

CENTRO UNIVERSITÁRIO DA FEI

ANTONIO PAULO DE MORAES LEME

**UM ESTUDO SOBRE OTIMIZAÇÃO EVOLUCIONÁRIA E EXTRAÇÃO DE
CONHECIMENTO DE FRONTEIRAS DE PARETO APLICADO A UM
AMPLIFICADOR OPERACIONAL DE TRANSCONDUTÂNCIA**

São Bernardo do Campo
2012

ANTONIO PAULO DE MORAES LEME

**UM ESTUDO SOBRE OTIMIZAÇÃO EVOLUCIONÁRIA E EXTRAÇÃO DE
CONHECIMENTO DE FRONTEIRAS DE PARETO APLICADO A UM
AMPLIFICADOR OPERACIONAL DE TRANSCONDUTÂNCIA**

Dissertação de Mestrado apresentada ao Centro Universitário da FEI para obtenção do título de Mestre em Engenharia Elétrica, orientada pelo Prof. Dr. Carlos Eduardo Thomaz.

Leme, Antonio Paulo de Moraes.

Um estudo sobre Otimização Evolucionária e Extração de
Conhecimento de Fronteiras de Pareto aplicado a um Amplificador
Operacional de Transcondutância / Antonio Paulo de Moraes
Leme. São Bernardo do Campo, 2012.

112 f. : il.

Dissertação (Mestrado) - Centro Universitário da FEI.

Orientador: Prof. Dr. Carlos Eduardo Thomaz

1. Eletrônica Evolucionária. 2. Múltiplos Objetivos. 3.
Amplificador Operacional de Transcondutância. I. Thomaz, Carlos
Eduardo, orient. II. Título.

CDU 621.381



Centro Universitário da **FEI**

APRESENTAÇÃO DE DISSERTAÇÃO ATA DA BANCA JULGADORA

PGE- 10

Programa de Mestrado de Engenharia Elétrica

Aluno: Antonio Paulo de Moraes Leme

Matrícula: 1091065

Título do Trabalho: **Um estudo sobre otimização evolucionária e extração de conhecimento de fronteiras de Pareto aplicado a um amplificador operacional de transcondutância.**

Área de Concentração: Inteligência Artificial Aplicada à Automação

Orientador: Prof. Dr. Carlos Eduardo Thomaz

ORIGINAL ASSINADA

Data da realização da defesa: 13 / abril / 2012

A Banca Julgadora abaixo-assinada atribuiu ao candidato o seguinte:

APROVADO

REPROVADO

São Bernardo do Campo, 13 / 04 / 2012.

MEMBROS DA BANCA JULGADORA

Prof. Dr. Carlos Eduardo Thomaz

Ass.: _____

Prof. Dr. Flávio Tonidandel

Ass.: _____

Prof. Dr. Sebastião Gomes dos Santos Filho

Ass.: _____

VERSÃO FINAL DA DISSERTAÇÃO

**ENDOSSO DO ORIENTADOR APÓS A INCLUSÃO DAS
RECOMENDAÇÕES DA BANCA EXAMINADORA**

Aprovação do Coordenador do Programa de Pós-graduação

Prof. Dr. Carlos Eduardo Thomaz

Aos meus filhos Paulo Gabriel e Maria Eduarda.

AGRADECIMENTOS

Este trabalho não seria completo sem os devidos agradecimentos a todos os que direta e indiretamente colaboraram com sua concepção e elaboração. Patrícia, minha esposa, supriu a minha ausência parcial aos meus filhos com a determinação e empenho de mãe e para que pudesse dedicar-me à pesquisa e redação da dissertação. O Prof. Dr. Carlos Eduardo Tomaz, na figura de orientador, apoiou-me em todos os aspectos da pesquisa e dissertação, orientou e recomendou artigo e participação em congresso e não permitiu que esmorecesse na hora mais difícil, quando o trabalho na Volkswagen e os problemas pessoais me consumiam. O Prof. Carlos ajudou a estruturar os alicerces fundamentais deste trabalho.

Ao Prof. Dr. Salvador Pinillos Gimenez cabe o título de co-orientador, ainda que esta atribuição não exista oficialmente para o mestrado no Centro Universitário da FEI. O Prof. Salvador encorajou muito a pesquisa realizada e sempre contribuiu com seu grande conhecimento na análise dos resultados obtidos e no direcionamento da pesquisa. Seu orientado, o colega Rodrigo Alves de Lima Moreto contribui na escolha do modelo BSIM3 do MOSFET, nas primeiras simulações com SPICE, na extração dos pontos de inversão da curva g_m/I_{DS} e contribuiu com discussões que ajudaram a responder questões importantes. A inspiração veio do trabalho de mestrado de outro colega, Thiago Turcato do Rego, que forneceu seus modelos MOSFET BSIMSOI para SPICE, utilizados nos primeiros experimentos, e sugeriu que os algoritmos evolucionários poderiam revelar regras de projetos. Esta idéia fundamental foi perseguida desde o início.

