

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

**SISTEMAS CLASSIFICADORES PARA REDUÇÃO
DE PERDAS EM REDES DE DISTRIBUIÇÃO DE
ENERGIA ELÉTRICA**

Autora : Patrícia Amâncio Vargas

Orientadores : Prof. Dr. Christiano Lyra Filho
Prof. Dr. Fernando José Von Zuben

Dissertação apresentada à Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas, como parte dos requisitos para obtenção do Título de **MESTRE EM ENGENHARIA ELÉTRICA**.

Banca Examinadora:

Prof. Dr. Christiano Lyra Filho (FEEC/UNICAMP)
Prof. Dr. Celso Cavellucci (CPFL/Campinas)
Profa. Dra. Leontina Pinto (Consultora/Rio de Janeiro)
Prof. Dr. Ricardo Ribeiro Gudwin (FEEC/UNICAMP)

Campinas, outubro de 2000

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

V426s	<p>Vargas, Patrícia Amâncio Sistemas classificadores para redução de perdas em redes de distribuição de energia elétrica / Patrícia Amâncio Vargas.-- Campinas, SP: [s.n.], 2000.</p> <p>Orientadores: Christiano Lyra Filho, Fernando José Von Zuben Dissertação (mestrado) - Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.</p> <p>1. Energia elétrica - Distribuição. 2. Otimização combinatória. 3. Inteligência artificial. 4. Algoritmos genéticos. I. Lyra Filho, Christiano. II. Von Zuben, Fernando José. III. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. IV. Título.</p>
-------	--

Resumo

O problema de minimização de perdas em redes de distribuição de energia elétrica corresponde a encontrar a “melhor” configuração para uma determinada rede, através do controle dos estados das chaves seccionadoras do sistema. Usando uma terminologia de grafos, o problema de minimização de perdas resulta em definir-se uma árvore geradora de peso mínimo para a rede. No entanto, como os pesos nos arcos, vinculados às perdas, variam com os fluxos nos mesmos, o problema não pode ser resolvido com os algoritmos clássicos, muito eficientes, mas desenvolvidos para situações em que os arcos têm pesos fixos. A busca de soluções ótimas para grafos com pesos variáveis é um problema em que a complexidade computacional cresce exponencialmente com a sua dimensão. Partindo de uma proposta de algoritmo evolutivo com codificação genética compacta, este trabalho propõe o uso do conceito de sistemas classificadores, em computação evolutiva, para encontrar uma configuração de rede próxima à de perdas mínimas, para perfis de demanda variantes no tempo. Baseado nas características do problema, os sistemas classificadores definem, a partir de um processo computacional de treinamento evolutivo, um conjunto de regras chamadas de classificadores. Para definição do conjunto de classificadores ótimos, interpretado como uma população, aplica-se os procedimentos intrínsecos à computação evolutiva: seleção, reprodução e mutação. Estudos de casos ilustram as possibilidades e limitações da abordagem.

Abstract

The problem of minimization of energy losses in electric power distribution systems can be formulated as obtaining the “best” network configuration, through the manipulation of sectionalizing switches. Using graph terminology, we have a combinatorial optimization problem, whose solution corresponds to finding the minimum network spanning tree. However, when the arc costs (directly linked to energy losses) vary according to the level of demand on each graph node, the problem can not be solved applying classic algorithms, very efficient, but developed for situations where all the arcs have fixed costs. The search for optimal solutions under the presence of varying demand represents a problem with high computational complexity. Starting with an evolutionary algorithm proposal with compact codification, this work employs evolutionary computation concepts, particularly classifier systems, to find network configurations close to the one associated with minimum energy losses, in the case of time-varying profiles of energy requirements. Based on features of the problem, the classifier system defines, through a computational process of evolutionary training, a set of rules, called classifiers. In order to define the set of optimal rules that composes the classifier system, operators for selection, reproduction and mutation are applied. Case studies illustrate the possibilities and limitations of this approach .

Dedico este trabalho
à minha família
e em especial a meus pais

Diná e
Joaquim (in memoriam)

Este trabalho teve o suporte financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq)

Agradecimentos

A realização deste trabalho tornou-se possível com a participação direta e indireta de várias pessoas. Entre elas gostaria de externar agradecimentos especiais aos meus orientadores Prof. Christiano e Prof. Fernando pela amizade, confiança e dedicação. Agradeço ao Prof. Celso Cavellucci também pela amizade e pelos vários momentos nos quais teve paciência em compartilhar sua experiência profissional com críticas e sugestões extremamente úteis. Aos Profs. Ricardo Gudwin e Fernando Gomide pelas indicações e incentivo no início das atividades. A todos meus amigos da faculdade pelo ajuda nos momentos mais críticos. A todos os funcionários do DENSIS, da CPG e da BAE pelo apoio. Às pessoas que fazem parte do meu círculo de amizade fora do meio acadêmico pelos momentos de troca de afeição e principalmente pela cumplicidade. À minha família pelo amor, confiança e apoio, em especial à minha mãe por acreditar em meus sonhos e por ela ser um dos principais motivos pelos quais consigo força para lutar e vencer. Finalmente, agradeço a Deus Onipotente, sem o qual nada seria possível.

SUMÁRIO

<i>Resumo</i>	<i>i</i>
<i>Dedicatória</i>	<i>iii</i>
<i>Agradecimentos</i>	<i>v</i>
<i>Lista de Tabelas</i>	<i>xiii</i>
<i>Lista de Figuras</i>	<i>xv</i>
1 – Apresentação	1
1.1 – Objetivo.....	1
1.2 – Composição da Tese.....	2
2 – O Problema de Minimização de Perdas : Fundamentos	3
2.1 – Perdas em Sistemas de Distribuição de Energia Elétrica	3
2.2 – Representação de Redes de Distribuição de Energia Elétrica.....	4
2.2.1 – Compactação das Redes de Distribuição de Energia Elétrica.....	6
2.2.2 – Caracterização do Problema.....	7
2.3 – Formulação e Motivação do Problema.....	7
2.4 – Proposições para o Problema de Minimização de Perdas.....	9
2.5 – Nova Abordagem por Computação Evolutiva.....	11

3 – Algoritmos Genéticos : Conceitos Básicos e Extensões Vinculadas ao Problema de Minimização de Perdas	13
3.1 – Conceitos Básicos.....	13
3.2 – Tipos de Representação.....	17
3.3 – Tamanho da População.....	19
3.4 – Mecanismos de Seleção.....	20
3.5 – Função de Fitness.....	21
3.6 – Operadores Genéticos.....	22
3.7 – Algoritmo Genético Aplicado ao Problema de Minimização de Perdas.....	23
3.8 – Resultados e Comentários.....	29
4 – Sistemas Classificadores	33
4.1 – Definição.....	33
4.2 – Subsistema de Tratamento de Regras e Mensagens.....	37
4.3 – Subsistema de Apropriação de Crédito.....	39
4.4 – Subsistema de Descoberta de Novas Regras.....	44
4.5 – Algoritmo Simplificado.....	46
4.6 – Exemplo Didático de Aplicação de um Sistema Classificador.....	47
4.7 – Especialização para Redução de Perdas Elétricas.....	55
5 – Sistemas Classificadores Aplicados ao Problema de Minimização de Perdas	57
5.1 – Interface com o Ambiente.....	57
5.2 – Subsistema de Tratamento de Regras e Mensagens.....	61

5.3 – Subsistema de Apropriação de Crédito.....	63
5.4 – Subsistema de Descoberta de Novas Regras.....	64
5.5 – Algoritmo e Aplicação.....	66
5.6 – Resultados e Comentários.....	68
5.6.1 – Caso 1 : Perfil de Demanda Fixo.....	70
5.6.2 – Caso 2 : Perfil de Demanda Variável.....	71
6 – Conclusões	81
6.1 – Comentários.....	81
6.2 – Contribuições e Sugestões para Novas Pesquisas.....	84
<i>Apêndices A – Equações de Fluxo de Carga</i>	87
<i>Apêndices B – Algoritmo de Sollin</i>	89
<i>Referências Bibliográficas</i>	93
<i>Índice Remissivo de Autores</i>	97

Lista de Tabelas

3.1 - Correspondência entre o Vocábulo Biológico e o Computacional.....	16
3.2 - Exemplo de uma População de Indivíduos com Codificação Binária.....	18
3.3 - Parâmetros Adotados.....	29
3.4 - Estatística.....	30
3.5 - Aumento das Perdas quando Diferentes Configurações são Aplicadas a Diferentes Perfis de Consumo.....	31
4.1 - Exemplos de Classificadores.....	34
4.2 - Fase de Competição : Exemplo de Cálculo do “bid” ou Lance Efetivo.....	41
5.1 - Quantização do Fluxo de Carga.....	58
5.2 - Exemplo de Codificação para MAX = 3140 (kW).....	58
5.3 - Parâmetros Adotados.....	63
5.4 - Desempenho do Sistema Classificador e do Algoritmo Genético para os Perfis 1, 2 e 3	73
5.5 - Desempenho do Algoritmo Genético para os Perfis 1, I1, I2 e 61, 2 e 3.....	76
5.6 - Desempenho do Sistema Classificador para os Perfis do Caso 2, <i>Etapa III</i>	76
5.7 - Configurações Propostas pelo Sistema Classificador para o Caso 2, <i>Etapa IV</i>	77
5.8 - Medida de Diversidade das Populações do Caso 2, <i>Etapa IV</i>	79

Lista de Figuras

2.1 - Diagrama Simplificado de uma Rede de Distribuição.....	4
2.2 - Modelo de Grafo para a Rede de Distribuição da Figura 2.1.....	5
2.3 - Representação de Redes por Chaves com Linhas.....	6
3.1 - Possibilidade de Classificação dos Algoritmos Genéticos.....	14
3.2 - Passos Básicos de um Algoritmo Genético.....	14
3.3 - Gráfico da Função a ser Maximizada, $f(x) = \text{sen}(x) + \sqrt{x}$	18
3.4 - Mecanismo “Roulette Wheel” de Seleção.....	21
3.5 - Exemplo de Crossover Simples.....	22
3.6 - Rede de Distribuição (Baran & Wu, 1989).....	24
3.7 - Distribuição dos Perfis de Demanda.....	25
3.8 - Exemplo do genótipo de um indivíduo gerado aleatoriamente. ...	26
3.9 - Exemplo do fenótipo correspondente ao genótipo do indivíduo da Figura 3.8. ...	27
3.10 - Fitness Máximo e Médio da População para Cada Perfil de Demanda.....	31
4.1 - Interação do Sistema Classificador com o Ambiente.....	33
4.2 - Fluxo Simplificado (Sistema Classificador e Ambiente).....	35
4.3 - Fluxo Interno do Subsistema de Tratamento de Regras e Mensagens.....	37
4.4 - Processo de Identificação de Classificadores com uma Mensagem do Ambiente.....	38
4.5 - Distribuição Gaussiana.....	40
4.6 - Fluxo Interno do Subsistema de Apropriação de Crédito	42
4.7 - Fluxo Interno do Subsistema de Descoberta de Novas Regras.....	44
4.8 - Algoritmo Simplificado de Geração de um Sistema Classificador.....	46
4.9 - Ambiente Computacional Proposto.....	47
4.10 - O Veículo e seus Campos Sensoriais.....	48
5.1 - Exemplo de Codificação da Parte Antecedente do Classificador.....	59

5.2 – Exemplo de Codificação da Parte Conseqüente do Classificador	
Antes da Aplicação do Algoritmo de Sollin.....	60
5.3 - Exemplo de Codificação da Parte Conseqüente do Classificador	
Após a Aplicação do Algoritmo de Sollin.....	60
5.4 - Exemplo de Mensagem Gerada com a Configuração do Ambiente	
(uma Rede de Distribuição com 37 arcos).....	62
5.5 - Exemplo de Mensagem Codificada em Binário.....	62
5.6 - Fase I da Regra de Reposição.....	65
5.7 - Fase II da Regra de Reposição.....	66
5.8 - Variação das Perdas de Energia Calculada a cada Iteração.....	69
5.9 - Relação entre a Especificidade e a Energia da População.....	70
5.10 - Caso 1 : Desempenho e Evolução do Sistema Classificador.....	71
5.11 - Caso 2, Etapa I : Desempenho e Evolução do Sistema Classificador.....	72
5.12 - Caso 2, Etapa II, 1 ^a Simulação : Desempenho e Evolução do Sistema Classificador.	74
5.13 - Caso 2, Etapa II, 2 ^a Simulação : Desempenho do Sistema Classificador.....	74
5.14 - Caso 2, Etapa III : Desempenho e Evolução do Sistema Classificador.....	75
5.15 - Caso 2, Etapa IV : Desempenho do Sistema Classificador.....	76
A.1 - Diagrama Simplificado de uma Rede de Distribuição.....	87
B.1 - Passos Básicos do Algoritmo de Sollin.....	89
B.2 - Aplicação do Algoritmo de Sollin.....	90

1 APRESENTAÇÃO

1.1 - Objetivo

Este trabalho explora a utilização da computação evolutiva, em particular de sistemas classificadores (Booker *et al.*, 1989), como alternativa de solução do problema de redução de perdas em sistemas de distribuição de energia elétrica.

Usando uma terminologia de grafos, o problema de minimização de perdas na distribuição de energia elétrica corresponde à definição de uma árvore geradora de peso mínimo para a rede. No entanto, quando os pesos nos arcos, vinculados às perdas, variam com os fluxos nos mesmos, o problema não pode ser resolvido com os algoritmos clássicos, muito eficientes, mas desenvolvidos para situações em que os arcos têm pesos fixos. A busca de soluções ótimas para grafos com pesos variáveis é um problema em que a complexidade computacional cresce exponencialmente com a dimensão do problema.

As abordagens propostas até o momento para o problema geralmente supõem que as demandas de energia são fixas. Costa (1999) propõe uma abordagem que impede a geração de soluções infactíveis, a partir do emprego de uma codificação genética compacta, a ser expandida pela aplicação de algoritmos clássicos para obtenção de árvores geradoras de peso mínimo. Este trabalho, por sua vez, procura estender os resultados de Costa (1999) para o tratamento de redes com variação das demandas nos nós (centros consumidores de energia). Para tanto, recorre-se aos sistemas classificadores, os quais apresentam grande potencial de adaptação a “ambientes” variantes no tempo.

Baseados nas características do problema, os sistemas classificadores definem, a partir de um processo computacional de treinamento evolutivo, um conjunto de regras, chamadas de classificadores. Para definição do conjunto de classificadores ótimos, interpretado como uma população, aplica-se os procedimentos intrínsecos à computação evolutiva: seleção, reprodução

e mutação.

Outra contribuição deste trabalho é a proposição de uma representação genética em ponto flutuante, em lugar da representação binária, aperfeiçoando as abordagens anteriores (Nara *et al.*, 1992; Costa, 1999).

1.2 - Composição da Tese

Os próximos capítulos estão organizados na forma descrita a seguir.

No Capítulo 2, apresentamos o problema de minimização de perdas em sistemas de distribuição de energia elétrica, suas formas de representação e formulação matemática. Discutimos também proposições apresentadas até o momento para o problema e fazemos uma breve introdução à nova abordagem por computação evolutiva.

No Capítulo 3, expomos os conceitos básicos de algoritmos genéticos. Em seguida, mostramos os detalhes da aplicação dessa ferramenta ao problema de minimização de perdas em sistemas de distribuição de energia, juntamente com resultados e comentários.

Os conceitos de Sistemas Classificadores são apresentados no Capítulo 4, no qual são detalhados os subsistemas que compõem o Sistema Classificador. Um exemplo didático procura ilustrar a aplicação dessa ferramenta.

No Capítulo 5, apresentamos as particularidades da aplicação dos Sistemas Classificadores ao problema de minimização de perdas, juntamente com resultados e comentários.

Discussões, conclusões e sugestões para novas pesquisas compõem o Capítulo 6. Seguem-se referências bibliográficas e os Apêndices A e B, onde apresentamos, respectivamente, as equações recursivas de fluxo de carga adotadas e o algoritmo de Sollin, empregado na obtenção de árvores geradoras de peso mínimo.

2 O PROBLEMA DE MINIMIZAÇÃO DE PERDAS : FUNDAMENTOS

2.1 - Perdas em Sistemas de Distribuição de Energia Elétrica

As perdas de energia elétrica nos sistemas de potência são decorrentes das resistências elétricas nas linhas e equipamentos dos subsistemas de transmissão e distribuição de energia. Na literatura internacional, essas perdas são normalmente estimadas em 7%, sendo 2% na transmissão e 5% na distribuição (Bunch *et al.*, 1982). No Brasil, as perdas totais são da ordem de 15%, sendo a distribuição responsável por cerca de 8% (CODI, 1997; Cavellucci, 1998).

A redução de perdas no sistema de distribuição pode ser alcançada por substituição de linhas (usando-se materiais de menor resistência), instalação de capacitores e reconfiguração de redes. Entre as alternativas, a reconfiguração de redes é a que apresenta a implantação mais econômica.

A redução de perdas por reconfiguração de redes de distribuição procura encontrar alternativas de abertura e fechamento de chaves que levem aos caminhos de menor resistência para atendimento de um determinado perfil de demanda.

Conforme ilustrado nas Figuras 2.1 e 2.2, a maioria das redes opera com uma estrutura radial (ou estrutura em árvore). O objetivo de reconfiguração de redes é encontrar a configuração que apresente a menor perda de energia dentre aquelas que possibilitam o atendimento da demanda. Dadas as chaves seccionadoras do sistema, a cada configuração de rede associa-se um único conjunto de estados para as chaves seccionadoras, que podem estar abertas ou fechadas.

Apresentaremos a seguir o modelo utilizado para representação das redes de distribuição.

2.2 - Representação de Redes de Distribuição de Energia Elétrica

Os componentes de uma rede de distribuição mais relevantes para procedimentos de redução de perdas são subestações, chaves seccionadoras, linhas e blocos de carga (ou pontos consumidores). A Figura 2.1 ilustra esses componentes - temos duas subestações (SE1, SE2), 16 chaves seccionadoras (C1, C2, ..., C16), e 10 blocos de carga ou pontos consumidores (B1, B2, ..., B10).

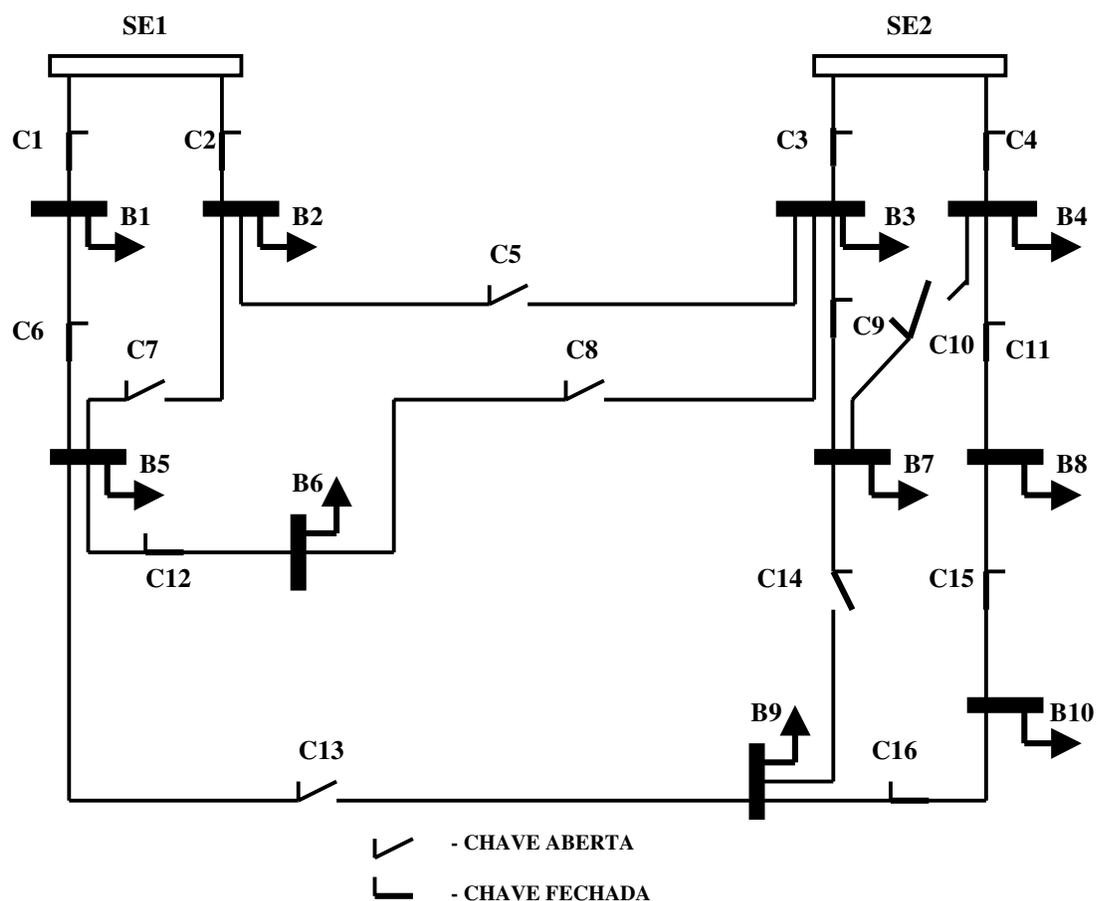


Figura 2.1 – Diagrama Simplificado de uma Rede de Distribuição

Para representar as redes de distribuição, adota-se um modelo na forma de grafo $G = [N,A]$, onde N representa o conjunto de nós (blocos de carga e subestações) e A representa a matriz de incidência nó-arco (chaves seccionadoras da rede) associada ao grafo G (Ahuja *et al.*, 1993). A Figura 2.2 apresenta o modelo de grafo associado à rede de distribuição da Figura 2.1. Um nó “raiz” (R), interligando as subestações, é acrescentado ao grafo para facilitar a manipulação computacional da rede.

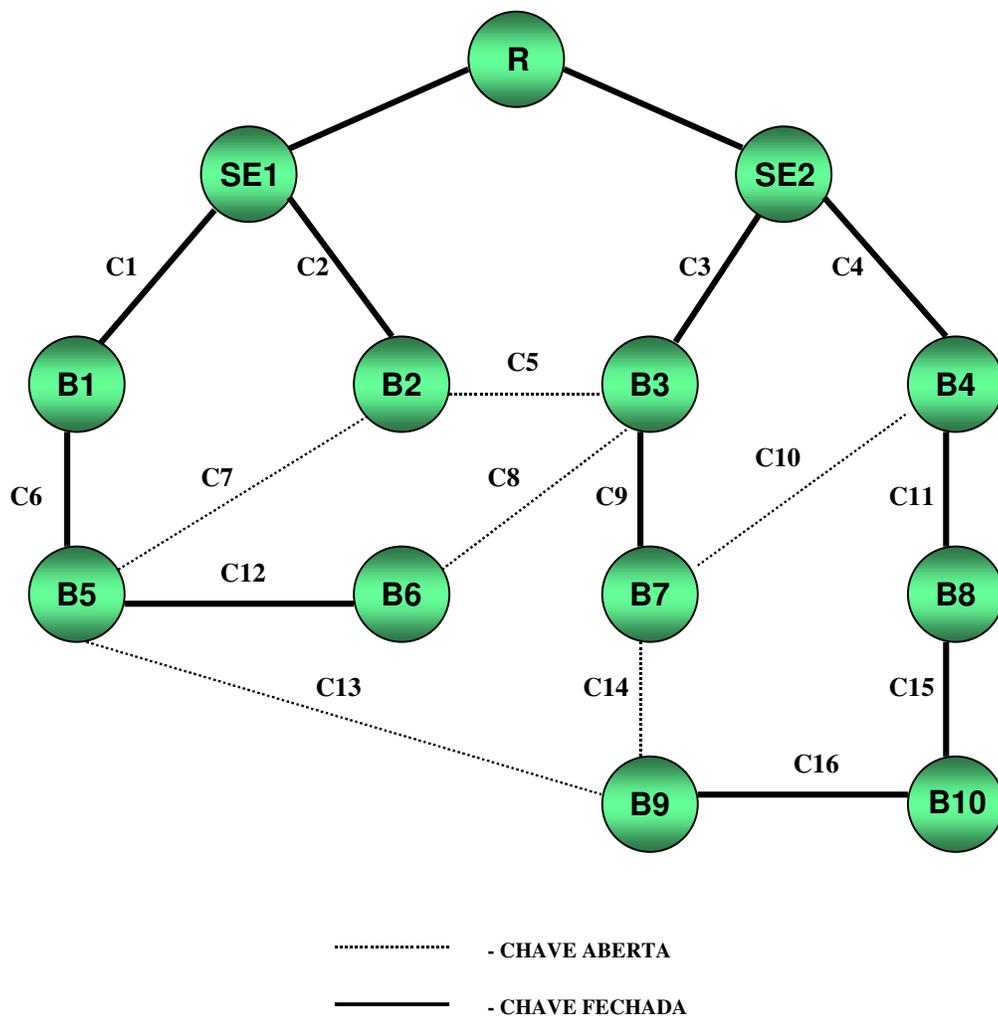


Figura 2.2 – Modelo de Grafo para a Rede de Distribuição da Figura 2.1

2.2.1 - Compactação das Redes de Distribuição de Energia Elétrica

As redes de distribuição são normalmente submetidas a algum tipo de simplificação para representação na estrutura de dados de problemas de minimização de perdas. O objetivo dessas simplificações é reduzir a dimensão das estruturas de dados que serão manipuladas pelos programas de computadores, sem perda significativa de informação. Uma abordagem de simplificação muito adotada (Civanlar *et al.*, 1988 ; Baran e Wu, 1989) é a representação de trechos de linhas compreendidos entre duas chaves por um único arco associado a uma das chaves, como ilustra a Figura 2.3 (o arco na parte (c) da Figura 2.3, inclui as resistências das linhas que ligam o terminal da chave às barras de carga do trecho). Esta forma de compactação das redes será adotada neste trabalho.

