas e Computadores  
and FEUP/DEEC - Faculdade de Engenharia da Univ. do Porto  
L. Mompilher - 4000 Porto - PORTUGAL  
Fax: 351.2.318692    ean: vmiranda@porto.inescn.pt

**Abstract** - This paper describes a genetic algorithm approach to the optimal multistage planning of distribution networks. The authors describe a mathematical and algorithmic model that they have developed and experimented with success. The paper also presents application examples, with real size systems. The advantage of adopting this new approach are discussed in the planning context, namely in conjunction with the adoption of multicriteria decision making methods.

## INTRODUCTION

For optimal distribution network planning, many mathematical models have been proposed in the past - for instance, see refs [1 - 9]. Many of them [1, 2, 4, 5, 7] are static models, giving an optimal solution for a fixed set of data and a single time period. Essays in dynamic planning, considering the evolution in power demand through time and consequent topological changes in the networks (new branches, new substations, reinforcements, etc.) have never been a definite success, when applied to real sized networks. The mathematical models behind those proposals either were heavy or neglected several project features that engineers take as important on distribution system design; for example, economies gained from cables in the same trench, reuse of disclassified lines, reshaping the whole network by introducing a new substation, etc.

Furthermore, the vast majority of the model proposals, on the last 15 years, was aimed at a so called "Optimal solution". However, during the last few years the objective of reaching this optimal concept has been challenged more and more, namely within the U.S., with the acceptance of principles of the "least cost planning" approach .

This evolution favours the option for multi-criteria methods and for algorithms giving, as an answer, a large set of possibly good solutions, instead of a single optimum.

Genetic algorithms share precisely this property, and therefore an investigation has been made on their behavior in the distribution network design or distribution planning problem (DPP). This research has been directed into answering the following questions :

- Can genetic algorithms adequately model the DPP problem?
- Is it possible to develop efficient computing algorithms for real size networks?
- Has the genetic approach an easy interface with multicriteria decision making procedures ?
- Do genetic algorithms show any advantages over previous proposed approaches ?

As the following sections report, the answer is positive to all these four questions. In fact, differently from many models previously proposed, this new model is flexible enough so that many realistic features and conditions of practical nature may be taken care of. For instance:

- the inclusion of multiple feeders in the same trench, with the related savings achieved;
- the possibility of disclassifying lines at some stage, and of re-using them at a later stage;
- the possibility of generating solutions with some open loops, which may be valuable from a reliability point of view;
- considering multi-objectives;
- dealing naturally with load diversity factors;
- no need to specify, in advance, at which year should a substation be built or put into service.

## REVIEW OF GENETIC ALGORITHMS

Genetic Algorithms (GA) are search and optimization methods based on natural evolution [Golberg89]. They consist on a *population of bit strings* transformed by three genetic operators: selection, crossover and mutation. Each string (chromosome) represents a possible solution for the problem being optimized and each bit (or group of bits), represents a value for some variable of the problem (gene). These solutions are classified by a *evaluation* function, giving better values, or *fitness*, to better solutions.

Although there are many forms [Grefestette91] for Genetic Algorithms, we will only refer to the *canonical* algorithm. This means that we will be dealing with three genetic operators (selection, crossover and mutation) and linear, binary, fixed-size chromosomes. Canonical GA use a fixed-size, non-overlapping population scheme and each new generation is created by the selection operator and altered by crossover and mutation. The first population is generated at random .

### Genetic Algorithm components

Each chromosome represents a potential solution for the problem to solve and must be expressed in binary form. For instance, if we want to maximize the function  $f(x)=x^2$ , in the integer interval  $I=[0,31]$ , we could simply code  $x$  in

binary base, using 5 bits. Each solution must be evaluated by the fitness function to produce a value. In our example, the chromosome 11011 would receive the fitness value  $27^2=729$ , while the chromosome 00111 would receive the value  $7^2=49$ . The pair (chromosome, fitness) represents an *individual*.

The *selection* operator creates a new population (or *generation*) by selecting individuals from the old population, biased towards the best. This means that there will be more copies of the best individuals, although there may be some copies of the worst. This operator can be implemented in a variety of ways, although we use here a technique known as Stochastic Tournament [Goldberg91]. This implementation is suited to a future distributed implementation and is very simple: every time we want to select an individual for reproduction, we choose two, at random, and the best wins with some fixed probability, typically 0.8. This scheme can be enhanced by using more individuals on the competition [Goldberg91c] or even by considering evolving winning probability, eventually leading to *Boltzman Tournament* [Goldberg91], generalizing the *Simulated Annealing* paradigm [Kirkpatrick83].

*Crossover* is the main genetic operator and consists in swapping chromosome parts between individuals. The simplest crossover operator is implemented by selecting a random crossover point in the chromosome, and swapping the genes that reside between the crossover point and the end of the chromosome. For example, if we have two individuals:

A=010100 ; B=010111

and choose a crossover point C=3 (indicated by '|') the resulting individuals after crossover would be:

A'=010111 ; B'=010100

Crossover is not performed on every pair of individuals, its frequency being controlled by a crossover *probability*. This probability should have a large value, typically  $P_c=0.8$ .

The last genetic operator is *mutation* and consists in toggling a random bit in an individual. This operator should be used with some care, with low probability, typically  $P_m=0.001$ , for normal populations.