A banca da qualificação do mestrado deu direcionamentos e correções importantes para o desenvolvimento da pesquisa, na área de Eletrônica pelo Prof. Dr. Renato Giacomini e na área de otimização a Profa. Dra. Patrícia Prado Belfiore com inúmeras sugestões de como superar o problema de restrições. Também a banca julgadora composta pelo Prof. Dr. Fávio Tonidandel e Prof. Dr. Sebastião Gomes dos Santos Filho, com nobre espírito crítico, conhecimento do tema e interesse, apontaram as deficiências e virtudes do trabalho em detalhes que passariam desapercebidos e para que pudessem ser corrigidas nesta versão final.

Por fim, agradeço ainda aos meus pais, Antonio Carlos e Maria Inês pelo encorajamento e orações em todos os momentos e também pelo apoio financeiro nos momentos de dificuldade.

“Evolution is free to explore very unusual designs: circuits with strange structures and intricate dynamical behaviours beyond the scope of conventional design and analysis. In this larger search-space there is the possibility of better solutions, if we are prepared to set aside our prejudices (based on existing design methods) of how an electronic circuit should be.”

*Analysis of Unconventional Evolved Electronics
Adrian Thompson & Paul Layzell, 1999*

RESUMO

A otimização de múltiplos objetivos do amplificador operacional de transcondutância é um dos problemas mais estudados em microeletrônica. Dentro da área de Automação do Projeto Eletrônico encontra-se um grande número de ferramentas para a automação de projetos de circuitos integrados digitais, com grandes possibilidades de abstração, capazes de realizar otimização de parâmetros até síntese de sistemas completos. Para *circuitos integrados analógicos*, por outro lado, não encontra-se ferramentas com as mesmas características. O principal fator para esta divergência é a falta de um fluxo estruturado no projeto de circuitos integrados analógicos. O objetivo desta dissertação é investigar o processo de otimização para Amplificadores Operacionais de Transcondutância utilizando Algoritmos Evolucionários de Múltiplos Objetivos na tentativa de descoberta de regras de projeto para a configuração automática de parâmetros de transistores na tecnologia CMOS. O desdobramento deste objetivo permite a elaboração de um arcabouço computacional que inclui a obtenção de aproximações da Fronteira de Pareto e a utilização de um modelo preciso para a simulação dos amplificadores operacionais de transcondutância, respeitando as restrições impostas pela topologia de interesse. Apesar do alto custo computacional, a obtenção de aproximações da fronteira de Pareto, através do conhecido algoritmo evolucionário *Nondominated Sorting Genetic Algorithm II*, integrado ao simulador SPICE, revela relações de compromisso entre os objetivos conhecidas muitas vezes somente intuitivamente pelos projetistas de circuitos integrados analógicos. Os resultados obtidos neste trabalho sugerem que a Análise Multivariada das aproximações Pareto é um guia importante para a obtenção de projetos de amplificadores operacionais de transcondutância mais aprimorados.

Palavras-chave: Eletrônica Evolucionária, Múltiplos Objetivos, Amplificador Operacional de Transcondutância.

ABSTRACT

The optimization of multiple objectives of the operational transconductance amplifier is one of the most studied problems in microelectronics. Within the area of Electronic Design Automation is a large number of tools for design automation of digital integrated circuits, with great possibilities of abstraction, able to perform from parameter optimization to the synthesis of complete systems. For *analog integrated circuits*, on the other hand, its tools do not have the same characteristics. The main reason for this discrepancy is the lack of a structured flow in the design of analog integrated circuits. The objective of this dissertation is to investigate the optimization process for Operational Transconductance Amplifiers using Evolutionary Algorithms of Multiple Objectives in an attempt to discover design rules for the automatic configuration of parameters for transistors in CMOS technology. The unfolding of this goal allows the development of a computational framework that includes obtaining approximations of the Pareto Front and the use of an accurate model for the simulation of the operational transconductance amplifiers, respecting the restrictions imposed by the topology of interest. Despite the high computational cost, to obtain approximations of the Pareto front, through the known evolutionary algorithm *Non-dominated Sorting Genetic Algorithm II*, integrated with SPICE simulation reveals compromise relationships between the objectives often known only intuitively by designers of analog integrated circuits. The present results suggest that the Multivariate Analysis of Pareto approaches is an important guide for obtaining more refined designs for operational transconductance amplifiers.

Keywords: Evolutionary Electronics, Multiple Objectives, Operational Transconductance Amplifier.

LISTA DE TABELAS

TABELA 2.1	Limites entre as regiões de inversão dos transistores utilizados	10
TABELA 3.1	Terminologia Biológica e os significados correspondentes em GAs (GOLDBERG, 1989, p. 22).	20
TABELA 3.2	Exemplo de cruzamento em um GA simples ($t=0$) (GOLDBERG, 1989).	23
TABELA 3.3	Relações Pareto binárias para vetores objetivo.	33
TABELA 3.4	Relações entre Conjuntos de Aproximação Pareto.	35
TABELA 3.5	Matriz de construção de topologias de amplificadores operacionais utilizada por Kruiskamp e Leenaerts (1995).	40
TABELA 5.1	Parametrização do Algoritmo	56
TABELA 5.2	Simbologia utilizada nos gráficos dos resultados experimentais	57
TABELA 5.3	Resultados do experimento de busca aleatória.	58
TABELA 5.4	Limites máximos e mínimos obtidos para os 5 experimentos.	62
TABELA B.1	Lista de Soluções	84