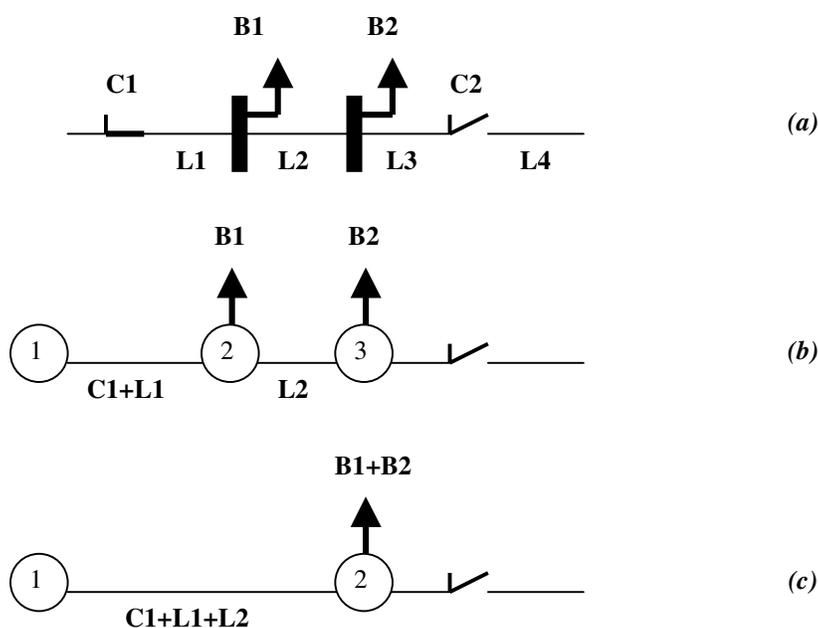


Figura 2.3 – Representação de Redes por Chaves com Linhas

2.2.2 - Caracterização do Problema

Usando uma terminologia de grafos, o problema de minimização de perdas nas redes de distribuição de energia elétrica corresponde à definição de uma árvore geradora de peso ou custo mínimo para a rede. Uma árvore corresponde a um subconjunto da rede, onde todos os nós estão interligados e não existem ciclos, ou seja, o caminho entre dois nós quaisquer é único. Para situações em que os arcos têm pesos fixos, existem algoritmos muito eficientes para se determinar a árvore geradora de peso mínimo (Ahuja *et al.*, 1993). No entanto, quando os pesos (custos) nos arcos variam com o nível de demanda em cada nó do grafo, o problema não pode ser resolvido com os algoritmos clássicos. A busca de soluções ótimas para grafos com pesos variáveis caracteriza um problema em que a complexidade computacional cresce exponencialmente com a dimensão da rede (Tão, 1997).

2.3 - Formulação e Motivação do Problema

Considerando o grafo $G = [N,A]$ representando uma rede de distribuição, o problema de obter a configuração em árvore da rede com menor perda de energia pode ser formulado como um problema de otimização com restrições, na forma :

$$\underset{c}{\text{Min}} \quad f(c, x) = \sum_{k: a_k \in A'=Ac} r_k x_k^2 \quad (2.1)$$

$$s.a. \quad Ax = b \quad (\text{Suprimento de Demanda})$$

$$\underline{x} \leq x \leq \bar{x} \quad (\text{Limites de Fluxo})$$

$$G' = [N, A'] \text{ é uma árvore} \quad (\text{Operação Radial})$$

onde :

- c - vetor de chaveamento (vetor de variáveis booleanas, que define as chaves abertas e fechadas)
- r_k - resistência da linha
- x_k - fluxo de energia no arco a_k , que pode ser alterado pela reconfiguração da rede
- A - matriz de incidência nó-arco associada ao grafo G
- x - vetor de fluxos
- b - vetor de carga nos nós
- \underline{x} e \bar{x} - vetores de limites de fluxos nos arcos (em cada direção)
- N - conjunto de nós do grafo G
- A' - subconjunto de colunas da matriz A , que corresponde a arcos do grafo com fluxos não nulos

Os fluxos nos arcos são calculados por equações recursivas de fluxo de carga, propícias a esquemas de solução computacionalmente eficientes. Estas equações recursivas, detalhadas por Baran & Wu (1989), são apresentadas no Apêndice A.

O problema (2.1) caracteriza uma situação de otimização combinatória, onde o esforço

computacional para se garantir a obtenção da solução ótima por avaliações exaustivas envolveria a análise de todas as árvores geradoras possíveis (Baran & Wu, 1989). Esta busca exaustiva é computacionalmente intratável, principalmente quando a demanda é variável.

A possibilidade do trato computacional é conquistada à medida que se abre mão da garantia de obtenção da solução ótima em prol de uma boa solução. Levando-se em conta este aspecto e a necessidade de se obter uma nova configuração a cada variação significativa de demanda nos nós, justifica-se a investigação da possibilidade de se aplicar uma ferramenta de computação evolutiva, desenvolvida para o tratamento de problemas que requerem ações contínuas e muitas vezes em tempo real : os Sistemas Classificadores (Booker *et al.*, 1989).

Precedendo a exposição desta abordagem evolutiva, faz-se, na próxima seção, uma apresentação concisa das principais propostas encontradas na literatura para a solução do problema de minimização de perdas em sistemas de distribuição de energia elétrica.

2.4 - Proposições para o Problema de Minimização de Perdas

Merlin & Back (1975), pioneiros na proposição e abordagem do problema, já identificaram dificuldades para encontrar uma configuração de perdas mínimas por meio de métodos que garantam a obtenção da solução ótima (por exemplo, branch-and-bound). Os autores desenvolveram duas abordagens para o problema : uma delas, capaz de encontrar a solução de mínimas perdas, é aplicável apenas a redes de pequeno porte; a outra, aproximada, pode ser aplicada a redes de maior porte.

Na análise dos casos estudados, Merlin & Back (1975) relataram também outros benefícios observados com a redução das perdas : melhora da distribuição de cargas entre os alimentadores; aumento do período em que as redes são capazes de atender a demanda, sem a

necessidade de investimentos em expansão, e maior robustez em relação a falhas. Resultados tão promissores impulsionaram as pesquisas nos anos que sucederam à publicação do trabalho de Merlin & Back, sendo divulgadas em mais de 50 trabalhos publicados nas revistas científicas da área.

As abordagens mais bem sucedidas e utilizadas, como “abertura seqüencial de chaves” (Merlin & Back, 1975; Shirmohammadi & Hong, 1989; Peponis *et al.*, 1995) e “troca de ramos” (Civanlar *et al.*, 1988; Baran & Wu, 1989; Peponis *et al.*, 1995), conduzem a soluções aproximadas. Recentemente, Cavellucci & Lyra (1997) apoiando-se na união de técnicas de otimização não linear em grafos com métodos de busca informada, ampliaram a possibilidade de encontrar um ótimo global para o problema de minimização de perdas. Porém, esta abordagem ainda tem limitações para utilização em redes de grande porte.

Nara *et al.* (1992) foram os primeiros autores a investigar o uso de computação evolutiva para redução de perdas em sistemas de distribuição de energia elétrica. A estratégia desenvolvida por Nara e co-autores levava à construção de soluções que violavam a restrição de radialidade; o processo de identificação e eliminação das soluções ineficazes comprometia o desempenho da abordagem. Costa (1999) resolveu este problema, ao acrescentar inovações metodológicas de computação evolutiva, e também explorou a possibilidade de usar esses conceitos juntamente com busca tabu (Glover & Laguna, 1997).

As inovações propostas por Costa (1999) utilizam notação binária na codificação genética para representar o custo de cada arco da rede. Como esses custos são valores reais, Vargas *et al.* (2000) propuseram um aperfeiçoamento junto ao trabalho de Costa adotando uma notação em ponto flutuante que se mostrou muito eficaz e será descrita no Capítulo 3.

A abordagem por Sistemas Classificadores, a ser apresentada nos Capítulos 4 e 5, é inovadora por representar um campo da Computação Evolutiva ainda inexplorado para o problema de minimização de perdas. Aspectos desta abordagem são brevemente descritos a seguir.

2.5 - Nova Abordagem por Computação Evolutiva

As abordagens empregadas na literatura e descritas na seção anterior, geralmente supõem que as demandas de energia são fixas. Este trabalho, por sua vez, procura estender as investigações sobre as possibilidades da computação evolutiva para um problema mais ambicioso, onde são consideradas as variações das demandas nos nós (centros consumidores de energia).

Antes de investigarmos o caso de perfil de demanda variável em cada nó do grafo, estudamos o quanto as perdas são afetadas por variações nos perfis de demanda. Para tratar este problema, incorporamos contribuições junto ao algoritmo proposto por Costa (1999), para situações em que as demandas são fixas. Como já mencionado, destaca-se a utilização de representação genética em ponto flutuante, em lugar da representação binária normalmente utilizada para este problema, o que aumentou a eficiência do processo evolutivo de busca da solução.

Como resultado da aplicação de algoritmos genéticos para casos distintos de perfis de demanda fixa, identificamos a necessidade de se definir configurações específicas para cada situação de demanda. Sendo assim, estando diante de perfis de demanda variáveis (situação normalmente encontrada na operação diária de sistemas reais) e procurando garantir uma operação com perdas mínimas, fica evidente a necessidade de se reconfigurar a rede frente a variações significativas no perfil de demanda. Para tanto, recorreremos aos sistemas classificadores, os quais apresentam grande potencial de adaptação a “ambientes” variantes no tempo.

Baseado nas características do problema, os sistemas classificadores definem, a partir de um processo computacional de treinamento evolutivo, um conjunto de regras, chamadas de classificadores. Após um processo de atribuição de créditos, seguido por etapas evolutivas, estas

regras (ou classificadores) serão capazes de apresentar soluções para cada perfil de demanda apresentado. A construção do conjunto de classificadores ótimos, interpretado como uma população, é realizada por procedimentos intrínsecos à computação evolutiva: seleção, reprodução e mutação.

No próximo capítulo, faremos uma exposição dos conceitos básicos de algoritmos genéticos e descreveremos os detalhes da aplicação desta ferramenta ao problema de minimização de perdas em redes de distribuição de energia elétrica com demandas fixas.

3 ALGORITMOS GENÉTICOS : CONCEITOS BÁSICOS E EXTENSÕES VINCULADAS AO PROBLEMA DE MINIMIZAÇÃO DE PERDAS

3.1 - Conceitos Básicos

Entendemos como *algoritmo* “um conjunto predeterminado e bem definido de regras e processos com operações finitas, destinados à solução de um problema com um número finito de etapas” e, como *genético*, “um termo relativo à genética, a qual é um ramo da biologia que estuda as leis da transmissão dos caracteres hereditários nos indivíduos, e os mecanismos que asseguram essa transmissão” (Ferreira, 1996).

Os *algoritmos* ditos *genéticos* são um tipo especial de algoritmo. Na realidade, são algoritmos de **busca estocástica polarizada** (Atmar, 1994). Portanto, uma definição de *algoritmos genéticos* poderia ser : um conjunto predeterminado e bem definido de regras e processos com operações finitas, destinados à **busca estocástica polarizada** da solução de um problema, com um número finito de etapas. Os algoritmos genéticos seguem as leis biológicas da transmissão dos caracteres hereditários nos indivíduos e os mecanismos que asseguram essa transmissão.

Apesar do caráter estocástico ou aleatório dos algoritmos genéticos, eles são capazes de explorar com eficiência a memória passada, no sentido de polarizar a busca por regiões promissoras no espaço de candidatos à solução (Goldberg, 1989).

Quanto à taxionomia, conforme pode ser observado na Figura 3.1, os algoritmos genéticos fazem parte dos sistemas computacionais inspirados em modelos de processos naturais, mais especificamente da computação evolutiva.

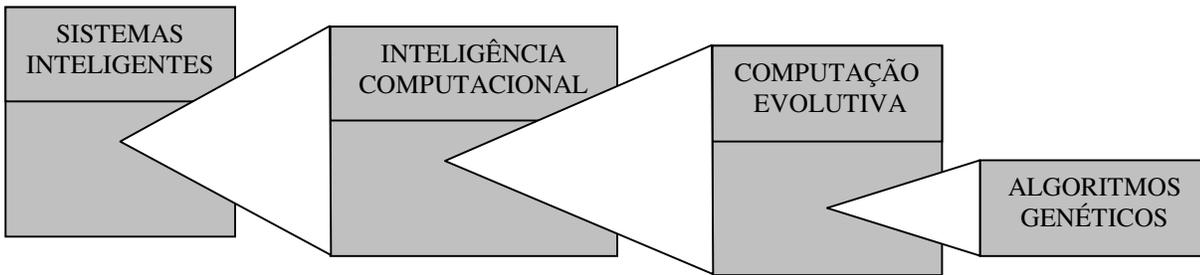


Figura 3.1 – Possibilidade de Classificação dos Algoritmos Genéticos

Na Figura 3.2, apresentamos de forma simplificada os passos básicos do processo de execução de um algoritmo genético (variações em relação a este esquema podem ser encontradas na literatura). Representamo-lo aqui como uma função que recebe como entrada uma *população inicial* e uma função de avaliação, normalmente denominada *fitness*, e fornece como saída o melhor *indivíduo* encontrado após o processo evolutivo. Para entendermos cada passo, necessitamos definir os seguintes termos : geração, população, indivíduo, função de fitness, seleção, reprodução e critério de parada.

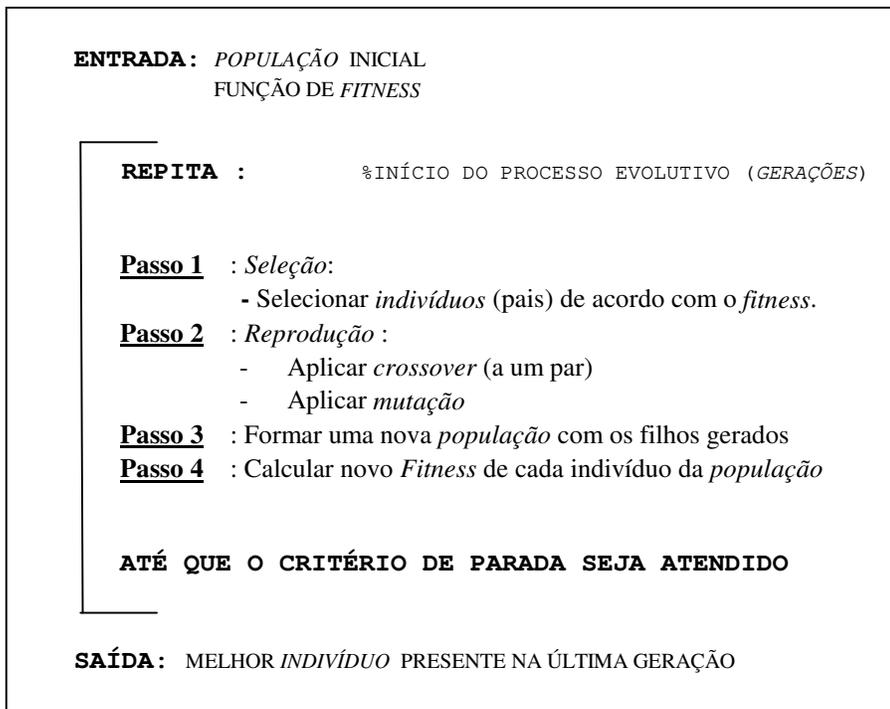


Figura 3.2 – Passos Básicos de um Algoritmo Genético

Geração

É o resultado da aplicação dos passos 1 a 4 junto a uma *população* (ver Figura 3.2)

População

Conjunto de *indivíduos* que compõe uma *geração*.

Indivíduo

Representação (genótipo) da solução (fenótipo) de um determinado problema (ambiente) através de um arranjo ou vetor cujos elementos são obtidos a partir de um alfabeto finito.

Função de Fitness

Função de avaliação, que mede o quão adaptado está o *indivíduo* ao ambiente.

Seleção

Processo de escolha que usualmente seleciona os *indivíduos* mais adaptados (que apresentam um maior *fitness*), para participarem do processo de *reprodução*.

Reprodução

Processo pelo qual *indivíduos* mais adaptados, ou seja, com melhores valores para a função de avaliação, têm a chance de perpetuar seu material genético, ou ao menos parte deste material, através da aplicação dos operadores genéticos de *crossover* e *mutação*.

Critério de Parada

Caracterizado pela obtenção de uma solução satisfatória ou pelo término do tempo computacional preestabelecido (Fogel, 1995).

Voltando à Figura 3.2 observa-se que o algoritmo genético parte de uma *população* inicial. Através de um mecanismo de *seleção*, dá preferência aos indivíduos mais adaptados ao ambiente (que apresentam maior *fitness*) e aplica os operadores genéticos de *crossover* e *mutação*. Caracteriza-se assim um processo evolutivo, onde espera-se que o *fitness* do melhor indivíduo a cada geração apresente uma tendência de crescimento continuado, sendo este indivíduo, por conseguinte, capaz de representar uma boa solução ao problema proposto, a qual pode não ser a melhor possível.

Como os algoritmos genéticos baseiam-se principalmente nos processos evolutivos das espécies, especialmente no mecanismo de seleção natural, descritos originalmente em Darwin (1859;1993), mostramos na Tabela 3.1 a correspondência entre alguns termos da linguagem adotada em ambiente computacional e na biologia.

Tabela 3.1 – Correspondência entre o Vocábulo Biológico e o Computacional

Termos Biológicos	Termos Computacionais
Cromossomo	Indivíduo
Gene	Caractere
Alelo	Valor do caractere
Lócus	Posição do caractere
Genótipo	Vetor de caracteres que representa o indivíduo
Fenótipo	Interpretação do vetor de caracteres

Procuramos detalhar nas próximas seções alguns tipos possíveis de representação, a dimensão das populações durante o processo evolutivo, certos mecanismos de seleção, as funções de avaliação ou *fitness* e determinados operadores genéticos. Em seguida, descrevemos em um estudo de caso, a implementação do algoritmo genético aplicado ao problema de

minimização de perdas em sistemas de distribuição de energia elétrica, apresentando resultados e comentários.

3.2 - Tipos de Representação

Usando termos da Tabela 3.1, cada indivíduo é considerado um “cromossomo” e, na representação clássica de algoritmos genéticos, ele é codificado como um vetor de caracteres de tamanho fixo, formado pela concatenação dos caracteres “0” e “1” do alfabeto binário {0,1} (representação binária). Existem variações para esta codificação, como a representação em ponto flutuante, onde o vetor de tamanho fixo é formado pela concatenação de elementos que são números reais (Michalewicz, 1996).

Representação Binária

No caso de uma representação binária, a codificação é direta quando as possíveis soluções já são de natureza binária. Caso contrário, procura-se transformar as possíveis soluções para o problema em um número binário ou em uma seqüência de números binários.

Como exemplo, temos o problema de maximização da função $f(x) = \text{sen}(x) + \sqrt{x}$, representada graficamente na Figura 3.3, onde x assume valores inteiros no intervalo [0,15]. Cada indivíduo representa a codificação binária de um valor inteiro da variável x no intervalo considerado. Como seus valores devem variar entre 0 e 15, cada indivíduo (candidato à solução) deverá possuir 4 bits. Em virtude da natureza do problema, a própria função $f(x)$ pode ser utilizada como função de *fitness* neste problema particular.

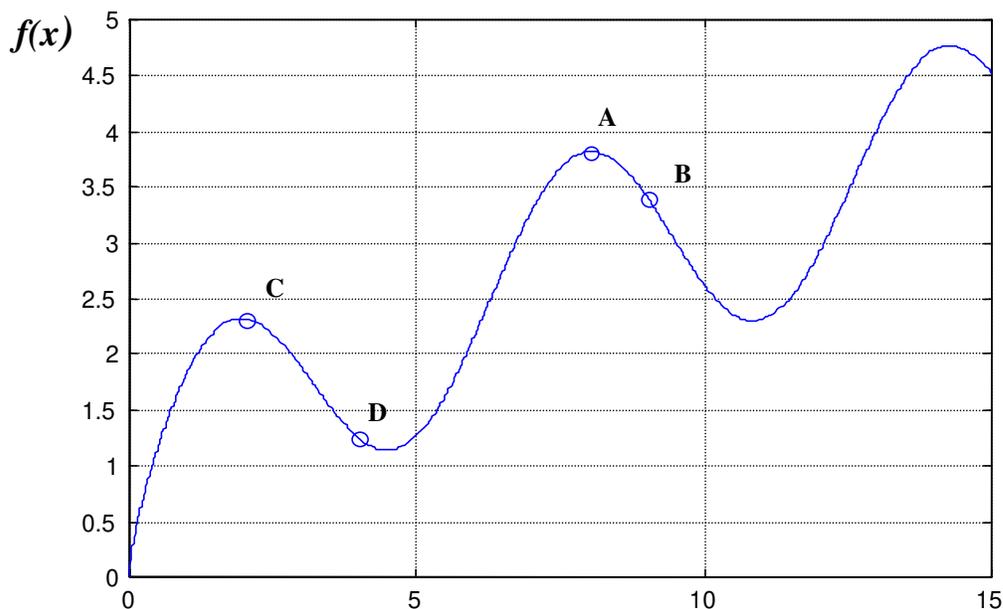


Figura 3.3 – Gráfico da Função a ser Maximizada, $f(x) = \text{sen}(x) + \sqrt{x}$

Observe na Tabela 3.2, uma população inicial gerada aleatoriamente para este problema de otimização, com 4 indivíduos.

Tabela 3.2 – Exemplo de uma População de Indivíduos com Codificação Binária

Candidato à solução	Codificação (genótipo)	x (fenótipo)	Fitness = $f(x)$
A	1 0 0 0	8	3,8178
B	1 0 0 1	9	3,4121
C	0 0 1 0	2	2,3235
D	0 1 0 0	4	1,2432

A partir desta população inicial (2ª coluna da Tabela 3.2), com base nos valores de fitness calculados para cada indivíduo (4ª coluna da Tabela 3.2), a aplicação repetida dos passos

apresentados na Figura 3.2 vai permitir evoluir a população, de geração em geração, até se atender o critério de parada. O melhor indivíduo que pode ser obtido neste caso é 1110, que corresponde a $x = 14$ e $f(x) = 4,7323$.

Representação em Ponto Flutuante

Na representação em ponto flutuante cada cromossomo é um vetor de tamanho fixo formado pela concatenação de números do conjunto dos números reais. Como exemplo, temos a representação adotada para aplicação junto ao problema de minimização de perdas, o qual veremos com detalhes na Seção 3.7.

Dependendo do problema, a representação em ponto flutuante apresenta uma série de vantagens em relação à representação binária. Entre elas podemos citar:

- o tamanho menor do cromossomo a ser considerado, reduzindo o consumo de CPU e memória no processamento computacional,
- a simplicidade da representação, tornando desnecessária a decodificação,
- maior controle sobre o efeito da perturbação causada pela aplicação do operador de mutação (preservação de critérios de vizinhança).

No entanto, a representação em ponto flutuante não permite o uso direto do conceito de blocos construtivos (building blocks) (Holland, 1975), conceito normalmente utilizado para demonstração de convergência do processo evolutivo.

3.3 - Tamanho da População

Um aspecto importante a ser considerado para o sucesso do processo evolutivo refere-se ao tamanho da população inicial e da população nas subseqüentes gerações, pois é possível comprometer a evolução dos indivíduos caso a quantidade escolhida seja muito grande ou muito

pequena. Esta medida, exceto em casos muito particulares, deve ser estabelecida empiricamente e de acordo com a disponibilidade de recursos computacionais (Goldberg, 1983 e 1989; Holland, 1975; Richards, 1995; Costa, 1999).

Deve-se considerar também a possibilidade da população ser dividida em subpopulações e aplicar-se diferentes formas de reprodução e de operadores para cada uma delas.

3.4 - Mecanismos de Seleção

Um outra etapa de grande impacto no desempenho do algoritmo genético é a fase de seleção de indivíduos para reprodução. Existem vários tipos de seleção que podem ser aplicados (Goldberg, 1989). Entre os mecanismos existentes destacamos o “Roulette Wheel”, adotado em Goldberg (1983) e a seleção por torneio.

A seleção por torneio é recomendada quando há uma grande diferença relativa no valor do fitness dos indivíduos. Em sua versão mais simples, para $k = 2$, um par de indivíduos é escolhido aleatoriamente e o indivíduo que possuir maior *fitness* será selecionado para reprodução. O processo se repete obedecendo a probabilidade de seleção normalmente estabelecida. O valor do parâmetro k está diretamente vinculado ao nível de pressão seletiva durante este processo (Michalewicz, 1996). Estudos comparativos entre este mecanismo e outros são apresentados em Koza (1996).

No mecanismo “Roulette Wheel” de seleção, a cada indivíduo é associada a porção de uma roleta, proporcional ao valor de seu fitness. Observe no exemplo da Figura 3.4 a formulação e aplicação desse mecanismo. Neste caso, após “rodar” a roleta, o indivíduo A foi o escolhido, apesar de possuir apenas 37,5 % de chance.

Conforme expusemos na definição de seleção, usualmente procura-se os indivíduos mais adaptados. Entretanto, com o objetivo de manter-se a diversidade da população durante a seleção, pode-se, algumas vezes, optar por indivíduos menos adaptados.

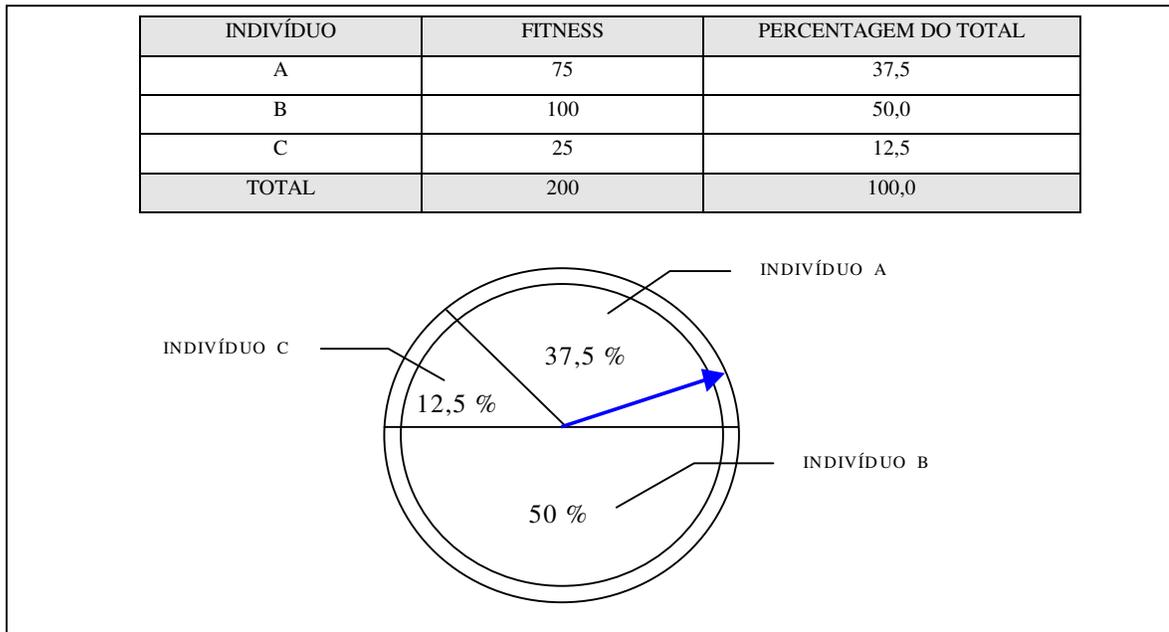


Figura 3.4 – Mecanismo “Roulette Wheel” de Seleção

Como já mencionado anteriormente, a escolha de um mecanismo de seleção apropriado é de suma importância durante o processo evolutivo. No entanto, exceto em casos particulares, a escolha é feita empiricamente, analisando-se as várias propostas existentes e o problema a ser abordado, não sendo ainda possível caracterizar a priori o melhor mecanismo.