#### How does a Genetic Algorithm work?

A canonical GA is a very simple process: we first generate a random initial population, evaluate it and start creating new populations by applying genetic operators. This high-level behavior can be depicted on the following piece of pseudo-C:

```
main()
{
    int gen;

    generate(oldpop);
    for(gen = 0; gen < MAXGEN; gen++)
    {
        evaluate(oldpop);
        newpop = select(oldpop);
        crossover(newpop);
        mutation(oldpop);
        oldpop = newpop;
    }
}
```

Obviously, there is the need for some bookkeeping functions, for statistics and so on, but they are not central to this explanation.

This very simple behavior hides a powerful processing, done by the GA. In fact, the combination of selection and crossover leads to a proliferation of individuals that possess small, tightly coupled *blocks* of bits leading to good performance. These blocks, usually called *schemata* [Holland75], are replicated through selection and combined or separated by crossover.

And mutation, what is its job? Mutation works as a kind of "life insurance". Some important bit values (genes) may be lost during selection; mutation can bring them back, if necessary. Nevertheless, too much mutation can be harmful: a mutation probability of 0.5 always leads to random search [Goldberg89], independently of crossover probability.

So, GA tends to select individuals with good performance and recombine some of their building blocks, creating more and more copies of good schemata, simply by the use of selection and crossover. This hidden processing is called *implicit parallelism* because the number of schemata processed in each generation is typically  $O(N^3)$ , being  $N$  the population size [Holland75]. This compares very well with the number of fitness function evaluations,  $N$ . This characteristic is distinctive of Genetic Algorithms [Grefenstette91].

#### Genetic algorithms in Power Systems

There have been some attempts to apply Genetic Algorithms to solve problems in the Power System area, but so far, to our knowledge, not in multi-stage distribution planning. In references [16] to [22] one may find the reports of attempted approaches to problems such as:

- clustering and network reduction [16];
- optimal capacitor placement [17];
- voltage optimization [18];
- harmonics [19];
- system observability [20];
- reactive power control [21];
- load flow analysis [22];

### DISTRIBUTION PLANNING MODEL

This section presents a model to solve the problems of the optimal sizing, timing and location of distribution substation and feeder expansion, using genetic algorithms. The model allows the inclusion of constraints related to network radiality, voltage drops and reliability assessment.

The objectives for distribution system planning that will be discussed are related to providing the designs and associated implementation plans necessary for an orderly expansion of facilities, minimizing new facility installation costs and operation costs, as well as achieving an acceptable level of reliability, under the following constraints :

- a) Operation of the networks under radial configuration (although some open loops may exist);

- b) Voltage drop constraints;
- c) Power demand specifications;
- d) Power flow availability, namely constrained by line thermal limits;
- e) Possible site location for substation and lines pre-specified.

Facility installation costs will be divided in three elements : substation cost, substation capacity expansion cost and new feeder cost. Power losses in the network will be taken as operation costs. Already existing elements (substations or feeders) are included at no investment cost in the model; however, their power losses are taken in account.

The following assumptions are made:

a) A peak load is considered for each stage expansion planning (load forecasting is out of the scope of this paper). Some extra information about load curves (such as load factor) is required, in order to evaluate losses and assess reliability indices such as average load disconnected or average annual energy not supplied.

b) New installation facility candidates are known beforehand, and their location and installation costs estimated.

An expansion strategy will be driven by load growth. The planning period will be divided into several stages (one year, for instance). One aims at having, as a result, a list of investments to be made at each stage.

The genetic algorithm approach to the DPP is drawn under the following general lines:

1. A set of variables is chosen to represent a multi-stage network solution; these variables are encoded in a chromosome.
2. A genetic algorithm is applied to a family of solutions, giving birth to new generations.
3. Each solution in the new generation is evaluated through a fitness function, that includes investment costs, power loss costs, reliability, voltage drop deviations; non compliance with other constraints is dealt with by the fitness function - an unfeasible solution, with a low fitness value, will hardly survive.
4. At the end of the process, a family of well fitted plans is available.

#### Variables:

For a m-stage planning problem, the following (0-1) integer decision variables could be defined:

$$F_{is} : \begin{cases} F_{is} = 1 & \text{: if feeder } i \text{ is used at stage } s \\ F_{is} = 0 & \text{: otherwise} \end{cases}$$

$$S_{is} : \begin{cases} S_{is} = 1 & \text{: if substation } i \text{ is used at stage } s \\ S_{is} = 0 & \text{: otherwise} \end{cases}$$

$$E_{is} : \begin{cases} E_{is} = 1 & \text{: if subst. expansion } i \text{ is used at stage } s \\ E_{is} = 0 & \text{: otherwise} \end{cases}$$

Existing facilities may be considered by fixing their respective values to 1.

#### Chromosome coding

The direct coding of the above variables into a chromosome has been tried and tested. Although the results obtained were satisfactory, the process was not very efficient, because the extremely large number of unfeasible solutions appearing at each generation led to a large computing time before reaching an acceptable stability.