LISTA DE FIGURAS

FIGURA 1.1 Percentual de Circuitos Integrados Digitais com Conteúdo Analógico (IBS Corporation, 2002).	2
FIGURA 1.2 Contextualização de Projetos Analógicos e EDA, adaptado de McConaghy et al. (2009).	2
FIGURA 2.1 O Amplificador Operacional de Transcondutância ideal.	6
FIGURA 2.2 Vistas esquemáticas de um MOSFET de canal N.	8
FIGURA 2.3 Curvas características I-V de um MOSFET de canal N.	9
FIGURA 2.4 Curva de g_m/I_{DS} em função de $I_{DS}/(W/L)$ para transistores NMOS e PMOS utilizados.	10
FIGURA 2.5 Esquema elétrico de um amplificador implementado com um único nMOSFET.	11
FIGURA 2.6 Esquema elétrico de um OTA de um único estágio e uma única saída.	11
FIGURA 2.7 OTA Miller	12
FIGURA 2.9 Resposta em frequência do OTA em malha aberta	14
FIGURA 2.8 Circuito OTA em malha aberta.	14
FIGURA 2.10 Circuito OTA em malha fechada.	15
FIGURA 2.11 Resposta à função degrau de grandes sinais utilizada para a extração do <i>Slew Rate</i>	15
FIGURA 2.12 Fluxo de projeto manual de circuitos integrados analógicos e o escopo de otimização adotado neste trabalho, adaptado de Hjalmarson (2003).	16
FIGURA 3.1 Função de aptidão artificial de Schwefel dada pela equação $\mathbf{f}(x) = 418.9829 \cdot n - \sum_{i=1}^n \sin\left(\sqrt{ x_i }\right)$	19
FIGURA 3.2 Método da Roleta ou Seleção Proporcional adaptado de Goldberg (1989).	23
FIGURA 3.3 Caracteres virtuais em um espaço contínuo de busca de 2 variáveis (GOLDBERG, 1990).	27

FIGURA 3.4 Distribuição probabilística do operador SBX.	28
FIGURA 3.5 Classificação de MOEAs quanto ao tratamento de relações de compromisso entre os objetivos (COELLO; LAMONT; VELDHUIZEN, 2006).	30
FIGURA 3.6 Distância de apinhamento, adaptado de Deb (2001).	31
FIGURA 3.7 Função de mapeamento do <i>espaço de decisão</i> ao <i>espaço de objetivos</i> . Adaptado de (ZITZLER et al., 2002)	32
FIGURA 3.8 Relações binárias Pareto, considerando <i>minimização</i> dos objetivos f_1 e f_2 , verifica-se que: $a \prec b$, $a \prec c$, $a \prec d$, $a \ll d$, $a \preccurlyeq a$, $a \preccurlyeq b$, $a \preccurlyeq c$, $a \preccurlyeq d$, $b \prec d$, $b \preccurlyeq b$, $b \parallel c$, $c \prec d$, $c \preccurlyeq c$ e $c \parallel b$	33
FIGURA 3.9 Relações entre Conjuntos de Aproximação para um problema de minimização de dois objetivos f_1 e f_2 . Observa-se que $\mathcal{A}_1 \ll \mathcal{A}_3$, $\mathcal{A}_1 \prec \mathcal{A}_3$, $\mathcal{A}_2 \prec \mathcal{A}_3$, $\mathcal{A}_1 \preccurlyeq \mathcal{A}_1$, $\mathcal{A}_1 \preccurlyeq \mathcal{A}_2$, $\mathcal{A}_1 \preccurlyeq \mathcal{A}_3$, $\mathcal{A}_2 \preccurlyeq \mathcal{A}_2$, $\mathcal{A}_2 \preccurlyeq \mathcal{A}_3$, $\mathcal{A}_3 \preccurlyeq \mathcal{A}_3$, $\mathcal{A}_1 \triangleleft \mathcal{A}_2$, $\mathcal{A}_1 \triangleleft \mathcal{A}_3$ e $\mathcal{A}_2 \triangleleft \mathcal{A}_3$	34
FIGURA 3.10 Deficiências na obtenção de Conjuntos de Aproximação Pareto.	35
FIGURA 3.11 O Hipervolume, exemplificado para o caso de minimização de dois objetivos, corresponde a área delimitada pelos pontos da <i>Fronteira de Pareto</i> e o ponto de referência nadir.	37
FIGURA 3.12 Circuito Embrionário de Koza et al. (1999, p. 403).	42
FIGURA 3.13 Exemplo de programa GP para a construção de um circuito eletrônico(KOZA et al., 1999)	42
FIGURA 3.14 A abstração do AGE comparada ao mecanismo biológico equivalente, adaptado de Mattiussi et al. (2008).	43
FIGURA 4.1 Heatmap de Andrade (2008) utilizado para exemplificação por Friendly (2009). As linhas (ou colunas) representam os genes e as colunas (ou linhas) representam as amostras. Os gradientes de cores representam a intensidade da expressão do gene na amostra. Os dendrogramas lateral e superior representam os <i>Agrupamentos</i> entre genes e entre amostras.	50
FIGURA 4.2 Integração do MOEA ao SPICE.	53
FIGURA 4.3 Processo proposto por este trabalho: Otimização e Extração de Conhecimentos.	54
FIGURA 5.1 Quantidade de indivíduos factíveis obtidos com VEGA e NSGA-II.	55