3.5 - Função de Fitness

Para cada indivíduo, calcula-se a função de avaliação (*fitness*). Este valor está associado a quão adaptado está o indivíduo ao ambiente com o qual ele interage. Em termos computacionais, esta medida indica o quão bem um dado candidato à solução (indivíduo) é capaz de resolver o problema (ambiente). É imprescindível a definição apropriada desta medida de adaptação, para que o processo evolutivo seja capaz de fornecer uma solução que atenda aos objetivos em questão (Goldberg, 1989).

3.6 - Operadores Genéticos

A forma de codificação adotada para representar cada indivíduo (ou cromossomo) determinará quais operadores genéticos serão aplicados e como serão utilizados os operadores escolhidos. Tais operadores possuem variações. O operador de crossover pode ser simples, multiponto, uniforme, ordenado (Goldberg, 1989), aritmético (Michalewicz, 1996), ou uma combinação deles. O mesmo acontece com o operador de mutação, o qual possui variantes e todas dependem do tipo de codificação adotada para se definir o cromossomo.

Dentre os vários tipos de crossover destacamos o crossover simples. Observe na Figura 3.5 a aplicação deste operador a um par de cromossomos. Basicamente, os pares trocam entre si o código genético a partir de um ponto de corte determinado aleatoriamente.

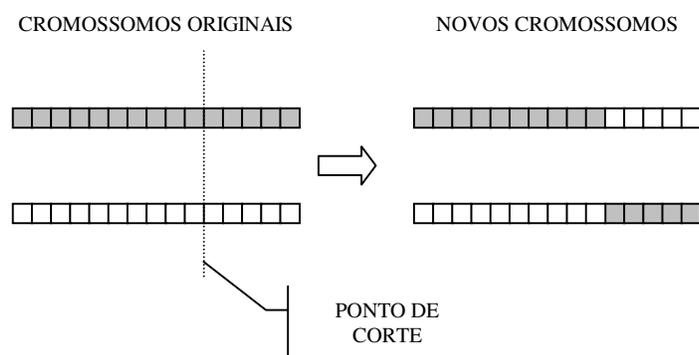


Figura 3.5 – Exemplo de Crossover Simples

O operador de mutação sempre opera sobre um único cromossomo, alterando seu material genético. Ele pode atuar em apenas um gene de cada vez (mutação simples) ou em uma porcentagem de genes determinada aleatoriamente (mutação aleatória). No caso de uma codificação binária, esta mutação ou alteração do código genético, corresponde simplesmente à

troca de um bit pelo seu complemento. No caso de uma codificação em ponto flutuante, a mutação corresponde ao acréscimo de um valor extraído de uma distribuição aleatória ao gene escolhido (ou aos genes).

Para representação em ponto flutuante, destacamos dois tipos de mutação : mutação uniforme, onde o valor aleatório a ser acrescido ao gene (ou genes) provém de uma distribuição constante ao longo do processo evolutivo; mutação não-uniforme, onde o valor a ser acrescido provém de uma distribuição que depende do tempo decorrido ao longo do processo evolutivo (Michalewicz, 1996).

3.7 - Algoritmo Genético Aplicado ao Problema de Minimização de Perdas

Introdução

Conforme exposto no Capítulo 2, o problema de minimização de perdas em sistemas de distribuição de energia elétrica caracteriza uma situação de otimização combinatória. A busca de soluções ótimas é um problema em que a complexidade computacional cresce exponencialmente com a dimensão da rede (Tão, 1997).

Este problema foi explorado por Costa (1999) a partir da aplicação de algoritmos genéticos com representação binária, juntamente com inovações na representação genética de estruturas em árvore. Com o objetivo de confirmar a necessidade de se encontrar soluções ótimas (estado das chaves seccionadoras) para cada perfil diferente de demanda, incorporamos representação genética em ponto flutuante ao algoritmo de solução para perfis de demanda fixa, proposto por Costa (1999).

A representação em ponto flutuante mostrou-se mais adequada, por preservar a noção de vizinhança na aplicação do operador de mutação, o que não ocorre com a representação binária.

Além disso, como apontado por Michalewicz (1996), esse tipo de codificação acelera o processo de evolução, é mais consistente de geração para geração e fornece uma melhor precisão, especialmente junto a problemas que requerem representação através de vetores de caracteres muito extensos.

Apresentamos na Figura 3.6 a rede de distribuição de energia elétrica considerada em todos os estudos de casos, neste capítulo e nos seguintes. Essa rede foi proposta inicialmente por Baran & Wu (1989). Ela é composta por 37 arcos, 32 nós e chaves seccionadoras associadas a cada arco. Na configuração apresentada, encontram-se abertas as chaves associadas aos arcos 33, 34, 35, 36 e 37.

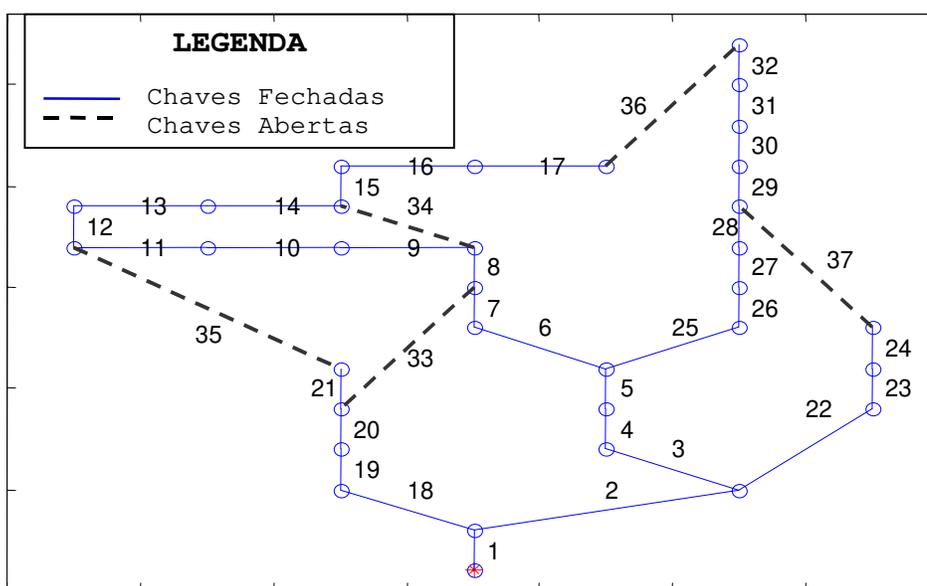


Figura 3.6 – Rede de Distribuição (Baran & Wu, 1989)

Objetivo

Para um dado perfil de demanda nos nós, buscamos minimizar as perdas de energia elétrica da rede de distribuição apresentada na Figura 3.6. Para tal, selecionamos seis propostas

de distribuição aleatórias de demanda para a rede, ilustradas na Figura 3.7. No eixo das ordenadas temos o valor da demanda para cada um dos 32 nós, os quais são representados no eixo das abscissas. Estes perfis são distintos mas possuem a mesma demanda total de energia.

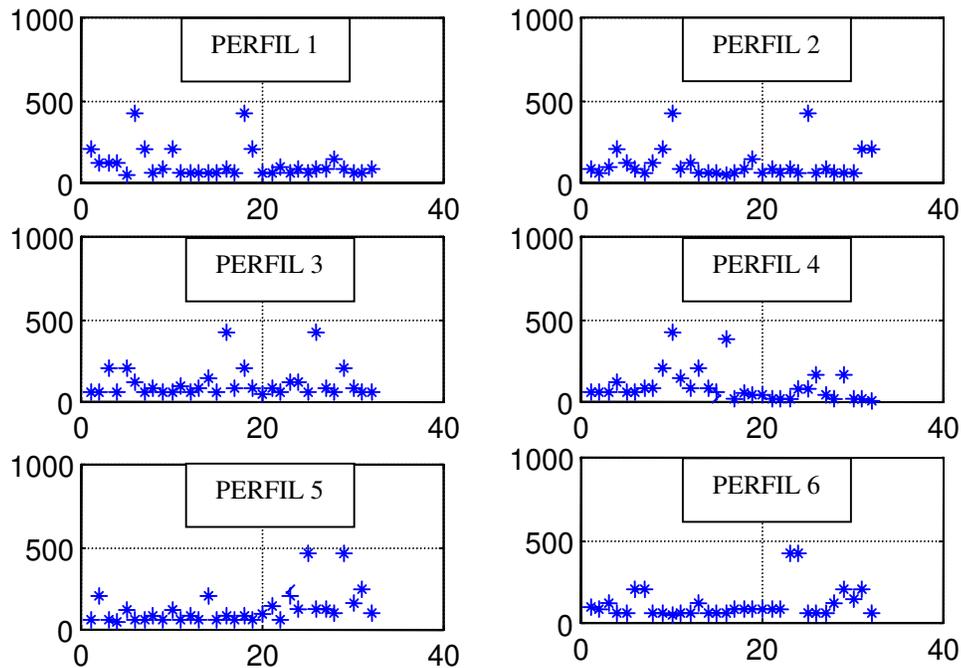


Figura 3.7 – Distribuição dos Perfis de Demanda

Descrevemos a seguir os principais componentes do algoritmo genético aplicado a este problema.

Representação

Como a solução do problema de perdas para a rede da Figura 3.6 resume-se em apontar as chaves seccionadoras que devem permanecer abertas, poderíamos simplesmente codificar indivíduos para indicar diretamente o estado das chaves : aberta ou fechada. Entretanto, devido às características do problema, com a exigência de soluções que mantenham a estrutura radial da

rede, impedindo a formação de ciclos e garantindo o suprimento de energia a todos os nós consumidores, não seria possível garantir, com esta codificação direta, a geração de filhos factíveis a partir de pais também factíveis.

Por esta razão, procuramos utilizar a mesma metodologia de obtenção de árvores geradoras de peso mínimo proposta por Costa (1999) e melhorar os resultados por ele obtidos. Assim, adotamos uma representação genética em ponto flutuante na definição dos dados de entrada para o algoritmo de obtenção da árvore geradora de custo mínimo, onde cada elemento do vetor de entrada de tamanho fixo, significa o peso ou custo de cada arco da rede, o qual é arbitrário e ainda não está associado ao perfil de demanda presente na rede de distribuição.

Como para cada vetor de entrada de tamanho fixo (indivíduo), sempre vai existir uma árvore geradora de custo mínimo associada (Ahuja *et al.*, 1993), obtemos, a partir desta árvore, a configuração proposta (ou estado das chaves seccionadoras) para cada indivíduo da população.

Basicamente, o indivíduo ou vetor de números reais no intervalo [0,1] (genótipo) deverá ser decodificado (gerando o fenótipo) para apontar quais chaves seccionadoras, do conjunto total de chaves da rede, devem ficar abertas. Observe nas Figuras 3.8 e 3.9 um exemplo do genótipo e do fenótipo correspondente de um indivíduo da população a ser evoluída.

INDIVÍDUO (GENÓTIPO)																		
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
0.15	0.28	0.78	0.29	0.74	0.02	0.35	0.45	0.26	0.90	0.48	0.64	0.82	0.19	0.76	0.39	0.91	0.05	0.59
20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	
0.27	0.43	0.60	0.56	0.93	0.23	0.78	0.39	0.83	0.71	0.49	0.14	0.42	0.62	0.46	0.71	0.42	0.86	
CUSTO OU PESO DO ARCO							NÚMERO DO ARCO											

Figura 3.8 – Exemplo do genótipo de um indivíduo gerado aleatoriamente. O custo ou peso dos arcos deverá ser evoluído para que a árvore geradora de custo mínimo obtida leve à minimização das perdas

INDIVÍDUO (FENÓTIPO)																		
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
1	1	0	1	1	1	1	1	1	0	1	1	0	1	1	1	0	1	1
20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	
1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	

1 – FECHADO
0 – ABERTO

NÚMERO DO ARCO

Figura 3.9 – Exemplo do fenótipo correspondente ao genótipo do indivíduo da Figura 3.8. Esta configuração de chaves foi extraída da árvore geradora de custo mínimo, mas como os custos dos arcos da Figura 3.8, usados para obter a árvore, podem ainda não estar associados ao perfil de demanda presente na rede de distribuição, pode não haver minimização das perdas na rede de distribuição com a adoção desta configuração de chaves

A decodificação do fenótipo do indivíduo da Figura 3.9 indica que as chaves 3, 10, 13, 17 e 24 devem estar abertas.

Teremos um vetor com tantos números em ponto flutuante quantos forem os arcos do sistema. Como já mencionado anteriormente, a decodificação do vetor de números (indivíduo) segue a metodologia apresentada em Costa (1999). Costa utilizou o algoritmo de Prim para produzir uma árvore geradora de custo mínimo (condição necessária para o processo de evolução da população), a partir de um conjunto de arcos com custo ou peso fixo. Em nosso caso, adotamos o algoritmo de Sollin (Apêndice B), mais indicado para a geração de árvores esparsas, conforme sugerido por Ahuja *et al.*(1993) – situação típica das redes de distribuição de energia elétrica.

Dimensão das Populações

A população inicial é gerada aleatoriamente com 50 indivíduos (ou vetores) contendo 37 posições, denominadas *locus*, formadas pela concatenação de números reais no intervalo [0,1]. A dimensão da população inicial e subsequentes é mantida constante durante o processo evolutivo.

Mecanismo de seleção

Foi adotado o mecanismo de seleção “Roulette Wheel”, apresentado na Seção 3.4.

Função de Avaliação

A função de avaliação em nossa abordagem está vinculada à função objetivo apresentada na Equação 2.1, Seção 2.3, Capítulo 2. Para uma dada configuração i ($G'=[N,A']$), de operação radial da rede de distribuição, o total de perdas é dado na forma

$Perdas(conf_i) = \sum_{k: a_k \in A'=Ac} r_k x_k^2$ e cada indivíduo será avaliado de acordo com o cálculo

apresentado na Equação 3.1 :

$$Fit(i) = \frac{1}{10 * Perdas(conf_i)} \quad (3.1)$$

onde $Fit(i)$ representa o fitness do i -ésimo indivíduo durante o processo evolutivo e $Perdas(conf_i)$ representa o total das perdas associadas à configuração i . Como podemos observar, o fitness é inversamente proporcional às perdas do sistema, calculadas a partir da configuração $conf_i$, associada ao fenótipo do indivíduo i .

Por exemplo, o indivíduo i representado nas Figuras 3.8 e 3.9, possui um fitness de 1,6524 ($Fit(i) = 1,6524$), referente a uma perda de 0,06051877 ($Perdas(conf_i) = 0,06051877 p.u.$). Essas perdas correspondem a 605,1877 kW.

Operadores Genéticos

Aplicamos os operadores genéticos de crossover simples e mutação uniforme. Na aplicação da mutação uniforme, procuramos respeitar o intervalo de variação dos números reais

[0,1] de cada *locus* dentro do vetor (seqüência de custos nos arcos da rede), ajustando os valores para 0 ou 1 em caso de extrapolação dos limites.

Parâmetros

Os parâmetros adotados, após exaustivos testes de desempenho, estão apresentados na Tabela 3.3. Na 1ª coluna, temos o tamanho da população, igual a 50 indivíduos criados aleatoriamente. Na 2ª coluna, relatamos que 10% da população é selecionada por mecanismo “Roulette Wheel” (discutido na Seção 3.4) para reprodução a cada geração. Nas 3ª e 4ª colunas temos respectivamente a percentagem de aplicação de crossover e mutação, aplicados aos 10% de indivíduos escolhidos para reprodução.

Tabela 3.3 – Parâmetros Adotados

Tamanho da população	Percentagem da população selecionada para reprodução	Probabilidade de Crossover	Probabilidade de Mutação
50	10 %	90 %	1 %

3.8 - Resultados e Comentários

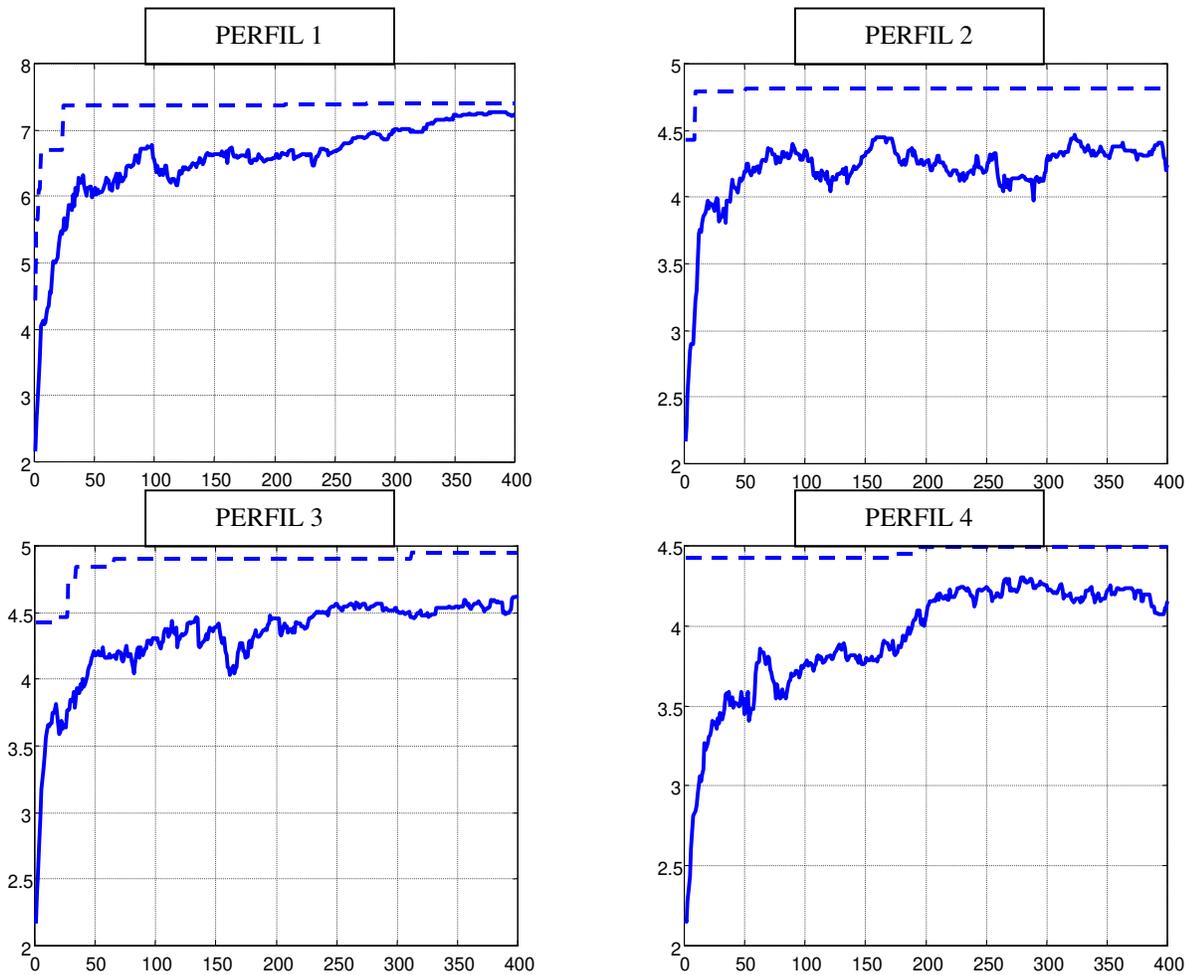
Na Tabela 3.4 apresentamos a estatística do desempenho do algoritmo genético aplicado a cada perfil de demanda ilustrado na Figura 3.7. Todas as simulações partiram da mesma população inicial gerada aleatoriamente e o cálculo da redução de perdas para todos os perfis toma como referência uma mesma configuração para a rede, chaves abertas : 33, 34, 35, 36 e 37. Essa configuração foi proposta por Baran & Wu (1989) – ela foi adotada neste trabalho para permitir comparações com outras abordagens. Observe na coluna 2 da Tabela 3.4, o valor da perda calculada em cada perfil para esta configuração. Na coluna 4, temos o valor das perdas

calculadas para cada perfil, considerando a configuração proposta pelo fenótipo do melhor indivíduo encontrado.

Tabela 3.4 – Estatística

PERFIL	PERDA REFERENCIAL (em kW)	FENÓTIPO DO MELHOR INDIVÍDUO (chaves abertas)	PERDAS CALCULADAS PARA O MELHOR INDIVÍDUO (em kW)	% DE REDUÇÃO NAS PERDAS
1	216,1733	7-10-14-16-28	135,0730	37,51 %
2	375,1484	7-10-14-17-28	207,7695	44,61 %
3	372,8436	7-9-14-17-28	202,0010	45,82 %
4	453,2261	10-14-15-28-33	222,4486	50,91 %
5	303,7213	7-9-14-28-36	178,0502	41,37 %
6	282,6649	7-9-14-32-37	204,1293	27,78 %

Na Figura 3.10 apresentamos, através da função de *fitness*, o desempenho do melhor indivíduo e a média do *fitness* da população.



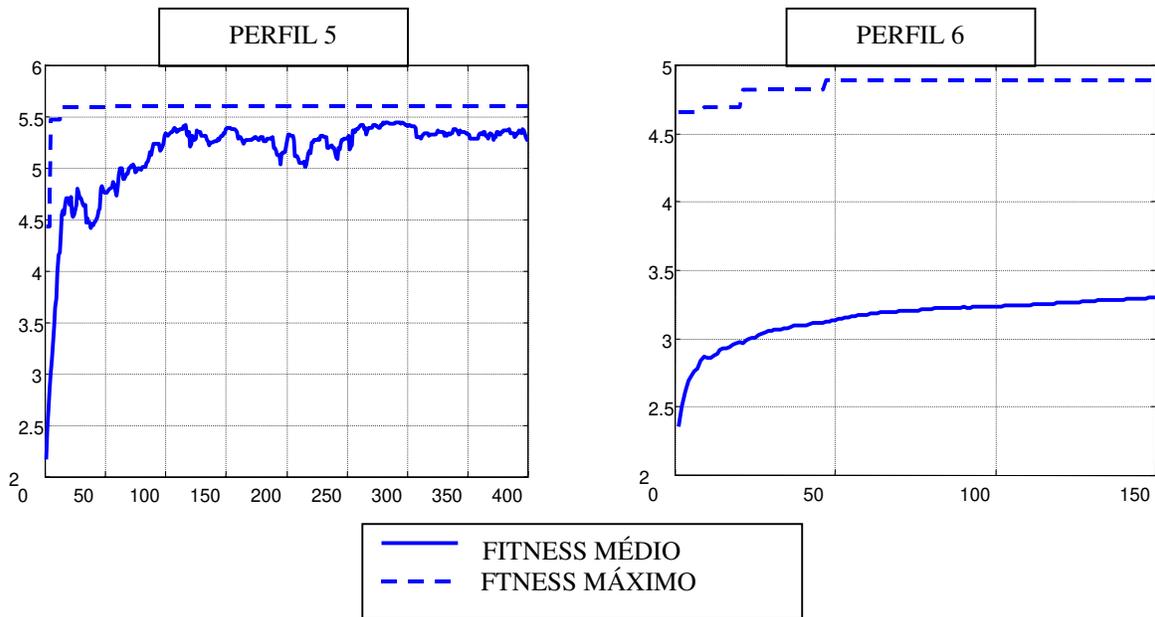


Figura 3.10 – Fitness Máximo e Médio da População para Cada Perfil de Demanda

Este estudo de casos, com aplicação de algoritmos genéticos para perfis distintos de demanda fixa, confirmou a necessidade de mudanças de configuração na rede na presença de demandas variáveis, procurando sempre manter a rede de distribuição em uma configuração de perdas mínimas. Isso pode ser observado a partir dos cálculos apresentados na Tabela 3.5.

Tabela 3.5 – Aumento das Perdas quando Diferentes Configurações são Aplicadas a Diferentes Perfis de Consumo

	P ₁	P ₂	P ₃	P ₄	P ₅	P ₆
P ₁	0	0,2911	2,2553	0,3059	1,7839	6,4485
P ₂	1,7181	0	1,0184	12,602	0,4144	4,2648
P ₃	1,5189	2,5179	0	13,277	0,1080	4,1104
P ₄	2,7524	2,8187	12,481	0	9,4363	12,819
P ₅	3,8348	2,4171	3,9084	16,925	0	1,5433
P ₆	17,918	32,532	21,187	26,369	17,757	0

A Tabela 3.5 ilustra o aumento das perdas, em percentagem, de uma determinada configuração ótima, encontrada para um perfil de consumo P_i ($i=1,\dots,6$), quando aplicada a outro perfil P_j ($j=1,\dots,6, j \neq i$). Por exemplo, a aplicação da melhor configuração encontrada para

o perfil P_1 (chaves abertas : 7, 10, 14, 16 e 28) em P_6 , resultou em um acréscimo de 6,4485 % nas perdas em relação ao valor determinado pela melhor configuração encontrada para P_6 (chaves abertas : 7, 9, 14, 32 e 37).