Therefore, we devised a new coding process. Its requirements were: it should lead to a minimum amount of unfeasible solutions generated; and it should provide very fast decoding, as this operation is required at every fitness evaluation. Its characteristics are:

- a) at one time stage, some nodes may be assigned with load values, while other may have a forecasted zero load;
- b) a node with a positive load must be connected to, at least, one feeder, while nodes with zero load may either have no connections or have one or more connections in order to allow power flow to other nodes;
- c) each node is represented in the chromosome by a number of bits needed to encode the number of possible connections to it - e.g., if four lines connect to the node, one needs two bits, if it is a positive load node, or a three bit string, if it is a zero load node (to include the case where no line goes through that node);
- d) a substation is assumed as a special type of line, that may be connected to the nodes chosen as possible building sites;

This encoding strategy is such that it gives, as a result, only solutions with a number of lines=(nodes-1), a radially condition. A few other details were included in the model, which are not relevant to its understanding but helped in gaining computer efficiency.

#### Fitness Function

The fitness function must reflect both the desired and the unwanted properties of a solution, rewarding the former and strongly penalizing the latter. In the DPP, desired properties are, for instance, low cost and high reliability, while unwanted features are non-radial configurations (open loops are accepted, but not closed loops), violations of thermal cable limits or of voltage drop constraints.

Fitness is evaluated *a posteriori*; therefore it may be non-linear, non-continuous, non-convex, whatever. This is very advantageous over strict mathematical programming approaches.

The general trend is to maximize fitness. Figure 1 presents the general scheme of evaluation of the fitness of a solution, represented by a chromosome, at any generation. The functions  $g()$ ,  $h()$  and  $v()$ , referred to in this figure, must be chosen so that, for no matter what solutions  $x$  are evaluated, one always obtains

$$g(x_i) < h(x_j) < v(x_k) < f(x_m), \quad \forall x_{i,j,k,m}$$

In function  $f$ , we have included the following:

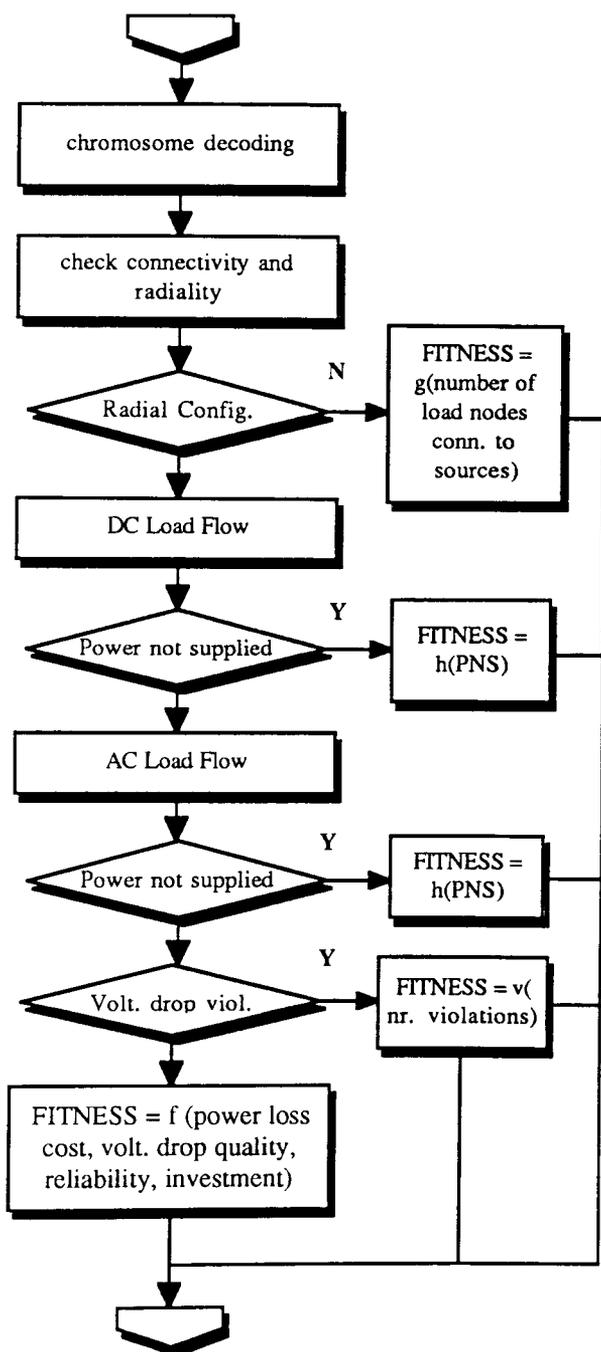


Fig.1 - Fitness function evaluation scheme

- investment costs IC are added for all the planning stages, considering a fixed discount rate;
- power loss costs PL are treated in the same way;
- voltage quality VQ may be assessed in many ways - we have used the following scheme:
  - 1) if the voltage drop at any node exceeds some threshold (e.g., 8%), the solution has been taken as unfeasible and its fitness evaluated by function v;
  - 2) else, if the voltage drops at some nodes lie within a given interval (e.g., [5%,8%]), the voltage quality index of the solution is assessed by the sum of the square deviations to the lower limit of this interval;

3) else, if at all nodes the voltage drop stays below that lower limit, the voltage quality index receives 0 value.