FIGURA 5.2 Hipervolume ($I_{\mathcal{H}\mathcal{V}}$), equação 3.12, para as 6000 gerações dos 5 experimentos com NSGA-II.	59
FIGURA 5.3 Saturação ($SAT = V_{DS} - V_{GS} + V_{TH}$), Tensão Bias de Saída ($\left \frac{V_{dd}}{2} - V_{out} \right \leq 0,1 \cdot V_{dd}$) e Margem de Fase ($45^\circ \leq \varphi_M \leq 75^\circ$).	60
FIGURA 5.4 Resposta Transiente das soluções obtidas no Apendice B.	61
FIGURA 5.5 Diagrama de Bode das soluções obtidas do Apendice B.	61
FIGURA 5.6 Projeções das aproximações da Fronteira de Pareto resultantes dos 5 experimentos com NSGA-II para cada par de objetivos: A_{v0} [dB], f_T [MHz], SR [V/ μ s], Pwr [mW] e $Area$ [μ m 2].	62
FIGURA 5.7 Heatmap e dendrogramas da correlação de Spearman ao quadrado (ρ^2) entre os parâmetros e os objetivos. IDWL [$I_{DS}/(W/L)$] é a medida da região de inversão do MOSFET.	63
FIGURA 5.8 Agrupamento de Observações das Fronteiras de Pareto (\mathcal{PF}^*) das soluções obtidas no Apendice B. (1) Preto: <i>Soluções de Médio Compromisso entre Objetivos</i> , (2) Vermelho: <i>Alto Ganho</i> , (3) Verde: <i>Alta Frequência</i> , (4) Azul: <i>Baixa Potência</i>	64
FIGURA 5.9 Exemplos de relações extraídas da observação do Heatmap e Agrupamento de Observações.	65
FIGURA 5.10 Parâmetros dos Transistores MOSFET. (1) Preto: <i>Soluções de Médio Compromisso entre Objetivos</i> , (2) Vermelho: <i>Alto Ganho</i> , (3) Verde: <i>Alta Frequência</i> , (4) Azul: <i>Baixa Potência</i>	66
FIGURA 5.11 Árvore de Classificação para as Classes: (1) Preto: <i>Soluções de Médio Compromisso entre Objetivos</i> , (2) Vermelho: <i>Alto Ganho</i> , (3) Verde: <i>Alta Frequência</i> , (4) Azul: <i>Baixa Potência</i>	67
FIGURA 5.12 Árvores de Regressão.	68
FIGURA 5.13 Densidade de A_{v0} (Nó 23) para soluções restritas pelas inequações $L_{78} > 18,374\mu m$ (Nó 1), $L_{56} > 1,224\mu m$ (Nó 17) e $L_{56} > 5,845\mu m$ (Nó 19) da árvore de regressão de A_{v0}	69

LISTA DE ALGORITMOS

ALGORITMO 1	Algoritmo Evolucionário	19
ALGORITMO 2	O Algoritmo Genético Canônico.	22
ALGORITMO 3	<i>Vector Evaluated Genetic Algorithm</i> (SCHAFFER, 1984 apud DEB, 2001, p. 179–184)	29
ALGORITMO 4	<i>Non-dominated Sorting Genetic Algorithm II</i>	47
ALGORITMO 5	<i>Non-dominated Sorting</i> de complexidade $\mathcal{O}(mn^2)$ (DEB et al., 2000) . .	48
ALGORITMO 6	Distância de <i>Apinhamento</i> (DEB et al., 2000)	49
ALGORITMO 7	<i>k-means clustering</i>	51
ALGORITMO 8	<i>k-medoids clustering</i>	52

LISTA DE ABREVIATURAS E SIGLAS

AGE “Analog Genetic Encoding” (Codificação Genética Analógica)

CI Circuito Integrado

CMOS “Complementary Metal Oxide Semiconductor” (Semicondutor Metal-Óxido Complementar)

DNA “Desoxyribonucleic Acid” (Ácido Desoxiribonucleico)

EA “Evolutionary Algorithm” (Algoritmo Evolucionário)

EDA “Electronic Design Automation” (Automação do Projeto Eletrônico)

EE “Evolutionary Electronics” (Eletrônica Evolucionária)

EHW “Evolvable Hardware” (Hardware Evolucionário)

EP “Evolutionary Programming” (Programação Evolucionária)

ES “Evolution Strategies” (Estratégias de Evolução)

FPAA “Field Programmable Analog Array”

FPGA “Field Programmable Gate Array”

FPTA Field Programmable Transistor Array

GA “Genetic Algorithm” (Algoritmo Genético)

GP “Genetic Programming” (Programação Genética)

GRN “Genetic Regulatory Network” (Rede de Regulação Genética)

HSO “Hypervolume by Slicing Objectives” (Hipervolume por Divisão de Objetivos”)

INNOVIZATION “Innovative Design Principles Through Optimization” (Princípios Inovadores de Projeto através da Otimização)

MOEA “Multi-Objective Evolutionary Algorithm” (Algoritmo Evolucionário de Múltiplos Objetivos)

NFL “There is No Free Lunch” (Teorema da Inexistência do Almoço Grátis)

NSGA-II “Nondominated Sorting Genetic Algorithm II” (NSGA-II)