Para a situação de perfis de demandas variáveis, recorreremos a uma outra ferramenta da Computação Evolutiva, os Sistemas Classificadores. Esta ferramenta apresenta grande potencial de adaptação a “ambientes” variantes no tempo e que requerem ações contínuas e muitas vezes em tempo real (Booker *et al.*, 1989).

Antes de investigarmos o caso de perfil de demanda variável em cada nó do grafo, verificaremos o desempenho do Sistema Classificador para perfis de demanda fixa. Em seguida, realizaremos experimentos correspondendo a situações em que o perfil de demanda do sistema sofre variações abruptas (em degrau), representando praticamente o reinício do processo de geração de classificadores - pois os melhores classificadores encontrados para o primeiro perfil, possivelmente não apresentarão bom desempenho na resposta ao segundo perfil de demanda, requerendo uma reavaliação do conjunto de classificadores.

Finalmente, estudaremos variações suaves e periódicas nos perfis de demandas, mais condizentes com a prática. O propósito é obter um Sistema Classificador suficientemente flexível para indicar novas soluções sempre que as variações de demanda começarem a interferir significativamente no nível de perdas associado a uma determinada configuração da rede de distribuição (estado das chaves).

São abordados no Capítulo 4 os conceitos de Sistemas Classificadores. No Capítulo 5 detalhamos a implementação e resultados da aplicação dessa ferramenta ao problema de minimização de perdas em redes de distribuição de energia, com perfis de demandas fixas e variáveis em cada nó consumidor.

4 SISTEMAS CLASSIFICADORES

4.1 - Definição

O conceito de Sistemas Classificadores foi originalmente proposto por Holland (1975). É uma das abordagens que se inspiram nos processos da natureza para solução de problemas (Kovacs & Lanzi, 1999). Estas técnicas normalmente recebem a denominação genérica de “computação natural”.

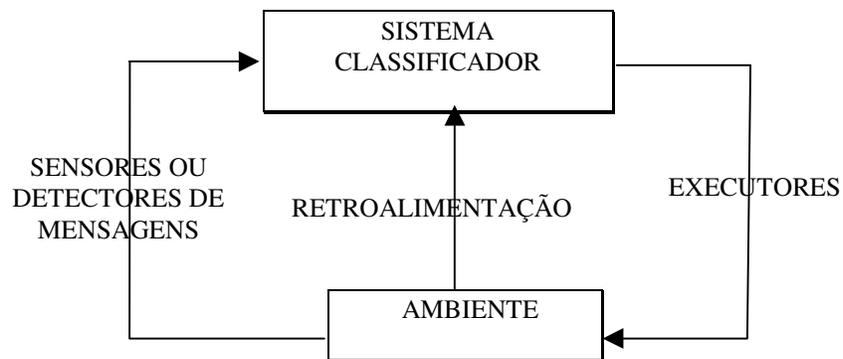


Figura 4.1 - Interação do Sistema Classificador com o Ambiente

Basicamente, o Sistema Classificador consiste de uma metodologia para criação e atualização evolutiva de regras (os classificadores) em um sistema de tomada de decisão, que codifica alternativas de ações específicas para as características de um ambiente em determinado instante. Entende-se como “ambiente” modelos de problemas do mundo real, não-estacionários e normalmente de otimização e controle. Pode-se mencionar, como exemplos de ambiente, o controle de operação de gás natural encanado (Goldberg, 1983), a otimização de formas geométricas obedecendo a critérios de qualidade em instrumentos industriais (Richards, 1995) e, em nosso caso, a minimização de perdas em redes de distribuição de energia elétrica.

A interação do Sistema Classificador com o ambiente (Figura 4.1) ocorre através da troca de mensagens. As mensagens provenientes do ambiente procuram retratar o seu estado atual. Já as mensagens advindas do Sistema Classificador retratam ações a serem aplicadas sobre o ambiente.

Todo Sistema Classificador comunica-se com o ambiente sobre o qual ele atua através de sensores (ou “detectores”) de mensagens e de “executores”. Os detectores são responsáveis pela recepção e codificação da mensagem (ou mensagens) recebidas pelo sistema, transformando-as em uma linguagem inteligível ao Sistema Classificador. Os “executores” decodificam as ações propostas pelo sistema, para que as mesmas possam ser colocadas em prática. As conseqüências encadeadas a partir de cada ação (etapa de retroalimentação) determinam a “recompensa” adequada aos classificadores responsáveis pela ação.

Existem duas variantes para formação dos classificadores, a abordagem “Pittsburgh”, na qual um indivíduo representa a solução para o problema, e a abordagem “Michigan”, na qual a solução é dada pela população e não pelos indivíduos da população - existe uma única solução sendo evoluída (Michalewicz, 1996). Utilizaremos a abordagem “Michigan”, ilustrada na Tabela 4.1, para formação dos classificadores. Portanto, cada classificador irá atuar vinculado à ocorrência de uma situação específica do ambiente, de modo que o desempenho do Sistema Classificador, tomando-se todo o histórico de atuação no ambiente, será sempre determinado considerando-se toda a população de classificadores. Como é usual em regras, estes classificadores são compostos por uma parte antecedente e outra conseqüente (existem variações em que um classificador pode possuir duas ou mais condições na parte antecedente).

Tabela 4.1 - Exemplos de Classificadores

Hipótese	Classificadores ou Regras (SE)... : (ENTÃO) ...	Energia
A	1#1## : 11	8,5
B	1110# : 01	15,2
C	11111 : 11	5,9
D	##0## : 10	19,0

A parte antecedente do Sistema Classificador é um vetor de tamanho fixo, formado pela concatenação dos caracteres “0”, “1” e “#”, os quais são elementos do conjunto que compõe o alfabeto ternário {0,1,#}. O caractere “#” conhecido como o símbolo “*don’t care*”, tem a função exercida por um curinga em um jogo de cartas, podendo assumir o valor “1” ou “0”, durante a “fase de comparação” (descrita na seção 4.2). A parte conseqüente é um outro vetor de tamanho fixo, formada pela concatenação dos caracteres “0” e “1” do alfabeto binário {0,1}.

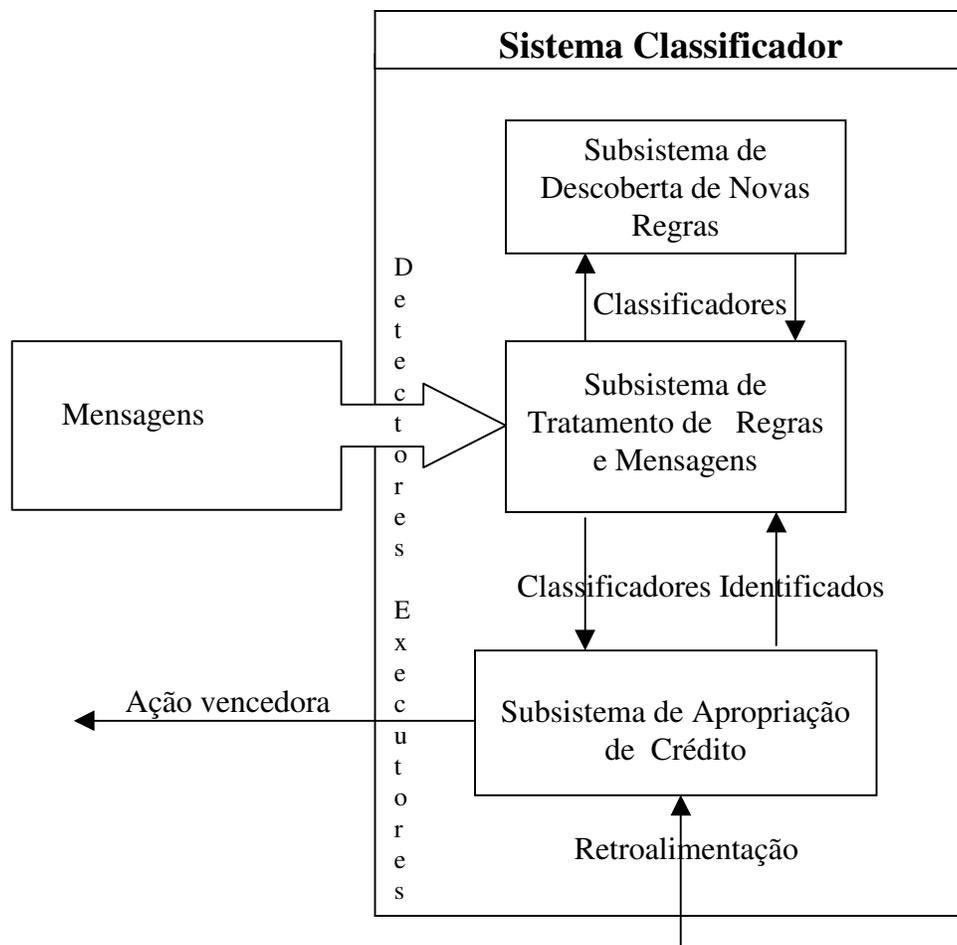


Figura 4.2 - Fluxo Simplificado (Sistema Classificador e Ambiente)

Associada a cada classificador, temos a sua “energia” (“*strength*” na literatura em inglês), utilizada para expressar o vigor, ou força, de cada um durante o processo evolutivo.

O casamento da parte antecedente do classificador com a mensagem do ambiente é que definirá quem irá competir ou não. A competição, neste caso, caracteriza-se por uma forma de avaliação dos classificadores, sendo que os mais bem adaptados disputarão o direito de atuar sobre o ambiente. No exemplo da Tabela 4.1, para uma mensagem do ambiente na forma 11101, os classificadores **A** e **B** irão competir, sendo que o classificador **B** está mais apto a vencer a competição, devido ao grau de energia que possui.

Outro conceito importante é o da “especificidade” de cada classificador, medida inversamente proporcional à quantidade de símbolos “#” (*don’t care*) na parte antecedente do classificador (Tabela 4.1).

Por exemplo, os classificadores **A** e **D** são menos específicos, podendo portanto identificar-se com um maior número de mensagens do ambiente. Suponha que cada bit da mensagem de tamanho $L = 5$ caracterize uma informação do ambiente. O classificador **A** se identificaria com esta mensagem e também com outras 7 mensagens. Entretanto, o classificador **C** se identificaria apenas com a mensagem 11111.

A parte do conseqüente do classificador é separada da parte antecedente pelo símbolo “:”. Seu valor determina a ação a ser aplicada no ambiente por intermédio dos atuadores. Por exemplo, nos classificadores **A** e **C** a seqüência 11 poderia significar “siga em frente”, determinando um dentre 4 movimentos possíveis de um robô móvel em um ambiente a ser explorado.

Internamente, os Sistemas Classificadores dividem-se em três subsistemas distintos e interativos : o Subsistema de Tratamento de Regras e Mensagens , o Subsistema de Apropriação de Crédito e o Subsistema de Descoberta de Novas Regras (Figura 4.2). Descreve-se a seguir cada um destes subsistemas.

4.2 - Subsistema de Tratamento de Regras e Mensagens

Quando os detectores de mensagens percebem a presença de alguma mensagem do ambiente, enviam a mesma para o Subsistema de Tratamento de Regras e Mensagens (Figura 4.3). Este codifica a mensagem, de forma que o Sistema Classificador possa reconhecê-la, e coloca a mesma à disposição para um processo de identificação, o qual denominaremos “comparação”. Na fase de comparação, todos os classificadores tentam identificar sua parte antecedente com a mensagem.

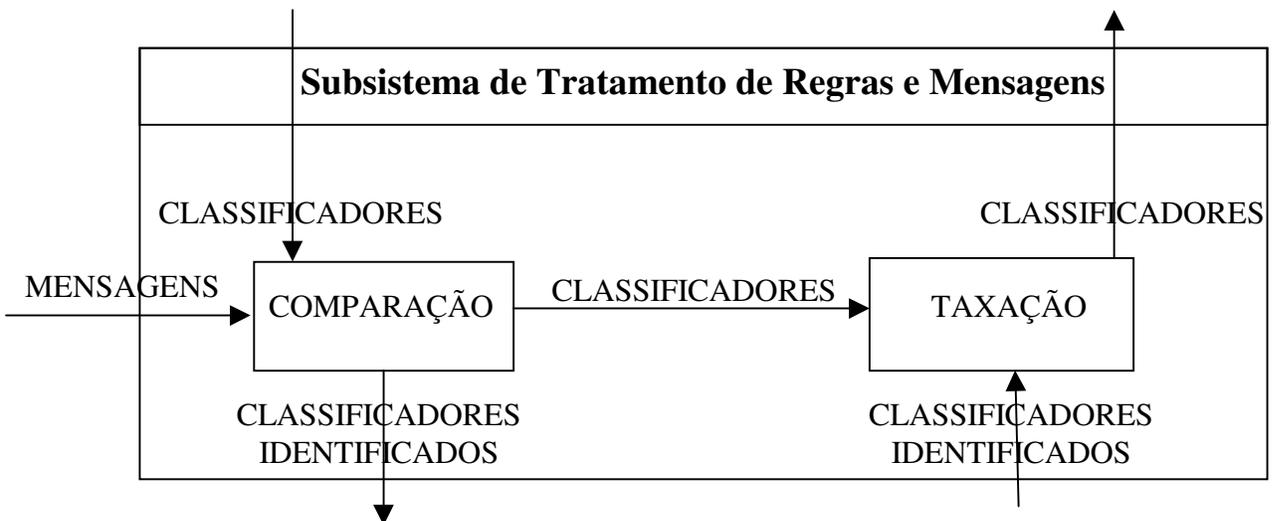


Figura 4.3 – Fluxo Interno do Subsistema de Tratamento de Regras e Mensagens

A identificação pode ser feita por comparação bit a bit, de acordo com regras específicas, ou apenas pelo cálculo de uma variante da Distância de Hamming, dada pela Equação 4.1 a seguir (Booker, 1985):

$$M = \frac{l - n}{l^2} \quad (4.1)$$

Equação 4.2 abaixo, temos o cálculo desta taxa, a qual é cobrada de cada classificador a cada iteração.

$$Taxa_v = 1 - \left(\frac{1}{2}\right)^{\frac{1}{n}} \quad (4.2)$$

onde: n - meia vida do classificador (definida em número de iterações)

4.3 - Subsistema de Apropriação de Crédito

Durante a fase de Apropriação de Crédito, todos os classificadores que se identificaram com a mensagem do ambiente participarão de uma “competição”, em que o ganhador é a regra que apresenta maior “bid” (“lance”) efetivo, definido pela Equação 4.3, abaixo. Ao ganhador será concedido o direito de atuar sobre o ambiente.

$$eBid_t = Bid_t + \sigma_bid * N_t \quad (4.3)$$

onde: $eBid_t$ - “bid efetivo” no instante t

Bid_t - “bid” no instante t (veja Equação 4.4)

N_t - modulação caracterizada por um ruído com distribuição gaussiana de média 0 e variância 1, representada na Figura 4.5.

σ_bid - nível de perturbação do ruído N_t

O σ_bid é um parâmetro específico do sistema, utilizado durante a competição, para determinar o nível de perturbação desejado durante a aplicação do ruído gaussiano sobre o Bid_t . A aplicação deste ruído gaussiano permite que classificadores com menor energia e mais genéricos também tenham chance de vencer a competição.

Calcula-se Bid_t a partir da Equação 4.4 :

$$Bid_t = k_0 * (k_1 + k_2 * Spec^{SPow}) * S_t \quad (4.4)$$

onde : Bid_t - “bid” no instante t

k_0 - coeficiente de bid 0, referente à energia do classificador (constante positiva menor que 1)

k_1 - constante de bid 1, referente à parte não específica do classificador (constante positiva menor que 1)

k_2 - constante de bid 2, referente à parte específica do classificador (constante positiva menor que 1)

$Spec$ - especificidade do classificador (definida na Equação 4.5), associada à proporção de símbolos “#” na string

$SPow$ - parâmetro de controle da influência da especificidade no valor do “bid” (normalmente igual a 1)

S_t - energia ou “strength” do classificador no instante t

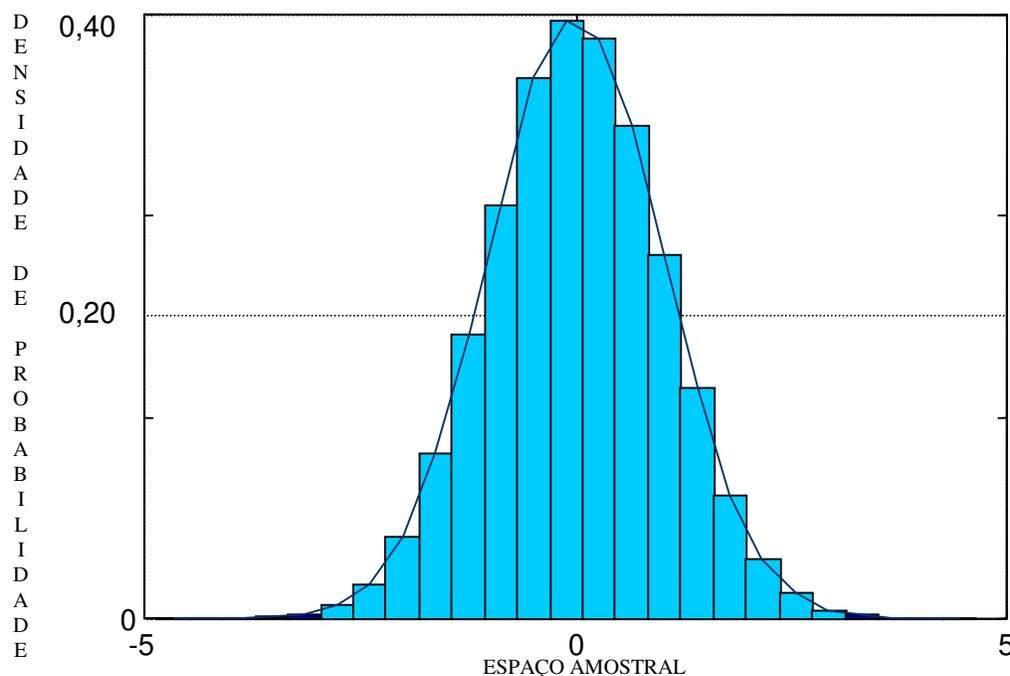


Figura 4.5 – Distribuição Gaussiana

A especificidade do classificador é definida pela Equação 4.5.

$$Spec = \frac{N - total_#}{N} \tag{4.5}$$

onde : N - tamanho da parte antecedente do classificador
 $total_#$ - total de símbolos “#” (*don't care*) presentes na parte antecedente do classificador

Para exemplificar, consideremos os classificadores identificados na Figura 4.4. Assumindo os parâmetros $k_0 = 0,1$, $k_1 = 0,1$, $k_2 = 0,0833$, $SPow = 3$ e $\sigma_{bid} = 0,1$, observe na Tabela 4.2, o cálculo do bid ou lance efetivo. Note que, apesar do classificador ou regra **B** possuir maior energia S_t , o mesmo não conseguiu vencer a competição. Isso foi consequência da aplicação do ruído gaussiano ao lance apostado por cada classificador, evitando-se que sempre o indivíduo de maior energia seja o vencedor. A aplicação do ruído gaussiano promove uma melhor exploração do espaço de hipóteses - os membros deste espaço de hipóteses são os classificadores (Richards, 1995).

Tabela 4.2 – Fase de Competição : Exemplo de Cálculo do “bid” ou Lance Efetivo

<i>Hipótese</i>	<i>Regras</i>	S_t	$Spec$	Bid_t	N_t	$eBid_t$	<i>Regra Vencedora</i>
A	1#1## : 11	8,5	0,4	0,0895	1,4151	0,2310	1#1## : 11
B	1110# : 01	15,2	0,8	0,2168	-0,8051	0,1363	

Uma taxa de participação, representada na Equação 4.6, é cobrada de cada indivíduo que participou da “competição”. O ganhador da competição paga também uma taxa, equivalente ao valor de seu próprio Bid_t , por ter o direito de atuar sobre o ambiente.

$$Taxa_bid = Bid_tax * Bid_t \quad (4.6)$$

- onde : $Taxa_bid$ - taxa de participação na competição
 Bid_tax - constante aplicada sobre o Bid do classificador
 Bid_t - Bid do classificador no instante t

O ambiente responderá, fornecendo uma retroalimentação para o Sistema Classificador (Figura 4.6).

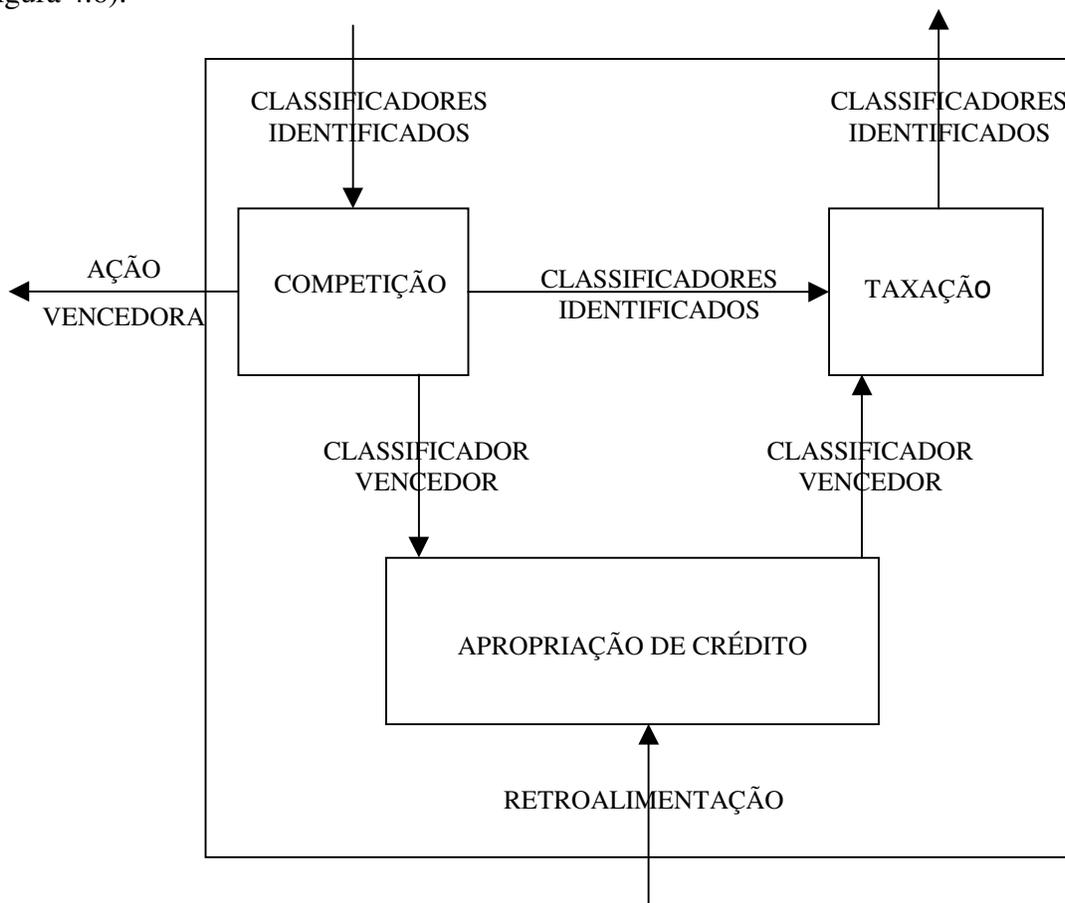


Figura 4.6 – Fluxo Interno do Subsistema de Apropriação de Crédito

De acordo com os objetivos previamente definidos, é responsabilidade do Subsistema de Apropriação de Crédito definir o valor da recompensa R_t e incorporar este valor à energia do

classificador ativo no momento ou a um elenco de classificadores que agiu recentemente. A Equação 4.7 apresenta a fórmula geral do cálculo da nova energia do classificador, a cada iteração (Richards, 1995).

$$S_{t+1} = (1 - Taxa_v) * S_t + R_t - Bid_t - Taxa_bid \quad (4.7)$$

- onde :
- $Taxa_v$ - taxa de vida
 - S_t - energia ou “*strength*” no instante t
 - R_t - valor baseado na retroalimentação dada pelo ambiente, caso o classificador tenha sido vencedor da competição no instante $t-1$ (♦)
 - Bid_t - Bid do classificador no instante t ($Bid_t = 0$ caso o classificador não tenha sido vitorioso na competição no instante t)
 - $Taxa_bid$ - taxa de participação na competição ($Taxa_bid = 0$ para quem não competiu)

- (♦) $R_t = 0$ caso o classificador não tenha sido vencedor no instante $t-1$
 $R_t > 0$ em caso de recompensa (ação positiva)
 $R_t < 0$ em caso de punição (ação negativa)

Uma vez definido o classificador vencedor, que será responsável pela ação sobre o ambiente, uma nova mensagem será fornecida pelo próprio ambiente, caracterizando o seu novo estado. Este novo estado, consequência da ação indicada pelo classificador vencedor, será o ponto de partida para se definir o valor da recompensa R_t . Em seguida, volta-se novamente ao tratamento de mensagens e apropriação de crédito. O processo continua por uma “época” de iterações. Ao final de cada época, o Sistema Classificador participará de outra fase de sua evolução, a fase de descoberta de novas regras.

4.4 - Subsistema de Descoberta de Novas Regras

Ao final de cada época de iterações, espera-se que a energia dos classificadores tenha sido devidamente ajustada e então aplica-se os procedimentos intrínsecos aos algoritmos genéticos. Neste momento, todas as vantagens desta ferramenta evolutiva, são exploradas em busca de uma população de classificadores cada vez mais adaptada ao ambiente, de acordo com o elenco de objetivos a serem atendidos, representados formalmente no Subsistema de Apropriação de Crédito.

Basicamente, o algoritmo genético produz uma nova geração de classificadores pela aplicação, em uma parte da população original, dos operadores de seleção, crossover e mutação (apresentados no Capítulo 3). A probabilidade de seleção de um classificador é proporcional à sua energia. Os filhos gerados serão inseridos na população em substituição aos indivíduos com menor energia (Figura 4.7).