- the reliability RB of a solution is evaluated through the approximate calculation of the expected annual energy not supplied - this calculation takes in account the existence of open loops in the network; we have used the following scheme:

1) an upper bound  $U_r$  in reliability level is calculated assuming that no switching devices are included in the network - therefore, disconnections take place only at the substation;

2) a lower bound  $L_r$  is calculated assuming that all branches are equipped with switching devices, allowing the isolation of failed branches and service restoration (taking in account the line capacities);

3) reliability fitness is given by

$$RB = \alpha U_r + (1 - \alpha) L_r$$

where  $\alpha \in [0,1]$  is an "improvement coefficient" that aims at simulating the effect of a compromise solution in switching device location policy - as this, in itself, is a very complex problem [23].

The fitness value  $f$  of a solution  $x$  is given by

$$f(x) = M - c_1(IC+PL) - c_2VQ - c_3RB$$

where  $M$  - Large (enough) constant value;  
 $c_i$  - constants externally fixed.

#### Other special features

a) the DC load flow calculations are used as a first filter for unfeasibilities, and are performed at the same time as the structure of the network is recognized - this strategy proved very efficient;

b) for AC load flow calculations, we used the method described in [24], applied to balanced systems, as it was specially developed for radial networks;

c) before load flow calculations, loads values to be used may be affected by coefficients to take in account the diversity in demand load curves - this feature also distinguishes this GA approach from other models.

### APPLICATION EXAMPLE

#### Data

The GA approach was applied to the system shown in Fig. 2, where solid lines represent existing cables in the initial radial system, and dotted lines represent possible sites for the expansion of the system. A complete data listing may be obtained from the authors, by request. The proposed substation sizes and other complementary system data are shown below

Number of time stages	3 (+ initial)
Discount Rate	10%
Nominal voltage	15 kV
Voltage thresholds	5%, 8%
No. of nodes	3 x 50
No. of branches - total	3 x 64
No. of potential branches	3 x 48
Total load for each time stg. (MVA)	45; 63; 79.5
Feeder cost (PTE)	$4 \cdot 10^6/\text{km}$