OTA “Operational Transconductance Amplifier” (Amplificador Operacional de Transcondutância)

PLD “Programmable Logic Device”

PTA “Programmable Transistor Array”

RNA “Ribonucleic Acid” (Ácido Ribonucleico)

SBX “Simulated Binary Crossover” (Cruzamento Binário Binário)

SMASH Simulador equivalente ao SPICE pertencente à Dolphin Integration

SoC “Systems on Chips” (Sistemas em Circuitos Integrados)

SPICE “Simulation Program with Integrated Circuit Emphasis” (Programa de Simulação com Enfase em Circuitos Integrados)

VEGA “Vector Evaluated Genetic Algorithm” (VEGA)

VLSI “Very Large Scale Integration” (Integração em Escala Muito Grande)

LISTA DE SÍMBOLOS

Amplificador Operacional de Transcondutância

A_{v0}	Ganho de tensão em malha aberta em baixa frequência [dB]
f_T	Frequência de ganho de tensão unitário [MHz]
SR	Máxima taxa de variação do sinal de saída (Slew Rate) [V/ μ s]
Pwr	Potência dissipada [mW]
$Area$	Área de Silício [μ m ²]
φ_T	Margem de fase para a tensão de ganho unitário [°]
M_i	MOSFET de índice i
W_i	Largura de canal do transistor M_i [μ m]
L_i	Comprimento de canal do transistor M_i [μ m]
g_m	Transcondutância [siemens]
V_{in+}	Entrada de tensão positiva do par diferencial do OTA [V]
V_{in-}	Entrada de tensão negativa do par diferencial do OTA [V]
V_{out}	Tensão de saída do OTA [V]
I_{out}	Corrente de saída do OTA [mA]
I_{abc}	Corrente de polarização do OTA [mA]
V_{DS}	Tensão entre Dreno e Fonte [V]
V_{TH}	Tensão de limiar [V]
V_{GS}	Tensão entre Porta e Fonte [V]
D	Dreno do MOSFET
S	Fonte do MOSFET

G Porta do MOSFET

B Substrato do MOSFET

Algoritmos Evolucionários

P População de pais

O População de descendentes

N Tamanho da População $|P|$

i Indivíduo

t Geração

p_{cross} Probabilidade de cruzamento

p_{mut} Probabilidade de mutação

η_c Fator de forma para o cruzamento binário simulado (SBX)

η_m Fator de forma para a mutação polinomial

Múltiplos objetivos e dominância Pareto

Ω Espaço de Decisão $\Omega = \{x \in \Re^n\}$

Λ Espaço de Objetivos $\Lambda = \{y \in \Re^m\}$

\mathcal{P}^* Conjunto ótimo de Pareto $\mathcal{P}^* \subset \Omega$

\mathcal{PF}^* Fronteira ótima de Pareto $\mathcal{PF}^* \subset \Lambda$

\mathcal{A}, \mathcal{B} Conjuntos de arbitrários de Aproximação à Fronteira de Pareto $\mathcal{A}, \mathcal{B} \subset \Lambda$

n Cardinalidade do espaço de decisão

m Cardinalidade do espaço de objetivos

$I_{GD}(\mathcal{A})$ Distância Geracional (Métrica Unária de Conjuntos Pareto)

$I_\Delta(\mathcal{A})$ Espalhamento (Métrica Unária de Conjuntos Pareto)

$I_{HV}(\mathcal{A})$ Hipervolume (Métrica Unária de Conjuntos Pareto)

$I_{\mathcal{C}}(\mathcal{A}, \mathcal{B})$ Cobertura do Conjunto (Métrica Binária de Conjuntos Pareto)

\prec Dominância Pareto Estrita (operador binário)

\preceq Dominância Pareto (operador binário)

\triangleleft Melhor Conjunto Pareto (operador binário)

\preccurlyeq Dominância Pareto Fraca (operador binário)

\parallel Incomparabilidade de Conjuntos Pareto (operador binário)

SUMÁRIO

1 INTRODUÇÃO	1
1.1 Motivação	3
1.2 Objetivo	3
1.3 Organização do Trabalho	4
2 O PROJETO DE AMPLIFICADORES OPERACIONAIS DE TRANSCONDUTÂNCIA	6
2.1 Amplificadores Operacionais de Transcondutância	6
2.2 OTAs implementados na Tecnologia CMOS	7
2.2.1 O Transistor de Efeito de Campo: MOSFET	7
2.2.2 Topologias de OTAs	10
2.3 O Simulador de Circuitos SPICE	13
2.3.1 Avaliação do Ponto de Operação (comando SPICE .OP)	13
2.3.2 Avaliação do Ganho em Malha Aberta, Frequência de Ganho Unitário e Margem de Fase (.AC)	13
2.3.3 Avaliação do <i>Slew-Rate</i> (.TRAN)	15
2.4 O ciclo manual de projetos.	15
3 FUNDAMENTAÇÃO TEÓRICA E CONTEXTUALIZAÇÃO	18
3.1 Algoritmos Evolucionários.	18
3.1.1 Representação Genética	20
3.1.2 O Algoritmo Genético Canônico	21
3.1.3 Teorema dos Esquemas de Holland	24
3.1.4 Teorema da Seleção e Covariância de Price	25
3.1.5 Codificação Genética por números Reais	27

