

7) CONTROLE DE PARÂMETROS EM EA

COMO A MUDANÇA DE UM PARÂMETRO PODE SER FEITO :

PARÂMETRO ESCOLHIDO E FIXADO ANTES DA EXECUÇÃO
 ("PARAMETER TUNING")

PARÂMETRO VARIÁVEL AO LONGO DA EXECUÇÃO
 ("PARAMETER CONTROL")

- "DETERMINÍSTICO" (NA VERDADE, SÃO VALORES QUE NÃO DEPENDEM DA EXECUÇÃO DO ALGORITMO)
- ADAPTATIVO — HÁ REAJUSTES DE VALORES COLHIDOS DURANTE A EXECUÇÃO, MAS O CRITÉRIO DE VALOR É EXTERNO À EXECUÇÃO.
- AUTO-ADAPTATIVO — HÁ REAJUSTES E OS MECANISMOS DE VALOR SÃO INTERNOS À EXECUÇÃO.

QUAL PARÂMETRO É INFLUENCIADO PELO VALOR :

— REPRESENTAÇÃO
 — SELEÇÃO DOS PAIS
 — RECOMBINAÇÃO

EX.: PESOS DO Crossover OU SUAS PROBABILIDADES

— MUTAÇÃO
 — SELEÇÃO DOS SOBREVIVENTES

EX.: TAMANHO

— E TAMBÉM

- CARACTERÍSTICAS DO FUNÇÃO CUSTO
- CARACTERÍSTICAS DA POPULAÇÃO

QUAIS INFORMACOES SÃO UTILIZADAS PARA CONTROLAR A VARIACAO:

("EVIDENCE")

— INFORMACAO ABSOLUTA — QUANDO O VALOR DE UM PARÂMETRO É ALTERADO POR UMA REGRA QUE SE OPIKA QUANDO UM EVENTO PRÉ-DEFINIDO OCORRE. É DEPENDENTE DA EXECUCAO DO ALGORITMO (≠ CONTROLE DETERMINÍSTICO).

EX.: BIXA DIVERSIDADE —> OMIENTOR p_m

— INFORMACAO RELATIVA — PARÂMETROS SÃO COMPARADOS DE ACORDO COM A APTIDAO DA PARCELA DA PROLE À QUAL ELAS ESTAO ASSOCIADOS

EX.: DIFERENTES PROBABILIDADES DE CROSSOVER EM SUB-GRUPOS DA POPULACAO — OS QUE OBTÊM MELHOR RESULTADO SE MANTÊM.

O QUÃO AMPLO PODE SER O USO DA VARIACAO: ("ESCOPO")

- UM OU MAIS "GENES" DE UM INDIVÍDUO
- INDIVÍDUO INTEIRO
- POPULACAO INTEIRA
- OUTRO ELEMENTO BÁSICO DO EA (EX.: SELECAO DE PAIS)
- FUNCAO CUSTO

A CLASSIFICACAO DO USO DA VARIACAO DE UM PARÂMETRO CONFORME O ESCOPO É COMPLICADA E MAL-DEFINIDA, PORQUE PODE HOVER INTERFERÊNCIAS ENTRE ESTRATÉGIAS PARA OS GENES E PARA A POPULACAO INTEIRA.

OBSERVAÇÕES:

1. AS MODALIDADES DE CONTROLE DE PARÂMETROS SE MISTURAM.
POR EXEMPLO, UM MÉTODO PODE SER AUTO-ADAPTATIVO, REATIVO, DEPENDENDO SÓ SOBRE OS PARÂMETROS DE MUDANÇA E O NÍVEL DE INDIVÍDUO. (ES, POR EXEMPLO)
2. MAS HÁ DUAS "MISTURAS" OU COMBINAÇÕES IMPOSSÍVEIS:
 - CONTROLE "DETERMINÍSTICO" COM INFORMAÇÃO REATIVA E
 - CONTROLE AUTO-ADAPTATIVO COM INFORMAÇÃO ABSOLUTA.
3. ASPECTOS POSITIVOS: USUÁRIO FICA LIBERADO DE FOMER O ESCUDO DE PARÂMETROS "SUB-ÓTIMOS", E PODE SER QUE O VALOR ÓTIMO DE UM PARÂMETRO MUDE CONFORME O ESTADO DA BUSCA. ATUAMENTE, HÁ CONCORDÂNCIA SOBRE O FATO QUE TODO EA PRECISO SER AJUSTADO PARA O PROBLEMA.
4. ASPECTOS "NEGATIVOS": MAIS PARÂMETROS PODEM SER NECESSÁRIOS, PARA CONTROLAR OS MECANISMOS DE CONTROLE DE PARÂMETROS. PORÉM, O "PARAMETER TUNING" PODE CUSTAR AINDA MAIS CARO — EX.: QUATRO PARÂMETROS, CINCO VALORES POSSÍVEIS PARA CADA UM, 100 RODADAS, ETC. E NÃO HÁ PARÂMETROS ÓTIMOS EM GERAL.
5. PODE-SE USAR UM EA PARA CONTROLAR OS PARÂMETROS DO EA BÁSICO.

EXEMPLOS DE CONTROLE DE PARÂMETROS:

— $\sigma(t) = 1 - 0.9 \frac{t}{T}$ ← N° MÁXIMO DE GERAÇÕES
(DETERMINÍSTICO)

— REGRA $\frac{1}{5}$ DE RECHENBERG (ADAPTATIVO , ABSOLUTO)

— ES (AUTO-ADAPTATIVO , INFORMACÃO RELATIVO)

— OTIMIZAÇÃO COM RESTRIÇÕES (CAP. 12) — CONTROLE DA IMPORTÂNCIA (PESO) QUE O PENALIDADE DEVE TER :

$J'(x) = J(x) + wH(x)$

↑
H(x) > 0 , SE x NÃO SOTISFAZ
AS RESTRIÇÕES DO PROBLEMA:

$g_i(x) \leq 0 , i = 1, \dots, q$

$h_j(x) = 0 , j = q+1, \dots, m$

MECANISMOS DE
CONTROLE PELA W:

DETERMINÍSTICO : $w(t) = Kt^\alpha$

ADAPTATIVO : W AUMENTA OU DIMINUI CONFORME , NAS ÚLTIMAS
GERAÇÕES , OS MELHORES INDIVÍDUOS NÃO ESTEJAM
(OU ESTEJAM) SATISFIZENDO AS RESTRIÇÕES .

AUTO-ADAPTATIVO : W (OU w_1, w_2, \dots, w_m) É INCLUÍDO NO
CROMOSSOMO .

$J'(x) = J(x) + \sum_{j=1}^m w_j (RESTRIÇÃO)_j$

OBS.: DESSE , A AUTO-ADAPTAÇÃO DOS PESOS
ALTERA O VALOR DE $J'(x)$, DIRETAMENTE .

(! — DIFERENTE DO ES)

— VALORES DA REPRESENTAÇÃO

GA REINICIADO UTILIZANDO SOLUÇÃO PARCIAL COMO OFFSET ("INTERIM SOLUTION")

— VALORES DO MUTAÇÃO

CRÓMOSSOMO DE GA BÁSICO COM 20 BITS ADICIONAIS QUE

REPRESENTAM p_m :

1. DECODIFICAR p_m
2. MUTAR 20 BITS COM PROB. p_m
3. DECODIFICAR DE NOVO $\rightarrow p'_m$
4. MUTAR BITS DE x COM PROB. p'_m

MÉTODO AUTAMENTE AUTO-ADAPTATIVO

— VALORES DO CROSSOVER, USANDO INFORMAÇÃO RELATIVO, AUTO-ADAPTATIVO

— VALORES DA SELEÇÃO DE PAIS, COM POPULAÇÃO DE TAMANHO 1 E SOMENTE MUTAÇÃO \rightarrow SIMULATED ANNEALING (!)