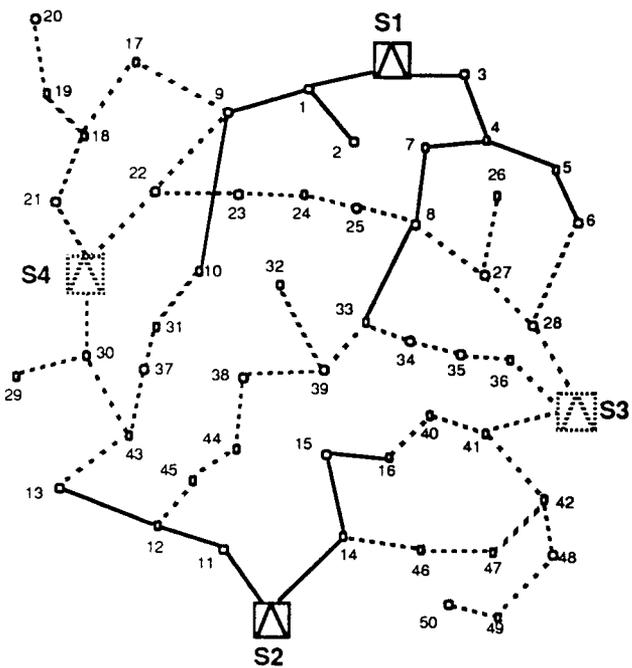


Fig. 2 Initial system

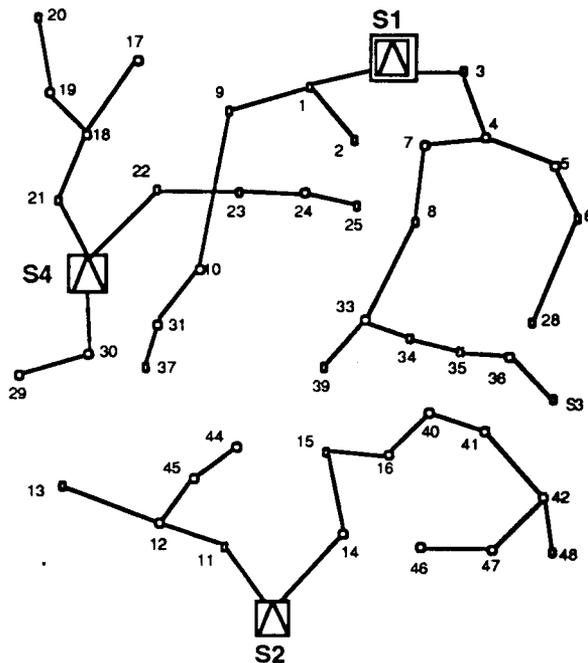


Fig. 3. Solution for Stage 1

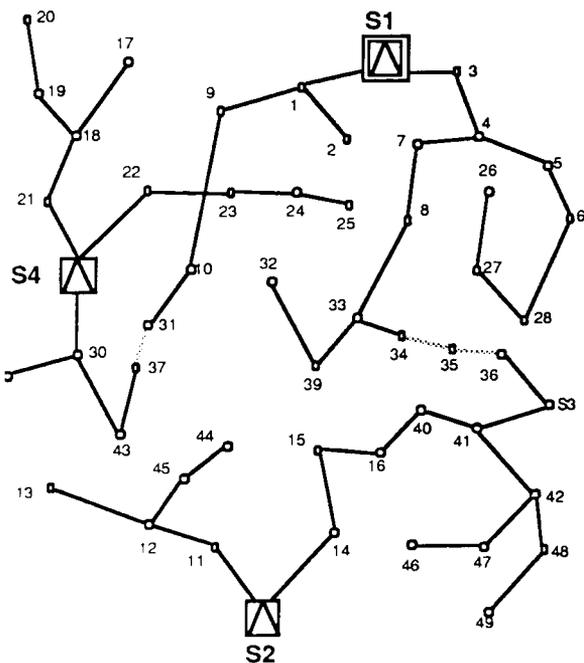


Fig. 4 Solution for Stage 2

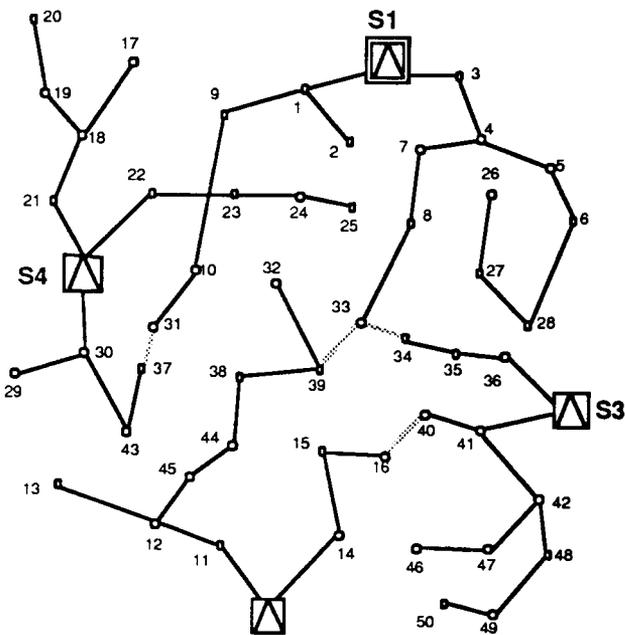


Fig. 5  
Solution for Stage 3

Substations	S1	S2	S3	S4
Initial cap (MVA)	16.7	16.7		
Poss. expansion (MVA)	16.7	13.3		
-> cost in stage 1 (PTE*10 <sup>6</sup> )	100	80		
Planned (MVA)			22.2	22.2
-> cost in stage 1 (PTE*10 <sup>6</sup> )			200	240

Run data - Several runs were made. The results presented were obtained for a population of 40, and for 300 generations (a value for which a robust stability in the "best-so-far" solution has been consistently observed). On average, user run times have been of around 300 sec., in a NeXTStation (33 MHz), but we are now aware that these times may still be largely improved by carefully revising the computer code.

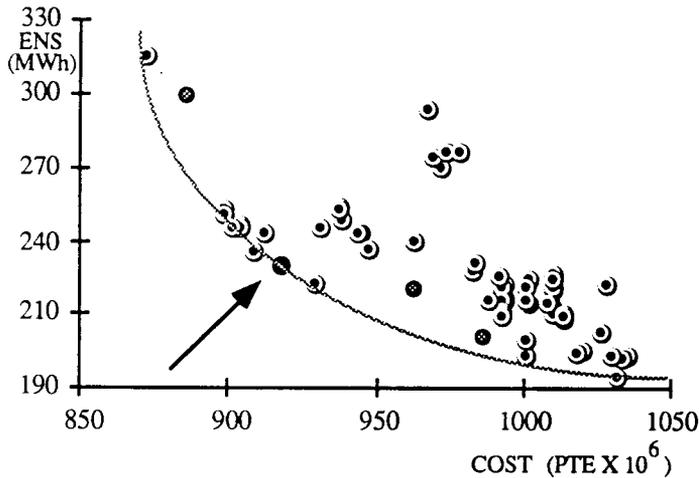


Fig. 6 - Plot of a family of solutions in a bi-attribute space (investment vs. reliability).

## Results

In figures 3-4-5, a substation symbol within a square means that there has been a reinforcement in capacity of that substation; shadowed lines represent feeders already installed that are not used in a given stage, remaining, however, as open loops. See, for instance, branches 33-34-35-36, built in stage 1; in stage 2, 34-35-36 are unused, but in stage 3 they are put in active service while 33-34 is now open. Notice that node 35 has no forecasted load until stage 3; nevertheless, a solution was built through it in order to reach node S3, right in stage 1, which had a positive load value attached. Notice also the rearrangement in the network when a new substation gets in.

Figure 6 presents a family of solutions, obtained at the end of the evolution process, in a bi-attribute space (investment, in Portuguese Escudos, vs. reliability, in average annual energy not supplied, both to be minimized). We have drawn a curve representing a convex approximation to the non-dominated border; the black dot, pointed by the arrow, stands for the solution depicted in figs. 2-5, and the three shadowed dots represent some special non-dominated solutions: they would not be found by classical mathematical programming methods such as the weighted addition of the functions representing the objectives - nevertheless, they may be thought of as good compromises, by the planner.

One may clearly see how few the non-dominated solutions (also called Pareto optimal) are in this example which, in principle, are the interesting solutions to look at. This clearly indicates that the combination of genetic algorithms followed by multi-criteria screening is likely to be a powerful tool in decision aid for network planning. We believe that there is field here for further research.