3.2 Algoritmos Evolucionários de Múltiplos Objetivos	29
3.2.1 Modelo de Apinhamento	30
3.2.2 Modelo de Compartilhamento de Aptidão	31
3.3 Múltiplos Objetivos e Dominância Pareto	32
3.3.1 Relações Binárias Pareto	32
3.3.2 Conjunto Pareto e Fronteira de Pareto Ótimos	33
3.3.3 Conjuntos de Aproximação Pareto	34
3.3.4 Indicadores de Qualidade para Conjuntos de Aproximação Pareto	34
3.4 Eletrônica Evolucionária	38
3.4.1 Hardware Evolucionário - EHW	38
3.4.2 Evolução Extrínseca de Circuitos Analógicos	39
4 MÉTODOS	44
4.1 Otimização Evolucionária	44
4.1.1 Formulação do Problema	45
4.1.2 <i>Nondominated Sorting Genetic Algorithm II</i> (NSGA-II)	46
4.1.3 Tratamento de Restrições	48
4.2 Extração de Conhecimentos	49
4.2.1 O Mapa de Aquecimento (<i>Heatmap</i>)	50
4.2.2 Agrupamento de Observações (<i>Clustering</i>)	51
4.2.3 Árvores de Classificação e Regressão	52
4.3 Implementação	53
5 RESULTADOS EXPERIMENTAIS	55
5.1 Parametrizações	56
5.2 Factibilidade dos Resultados Experimentais	56
5.3 Fronteira de Pareto	61

5.4 Extração de Conhecimentos	63
5.4.1 Automação da Extração de Conhecimentos	67
6 CONCLUSÃO	70
REFERÊNCIAS	72
APÊNDICE A – Listagens SPICE	76
A.1 Listagem para SIMULAÇÃO	76
A.2 Modelo nMOSFET	79
A.3 Modelo pMOSFET	80
A.4 Extração de g_m/I_{ds} (NMOS)	81
A.5 Extração de g_m/I_{ds} (PMOS)	82
APÊNDICE B – Lista de Soluções (\mathcal{PF}^*)	84
ANEXO A – TRABALHO PUBLICADO EM CONGRESSO	106

1 INTRODUÇÃO

“Analog designers are few and far between. In contrast to digital design, most of the analog circuits are still handcrafted by the experts or so-called ‘zahs’ of analog design. The design process is characterized by a combination of experience and intuition and requires a thorough knowledge of the process characteristics and the detailed specifications of the actual product.”

“Analog circuit design is known to be a knowledge-intensive, multiphase, iterative task, which usually stretches over a significant period of time and is performed by designers with a large portfolio of skills. It is therefore considered by many to be a form of art rather than a science.”

*Trends in current analog design: A panel debate
O. Aaserud and I. Ring Nielsen, 1995*

Otimização é um problema ubíquo em ciências e engenharias. Encontrar soluções ótimas para um determinado problema, dadas as preferências e restrições para sua resolução, é uma questão de central importância para todos os campos de atuação humana. Soluções que minimizam a utilização de recursos, minimizam perdas e maximizam o desempenho são cada vez mais necessárias em nosso mundo competitivo e com recursos cada vez mais escassos.

A Eletrônica nas últimas décadas expandiu em integração e complexidade acompanhando as profecias da lei de Moore. O uso dos circuitos chamados de *System on Chips* (SoCs) são encontrados em vários campos de aplicação: automotivo, biomédico, comunicações, etc. SoCs tornaram-se realidade em meados da década de 1990 devido à grande evolução da tecnologia *Very Large Scale Integration* (VLSI) (SANTOS et al., 2011). A cada dia mais e mais funcionalidades podem ser integradas com a evolução de tecnologias de processos de fabricação e miniaturização. Neste contexto, as ferramentas para o auxílio de projetos *Electronic Design Automation* (EDA) são fundamentais dado o crescimento da complexidade de projetos eletrônicos.

Dentro da área de EDA, encontra-se um grande número de ferramentas para a automação de projetos de circuitos integrados digitais, com grandes possibilidades de abstração, capazes de

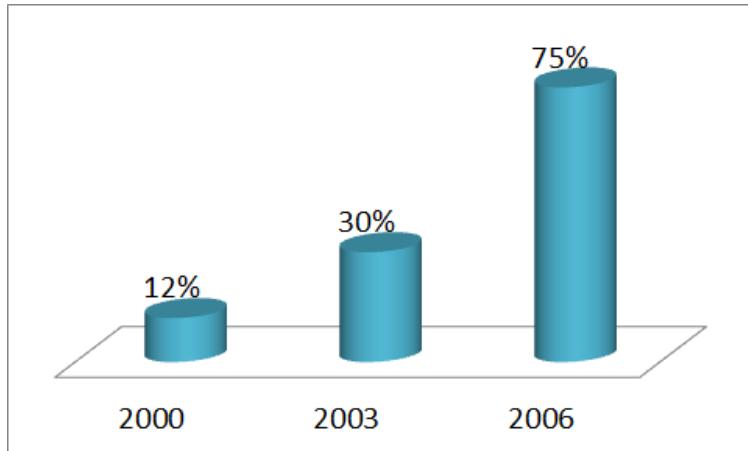


Figura 1.1: Percentual de Circuitos Integrados Digitais com Conteúdo Analógico (IBS Corporation, 2002).

realizar otimização de parâmetros até síntese de sistemas completos. Para *circuitos integrados analógicos*, por outro lado, não encontra-se ferramentas com as mesmas características. Hjalmarson (2003) argumenta que dentro de um Circuito Integrado (CI) de configuração comum, com 90% do CI composto de componentes digitais e 10% de componentes analógicos, e apesar desta grande diferença o projeto da parte analógica requer mais tempo e recursos do que a parte digital. Segundo Hjalmarson (2003) o principal fator para esta divergência é a falta de um fluxo estruturado no projeto de circuitos integrados analógicos.