CONTROLE DETERMINÍSTICO DA TEMPERATURA.

— VALORES DO TAMANHO DA POPULAÇÃO

GA VAPS — NÃO POSSUI μ .

ALGORITMO — ADAPTATIVO COM INFORMAÇÃO RELATIVO.

— VALORES DE DIVERSOS PARÂMETROS AO MESMO TEMPO

GA "SEM PARÂMETROS" — NÃO PRECISO SER AJUSTADO PELO USUÁRIO.

8) PROBLEMAS MULTIMODAIS E DISTRIBUIÇÃO ESPACIAL ; E

PROBLEMAS MULTI-OBJETIVO


CONCEITOS INTRODUTÓRIOS

— SELEÇÃO DE PIS NÃO-BASEADOS UNICAMENTE EM OPTIMOS

— DIVISÃO DA POPULAÇÃO EM SUB-POPULAÇÕES QUE SE COMUNICAM POUCO

— NICHOS

— DERIVO GENÉTICO



— FORMAS DE ESPÉCIES ; RESTRIÇÕES DE DISSOLVIMENTO

— EQUILÍBRIO INTERROMPIDO

— PRESERVAÇÃO DE DIVERSIDADE

- IMPLÍCITO
- EXPLÍCITO

— "ESPAÇOS"

- ESPAÇO ALGORÍTMICO ("ENDEREÇO DE MEMÓRIA")
- ESPAÇO DO GENÓTIPO (\mathbb{R}^n ETC.)
- ESPAÇO DO FENÓTIPO ($J(x)$)

8.1 MÉTODOS IMPLÍCITOS PARA PRESERVAÇÃO DE DIVERSIDADE

SÃO MAIS SUTIS DO QUE EXECUTAR DIVERSAS RODADAS DE UM EA E ORIENTAR OS MELHORES RESULTADOS.

a) MODELO DE ILHAS * — MÚLTIPLOS EAs EM PARALELO, COM COMUNICAÇÃO ; "MUCHO LARGO"

— ÉPOCA → MIGRAÇÃO * ILHAS DE "MEMÓRIA"

— EXPLORADOR E "EXPLOITADOR"

— VARIACÃO DE DESEMPENHO CONFORTE O ESCOPO DOS PARÂMETROS:

— COM QUE FREQUÊNCIA FAZER O INTERCÂMBIO?

— QUANTOS E QUAIS INDIVÍDUOS?


— COMO DIVIDIR A POPULAÇÃO EM SUB-GRUPOS?

— OS PARÂMETROS DE ESTRATÉGIA PODER SER DIFERENTES NOS DIFERENTES ILHAS.

b) MODELO DIFUSIVO — DISTRIBUIÇÃO ESPACIAL DENTRO DE UMA MESMA POPULAÇÃO; "MUITO FINO"