## CONCLUSIONS

The research reported in this paper clearly demonstrates that a GA approach to a dynamic multi-stage planning problem is both feasible and advantageous.

It provides the planner with a set of time-ordered investment decisions which is not obtained from static sub-optimizations, but directly from the consideration of the time dimension of the problem. In this respect, it is more complete than many published approaches which claim feasibility under constrained computing environments.

Furthermore, it allows the representation of non-linearities which are hard to include in pure mathematical programming methods; in fact, the existence of non-linearities enhances the advantages of using GA against pure mathematical programming. These non-linearities arise not only from the non-linear character of objective functions and constraints but also from the discrete nature of many aspects of the distribution planning problem. These in some cases could lead to a non-convex domain, perhaps in some cases not even connex - but GA are able to deal with such environments and can detect local minima or even "islands" of solutions.

The results of a GA are a generation of solutions, filtered through the struggle for survival. Therefore, many interesting and valuable exercises on comparisons and trade offs may be executed, helping the planner to gain insight on the problem he is faced with and allowing field for better decisions to be taken.

The fact that many solutions will be available also enhances the opportunity for multicriteria methods to be explicitly applied, which is, in our point of view, a step towards an adequate direction in distribution planning.

## REFERENCES

- [1] Y. Baklund, J.A. Bubenko, "Computer-aided distribution system planning", *Electrical Power & Energy Systems*, vol.1, no.1, Apr 1979
- [2] M.F. Oliveira, V. Miranda, "Etudes d'optimisation dans les réseaux de distribution comprenant des calculs de fiabilité", *Proceedings of CIRED'79*, s.6, Liège, Belgium, Apr 1979
- [3] R.N. Adams et al., "A methodology for distribution system planning", *Proceedings of the 8th PSCC*, Helsinki, Finland, Aug. 1984
- [4] M.A el-Kady. "Computer aided planning of distribution substation and primary feeders", *IEEE Transactions on PAS*, vol. 103, Jun 1984
- [5] T. Burkhardt et al., "Decision making including forecast uncertainties and optimal routing in distribution networks", *Proceedings of CIRED'85*, s.6, Brighton, U.K., Apr 1985
- [6] T. Gönen, I.J. Ramirez-Rosado, "Review of distribution planning models: a model for optimal multistage planning", *IEEE Proceedings*, Vol. 133, Pt. C, No. 7, Nov 1986

## Bibliografia

- [Ada73] R.N. Adams, M.A. Laughton, "A dynamic programming network flow procedure for distribution system planning", Proc. of the 8th PICA Conference, Minneapolis, MN, USA, June 1973
- [Ada74] R.N. Adams, M.A. Laughton, "Optimal planning of power networks using mixed-integer programming Pt. 1 - static and time-phased network synthesis", Proc IEEE 1974, 121, (2)
- [Ada84] R.N. Adams, A. Afuso, A Rodriguez, V. Gerez, "A methodology for distribution system planning", Proceedings of the 8th PSCC, Helsinki, Finland, Aug. 1984
- [Afu82] A. Afuso, V. Gerez, "An integrated system for distribution planning", Proceedings of the 4th IEEE International Symposium on Large Engineering Systems Calgary, Alberta, Canada, Jun. 1982.
- [Ajj91] V. Ajjarapu, Z. Albanna., "Application of genetic based algorithms to optimal capacitor placement", Proc. First International Forum on Applications of Neural Networks to Power Systems, New York, NY, USA, IEEE 1991
- [Aok90] K.Aoki, K. Nara, T. Satoh, M. Kitagawa, K. Yamanaka, "New approximate optimization method for distribution system planning", *IEEE Transactions on PWRS*, vol 5, no.1, Feb. 1990
- [Bac79] Y. Baklund, J.A. Bubenko, "Computer-aided distribution system planning", *Electrical Power & Energy Systems*, vol.1, no.1, Apr. 1979
- [Bac91] T. Bäck, F. Hoffmeister, H.-P. Schwefel, "A survey of evolution strategies", Proc. of the 4th International conference on Genetic Algorithms, 1991
- [Bak85] J. E. Baker, "Adaptative selection methods for genetic algorithms", Proc. 1st Int. Conference on Genetic Algorithms, 1985
- [Bur85] T. Burkhardt, H.-J. Koglin, K. Werth, "Decision making including forecast uncertainties and optimal routing in distribution networks", Proceedings of CIRED'85, s.6, Brighton, U.K., Apr. 1985
- [Din92] H. Ding, A. A. El-Keib, R. Smith, "Optimal clustering of power networks using genetic algorithms", Proc. 3rd Biennial Symp. Indust. Elect. Applications, Ruston, LA, USA, LA Tech. Univ., 1992
- [Faw83] T.H. Fawzi, K. F. Ali, S. M. El-Sobki, "A new planning model for distribution systems", *IEEE Trans*, 1983, PAS-102, (9)
- [Fle93] Peter J. Fleming, C. M. Fonseca, "Genetic algorithms in control systems engineering", 1993
- [Fon93] C. M. Fonseca, Peter J. Fleming, "Genetic algorithms for Multiobjective Optimization : Formulation, Discussion and Generalization", Proc. of the 5th International conference on Genetic Algorithms, San Mateo, CA, USA, 1993