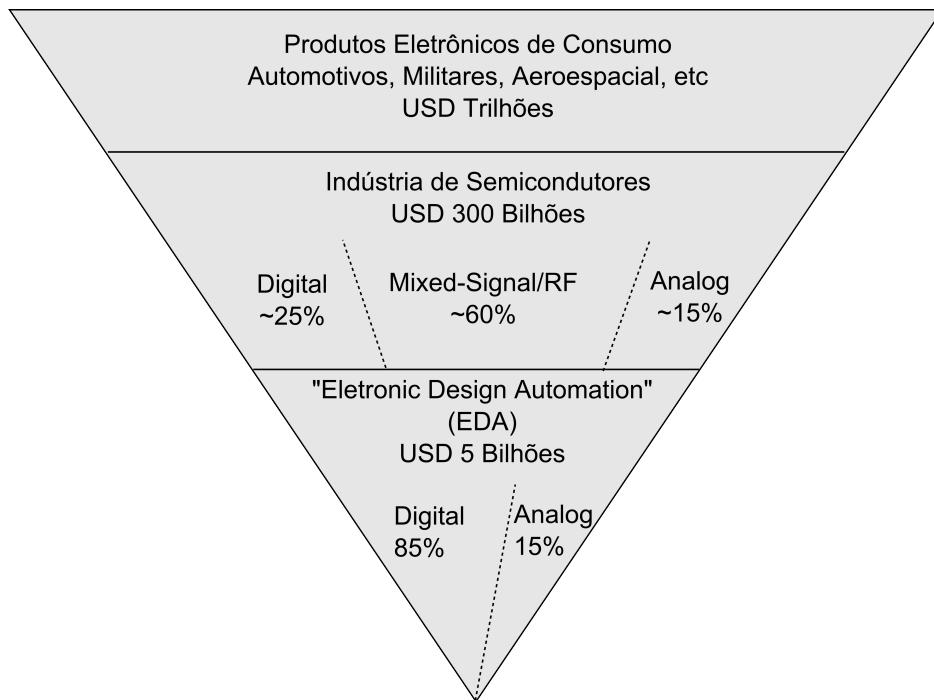


Figura 1.2: Contextualização de Projetos Analógicos e EDA, adaptado de McConaghy et al. (2009).

1.1 Motivação

Enquanto a relevância dos *circuitos integrados analógicos* cresce com a miniaturização e aumento de complexidade e funcionalidade dos CIs , conforme ilustrado na Figura 1.1, as ferramentas de automação de projetos de circuitos integrados analógicos ainda permanecem com participação de mercado aquém de suas equivalentes para circuitos integrados digitais. A Figura 1.2 apresenta uma contextualização desta afirmativa.

O maior desafio do projeto analógico, segundo Hjalmarson (2003), consiste no projeto de células básicas, como amplificadores operacionais, que exigem algumas semanas em um ciclo completo de projeto. O caminho crítico de um projeto passa pelo desenho e parametrização destas células. Ainda segundo Hjalmarson (2003), outro grande desafio são as relações de compromissos existentes entre as múltiplas especificações de desempenho exigidas dentro do projeto do sistema. A obtenção do correto balanço entre os parâmetros de desempenho exige múltiplas revisões e ciclos dentro do projeto de circuitos integrados analógicos.

Na verdade, as especificações de desempenho de um circuito analógico simples podem ser vistas como múltiplos objetivos de um problema de otimização. Os Algoritmos Evolucionários de Múltiplos Objetivos (MOEAs) permitem a obtenção de uma aproximação da *Fronteira de Pareto*, que é um conjunto de soluções com as melhores relações de compromisso entre os objetivos.

Durante a fase final da pesquisa bibliográfica desta dissertação, foi encontrada uma referência que possui uma filosofia semelhante à proposta deste trabalho, que é a extração de conhecimento tácito das *Fronteiras de Pareto*, chamada de *Innovative Design Principles Through Optimization* (INNOVIZATION) de Deb e Srinivasan (2005). Embora o princípio seja o mesmo, existem diferenças significativas nos métodos de extração de conhecimentos e acréscimos importantes feitos neste trabalho, como uma análise de sensibilidade global feita através de um *Mapa de Aquecimento* ou *Heatmap* e uma forma distinta de automação da extração de conhecimento utilizando-se árvores de classificação e regressão. A automação da extração de conhecimento surgiu pela primeira vez no trabalho de Bandaru e Deb (2010) através de *agrupamento de observações* ou *clustering* durante o processo evolutivo. A comparação com estas referências sugere que a proposta apresentada neste trabalho, desenvolvida de forma independente, além de estar muito próxima ao estado da arte acrescenta métodos importantes.