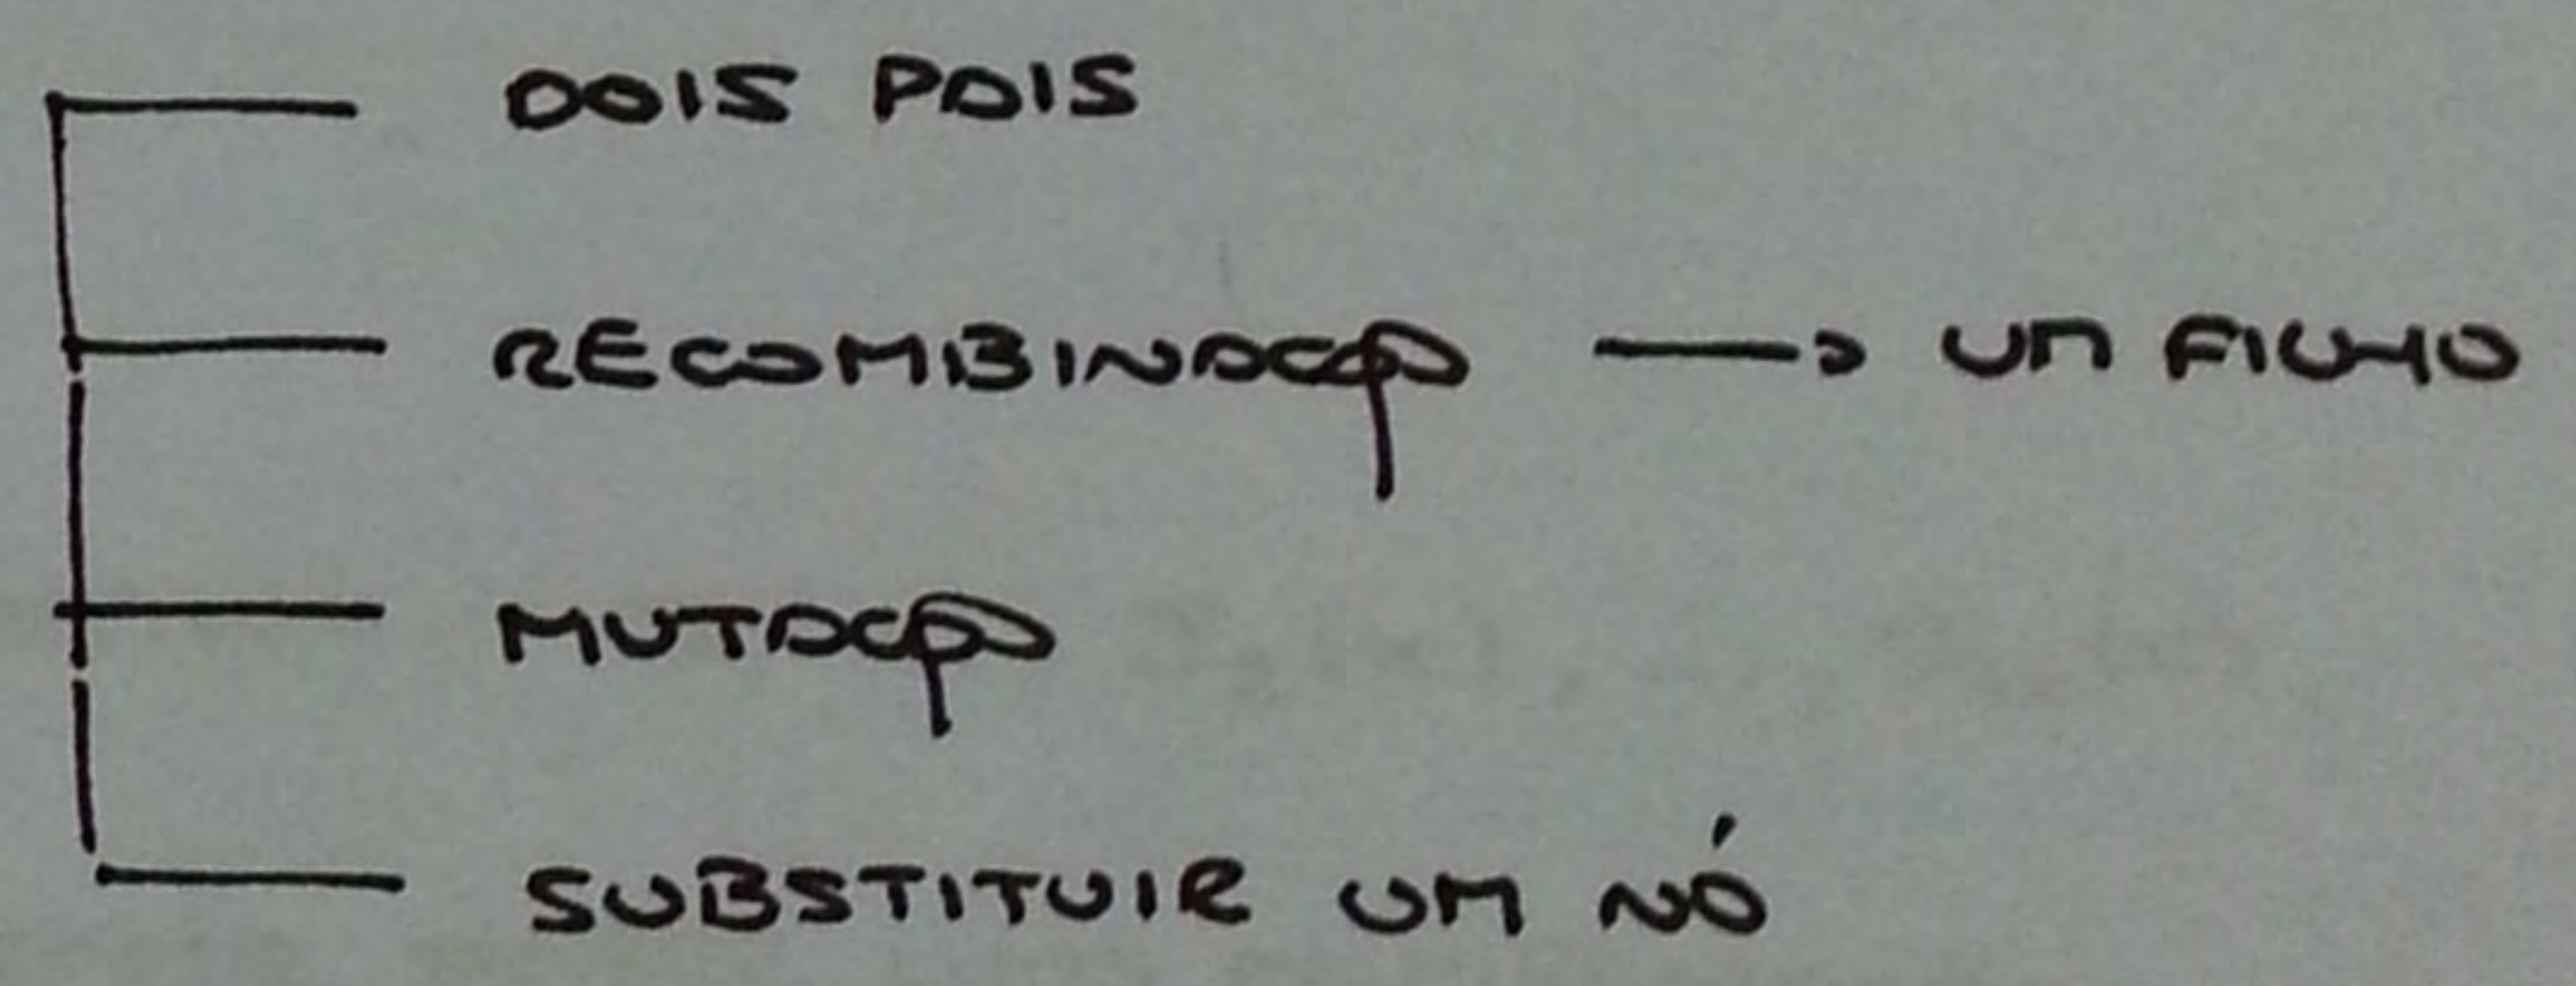
— SOMENTE HÁ INTERACÇÃO ENTRE INDIVÍDUOS DAS VIZINHANÇAS

— PSEUDO-CÓRIGO:

1. —> GRID 

2. VIZINHANÇAS

3. LOOP SOBRE VIZINHANÇAS



c) GERACÃO AUTOMÁTICA DE ESPÉCIES COM RESTRICÇÕES DE ASSASSINAMENTO

— NÃO HÁ DISTÂNCIA "GEOGRÁFICA" (ALGORÍTMICA), MAS SIM ENTRE ALGUMA PROPRIEDADE DO INDIVÍDUO E OUTRO

— ASSASSINAMENTO RESTRITO POR GENÓTIPO OU FENÓTIPO

— ASSASSINAMENTO RESTRITO POR "TAGS"

8.2 MÉTODOS EXPLÍCITOS PARA PRESERVAÇÃO DE DIVERSIDADE

a) COMPARTILHAMENTO DE APTIDÃO (FITNESS SHARING):

FUNÇÃO "SHARING":
$$s(d) = \begin{cases} 1 - \left(\frac{d}{\sigma_s}\right)^\alpha, & \text{SE } d \leq \sigma_s \\ 0, & \text{CASO CONTRÁRIO} \end{cases}$$

$$J'(i) = \frac{J(i)}{\sum_j s(d(i,j))}$$

α : FORMATO DO FUNÇÃO SHARING

σ_s : RAIO DO COMPARTILHAMENTO

NÚMERO DE SOLUÇÕES NO NICHOS TENDE A SER PROPORCIONAL À APTIDÃO MÁXIMO DO NICHOS.

b) "DETERMINISTIC CROWDING"

NÚMERO DE SOLUÇÕES POR NICHOS TENDE A SER SEMPRE O MESMO.