- [Gol89] D. E. Goldberg, "Genetic algorithms in Search, Optimization and Machine Learning", 1989, Addison-Wesley
- [Gol91a] D. E Goldberg, "A Note on Boltzman Tournament Selection for Genetic Algorithms and Population-Oriented Simulated Annealing", 1991, Complex Systems 3
- [Gol91b] D. E Goldberg, K. Deb, "A Comparative Analysis of Selection Schemes Used in Genetic Algorithms", Genetic Algorithms in Search, Optimization and Machine Learning Summer School, 1991, Stanford
- [Gon81] T. Gönen, B.L. Foote, "Distribution system planning using mixed-integer programming", IEEE Proc., Gen. Trans. & Distrib, 1981, 128, (2)
- [Gon82] T. Gönen, B.L. Foote, "Mathematical dynamic optimization model for electrical distribution system planning", Electric Power & Energy Systems, 1982, 4, (2)
- [Gon86] T. Gönen, I.J. Ramirez-Rosado, "Review of distribution planning models: a model for optimal multistage planning", IEEE Proceedings, Vol. 133, Pt. C, No. 7, Nov. 1986
- [Gor92] M. Gorges-Schleuter, "Comparison of local mating strategies in massively parallel genetic algorithms", Parallel problem solving from nature, 2, North-Holland, 1992
- [Gre91] J. Grefenstette, "Conditions for Implicit Parallelism", Navy Center for Applied Research in Artificial Intelligence, Internal Report, 1991, Washington
- [Hai91] T. Haida, Y. Akimoto, "Genetic algorithms approach to voltage optimization", Proc. First International Forum on Applications of Neural Networks to Power Systems, New York, NY, USA, IEEE 1991
- [Hin77] K.S. Hindi, A. Brameller, "Design of low-voltage distribution networks", Proc. IEEE, 1977, 124, (1)
- [Hlt76] S. B. Holt, D. M. Crawford " distribution substation planning using optimization methods", IEEE Tutorial Course, 1976
- [Hol75] J. H. Holland, "Adaptation in Natural and Artificial Systems", The University of Michigan Press, 1975, Ann Arbor
- [Iba93] K. Iba, "Reactive Power Optimization by Genetic Algorithm", PICA'93, Phoenix, AR, USA, May 1993
- [Jor85] Jorma Mörski, Jorma Seppälä, "Integrated control and planning of several voltage levels with special reference to electricity supply quality", Proc. of CIRED'85, s.6, Brighton, U.K., Apr. 1985
- [Kad84] M.A el-Kady, "Computer aided planning of distribution substation and primary feeders", *IEEE Transactions on PAS* vol. 103, Jun. 1984
- [Kag90] N. Kagan, R.N. Adams, "Application of Benders decomposition technique to the distribution planning problem", Proceedings of the 10th. PSCC, Graz, Austria, Aug. 1990, ed. Butterworths, London

- [Kag93] N. Kagan, R.N. Adams, "Electrical power distribution systems planning using fuzzy mathematical programming", Proceedings of the 11th. PSCC, Avignon, France, 1993
- [Kir93] S. Kirkpatrick, C. D. Gelatt, M. P. Vecchi, "Optimization by Simulated Annealing" 1983 Science, Vol 220, number 4598
- [Lin92] D. A. Linkens, H. O. Nyongesa, "A real-time genetic algorithm for fuzzy control", IEE Colloq. on Genetic Algorithms for Control System Engineering, 1992
- [Mat88] M. Matos, "Ajuda à decisão multicritério - novas contribuições", Dissertação de doutoramento, FEUP, Porto, 1988
- [Mat92] M. Matos, L. M. Proença, "Método de Amplificações Sucessivas", Investigação Operacional, vol 12., Junho, 1992
- [Mil90] W. T. Miller, R. S. Sutton, P. J. Verbois, "Neural networks for control", MIT Press, Cambridge, 1990
- [Mir83] V. Miranda, F.M. Barbosa, "Three phase load flow for radial networks", Proc. of MELECON'83, rp. D4.07, Athens, Greece, 1983
- [Mir91] V. Miranda, "Using fuzzy reliability indices in a decision aid environment for establishing interconnection and switching location policies", Proc. CIRED'91, s.6, Liège, Belgium, Apr. 1991
- [Mor91] H. Mori, "A genetic approach to power system topological observability", Proc. IEEE International Symp. on Circuits and Systems, New York, NY, USA, IEEE, 1991
- [Nar91] K.Nara, T. Satoh, K. Aoki, M. Kitagawa, "Multi-year expansion planning for distribution systems", IEEE Transactions on PWRs, vol 6, no.3, Aug. 1991
- [Oli79] M.F. Oliveira, V. Miranda, "Etudes d'optimisation dans les réseaux de distribution comprenant des calculs de fiabilité", Proceedings of CIRED'79, s.6, Liège, Belgium, Apr. 1979
- [Osi87] Osidacz, Andrezej J., "Simulation and Analysis of Gas Networks", Gulf Publishing company, 1987
- [Ran93] J. V. Ranito, "Algoritmos genéticos na optimização de perguntas relacionais", Tese de mestrado, Faculdade de Engenharia da Universidade do Porto, Outubro 1993
- [Rod93] S. Rodriguez, A. Paricio, J. R. Velasco, "Learning with fuzzy logic : a way to combine genetic algorithms with fuzzy logic", Proc. of International Fuzzy Systems and Intelligent Control Conference, 1993
- [Spe91] W. M. Spears, "An analysis of multi-point crossover", Foundations of genetic algorithms, G. J. E. Rawlins (Ed.), San Mateo, CA : Morgan Kaufmann