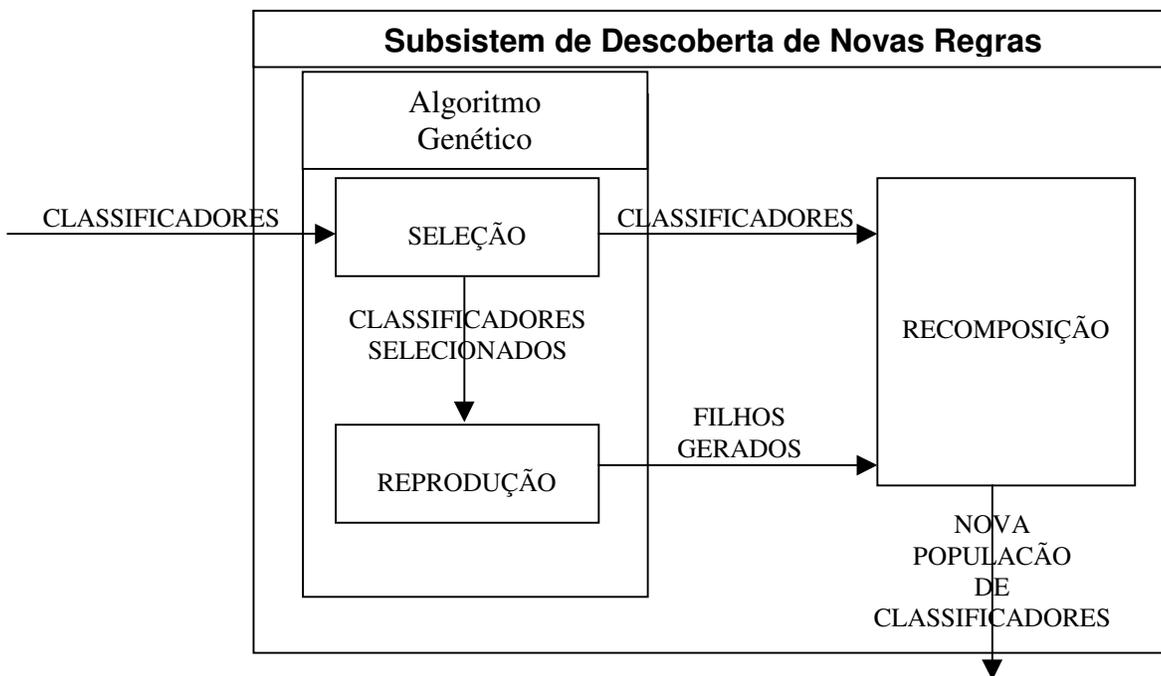


Figura 4.7 – Fluxo Interno do Subsistema de Descoberta de Novas Regras

Decidida a forma de representação do classificador, ele será tratado como um “cromossomo”. Como já mencionado no Capítulo 3, existem variações para esta codificação. Em nosso caso, adotamos representação em ponto flutuante (Michalewicz, 1996) na parte conseqüente do classificador e representação binária na parte antecedente.

Criamos aleatoriamente a população inicial de indivíduos a evoluir. Em seguida, calculamos uma medida de adequação, denominada “*fitness*” na literatura em inglês, a qual, em nossa aplicação, é representada pela energia (em inglês, “*strength*”) de cada classificador. Inicialmente, todos os classificadores têm a mesma energia.

Como já observado anteriormente, o valor da energia está associado à adequação do classificador ao ambiente, com o qual ele interage. A ação indicada pelo classificador vencedor pode ir contra ou a favor dos objetivos, de modo que o classificador poderá diminuir ou aumentar sua energia ao longo das iterações. Através desta medida, será possível a avaliação de cada um durante o processo evolutivo.

Uma vez criada a população e atribuída a energia de cada classificador, aplicamos, após uma época de iterações (seqüência de ações indicadas pelos classificadores vencedores a cada passo), os operadores de seleção, crossover e mutação. Os operadores de crossover adotados foram do tipo crossover simples para a parte antecedente e crossover aritmético para a parte conseqüente (esses operadores foram discutidos e listados no Capítulo 3). Para o operador de mutação, foram escolhidas a mutação simples para a parte antecedente e a mutação não-uniforme para a parte conseqüente (Michalewicz, 1996) .

A seleção se deu pelo mecanismo de “Roulette Wheel”, proposto por Goldberg (1983).

O tamanho da população inicial e das subseqüentes gerações foi definido empiricamente e mantido constante durante o processo de evolução.

No módulo “recomposição” (Figura 4.7), a substituição dos indivíduos ou classificadores menos aptos (baixa “energia”), obedece um tipo de seleção aleatória. Para cada filho gerado, uma percentagem da população original é selecionada e o classificador com menor energia é incluído em um conjunto, o qual servirá em seguida para as substituições. A partir

deste conjunto, o filho gerado substituirá o classificador com o qual ele possuir maior afinidade.

Mostraremos no próximo capítulo a codificação do processo de descoberta de novas regras.

4.5 - Algoritmo Simplificado

De forma simplificada, o algoritmo de geração de um Sistema Classificador está representado na Figura 4.8.

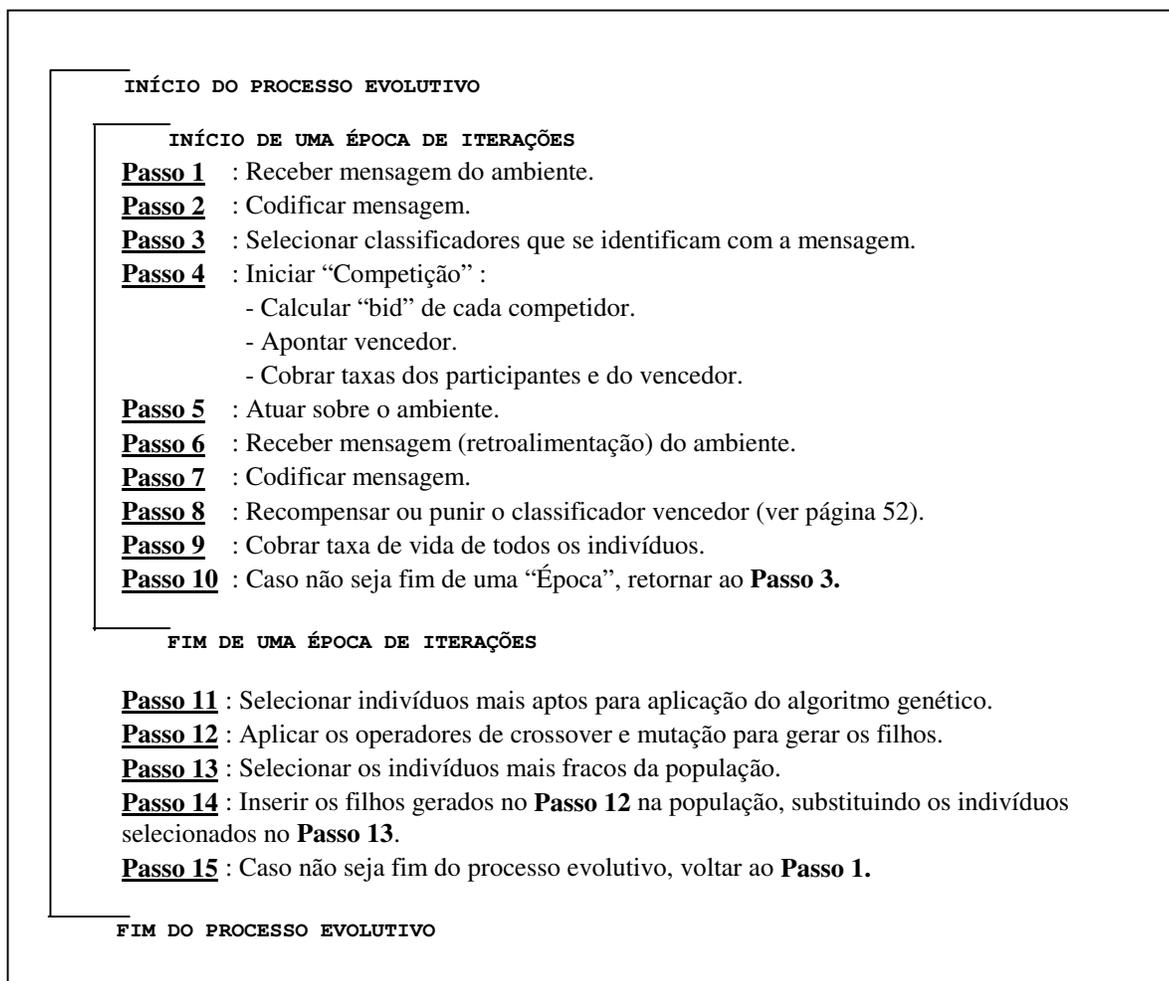


Figura 4.8 – Algoritmo Simplificado de Geração de um Sistema Classificador

4.6 - Exemplo Didático de Aplicação de um Sistema Classificador

Para ilustrar o funcionamento de um Sistema Classificador, vamos discutir as várias etapas de sua aplicação a exemplo didático: o controle de um veículo autônomo auto-guiado.

O ambiente computacional implementado para simulação do desempenho deste Sistema Classificador está representado na Figura 4.9 ⁽¹⁾, sendo que a área para deslocamento do veículo é de 700x700 unidades.

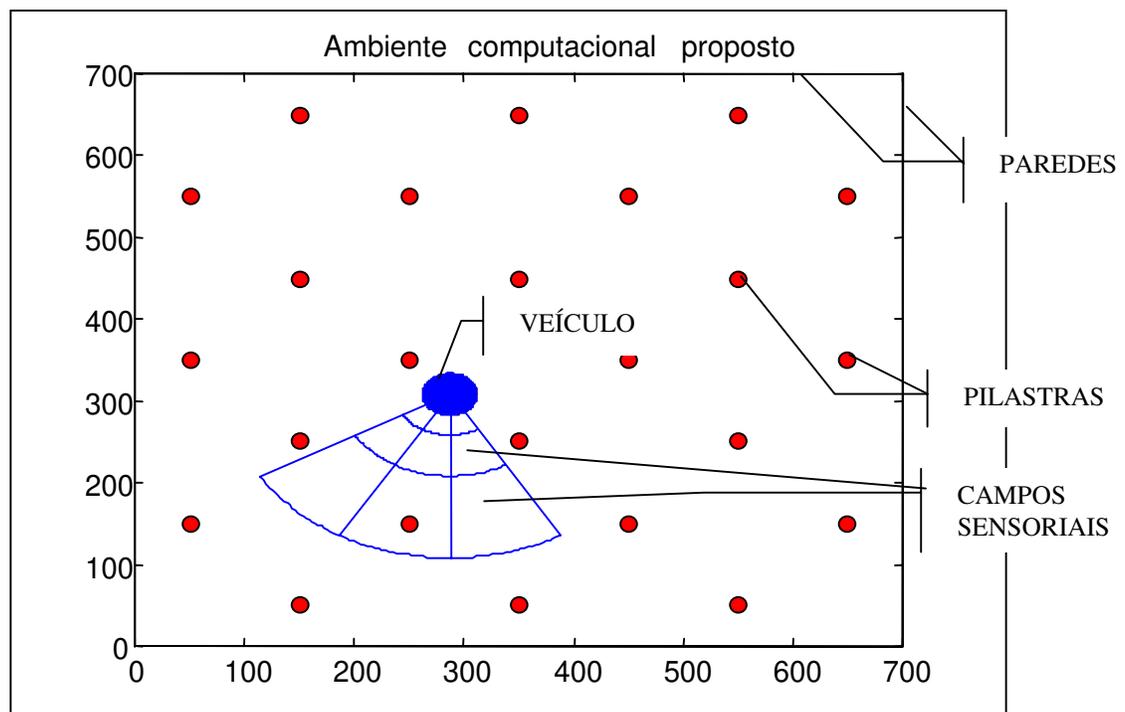


Figura 4.9 – Ambiente Computacional Proposto

O veículo deve desenvolver uma velocidade constante de 15 unidades por iteração,

⁽¹⁾ Este exemplo foi originalmente proposto em notas de aula da disciplina Computação Evolutiva (IA369-FEEC/UNICAMP-1998) pelos professores Fernando J. Von Zuben e Ricardo R. Gudwin.

podendo deslocar-se em linha reta ($\theta = 0$), à direita ($\theta = 15^\circ$) ou à esquerda ($\theta = -15^\circ$). Para decidir sobre os deslocamentos, o veículo possui dois sensores, um de visão, com nove campos sensoriais, os quais detectarão a presença de pilastras ou paredes (Figura 4.10), e outro de contato, para detecção de colisão.

O Sistema Classificador

Cada classificador será representado por uma regra, constituída por um vetor de 11 posições, onde as 9 primeiras posições refletem os nove campos sensoriais do sensor de visão (chamada “parte antecedente”). As 10^a e 11^a posições representam as ações a serem tomadas (“parte conseqüente”); “00” ou “11” significa siga em frente, “01” significa vire 15° à direita, e “10” significa vire 15° à esquerda .

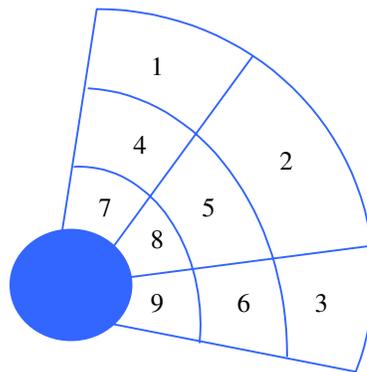


Figura 4.10 – O Veículo e seus Campos Sensoriais

Tanto a parte antecedente quanto a parte conseqüente serão criadas aleatoriamente para a população inicial. A cada classificador será designada uma energia inicial de 100 unidades. A especificidade de cada classificador será calculada com a metodologia descrita na Equação 4.5.

A Evolução

Caso um classificador obtenha êxito em sua ação, ele será recompensado, somando-se 1 unidade à sua energia. Caso contrário, ele será punido, subtraindo-se 2 unidades de energia.

Adota-se um algoritmo genético para criação de novas regras, o qual será aplicado a cada período de 100 iterações. Uma vez selecionado o par para reprodução, a taxa de crossover aplicada será de 100%, enquanto que a taxa de mutação aplicada será de 2%. Apenas 10% da população será selecionada para reprodução, o que significa um total de 10% da população original sendo substituída pela nova geração.

Um Ciclo Completo de Evolução

Durante esta simulação, vamos acompanhar todos os passos descritos no Algoritmo Simplificado (Figura 4.8), supondo que algumas iterações já foram realizadas – assim, já existe um valor distinto de energia atribuída a cada classificador. Formularemos a hipótese de que o veículo encontra-se na posição ilustrada na Figura 4.9.

Para efeito de demonstração, vamos supor também que após o Passo 10 (Figura 4.8) caracterizar-se-á o final de uma “época” de iterações, permitindo-nos visualizar a fase de descoberta de novas regras.

- Passos 1, 2 e 3** :
- Receber mensagem do ambiente
 - Codificar mensagem
 - Selecionar classificadores que se identificam com a mensagem

MENSAGEM
DO AMBIENTE

010000000



CLASSIFICADORES
IDENTIFICADOS

Rótulo	Classificador
A	##00###0# : 01
B	01# 000###: 11
C	010#0#0#0 : 00

POPULAÇÃO DE
CLASSIFICADORES

CLASSIFICADOR	ENERGIA
##00###0# : 01	80
010110000 : 11	20
101011000 : 10	10
0#1#1#1#1 : 01	98
01# 000###: 11	87
#11##1##1 : 01	45
010#0#0#0 : 00	67
.	
.	
.	

Comentários :

- no processo de codificação da mensagem, o estado detectado pelos campos sensoriais foi transformado em uma seqüência de bits 010000000, indicando a existência de um obstáculo no campo 2 (veja Figuras 4.9 e 4.10).
- para esta mensagem do ambiente, foram selecionados 3 classificadores (A, B e C), os quais sugerem como próxima ação: vire 15° à direita (01) ou siga em frente (11 e 00), respectivamente.

Passo 4 :

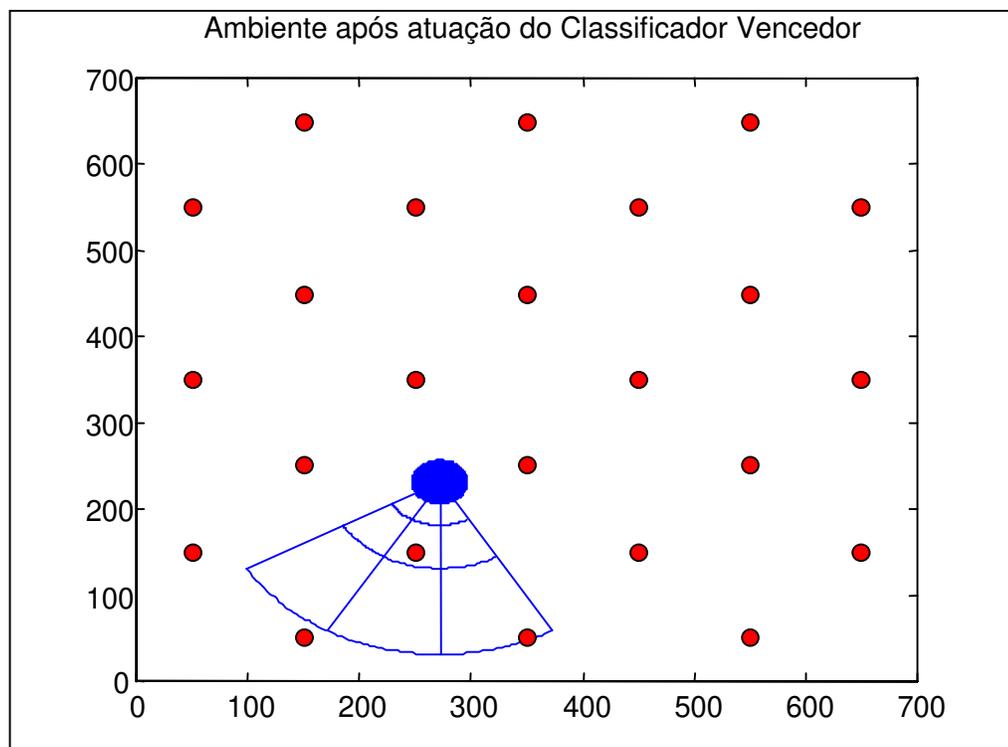
- Iniciar “Competição” :
 - Calcular “bid” de cada competidor.
 - Apontar vencedor.
 - Cobrar taxas dos participantes e do vencedor.

Hipótese	S_t	Spec	Bid_t	N_t	$eBid_t$	Regra Vencedora	Taxa_bid	Novo S_t
A	80	0,3333	1,0221	-1,6656	0,6581	B	0,003	79,997
B	87	0,5556	1,2726	0,1253	1,0068		0,004	86,996
C	67	0,6667	1,0421	0,2877	0,8641		0,003	66,997

Regra Vencedora	Ação	S_t	Bid_t	Novo S_t
B	“11” - “siga em frente”	86,996	1,2726	85,723

Comentários : • a regra B vencedora indica que o veículo deve seguir em frente

Passo 5 : • Atuar sobre o ambiente

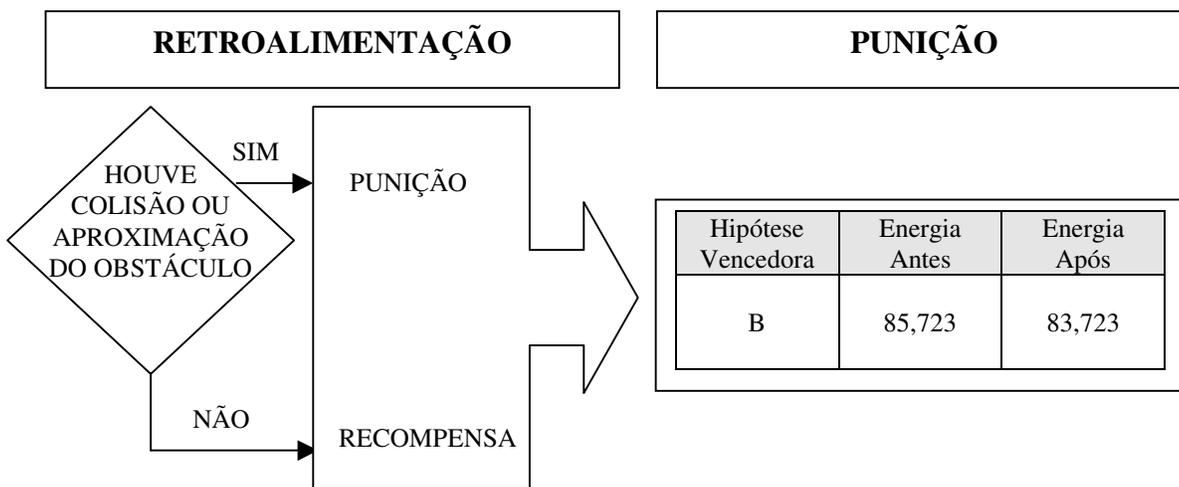


Comentários :

- o veículo segue em frente, deslocando-se 15 unidades de distância sem sofrer colisão

Passos 6,7 e 8 :

- Receber mensagem (retroalimentação) do ambiente
- Codificar mensagem
- Recompensar ou punir classificador vencedor



Comentários :

- não houve colisão resultante da aplicação da regra B, entretanto a ação proposta fez com que a pilastra invadisse um campo sensorial mais interno
- a regra B será “punida” com um decréscimo em sua energia

Passos 9 :

- Cobrar taxa de vida de todos os indivíduos

TAXA DE VIDA

$$Taxa_v = 1 - \left(\frac{1}{2}\right)^{\frac{1}{n}} = 0,0069, \text{ com } n = 100.$$

POPULAÇÃO DE CLASSIFICADORES

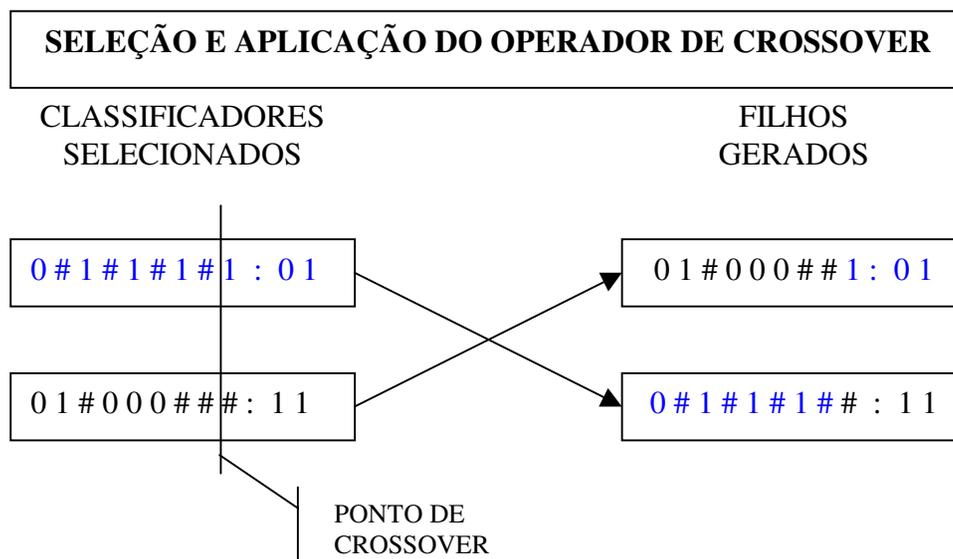
CLASSIFICADOR	ENERGIA	ENERGIA APÓS COBRANÇA DA TAXA
##00##0# : 01	79,997	79,444
010110000 : 11	20,000	19,861
101011000 : 10	10,000	9,930
0#1#1#1#1 : 01	98,000	97,323
01#000### : 11	83,723	83,124
#11##1##1 : 01	45,000	44,689
010#0#0#0 : 00	66,997	66,534
	.	
	.	
	.	

Comentários :

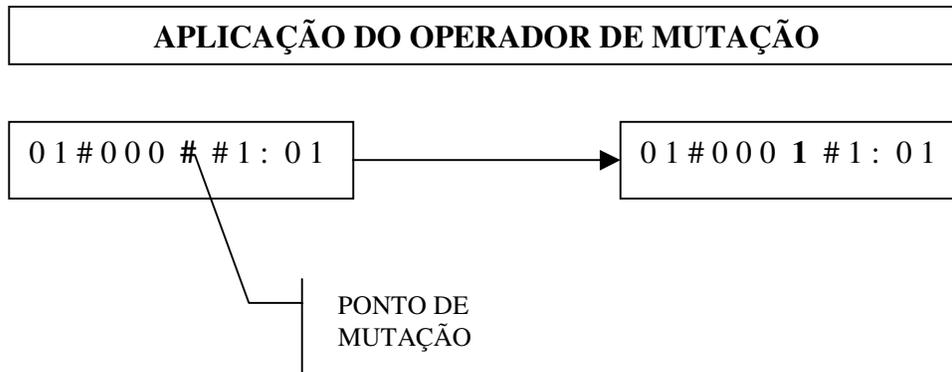
- a taxa de vida foi calculada considerando-se $n = 100$ (número de iterações antes da aplicação do algoritmo genético)
- apenas o classificador que venceu a competição sofreu um maior decréscimo em sua energia, devido à punição que recebeu.

Passos 11 e 12 :

- Selecionar indivíduos mais aptos para aplicação do algoritmo genético
- Aplicar os operadores de crossover e mutação para gerar os filhos



Comentários : • o ponto de crossover foi selecionado aleatoriamente (logo após locus nº 8)

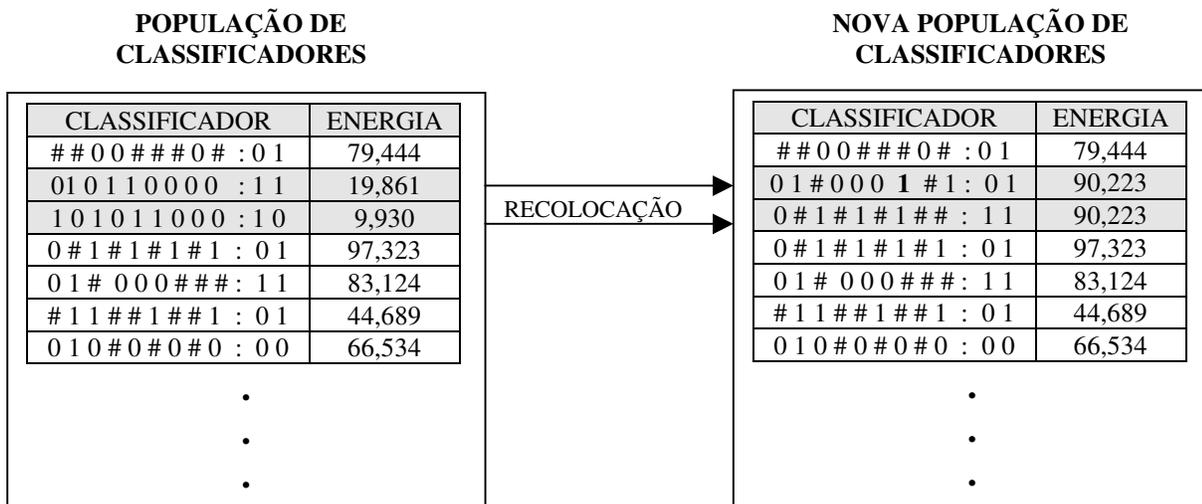


Comentários :

- foi escolhido aleatoriamente o gene do locus nº 7
- como trata-se do símbolo “#”, este poderá ser “mutado” para “0” ou “1”

Passos 13 e 14 :

- Selecionar os indivíduos mais fracos da população.
- Inserir os filhos gerados no **Passo 12** na população, substituindo os indivíduos selecionados no **Passo 13**.