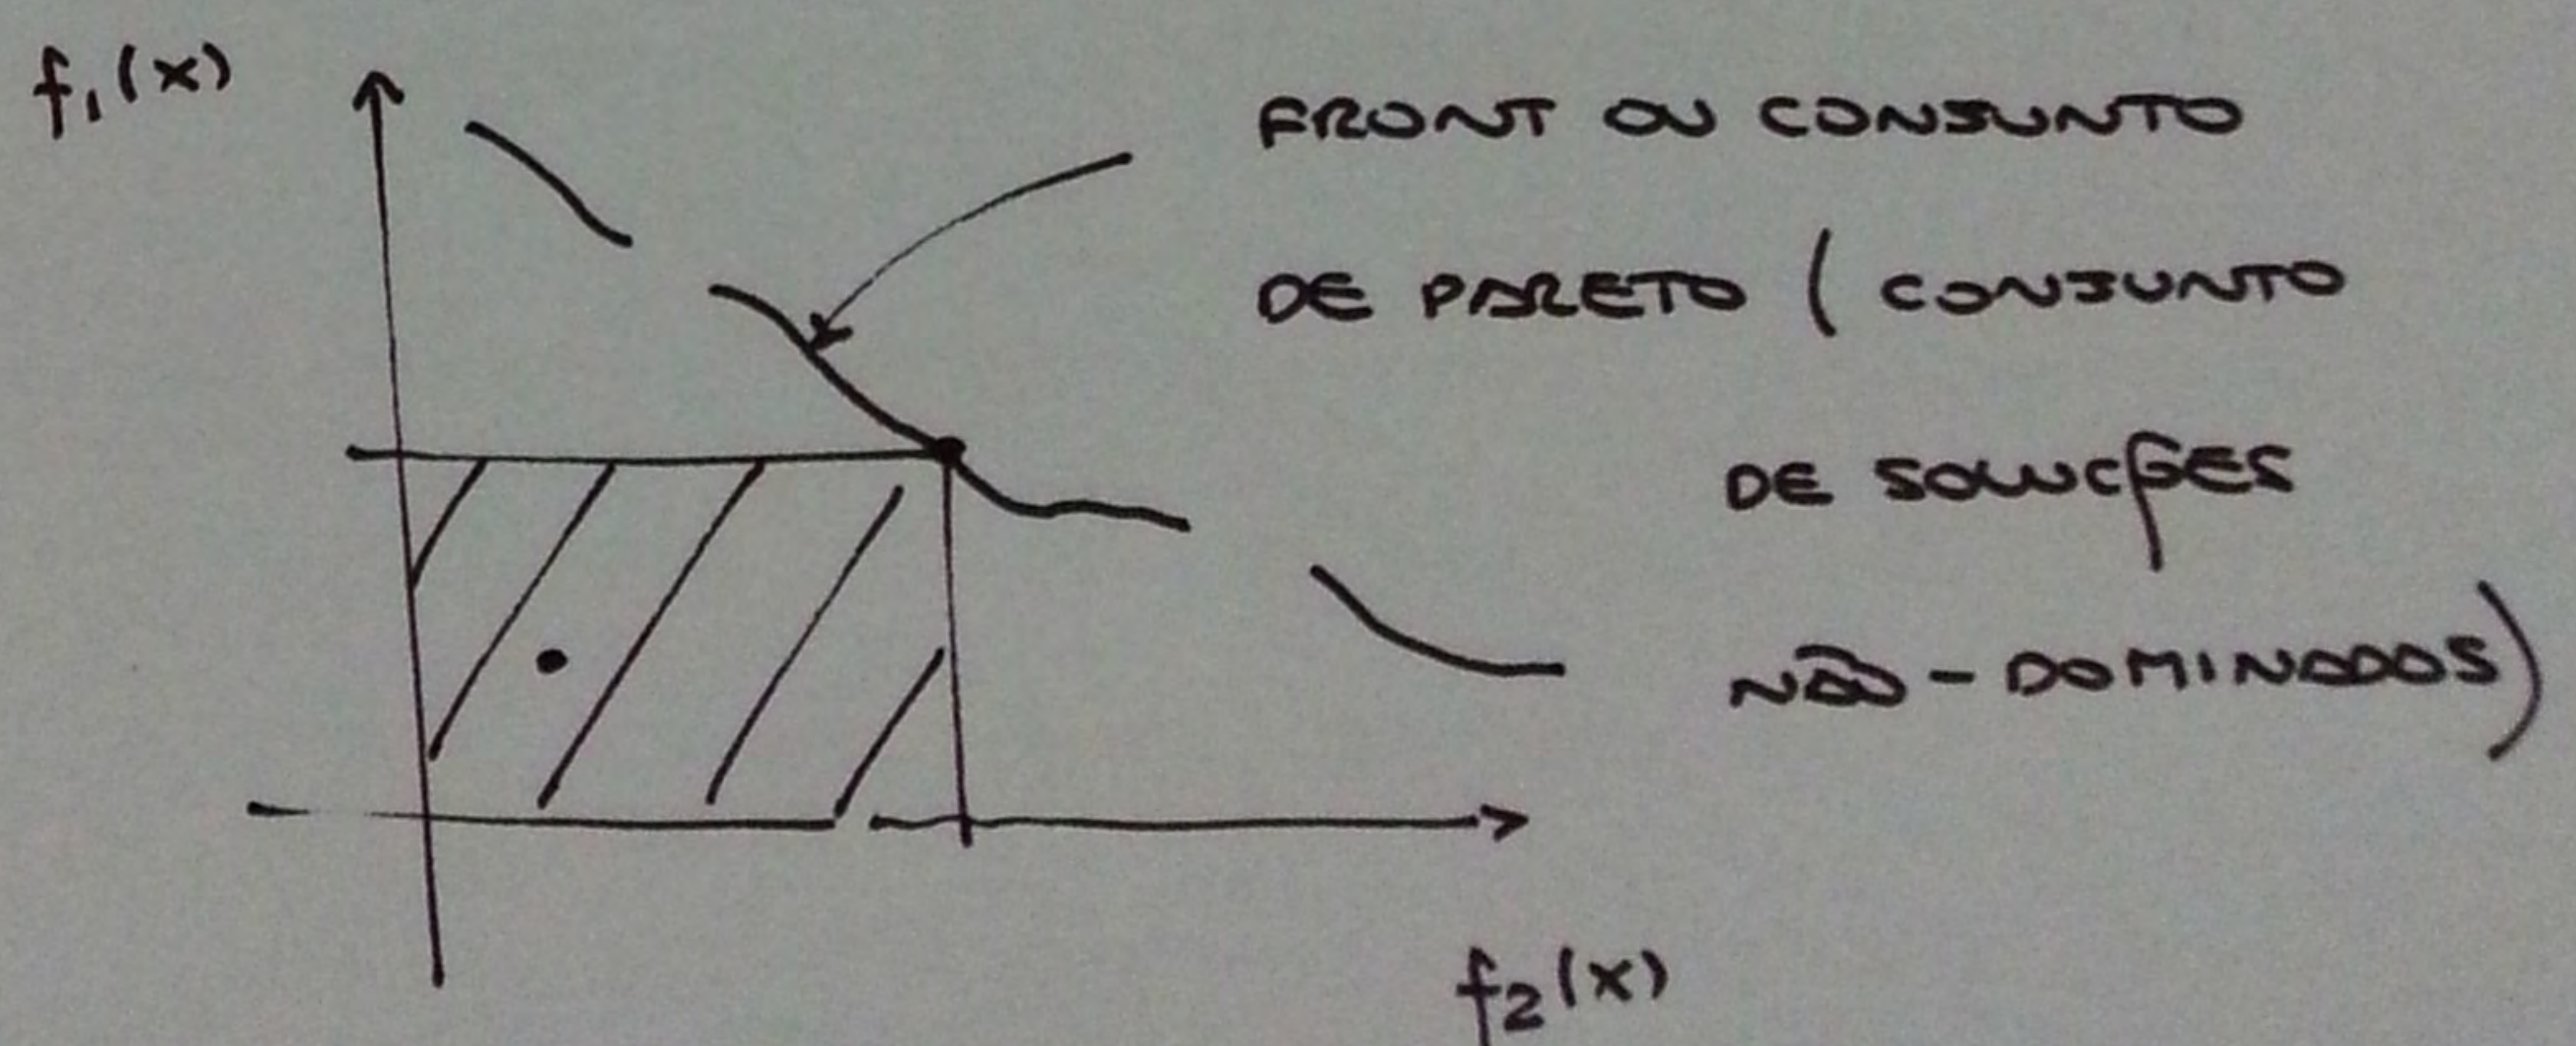
8.3 EA MULTI-OBJETIVO

DEFINIÇÃO DE PROBLEMA MULTI-OBJETIVO: $J_1(x), J_2(x), \dots, J_k(x)$,

SEM QUE QUEIRAMOS NECESSARIAMENTE FAZER UMA COMBINAÇÃO

LINEAR ("ESCALARIZAÇÃO") DESTAS FUNÇÕES-CUSTO.

DOMINÂNCIA E
OPTIMIDADE DE
PARETO:



ABORDAGENS PARA EA MULTI-OBJETIVO:

— VECTOR-EVALUATED GENETIC ALGORITHM

UMA POPULAÇÃO POR OPTIMÃO, MAS COM SELEÇÃO DE PAIS E RECOMBINAÇÃO GLOBAIS

— GOLDBERG: OPTIMÃO BASEADO EM DOMINÂNCIA

— ABORDAGENS NÃO-ELITISTAS (PERDEM SOLUÇÕES BOAS)

MULTI-OBJECTIVE GENETIC ALGORITHM

NONDOMINATED SORTING GA

NICHED PARETO GA

— ABORDAGENS ELITISTAS

NSGA-II

STRENGTH PARETO EA (SPEA-2)

PARETO ARCHIVED ES

OBS.: MANUTENÇÃO EXPÍCITA DA DIVERSIDADE EM EA MULTI-

OBJETIVO.