- [Sun82] D. I. Sun, D. R. Farris, P. J. Cote, R. R. Shoults, M. S Chen, "Optimal distribution substation and primary feeder planning via the fixed charge network formulation", IEEE Transactions on PAS-101 (3) 1982
- [Whi91] D. Whitle, T. Starkweather, D. Shaner, "The traveling salesman and sequence scheduling : Quality solutions using genetic edge recombination", Handbook of genetic algorithms, van Nostrand Rheinhold, NY, 1991
- [Yan92] H. Yang, "Worst case analysis of distribution system harmonics using genetic algorithms", Proc. IEEE SOUTHEASTCON '92 New York, NY, USA, IEEE 1992
- [Yin91] X. Yin, N. Germany, "Investigations on Solving the Load Flow Problem by Genetic Algorithms", Electric Power Systems research, 22 (1991), 1991 Elsevier

- [7] K.Aoki et al., "New approximate optimization method for distribution system planning", *IEEE Transactions on PWRs*, vol 5, no.1, Feb 1990
- [8] N. Kagan, R.N. Adams, "Application of Benders decomposition technique to the distribution planning problem", Proceedings of the 10th. PSCC, Graz, Austria, Aug 1990, ed. Butterworths, London
- [9] K.Nara et al., "Multi-year expansion planning for distribution systems", *IEEE Transactions on PWRs*, vol 6, no.3, Aug 1991
- [10] D. E. Goldberg, "Genetic algorithms in Search, Optimization and Machine Learning", 1989 Addison-Wesley
- [11] J. Grefenstette, "Conditions for Implicit Parallelism", Navy Center for Applied Research in Artificial Intelligence, Internal Report, 1991 Washington
- [12] D. E Goldberg, "A Note on Boltzman Tournament Selection for Genetic Algorithms and Population-Oriented Simulated Annealing", 1991, Complex Systems 3
- [13] D. E Goldberg, K. Deb, "A Comparative Analysis of Selection Schemes Used in Genetic Algorithms", Genetic Algorithms in Search, Optimization and Machine Learning Summer School, 1991 Stanford
- [14] S. Kirkpatrick et al. "Optimization by Simulated Annealing" 1983 Science
- [15] J. H. Holland, "Adaption in Natural and Artificial Systems", The University of Michigan Press, 1975 Ann Arbor
- [16] H. Ding et al, "Optimal clustering of power networks using genetic algorithms", Proc. 3rd Biennial Symp. Indust. Elect. Applications, Ruston, LA, USA, LA Tech. Univ., 1992
- [17] V. Ajjarapu et al., "Application of genetic based algorithms to optimal capacitor placement", Proc. First International Forum on Applications of Neural Networks to Power Systems, New York, NY, USA, IEEE 1991
- [18] T. Haida et al., "Genetic algorithms approach to voltage optimization", Proc. First International Forum on Applications of Neural Networks to Power Systems, New York, NY, USA, IEEE 1991
- [19] H. Yang, "Worst case analysis of distribution system harmonics using genetic algorithms", Proc. IEEE SOUTHEASTCON '92 New York, NY, USA, IEEE 1992
- [20] H. Mori, "A genetic approach to power system topological observability", Proc. IEEE International Symp. on Circuits and Systems, New York, NY, USA, IEEE 1991
- [21] K. Iba, "Reactive Power Optimization by Genetic Algorithm", PICA'93, Phoenix, AR, USA, May 1993
- [22] X. Yin, N. Germany, "Investigations on Solving the Load Flow Problem by Genetic Algorithms", Electric Power Systems research, 22 (1991), 1991 Elsevier
- [23] V. Miranda, "Using fuzzy reliability indices in a decision aid environment for establishing interconnection and switching location policies", Proc. CIRED'91, s.6, Liège, Belgium, Apr 1991
- [24] V. Miranda, F.M. Barbosa, "Three phase load flow for radial networks", Proc. of MELECON'83, rp. D4.07, Athens, Greece, 1983

Vladimiro Miranda was born in Oporto, Portugal, on March 11, 1955. He received his Licenciado, Ph.D. and Agregado degrees from the Faculty of Eng. of the University of Oporto (FEUP) in 1977, 1982 and 1991, in Electrical Engineering. In 1981 he joined FEUP and currently holds the position of Professor Associado. In 1985 he joined also INESC - Research Engineering Institute for Systems and Computers and holds presently the position of Project Manager - Head of Information and Decision in Energy Systems area.

João Vasco Ranito was born in Oporto, Portugal, on January 23, 1965. He received his Licenciado and M.Sc. degrees from FEUP in 1988 and 1993, in Electrical Engineering and Computers. In 1988 he joined INESC as a researcher in the Information Systems area. He presently holds there the position of Team Leader in the Software Engineering Development Center and is a Ph.D. student.

Luís Miguel Proença was born in Lisbon, Portugal, on May 10, 1966. He received his Licenciado degree from FEUP in 1989 in Electrical Engineering and Computers. He is now a M.Sc. student at INESC, in the Information and Decision in Energy Systems group.