- Comentários :**
- os filhos gerados substituíram os indivíduos mais fracos (com menor energia)
 - o *strength* dos filhos será calculado pela média do *strength* dos pais
 - como descrito na seção 4.4, existem alternativas a esta substituição direta

4.7 - Especialização para Redução de Perdas Elétricas

Quando aplicamos os Sistemas Classificadores a um determinado problema, são necessárias especializações para as características de cada aplicação. As especializações para redução de perdas em sistemas de distribuição de energia elétrica serão detalhadas no Capítulo 5.

5 SISTEMAS CLASSIFICADORES APLICADOS AO PROBLEMA DE MINIMIZAÇÃO DE PERDAS

Como já mencionado no Capítulo 2, pode-se reduzir as perdas de energia elétrica reconfigurando-se a rede de distribuição através da abertura e fechamento de chaves. A função do Sistema Classificador é apontar qual a configuração de chaves ideal para redução das perdas, para cada perfil de demanda, que pode ser fixa ou variável. Para se realizar o processo de codificação, utiliza-se os dados da rede, verificados nos nós e arcos que compõem o grafo. Entende-se como dados da rede as especificações consideradas como invariantes nesta abordagem do problema (número de nós de demanda, número de arcos, ligações entre os nós, resistências, reatâncias e tensão no barramento da subestação). Neste capítulo, descreveremos a interface entre o Sistema Classificador e o ambiente (a rede de distribuição), que pode ser estacionário ou variante no tempo, e a implementação de cada subsistema que compõe o Sistema Classificador.

5.1 - Interface com o Ambiente

Como discutido no Capítulo 4 (e resumido na Figura 4.1), o Sistema Classificador deve interagir com o ambiente através dos “detectores” de mensagens, dos “executores” e da “retroalimentação”.

Detectores

A rede de distribuição passa como mensagem ao Sistema Classificador o fluxo de energia em cada arco do grafo. Uma vez captada esta mensagem pelos detectores, ela deve ser codificada de forma a ser processada internamente. É evidente que o fluxo de energia nos arcos do grafo é função do perfil de demanda presente na rede de distribuição.

Neste trabalho, o fluxo de cada arco (um número real) é quantizado em 4 níveis para transformar-se em uma representação de 2 (dois) bits. Portanto, adotou-se uma classificação dos fluxos em quatro níveis ou setores. Por exemplo, se tivermos um fluxo máximo MAX (identificado como o maior fluxo de carga nas linhas de transmissão e calculado por equações recursivas de fluxo de carga – Apêndice A), o nível/setor 1 engloba os fluxos f de 0 a $\lfloor \text{MAX}/4 \rfloor$, o nível/setor 2 de $\lfloor (\text{MAX}/4)+1 \rfloor$ a $\lfloor \text{MAX}/2 \rfloor$, o nível/setor 3 de $\lfloor (\text{MAX}/2)+1 \rfloor$ a $\lfloor 3*\text{MAX}/4 \rfloor$ e o nível/setor 4 de $\lfloor (3*\text{MAX}/4)+1 \rfloor$ a $\lfloor \text{MAX} \rfloor$ ⁽¹⁾. As Tabelas 5.1 e 5.2 ilustram este processo de codificação da mensagem.

Tabela 5.1 – Quantização do Fluxo de Carga

SETORES Fluxo : 0 a MAX (kW) Cada Setor : $\lfloor \text{MAX} / 4 \rfloor$ (kW)			
1	2	3	4
0 a $\lfloor \text{MAX}/4 \rfloor$	$\lfloor \text{MAX}/4+1 \rfloor$ a $\lfloor \text{MAX}/2 \rfloor$	$\lfloor \text{MAX}/2+1 \rfloor$ a $\lfloor 3*\text{MAX}/4 \rfloor$	$\lfloor 3*\text{MAX}/4+1 \rfloor$ a $\lfloor \text{MAX} \rfloor$

Identificado o setor ao qual cada fluxo f pertence, este é transformado em uma seqüência binária. Continuando o exemplo anterior, seja $f_1 = 1680$, o fluxo no arco 1. Neste caso, f_1 pertence ao setor 3 e é representado pela seqüência “10”.

Tabela 5.2 - Exemplo de Codificação para MAX = 3140 (kW)

SETOR	DE	ATÉ	EM BINÁRIO
1	0	784	00
2	785	1569	01
3	1570	2354	10
4	2355	3140	11

Como tem-se um fluxo associado a cada arco e cada arco é representado por 2 bits, o número de bits na parte antecedente de cada classificador vai corresponder a duas vezes o número de arcos do grafo.

¹ O símbolo “ $\lfloor \rfloor$ ” representa truncamento do resultado da expressão, mantendo-se somente a parte inteira.

para o processo de evolução da população de classificadores), a partir de um conjunto de arcos com custo ou peso fixo. Em nosso caso, adotamos o algoritmo de Sollin (Apêndice B), mais indicado para a geração de árvores esparsas (Ahuja *et al.*, 1993) – situação típica das redes de distribuição de energia elétrica.

Observe nas Figuras 5.2 e 5.3 um exemplo de codificação da parte conseqüente do classificador antes e depois da aplicação do Algoritmo de Sollin, respectivamente.

PARTE CONSEQÜENTE DE UM CLASSIFICADOR																		
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
0.15	0.28	0.78	0.29	0.74	0.02	0.35	0.45	0.26	0.90	0.48	0.64	0.82	0.19	0.76	0.39	0.91	0.05	0.59
20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	
0.27	0.43	0.60	0.56	0.93	0.23	0.78	0.39	0.83	0.71	0.49	0.14	0.42	0.62	0.46	0.71	0.42	0.86	
CUSTO OU PESO DO ARCO										NÚMERO DO ARCO								

Figura 5.2 – Exemplo de Codificação da Parte Conseqüente do Classificador Antes da Aplicação do Algoritmo de Sollin

PARTE CONSEQÜENTE DE UM CLASSIFICADOR																		
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
1	1	0	1	1	1	1	1	1	0	1	1	0	1	1	1	0	1	1
20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	
1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	
1 – FECHADO 0 – ABERTO										NÚMERO DO ARCO								

Figura 5.3 – Exemplo de Codificação da Parte Conseqüente do Classificador Após a Aplicação do Algoritmo de Sollin

Retroalimentação

Após a aplicação da ação proposta pelo Sistema Classificador, o ambiente apresentará uma mensagem com sua nova configuração. Esta retroalimentação será avaliada pelo cálculo do nível de perda do sistema após a intervenção do classificador. Caso a perda tenha aumentado, o Sistema Classificador será punido de forma que a regra ativa no momento não receberá nenhum crédito pela sua atuação. Caso contrário, ou seja, se a perda diminuir, o Sistema Classificador será recompensado levando-se em consideração a redução das perdas. Adotamos a remuneração especificada na Equação 5.1, inspirada no trabalho de Richards (1995).

$$R_t = \left(\frac{2 * P_{t-1} - P_t}{P_{t-1}} \right) * Taxa_r \quad (5.1)$$

onde :

R_t	-	valor da recompensa no instante t
P_{t-1}	-	perda anterior do sistema, no instante $t-1$
P_t	-	perda atual do sistema, no instante t
$Taxa_r$	-	fator de recompensa, igual a 7,5 (Richards,1995)

Tendo detalhado a interação com o ambiente, descreveremos em seguida os detalhes de implementação dentro de cada subsistema.

5.2 - Subsistema de Tratamento de Regras e Mensagens

Como já visto anteriormente, a mensagem proveniente do ambiente necessita ser codificada em uma linguagem inteligível ao Sistema Classificador. No exemplo a seguir, ilustrado pelas Figuras 5.4 e 5.5, temos uma mensagem gerada pelo ambiente e a sua correspondente codificação.

MENSAGEM GERADA PELO AMBIENTE																		
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
3715	2775	2405	2285	2165	1430	1010	800	740	650	450	390	330	270	210	150	60	740	320
20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	
120	60	250	150	90	690	630	540	450	300	210	150	90	0	0	0	0	0	

VALOR DO FLUXO DE POTÊNCIA NÚMERO DO ARCO

Figura 5.4 – Exemplo de Mensagem Gerada com a Configuração do Ambiente (uma Rede de Distribuição com 37 arcos)

MENSAGEM CODIFICADA																								
BITS REFERENTES AO FLUXO NO ARCO 1																								
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	0	1	0	1
26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50
0	0	1	0	1	0	1	0	0	1	1	1	0	0	1	0	0	0	1	0	1	0	0	1	0
51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73	74	
1	0	1	0	1	0	0	1	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	

VALOR BINÁRIO

Figura 5.5 – Exemplo de Mensagem Codificada em Binário

Após a codificação da mensagem, passamos à fase de comparação, a qual é executada pelo cálculo de uma variante da Distância de Hamming, descrita no Capítulo 4, na Equação 4.1.

Na etapa de taxação deste Subsistema de Tratamento de Regras e Mensagens, é cobrada de toda a população de classificadores uma “taxa de vida” (Capítulo 4, Equação 4.2). Esta taxa leva em consideração a meia vida (parâmetro n), do indivíduo (um classificador). Adotamos $n = 150$, que corresponde ao período de aplicação, em número de iterações, do algoritmo genético à população. Este intervalo refere-se ao final de uma “época” de iterações (Seção 5.5).

5.3 - Subsistema de Apropriação de Crédito

Uma vez determinados os classificadores aptos a participar da fase de competição, passamos ao cálculo do “bid efetivo” (Equação 4.3) e do “bid” (Equação 4.4) de cada indivíduo. Apresentamos na Tabela 5.3 os valores adotados para cada parâmetro utilizado. Inspirados nos trabalhos de Goldberg (1983) e Richards (1995), todos os valores foram selecionados a partir de numerosos testes de adequação, baseados em experimentos de tentativa e erro.

Tabela 5.3 – Parâmetros Adotados

PARÂMETRO	VALOR ADOTADO
σ_{bid}	0,1000
k_0	0,1000
k_1	0,1000
k_2	0,0833
$SPow$	3,0000
Bid_{tax}	0,0030

Conforme apresentado no Capítulo 4, Equação 4.6, uma taxa de participação é cobrada de cada classificador que participa da competição. Adotamos para o parâmetro Bid_{tax} o valor de 0,0030 (Tabela 5.3).

De acordo com a Equação 5.1, calculamos a recompensa com base na redução de perdas de energia obtida com a configuração de rede proposta pelo classificador vencedor.

5.4 - Subsistema de Descoberta de Novas Regras

Seguindo as especificações e conceitos apresentados no Capítulo 3, o algoritmo genético é aplicado a 10% da população de classificadores; a população é selecionada com base na energia (fitness) de cada indivíduo. A percentagem de crossover adotada é de 100% e a de mutação 1%. São criados parâmetros distintos para aplicação dos operadores a cada parte do indivíduo (antecedente e conseqüente). Na parte antecedente, é aplicado o crossover simples e mutação com 50% de chance para cada um dos dois “alelos” restantes (lembramos que os valores possíveis são 0, 1 e #). Na parte conseqüente, são aplicados crossover simples e mutação uniforme, específica para representação em ponto flutuante (Michalewicz, 1996).

A população inicial de indivíduos (classificadores ou regras) é criada aleatoriamente. Na parte antecedente, a probabilidade inicial de encontrar-se o símbolo “#” é de 70 %. A energia (ou *strength*) inicial de cada um é de 20 unidades.

No processo de recomposição das regras, seguimos um mecanismo de reposição adotada por Richards (1995). Esse mecanismo, descrito a seguir, está representado nas Figuras 5.6 e 5.7.

Durante a Fase I, criamos uma coleção de indivíduos, classificadores ou regras, candidatos à reposição (uma subpopulação) a partir de seleções aleatórias dentro da população, as quais obedecem ao que chamamos de “fator de reposição”, discutido no próximo parágrafo.

Determinamos primeiramente o tamanho da subpopulação (em nosso caso 30% da população original). Em seguida, entramos em um processo iterativo pelo qual uma pequena fração da população é escolhida aleatoriamente (adotamos a quantidade de 3 indivíduos).

Desta pequena fração, selecionamos o indivíduo com menor energia ou *strength* e introduzimo-lo na subpopulação.

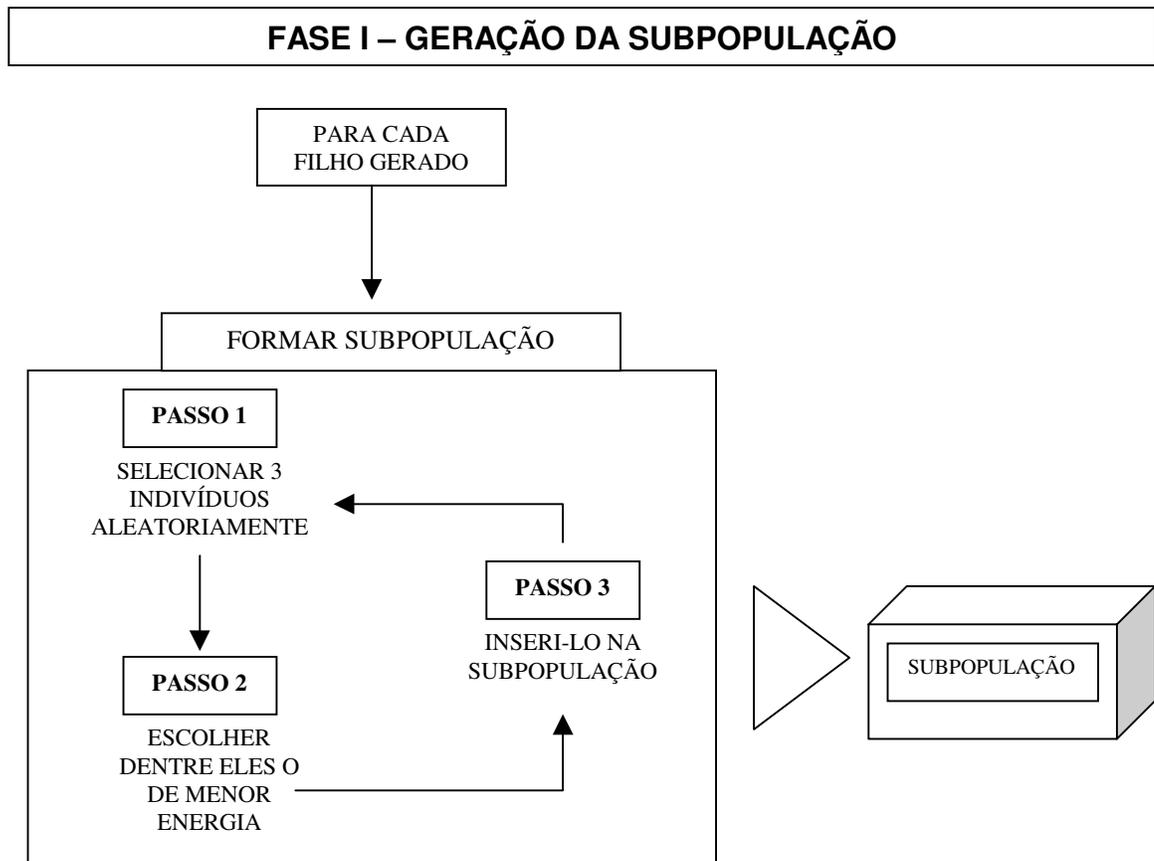


Figura 5.6 – Fase I da Regra de Reposição

Desta forma, espera-se formar uma subpopulação com os indivíduos menos aptos à sobrevivência, ou seja, com baixa energia. O processo continua até a formação da subpopulação ou coleção de indivíduos candidatos à reposição.

Na Fase II, um filho gerado por pais da população atual substituirá um classificador da subpopulação obtida na Fase I, com o qual tiver maior “afinidade”. A afinidade é caracterizada pelo número de bits em comum no antecedente dos dois classificadores.



Figura 5.7 – Fase II da Regra de Reposição

5.5 - Algoritmo e Aplicação

Embora os Sistemas Classificadores sejam particularmente adequados para fornecer soluções no caso de “ambientes” variantes no tempo, verificamos também a produção de boas taxas de convergência do Sistema Classificador para situações em que as demandas não variam.

Portanto, dividimos nossa aplicação em dois casos, descritos a seguir. Para os dois casos, utilizamos como base o conjunto de treinamento apresentado no Capítulo 3, Figura 3.7, com perfis de demanda diferentes, os quais vão requerer configurações de chaves distintas.

Caso 1 : Perfil de Demanda Fixo

Primeiramente, empregamos o Sistema Classificador descrito no Capítulo 4, para o Perfil 1, com demanda fixa, do conjunto mostrado no Capítulo 3, Figura 3.7. Para avaliarmos o aprendizado, monitoramos o sistema, acompanhando os parâmetros criados para a análise de desempenho e promovendo intervenções quando necessário. Em princípio, determina-se um número máximo de 4500 iterações para o perfil de demanda apresentado.

Caso 2 : Perfil de Demanda Variável (Variações Abruptas e Suaves)

Para o **Caso 2**, com perfil de demanda variável, realizamos experimentos em 4 etapas. Na *Etapa I*, inicialmente o perfil de demanda do sistema sofre variações abruptas, com alterações acentuadas de demanda, representando praticamente o reinício do processo de geração de classificadores. Foram escolhidos os Perfis 1, 3 e 2 (Figura 3.7), os quais foram apresentados ao Sistema Classificador nesta seqüência. Como já observado no Capítulo 3, uma boa solução para o Perfil 1 não vai apresentar bom desempenho para os demais perfis, exigindo uma readaptação.

Em seguida, o objetivo foi o de promover variações suaves e periódicas nos perfis de demanda, mais condizentes com a operação diária de sistemas de distribuição. Inicialmente, na *Etapa II*, escolhemos um determinado perfil, Perfil 6 (Figura 3.7), e dobramos a demanda nos nós, obtendo um outro ponto de operação. Na *Etapa III*, escolhemos dois perfis do conjunto da Figura 3.7, Perfis 1 e 6. Iniciamos o treinamento com o Perfil 1 e fizemos a transição gradativa para o Perfil 6, escolhendo dois pontos intermediários, I1 e I2, os quais caracterizam pontos de transição suave. Finalmente na *Etapa IV*, submetemos o Sistema Classificador a variações suaves e cíclicas de demanda, introduzindo os perfis da *Etapa III* na seguinte ordem : 1 , I1, I2, 6, I2, I1, 1, I1, I2 e 6.

Em todos os casos, o objetivo é obter um Sistema Classificador suficientemente flexível

para indicar novas soluções, sempre que as variações de demanda comecem a interferir significativamente no nível de perdas, associado a uma determinada configuração da rede de distribuição (estado das chaves seccionadoras).

Seguindo o algoritmo descrito no Capítulo 4, Figura 4.7, definimos que cada “época” compreenderá a 150 iterações. O número de épocas depende do conjunto de treinamento e ficaram assim definidas :

- *Etapa I* - 20 épocas para cada perfil
- *Etapa II* - na primeira simulação, 35 épocas para o primeiro perfil e 45 épocas para o segundo; na segunda simulação, 30 épocas para cada perfil
- *Etapa III* - 20 épocas para cada perfil
- *Etapa IV* - 15 épocas para cada perfil

Adotamos, como parâmetro para análise de desempenho, a média das perdas de energia apresentadas pelo sistema de distribuição durante a evolução do Sistema Classificador.

5.6 - Resultados e Comentários

Primeiramente, notamos que o desempenho do Sistema Classificador está intimamente ligado à sua forma de interação com o ambiente. Verificamos que, conforme pode ser observado na Figura 5.8, durante o treinamento, a evolução das regras ou classificadores dependem da atuação efetiva do Sistema Classificador a cada iteração, mesmo com degradação de desempenho. Apesar desse tipo de interação às vezes promover uma piora do ambiente, ela mostrou-se necessária ao desenvolvimento do conjunto de regras. Seria possível impedir o aumento de perdas, simplesmente não adotando uma configuração de chaves que levasse a isso.

Mas, o desempenho do Sistema Classificador depende da retroalimentação efetiva do ambiente, a qual não ocorreria caso se permanecesse com a configuração de chaves anterior. Além disso, é importante evidenciar que em uma implementação prática do Sistema Classificador esta etapa de evolução de desempenho não será implementada na rede de distribuição real; é apenas uma etapa da simulação computacional que vai evoluir a solução a ser implementada.

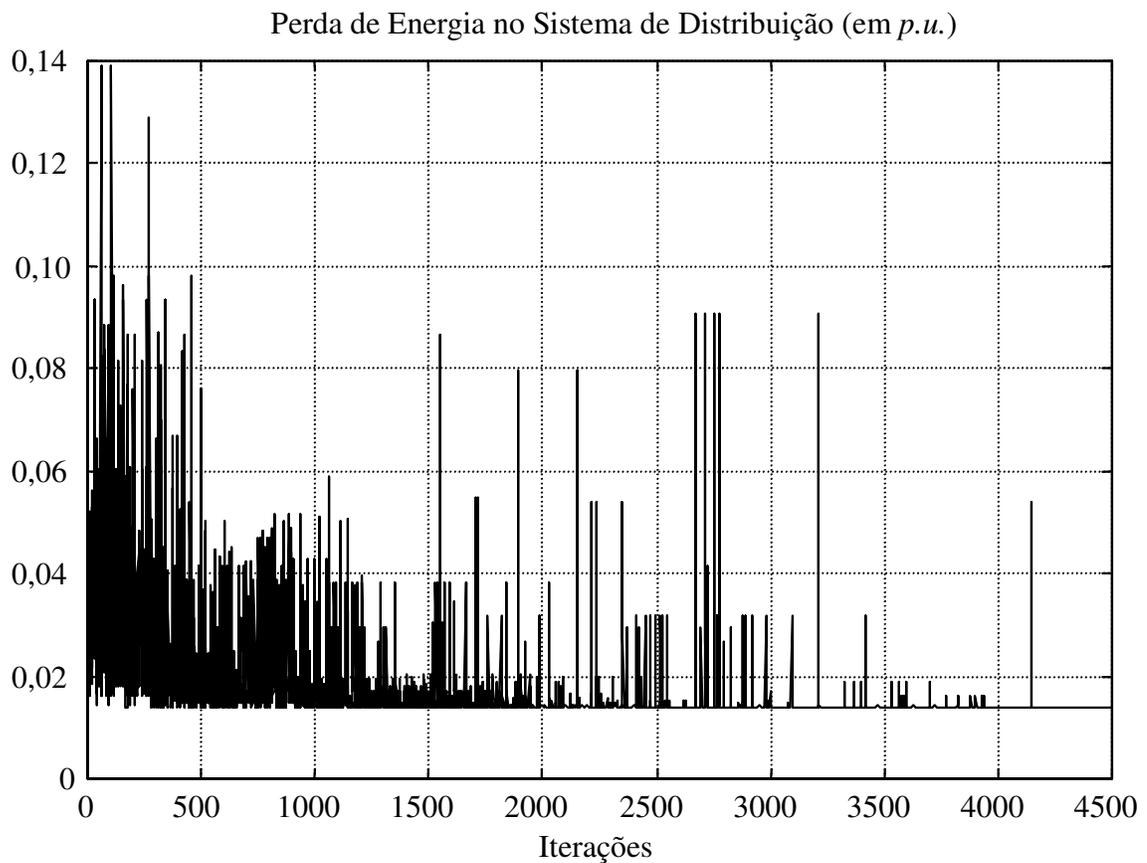


Figura 5.8 – Variação das Perdas de Energia Calculada a cada Iteração

Apresentamos na Figura 5.9, a relação entre a especificidade, caracterizada no Capítulo 4, Equação 4.5, e a energia (Capítulo 4, Seção 4.1) de um determinado conjunto de classificadores após o treinamento. Comprovamos a tendência da relação quase que inversa

entre a energia e a especificidade dos melhores indivíduos, ou seja, quanto melhor a regra (mais energia), menor é a sua especificidade (mais genérica).

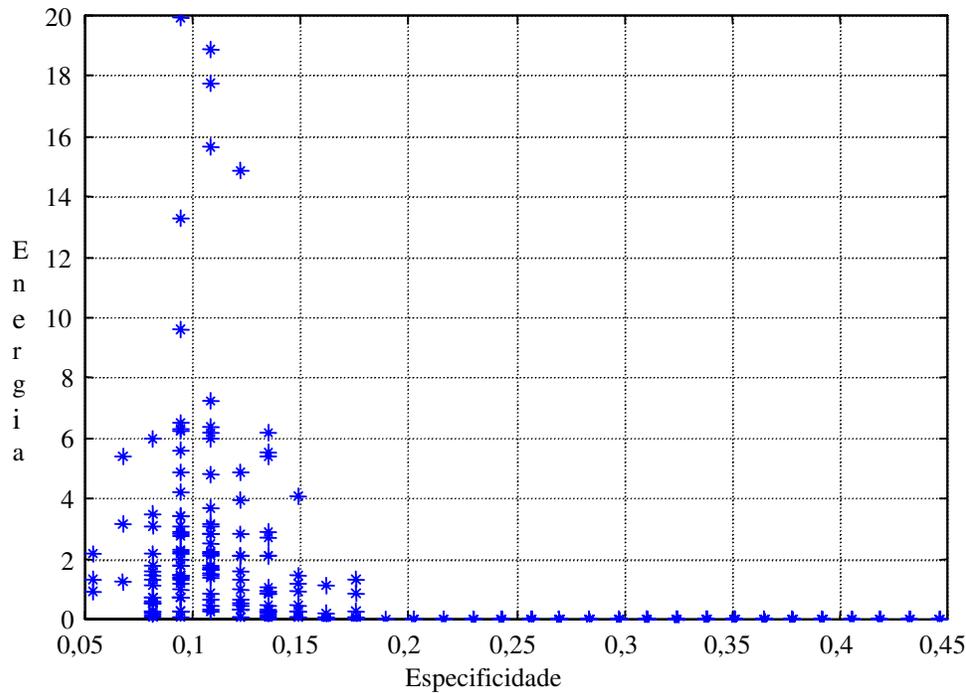


Figura 5.9 – Relação entre a Especificidade e a Energia da População

Para facilitar a análise do desempenho do Sistema Classificador, ao invés de utilizarmos a informação do valor das perdas no sistema à cada iteração, mostraremos nos próximos resultados e gráficos a média das perdas por época de iterações (150 iterações).

Apresentamos a seguir os resultados para cada caso abordado.

5.6.1 - Caso 1 : Perfil de Demanda Fixo

Mostramos na Figura 5.10, gráfico à esquerda, o desempenho do Sistema Classificador na redução das perdas. No gráfico à direita, temos a evolução da média de energia da população.

Empregando-se o Sistema Classificador para este **Caso 1**, obtivemos a configuração de

chaves abertas 7, 10, 14, 16 e 27, resultado muito próximo ao melhor resultado encontrado pelo Algoritmo Genético empregado no Capítulo 3 (chaves abertas: 7, 10, 14, 16 e 28). Observamos que o Sistema Classificador não é tão eficaz como o algoritmo genético, pois ele não assume o caráter estacionário do ambiente, mantendo ao longo do processo de busca de uma solução ótima a flexibilidade necessária para se adaptar a novas situações (não existentes aqui).

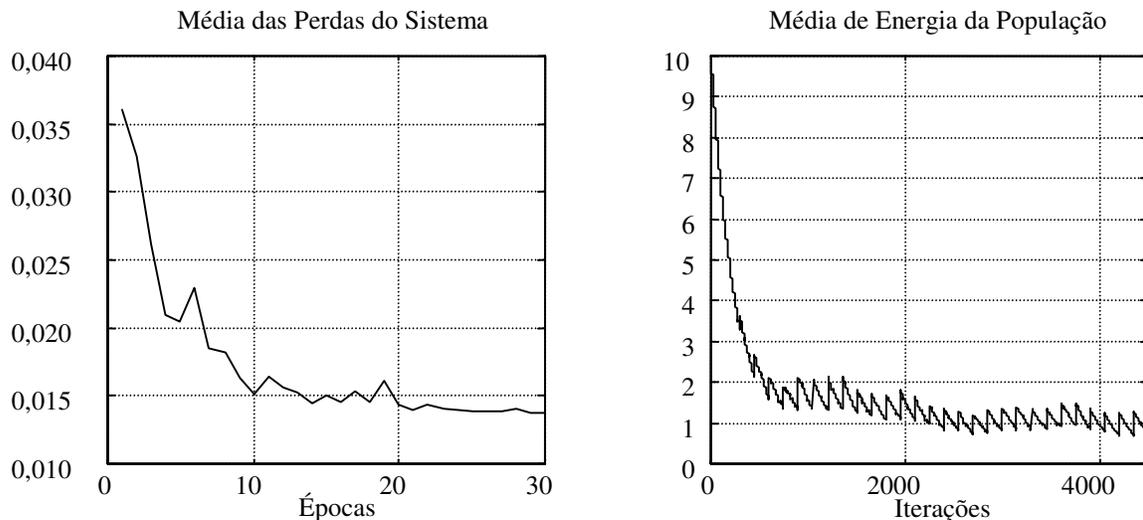


Figura 5.10 – Caso 1 : Desempenho e Evolução do Sistema Classificador

A média de energia da população da Figura 5.10, gráfico à direita, retrata a especialização do Sistema Classificador ao perfil apresentado, onde, após a evolução, apenas algumas regras possuem força para atuar sobre o ambiente. A maioria das regras já consumiu toda a sua carga de energia ou “strength”, não tendo mais força para competir com as regras mais adaptadas e que, por isso mesmo, mantiveram um nível de energia elevado.

5.6.2 - Caso 2 : Perfil de Demanda Variável

Etapa I - perfil de demanda com variação em degrau (Perfis 1, 3 e 2)

Observamos na Figura 5.11, gráfico à esquerda, o desempenho do Sistema Classificador para cada perfil introduzido. As retas na horizontal, a cada 20 épocas, representam o menor nível de perdas encontrado pelo algoritmo genético para cada perfil isoladamente (Capítulo 3). Apesar de não conseguir igualar o nível de perdas apresentado pelo algoritmo genético, o sistema foi capaz de acompanhar a variação do nível de perdas para cada perfil, apresentando progressos a cada novo perfil de demanda e propondo uma configuração final distinta para cada perfil introduzido.

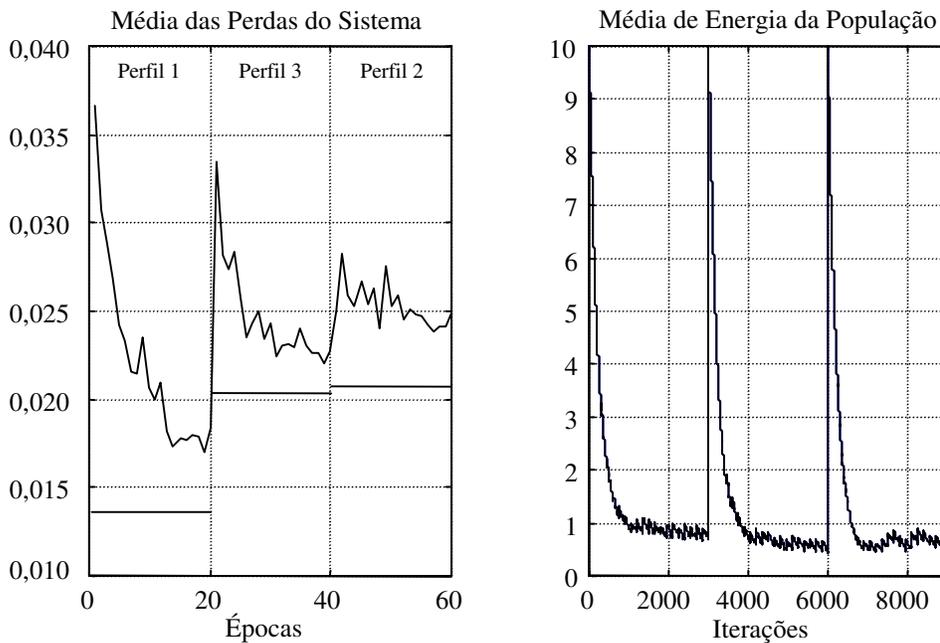


Figura 5.11 – Caso 2, Etapa 1 : Desempenho e Evolução do Sistema Classificador

Conforme pode ser observado na Figura 5.11, gráfico à direita, a cada introdução de um novo perfil, a energia de toda a população é recuperada automaticamente, igualando-se os valores de energia de todos os indivíduos. Isto caracteriza quase que um reinício do processo evolutivo. Apesar dessa recuperação de energia, o sistema entra em equilíbrio novamente, prevalecendo apenas as regras pertinentes ao final de cada período de evolução.

Novamente, todas as simulações partiram da mesma população inicial e o cálculo da redução de perdas leva em consideração a rede com a mesma configuração inicial de chaves

seccionadoras abertas, para todos os perfis. Observe na Tabela 5.4 a comparação entre as melhores configurações encontradas pelo Sistema Classificador e pelo Algoritmo Genético. Na coluna 2, temos o valor da perda calculada em cada perfil para a mesma configuração inicial (chaves : 33, 34, 35, 36 e 37) proposta por Baran & Wu (1989) (adotada aqui para permitir uma possível comparação com essa e outras abordagens), e na coluna 4, o valor da perda calculada para cada perfil, considerando-se a configuração proposta pelo fenótipo do melhor indivíduo encontrado.

Tabela 5.4 – Desempenho do Sistema Classificador e do Algoritmo Genético para os Perfis 1, 2 e 3

ALGORITMO GENÉTICO (tratando perfil fixo)				
PERFIL	PERDA INICIAL (em kW)	FENÓTIPO DO MELHOR INDIVÍDUO (chaves abertas)	PERDAS CALCULADAS PARA O MELHOR INDIVÍDUO (em kW)	% DE REDUÇÃO NAS PERDAS
1	216,1733	7-10-14-16-28	135,0730	37,51 %
2	375,1484	7-10-14-17-28	207,7695	44,61 %
3	372,8436	7-9-14-17-28	202,0010	45,82 %
SISTEMA CLASSIFICADOR				
PERFIL	PERDA INICIAL (em kW)	FENÓTIPO DO MELHOR INDIVÍDUO (chaves abertas)	PERDAS CALCULADAS PARA O MELHOR INDIVÍDUO (em kW)	% DE REDUÇÃO NAS PERDAS
1	216,1733	10-15-27-33-34	138,8658	35,76 %
2	375,1484	7-8-12-16-28	236,9504	36,83 %
3	372,8436	7-12-16-28-35	218,5224	41,39 %

Etapa II - perfil de demanda com variação em degrau (Perfis 6, e novo perfil com demandas duplicadas em relação ao Perfil 6)

Na Figura 5.12, gráfico à esquerda, temos o desempenho do Sistema Classificador para cada perfil apresentado. Nessa simulação, observamos uma melhora no nível de perdas quando da introdução do mesmo perfil com demandas duplicadas. A melhor configuração de chaves abertas, proposta pelo sistema, para o perfil com uma dada demanda foi 7,12,16,28 e 35, resultando em total de perdas igual a 226,8831 kW. Para o mesmo perfil, mas agora com demanda duplicada, o sistema propôs a mudança da configuração de chaves para 7, 10, 28, 32 e 34, resultando em uma diminuição do total de perdas calculadas para 839,6988 kW (o

equivalente a 209,9247 kW de perdas, se aplicadas ao perfil anterior, mas com demanda original). Esse comportamento deve-se ao aumento das demandas, o qual ocasionou um aumento significativo nas perdas, sinalizando com mais intensidade a necessidade de se alterar a configuração em busca das perdas mínimas.

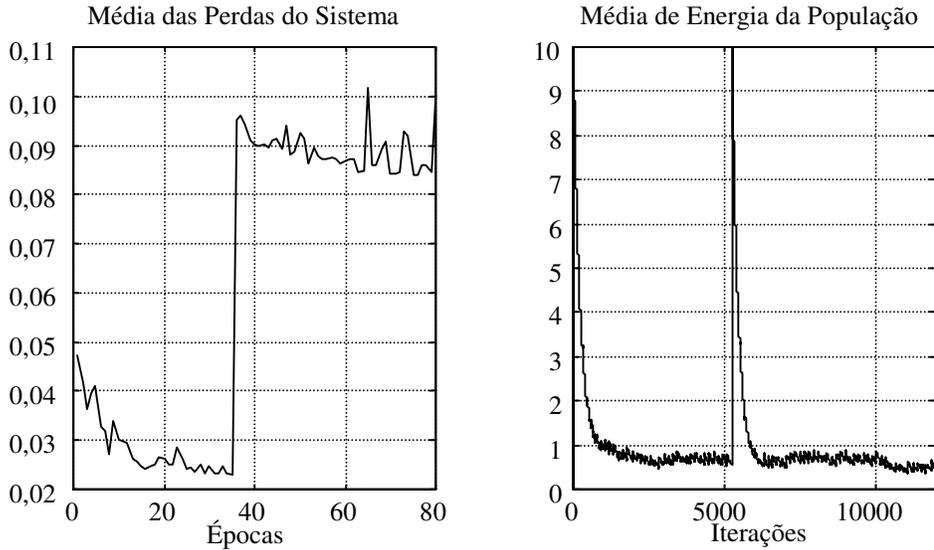


Figura 5.12 – Caso 2, Etapa II, 1ª Simulação : Desempenho e Evolução do Sistema Classificador

No entanto, como se trata de uma técnica que envolve operadores estocásticos, quando um nível de perdas satisfatório é encontrado já para o primeiro perfil de demandas, a configuração sugerida (no caso 7, 9 14, 27 e 32, com valor das perdas igual a 209,2404 kW) é mantida quando introduzimos o mesmo perfil com demandas dobradas (Figura 5.13).

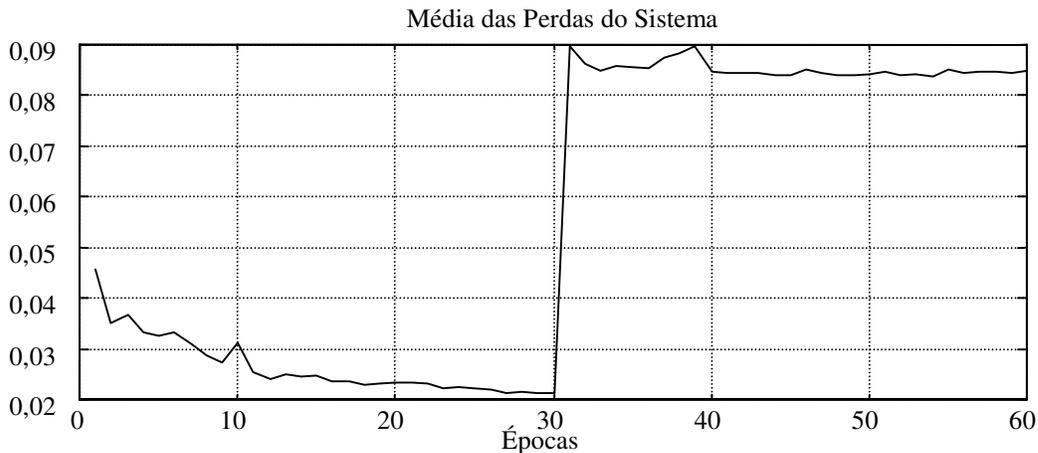


Figura 5.13 – Caso 2, Etapa II, 2ª Simulação : Desempenho do Sistema Classificador

Etapa III - perfil de demanda com variação suave (variação do Perfil 1 para o Perfil 6, com dois perfis intermediários, I1 e I2)

Ilustramos na Figura 5.14, gráfico à esquerda, o desempenho do Sistema Classificador na redução das perdas do sistema de distribuição. As retas na horizontal, a cada 20 épocas, representam o menor nível de perdas encontrado pelo Algoritmo Genético para cada perfil isoladamente (Capítulo 3).

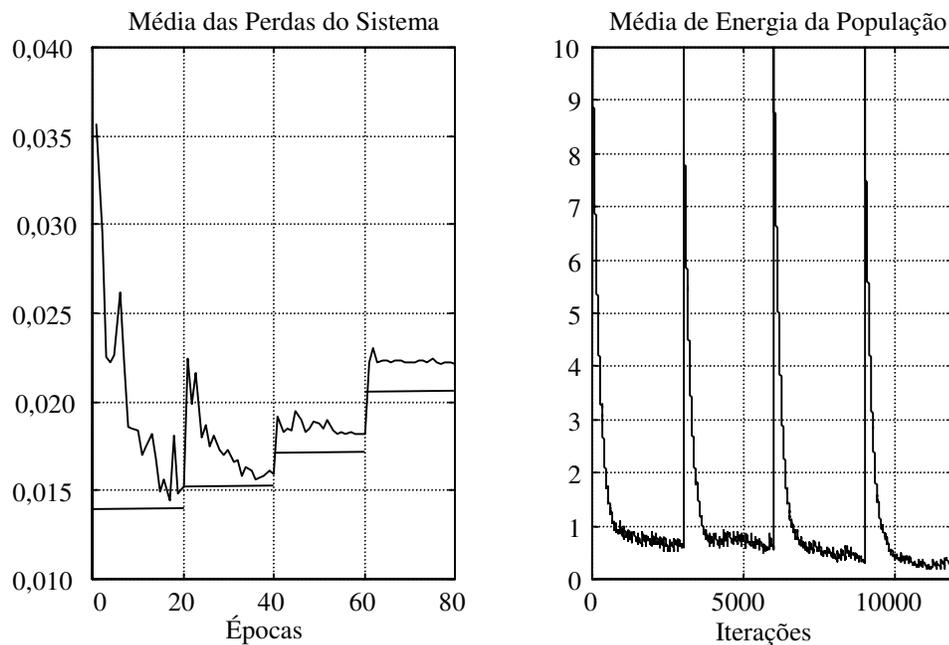


Figura 5.14 – Caso 2, *Etapa III* : Desempenho e Evolução do Sistema Classificador

Observe nas Tabelas 5.5 e 5.6 as melhores configurações encontradas pelo Algoritmo Genético e pelo Sistema Classificador, para os perfis 1, I1, I2 e 6. Na coluna 2, temos o valor das perdas calculadas em cada perfil para a mesma configuração inicial (chaves abertas: 33, 34, 35, 36 e 37) proposta por Baran & Wu (1989), e na coluna 4, o valor da perda calculada para cada perfil, considerando-se a configuração proposta pelo fenótipo do melhor indivíduo encontrado.

Tabela 5.5 –Desempenho do Algoritmo Genético para os Perfis 1, I1, I2 e 6

ALGORITMO GENÉTICO (tratando perfil fixo)				
PERFIL	PERDA INICIAL (em kW)	FENÓTIPO DO MELHOR INDIVÍDUO (chaves abertas)	PERDAS CALCULADAS PARA O MELHOR INDIVÍDUO (em kW)	% DE REDUÇÃO NAS PERDAS
1	216,17	7-10-14-16-28	135,07	37,51 %
I1	229,98	7-9-14-28-36	150,06	34,75 %
I2	252,15	7-9-14-28-36	172,65	31,52 %
6	292,83	7-9-14-32-37	204,12	30,29 %

Tabela 5.6 –Desempenho do Sistema Classificador para os Perfis do Caso 2, Etapa III

SISTEMA CLASSIFICADOR				
PERFIL	PERDA INICIAL (em kW)	FENÓTIPO DO MELHOR INDIVÍDUO (chaves abertas)	PERDAS CALCULADAS PARA O MELHOR INDIVÍDUO (em kW)	% DE REDUÇÃO NAS PERDAS
1	216,17	10-15-25-33-34	143,29	33,71 %
I1	229,98	7-10-15-27-34	156,47	31,96 %
I2	252,15	7-10-12-16-28	181,54	28,00 %
6	292,83	7-9-12-16-28	220,57	24,67 %

Novamente, apesar de não conseguir igualar o nível de perdas apresentado pelo Algoritmo Genético, o Sistema Classificador apresentou-se flexível, reagindo a cada variação de perfil de demanda apresentada, procurando melhorar o nível de perdas do sistema de distribuição, propondo novas configurações de chaves.

Etapa IV - perfil de demanda com variação suave

Podemos observar, na Figura 5.15, o desempenho adequado do Sistema Classificador para o perfil de demanda com variação cíclica (seqüência de perfis : 1, I1, I2, 6, I2, I1, 1, I1, I2, 6), confirmando suas características. As retas na horizontal, a cada 15 épocas a partir da época de número 90, representam o menor nível de perdas encontrado pelo algoritmo genético para cada perfil isoladamente (Tabela 5.5).

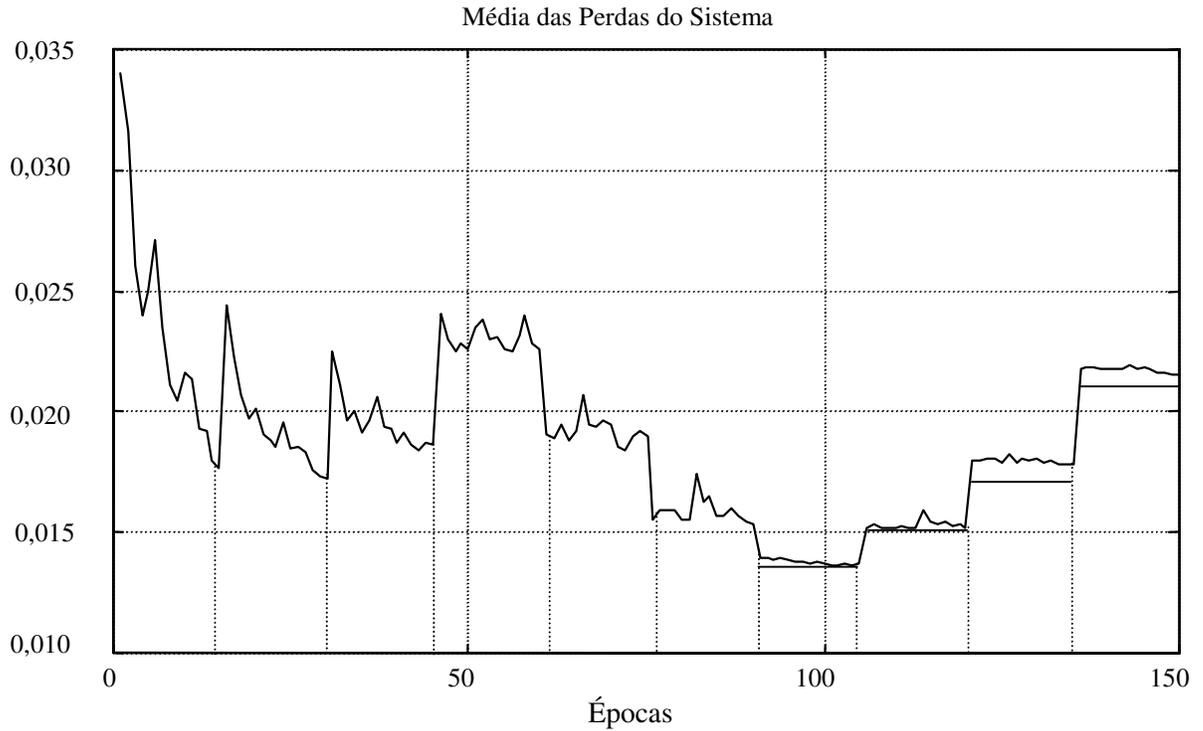


Figura 5.15 – Caso 2, Etapa IV : Desempenho do Sistema Classificador

Mostramos na Tabela 5.7 as melhores configurações propostas pelo Sistema Classificador para cada perfil apresentado.

Tabela 5.7 – Configurações Propostas pelo Sistema Classificador para o Caso 2, Etapa IV

PERFIL	FENÓTIPO DO MELHOR INDIVÍDUO (chaves abertas)	PERDAS CALCULADAS PARA O MELHOR INDIVÍDUO (em kW)
1	7 8 9 16 25	148,4455
I1	7 8 9 16 28	155,4287
I2	7 8 9 16 28	182,4509
6	7 8 9 16 28	221,7110
I2	7 8 9 17 28	181,0241
I1	7 9 14 16 28	150,4217
1	7 9 14 16 28	135,3916
I1	7 9 14 16 28	150,4217
I2	7 9 14 16 28	177,6978
6	7 9 14 28 36	207,2796

A cada mudança periódica e suave de perfil, o sistema foi capaz de não somente se adaptar a nova situação do ambiente, como também procurar melhorar seu desempenho a cada nova mudança, chegando nas últimas simulações quase que a uma condição estável. Esse fato retrata um comportamento esperado para um sistema complexo adaptativo, em que a exposição repetida a um dado estado do ambiente produz uma resposta de melhor qualidade. É muito provável que isso tenha ocorrido porque as regras que venceram na última vez que o perfil foi apresentado (regras do passado) ainda estavam presentes na população de regras, embora com um nível de energia menor. Portanto, podemos afirmar que o Sistema Classificador é um sistema suficientemente flexível para adaptar-se a novos contextos, nunca antes apresentados, e também eficaz na produção de respostas secundárias a estímulos do ambiente, reutilizando a memória do passado.

Para este último estudo de caso apresentado, investigamos também a queda de diversidade da população através do cálculo de um coeficiente de correlação amostral (Equação 5.2). Esse coeficiente faz parte de fórmulas estatísticas para dados amostrados, encontradas em Mardia *et al.* (1979).

$$r_{ij} = \frac{\sigma_{ij}}{\sigma_i \sigma_j} \quad (5.2)$$

onde :

- r_{ij} - coeficiente de correlação amostral entre as amostras i e j
- σ_{ij} - covariância amostral entre as amostras i e j
- σ_i - desvio padrão amostral da amostra i
- σ_j - desvio padrão amostral da amostra j

Inicialmente, calculamos o coeficiente de correlação entre todos os 500 indivíduos da população inicial (antes do processo evolutivo) e final (após o processo evolutivo) , totalizando 124.750 coeficientes de correlação para cada uma. Efetuamos esse cálculo da correlação

separadamente para a parte antecedente, conseqüente e para o indivíduo como um todo. Consideramos como medida de diversidade a quantidade de coeficientes de correlação maiores ou iguais a 0,5. Mostramos os resultados obtidos na Tabela 5.8.

Tabela 5.8 – Medida de Diversidade das Populações do Caso 2, Etapa IV

Parte	Quantidade de Indivíduos com coeficiente de correlação $r_{ij} \geq 0,5$	
	População INICIAL	População FINAL
Antecedente	3	4.931
Conseqüente	2.534	7.009
Antecedente + Conseqüente	84.628	81.941

Analisando os valores da Tabela 5.6, observamos que a diversidade da população diminui quando consideramos em separado as partes antecedente e conseqüente que compõem cada indivíduo.

Essa mesma diversidade praticamente se mantém equilibrada quando examinamos o indivíduo como um todo.

Essa observação caracteriza um comportamento de sistemas complexos adaptativos, que são capazes de explorar toda a potencialidade de módulos eficazes, pouco diversificados e já evoluídos (por exemplo, antecedentes e conseqüentes), ao combiná-los adequadamente na produção de classificadores bem diversificados (Holland, 1995; Holland, 1998).

6 CONCLUSÕES

6.1 - Comentários

O trabalho apresentou os desenvolvimentos metodológicos necessários à aplicação de Sistemas Classificadores na minimização de perdas em sistemas de distribuição de energia elétrica, com perfis de demanda fixa e variável em cada nó consumidor.

Primeiramente, foi comprovada a necessidade de mudanças de configuração na rede, pois foram encontradas configurações de redes específicas para redução de perdas junto a cada perfil de demanda. Tais resultados foram obtidos através de estudo de casos isolados para demandas distintas, mas fixas (constantes), aplicando um algoritmo genético com representação em ponto flutuante. Esta representação não havia sido explorada até o momento para este problema de minimização. A aplicação apresentou, para a rede proposta por Baran e Wu (1989), uma configuração de menores perdas do que a obtida por Costa (1999).

Com base nos experimentos computacionais com algoritmos genéticos, aplicados à otimização de redes para demandas fixas, propusemos uma nova abordagem por computação evolutiva para o caso de demanda variável, utilizando os conceitos de Sistemas Classificadores.

A aplicação de Sistemas Classificadores se justifica pelo fato destes apresentarem estratégias de aprendizado por exposição continuada a um ambiente a ser explorado, e serem suficientemente flexíveis para solução de problemas de otimização combinatória, sujeitos a comportamentos variantes no tempo. Isso se deve à capacidade dos Sistemas Classificadores de estabelecerem um compromisso entre as inovações recebidas do ambiente e a história passada, basicamente associada às repercussões das ações até então adotadas.

O sucesso da aplicação de Sistemas Classificadores depende da definição de diversos parâmetros de controle, como também da interação persistente entre o sistema e o ambiente. Conforme pôde ser observado, mesmo as interações que promovem pioras do ambiente são

necessárias ao desenvolvimento do conjunto de regras procurado, pois os Sistemas Classificadores necessitam da retroalimentação efetiva do ambiente.

Em outras abordagens envolvendo Sistemas Classificadores, encontramos duas fases : aprendizagem e aplicação. Na fase de aprendizagem, procura-se criar um sistema auto-suficiente através do treinamento exaustivo e a aplicação ocorre sem que haja qualquer adaptação adicional. Em nossa abordagem, esse procedimento torna-se impraticável devido à impossibilidade de se prever todos os perfis de demanda que podem surgir no ambiente.

Como os Sistemas Classificadores são formados por uma população de regras, observamos que, em alguns casos da literatura, essas regras podem ser interpretadas, resultando, ao final da evolução, em uma base de conhecimento (como em um Sistema Especialista, (Waterman, 1985)). Iniciativa análoga poderia ter sido adotada neste trabalho. No entanto, em virtude da explosão combinatória de possíveis perfis de demanda, uma base de regras que permitissem uma associação biunívoca entre todos os perfis de demanda e suas respectivas configurações ótimas de chaves, teria que ser muito grande, e portanto inviável. A base de regras do nosso Sistema Classificador em determinado instante, composta por um número reduzido de regras ativas, constitui uma representação contextual da associação entre os perfis de demanda e respectivas configurações. Esta base de regras está adaptada aos últimos perfis de demanda apresentados pelo ambiente. Após a convergência, apresenta regras com cerca de 80% de sua composição formada por símbolos # (*don't care*).

Em situações em que o ambiente é estacionário (demandas de energia elétrica fixas), observamos que o Sistema Classificador não é tão eficaz como o algoritmo genético, pois não explora o caráter estacionário do ambiente. Isso se deve à sua característica inerente de manter a flexibilidade durante a busca por uma solução ótima, o que lhe permite adaptar-se a novas situações. No entanto, esta flexibilidade é inútil em situações de ambiente estacionário, fazendo com que o seu desempenho seja inferior.

Para situações em que o ambiente apresentou variações abruptas (com grande mudança nas demandas dos nós), concluímos que, apesar de não conseguir igualar o nível de perdas apresentado pelo algoritmo genético (o qual foi aplicado a cada perfil isoladamente), o sistema

foi capaz de reagir à variação do nível de perdas para cada perfil, apresentando progressos a cada novo perfil de demanda introduzido e propondo uma configuração final distinta para cada um, quando pertinente.

A cada introdução de um novo perfil, foi necessária a recuperação da energia de toda a população, igualando-se os valores de energia de todos os indivíduos. Isto caracteriza quase que um reinício do processo evolutivo. No entanto não se configura de fato como um reinício, pois as regras já existentes eram mantidas e representavam o efeito de toda a ação passada do Sistema Classificador; ou seja, a base de conhecimento era preservada, mas a relação de valores era reiniciada. Apesar da recuperação abrupta de energia, o sistema sempre foi capaz de entrar em um outro estado de equilíbrio, mantendo uma nova relação de valores entre as regras ao final de cada período de evolução.

Analisando o comportamento do Sistema Classificador para um mesmo perfil, inicialmente com uma dada demanda e posteriormente com demanda duplicada, verificamos que o sistema melhorou o desempenho da rede de distribuição, propondo uma mudança na configuração que resultou em diminuição do total de perdas. Esse comportamento deve-se à duplicação das demandas, a qual ocasionou um aumento significativo nas perdas, sinalizando com mais intensidade a necessidade de se alterar a configuração em busca de perdas mínimas.

Continuando a avaliação do desempenho do Sistema Classificador em ambientes não-estacionários, mas com variações suaves (demandas de energia elétrica com variações suaves), verificamos que o sistema apresentou-se flexível, reagindo a cada variação de perfil de demanda apresentada, propondo novas configurações de chaves quando necessário e procurando sempre reduzir o nível de perdas do sistema de distribuição.

Finalmente, expusemos o Sistema Classificador a um ambiente com comportamento não-estacionário cíclico. O sistema apresentou um comportamento esperado para um sistema complexo adaptativo, em que a exposição repetida a um dado estado do ambiente produz uma resposta de melhor qualidade. Portanto, podemos afirmar que o Sistema Classificador é um sistema suficientemente flexível para adaptar-se a novos contextos, nunca antes apresentados, e também eficaz na produção de respostas secundárias a estímulos do ambiente (comparável

às respostas secundárias associadas ao conceito de vacina em sistemas imunológicos (Farmer *et al.*, 1986)).

Das duas técnicas de solução empregadas neste trabalho, o Sistema Classificador supera o desempenho do Algoritmo Genético quando há necessidade de se manter a diversidade da população, por exemplo, em ambientes não-estacionários. Através do emprego de operadores genéticos eficientes, o algoritmo genético busca encontrar um indivíduo que represente a melhor solução para o problema (associado à situação do ambiente em determinado momento). Entretanto, ao final da evolução, temos não somente um melhor indivíduo, mas uma população de indivíduos idênticos. Essa população seria incapaz de reagir a uma mudança de estado do ambiente.

Em situações de ambiente variável, precisamos de uma ferramenta capaz de explorar toda a potencialidade de módulos eficazes, pouco diversificados e já evoluídos, e combiná-los adequadamente na produção de uma população bem diversificada e especializada. Os Sistemas Classificadores satisfazem este requisito.

6.2 - Contribuições e Sugestões para Novas Pesquisas

Quando nos referimos à necessidade de injeção de energia na população, poderíamos investigar essa recuperação de uma forma mais suave, diminuindo a variância entre os valores de energia das regras, sem anular esta variância, como adotado neste trabalho.

A representação em ponto flutuante adotada na codificação de indivíduos em computação evolutiva, permite a utilização de operadores genéticos de crossover e mutação específicos para este tipo de representação, os quais nos permitem incrementar o desempenho do sistema, por exemplo, explorando melhor buscas locais. Em nossa aplicação, empregamos o crossover simples e a mutação uniforme. Podemos procurar melhorar os resultados obtidos investigando o desempenho de outros tipos de operadores disponíveis, como o crossover

aritmético e mutação não uniforme (Michalewicz, 1996).

Em nossa abordagem consideramos apenas indivíduos factíveis durante o processo evolutivo. Michalewicz (2000) utilizou, com sucesso, a evolução conjunta de indivíduos factíveis e infactíveis, explorando características de vizinhança. Podemos investigar as proposições apresentadas, procurando inseri-las no contexto de nosso trabalho.

A extensão da metodologia desenvolvida neste trabalho a outras aplicações que envolvem otimização combinatória, em ambientes variantes no tempo, é direta, desde que se defina em cada caso uma codificação apropriada para a parte antecedente e conseqüente dos classificadores.

APÊNDICE A EQUAÇÕES RECURSIVAS DE FLUXO DE CARGA

Conforme apresentado em Baran & Wu (1989) e resumido neste Apêndice, o fluxo de carga em redes de distribuição de energia elétrica pode ser calculado por equações recursivas, chamadas na literatura em inglês de “DistFlow branch equations”. A partir do valor da potência ativa, potência reativa e tensão (P_n , Q_n e V_n), referentes ao último nó da rede (nó n), efetua-se cálculos retrógrados, atualizando o valor do fluxo nos arcos, utilizando as Equações A sucessivamente. O processo termina quando chegamos ao primeiro nó (nó 0) e obtemos a estimativa da quantidade de energia injetada na rede (P_0 e Q_0).

Para ilustrar o cálculo do fluxo de carga aplicando as Equações A, considere o diagrama de uma rede de distribuição mostrada na Figura A.1 a seguir.

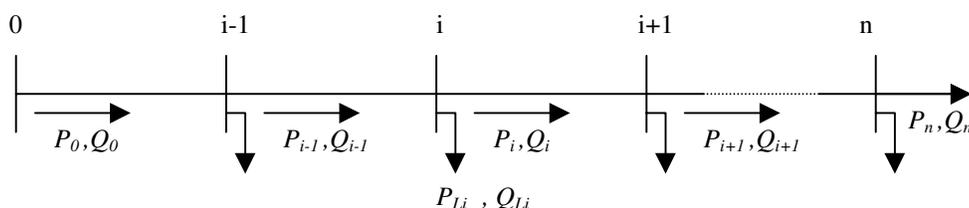


Figura A.1 – Diagrama Simplificado de uma Rede de Distribuição

$$P_{i-1} = P_i + r_i \frac{P_i^2 + Q_i^2}{V_i^2} + P_{Li} \quad (\text{A.i})$$

$$Q_{i-1} = Q_i + x_i \frac{P_i^2 + Q_i^2}{V_i^2} + Q_{Li} \quad (\text{A.ii})$$

$$V_{i-1}^2 = V_i^2 + 2(r_i P_i + x_i Q_i) + (r_i^2 + x_i^2) \frac{P_i^2 + Q_i^2}{V_i^2} \quad (\text{A.iii})$$

$$P_i' = P_i + P_{Li} \quad (\text{A.iv})$$

$$Q_i' = Q_i + Q_{Li} \quad (\text{A.v})$$

onde :

- P_i - fluxo de potência ativa no arco i
- Q_i - fluxo de potência reativa no arco i
- V_i - tensão no arco i
- r - resistência da linha
- x - reatância da linha

APÊNDICE B ALGORITMO DE SOLLIN

O algoritmo de Sollin é um algoritmo de obtenção de árvores geradoras de custo mínimo. Considerando um grafo $G = (N,A)$, com $n = |N|$ nós e $m = |A|$ arcos e custo c_{ij} associado a cada arco $(i, j) \in A$, procuramos encontrar a árvore T^* de G que apresenta custo mínimo. Basicamente, o algoritmo de Sollin mantém, a cada iteração, uma coleção de subárvores desconectadas e as conecta através do arco de menor custo que sai de cada uma, gerando novas subárvores com custo mínimo.

Este algoritmo apresenta complexidade $O(m \log n)$ (Ahuja *et al.*,1993). Apresentamos na Figura B.1, os passos do algoritmo de Sollin e na Figura B.2, um exemplo de aplicação retirado de Ahuja *et al.* (1993) .

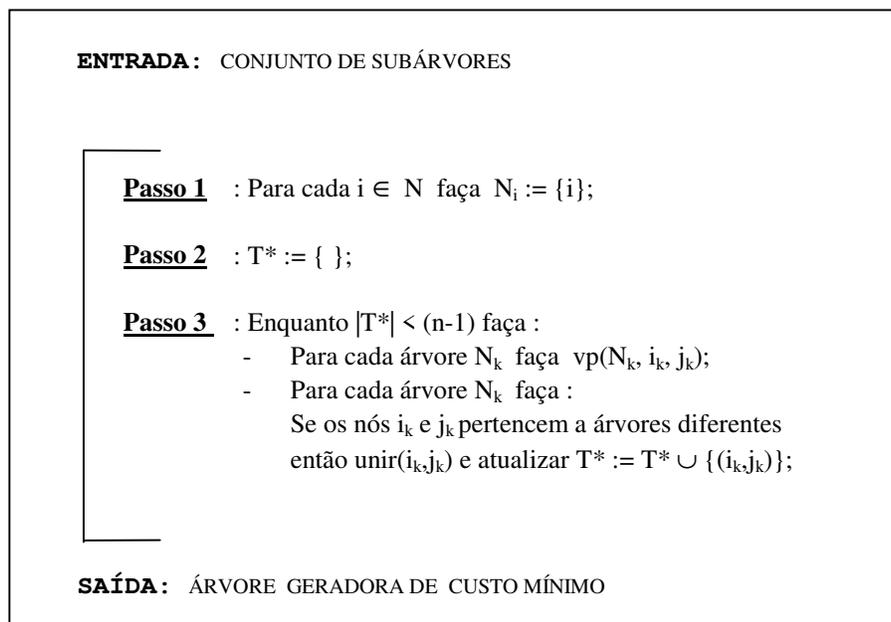


Figura B.1 – Passos Básicos do Algoritmo de Sollin

Conforme pode ser observado na Figura B.1, este algoritmo processa repetidamente as operações $vp()$ e $unir()$, resumidas a seguir :

$vp(N_k, i_k, j_k)$ – esta operação $vp()$, abreviação para “vizinho mais próximo”, encontra dentre os arcos que saem dos nós de N_k , o de menor custo e que tenha nó destino fora de N_k

$unir(i_k, j_k)$ – a partir dos nós i_k e j_k , pertencentes a árvores diferentes, esta operação conecta estas duas árvores, gerando uma única árvore.

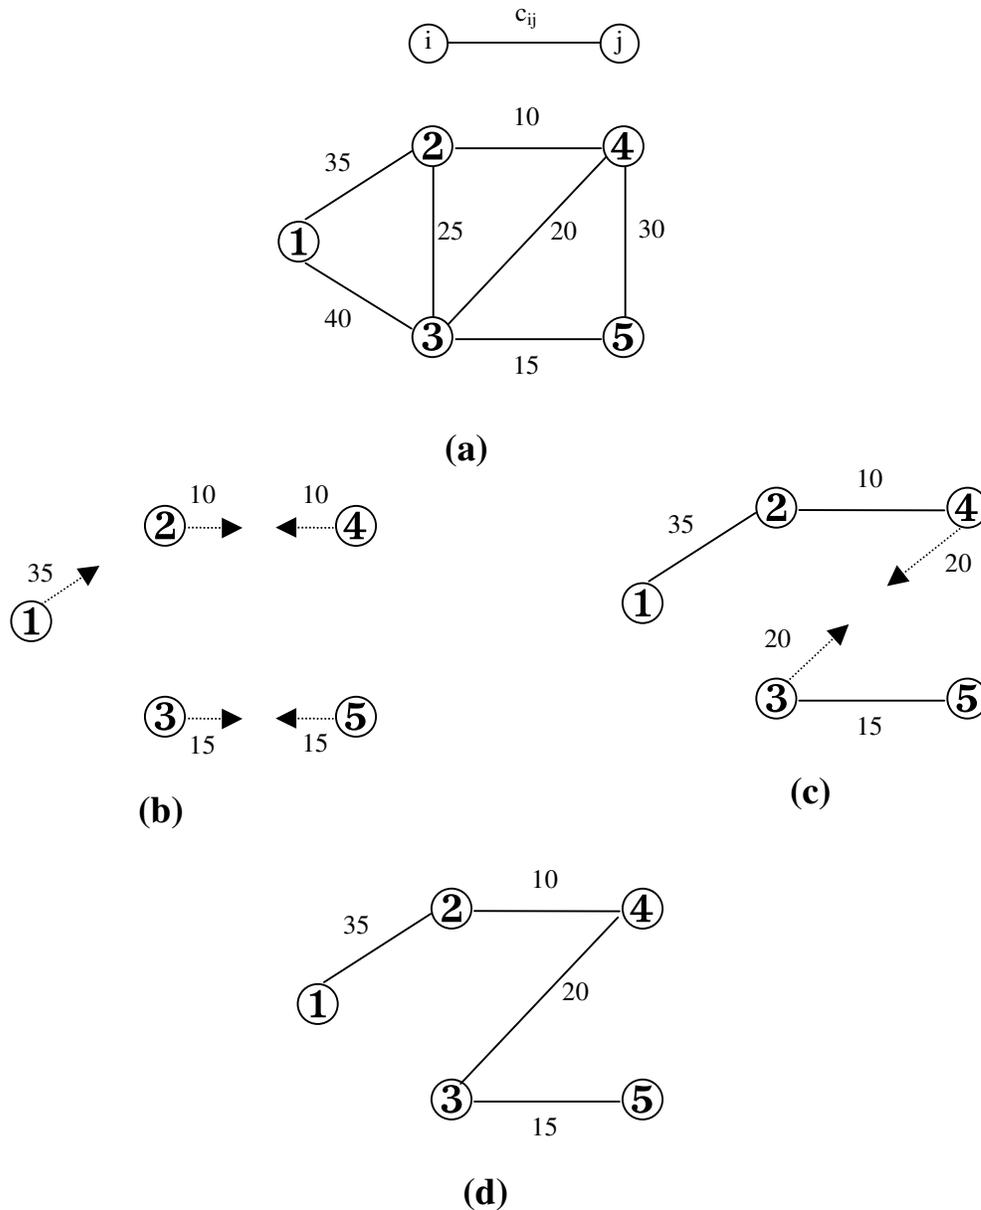


Figura B.2 – Aplicação do Algoritmo de Sollin (esta ilustração foi apresentada por Ahuja *et al.* (1993))

Na Figura B.2 (b), observamos que o processo se inicia com cinco árvores compostas por um único nó e de cada árvore sai um arco de custo mínimo. O próximo passo será unir estas árvores por esses arcos de custo mínimo, resultando nas duas árvores da Figura B.2 (c). Note que os arcos referentes aos nós 3 e 4 são os arcos de custo mínimo associados a estas árvores. Unindo estas duas árvores por esses arcos, o processo termina e obtemos a árvore final, ilustrada na Figura B.2 (d).

REFERÊNCIAS BIBLIOGRÁFICAS

Atmar W. (1994). *Notes on Simulation of Evolution*. IEEE Transactions on Neural Networks, vol. 5, no. 1, pp. 130-147.

Ahuja, R. K., Magnanti, T. L. & Orlin, J. B. (1993). *Network Flows : Theory, Algorithms and Applications*. Prentice Hall, Englewood Cliffs, NJ.

Baran, M. E. & Wu, F. F. (1989). *Network Reconfiguration in Distribution Systems for Loss Reduction and Load Balancing*. IEEE Transactions on Power Delivery, vol. 4, no. 2, pp. 1401-1407.

Booker, L. B. (1985). *Improving the Performance of Genetic Algorithms in Classifier Systems*. Proceedings of an International Conference on Genetic Algorithms and their Applications, pp. 80-92.

Booker, L. B., Goldberg, D. E. & Holland, J. H. (1989). *Classifier Systems and Genetic Algorithms*. Artificial Intelligence, vol. 40, pp. 235-282.

Bunch, J.B., Miller, R. D. & Wheeler, J.E. (1982). *Distribution system integrated voltage and reactive power control*. IEEE Transactions on Power Apparatus and Systems, vol. 101, pp. 284-289.

Cavellucci, C. (1998). *Buscas Informadas baseadas em Grafos para Minimização das Perdas em Sistemas de Distribuição de Energia Elétrica*. Tese de Doutorado, FEEC, Unicamp, Dezembro.

Cavellucci, C. & Lyra, C. (1997). *Minimization of Energy Losses in Electric Power Distribution Systems by Intelligent Search Strategies*. International Transactions in Operational Research, vol. 4, no. 1, pp. 23-33.

Civanlar, S., Grainger, J. J., Yin, H. & Lee, S. S. H. (1988). *Distribution feeder Reconfiguration for Loss Reduction*. IEEE Transactions on Power Delivery, vol. 3, pp. 1217-1223.

CODI - Comitê de Distribuição (1997). *Relatório CODI - 3.2.19.34.0. Método para determinação, análise e otimização das perdas técnicas em sistemas de distribuição*. ABRADE - Associação Brasileira de Distribuidores de Energia Elétrica.

Costa, M. F. N. (1999). *Computação Evolutiva para Minimização de Perdas Resistivas em Sistemas de Distribuição de Energia Elétrica*. Tese de Mestrado, FEEC, Unicamp, Julho.

- Darwin, C. (1859;1993). *The Origin of Species by Means of Natural Selection Or The Preservation of Favored Races in The Struggle for Life*. The Modern Library, New York.
- Farmer, J. D., Packard, N. H. & Perelson, A. S. (1986). *The Immune System, Adaptation, and Machine Learning*. Physica, Vol.22D, pp.187-204.
- Ferreira, A. B. H., (1996). *Novo Dicionário Aurélio da Língua Portuguesa*. Editora Nova Fronteira.
- Fogel, D. B. (1995). *Evolutionary Computation : Toward a new philosophy of machine intelligence*. IEEE Press.
- Glover, F., Laguna, M. (1997). *Tabu Search*. Kluwer Academic Publishers.
- Goldberg, D. E. (1983). *Computer-Aided Gas Pipeline Operation using Genetic Algorithms and Rule Learning*. Phd. Dissertation, University of Michigan, Ann Arbor, MI.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley, Inc.
- Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems : an Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*. The MIT Press, Ann Arbor, MI.91.
- Holland, J. H. (1995). *Hidden order : how adaptation builds complexity*. Addison-Wesley, Inc.
- Holland, J. H. (1998). *Emergence : from chaos to order*. Addison-Wesley, Inc.
- Kovacs, T. & Lanzi, P. L. (1999). *A Learning Classifier Systems Bibliograph*. Technical Report: CSRP-99-19, University of Birmingham, United Kingdom. <http://www.cs.bham.ac.uk/~tyk/lcs>
- Koza, J. R. (1996). *Genetic programming : on the programming of computers by means of natural selection*. The MIT Press, Cambridge, Massachusetts.
- Mardia, K. V., Kent, J. T. & Bibby, J. M. (1979). *Multivariate Analysis*. Academic Press.
- Merlin, A. & Back, H. (1975). *Search for a Minimal-Loss Operating Spanning Tree Configuration in Urban Power Distribution Systems*. Proceedings of 5th Power Systems Comp. Com., Cambridge, U.K., September,1-5.
- Michalewicz, Z. (1996). *Genetic Algorithms + Data Structures = Evolution Programs*. Springer-Verlag Berlin Heidelberg, New York.

- Michalewicz, Z. (2000). *Evolutionary Algorithms for Constrained Optimization Problems*. Tutorial Program, Genetic and Evolutionary Computation Conference - GECCO 2000, Las Vegas, Nevada.
- Nara, K. A., Shiose, M., Kitagawa & Ishihara, T. (1992). *Implementation of Genetic Algorithm for Distribution Systems Loss Minimum Reconfiguration*. IEEE Transactions on Power Systems, vol.7,no.3, pp.1044-1051.
- Peponis, G. J., Papadopoulos, M. P. & Hatziargyriou, N. D. (1995). *Distribution Network Reconfiguration to Minimize Resistive Line Losses*. IEEE Transactions on Power Delivery, vol. 10, no. 3, pp. 1338-1342.
- Richards, R. A. (1995). *Zeroth-Order Shape Optimization utilizing Learning Classifier Systems*. <http://www.stanford.edu/~buc/SPHINcsX/book.html>. Tese de Doutorado, Stanford University.
- Shirmohammadi, D. & Hong, H. W. (1989). *Reconfiguration of electric distribution networks for resistive line losses reduction*. IEEE Transactions on Power Delivery, vol. 4, pp. 1492-1498.
- Tão, W. (1997). *Minimização de Perdas em Redes de Distribuição de Energia Elétrica através de Métodos de Busca Inteligentes com Processamento Paralelo*. Tese de Mestrado, FEEC, Unicamp, Julho.
- Vargas, P. A., Lyra, C. & Von Zuben, F. J. (2000). *Sistemas Classificadores para Redução de Perdas em Redes de Distribuição de Energia Elétrica*. Anais do XIII Congresso Brasileiro de Automática (CBA 2000), Florianópolis, Setembro, pp. 2186-2191.
- Waterman, D. A. (1985). *A Guide to Expert Systems*. Addison-Wesley, Inc.

ÍNDICE REMISSIVO DE AUTORES

Atmar (1994).....	13
Ahuja <i>et al.</i> (1993).....	5, 7 , 26, 27, 60, 89, 90
Baran & Wu (1989).....	6, 8, 9, 24, 29, 73, 81, 87
Booker (1985).....	37
Booker <i>et al.</i> (1989).....	1, 9, 10, 32
Bunch <i>et al.</i> (1982).....	3
Cavellucci (1998).....	3
Cavellucci <i>et al.</i> (1997).....	10
Civanlar <i>et al.</i> (1988).....	6, 10
CODI - Comitê de distribuição (1997).....	3
Costa (1999).....	1, 2, 10, 11, 20, 23, 26, 27, 59, 81
Darwin (1859;1993).....	16
Farmer <i>et al.</i> (1986).....	84
Ferreira (1996).....	13
Fogel (1995).....	16
Glover & Laguna (1997).....	10
Goldberg (1983).....	20, 33, 45, 63
Goldberg (1989).....	13, 20, 21, 22
Holland (1975).....	19, 20, 33
Holland (1995).....	79
Holland (1998).....	79
Kovacs & Lanzi (1999).....	33
Koza (1996).....	20
Mardia <i>et al.</i> (1979).....	78
Merlin & Back (1975).....	9, 10
Michalewicz (1996).....	17, 20, 22, 23, 24, 34, 45, 64, 85

Michalewicz (2000).....	85
Nara <i>et al.</i> (1992).....	2, 10
Peponis <i>et al.</i> (1995).....	10
Richards (1995).....	20, 33, 41, 43, 61, 63, 64
Shirmohammadi & Hong (1989).....	10
Tão (1997).....	7, 23
Vargas <i>et al.</i> (2000).....	10
Waterman (1985).....	82