1.2 Objetivo

O conhecimento da *Fronteira de Pareto* de um circuito analógico permite que configuremos o mesmo, para várias aplicações, sempre na condição ótima. Por outro lado, o conhecimento da

Fronteira de Pareto também permite investigar quais as relações entre parâmetros e objetivos que são ótimas para o projeto analógico, permitindo a extração de conhecimento e re-alimentação do ciclo de projetos.

O objetivo geral deste trabalho é investigar o processo de otimização para Amplificadores Operacionais de Transcondutância (OTAs) utilizando Algoritmos Evolucionários de Múltiplos Objetivos (MOEAs) na tentativa de descoberta de *regras de projeto* para a configuração de parâmetros de transistores na tecnologia CMOS (*Complementary Metal Oxide Semiconductor*). Os parâmetros de transistores de Semicondutor Metal Óxido Complementar (CMOS) de interesse são: Largura de Canal (W), Comprimento de Canal (L), Razão de Largura por Comprimento (W/L) e a Região de Inversão que os transistores operam (Fraca, Moderada ou Forte). As configurações de parâmetros devem levar em conta os compromissos de objetivos entre os diversos tipos de aplicação, como: *Micropower*, Alto Ganho e Alta Frequência.

O desdobramento deste objetivo inclui a elaboração de metodologia eficaz para a obtenção de aproximações da *Fronteira de Pareto Ótima*(\mathcal{PF}^*), utilização de um modelo preciso para a simulação de circuitos e MOEA), superação por parte do algoritmo utilizado sobre as restrições impostas pela topologia do circuito estudado e o estudo das correlações entre objetivos e parâmetros de projeto, permitindo a extração de regras de projeto das aproximações da *Fronteira de Pareto*(\mathcal{PF}).

1.3 Organização do Trabalho

Este trabalho está dividido em seis capítulos, nos quais apresentam-se:

1. *Introdução*: Motivação e Objetivos;
2. *Projeto de Amplificadores Operacionais de Transcondutância*: O objeto de estudo, o OTA em tecnologia CMOS;
3. *Fundamentação Teórica e Contextualização*: A teoria de Algoritmos Evolucionários de Múltiplos Objetivos e seu contexto dentro da área de Eletrônica Evolucionária;
4. *Métodos*: A Formulação do Problema, o método de Otimização Evolucionária de Múltiplos Objetivos e os métodos para a Descoberta de Conhecimento a partir das aproximações da Fronteira de Pareto;
5. *Resultados Experimentais*: A evidência experimental para o suporte do discurso e argumentação sobre o OTA deste trabalho;

6. *Conclusão:* A conclusão sobre as questões abordadas, questões em aberto e possibilidades para trabalhos futuros.

2 O PROJETO DE AMPLIFICADORES OPERACIONAIS DE TRANSCONDUTÂNCIA

“Analog synthesis is always the holy grail.”

Ron Gyurcsik (*Cadence AMS Group Director*)

Neste capítulo são discutidos os aspectos básicos do projeto manual de Amplificadores Operacionais de Transcondutância (OTA) bem como os cálculos utilizando-se equações de primeira ordem, métricas de desempenho e refinamento do projeto por meio do simulador SPICE¹.

2.1 Amplificadores Operacionais de Transcondutância

Amplificadores Operacionais são essencialmente circuitos que amplificam em sua saída uma corrente ou tensão de entrada. Os amplificadores podem ser classificados em quatro tipos (GLISSON, 2011): Amplificadores de Corrente, Transresistência (ou Amplificador de Corrente-Tensão), Amplificadores de Tensão e Transcondutância (ou Amplificador de Tensão-Corrente). Este último é o objeto de estudo deste trabalho. Uma representação simbólica do OTA ideal é apresentada na Figura 2.1(a) e seu modelo de pequenos sinais é apresentado na Figura 2.1(b).

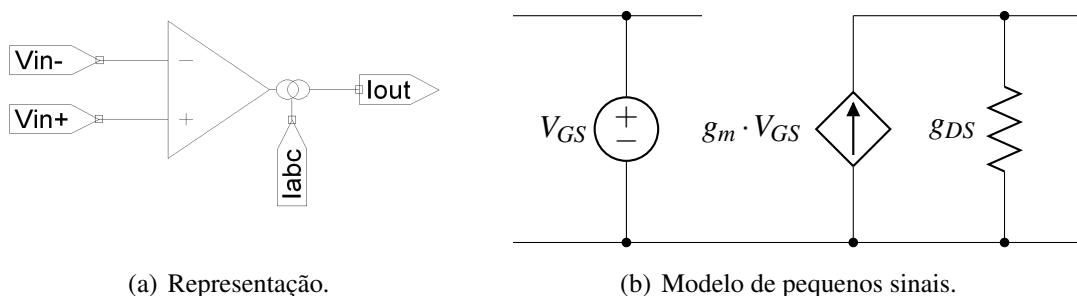


Figura 2.1: O Amplificador Operacional de Transcondutância ideal.

A transcondutância (g_m), propriedade principal deste circuito analógico, é definida pela razão entre a variação da corrente de saída (ΔI_{out}) pela variação da tensão de entrada (ΔV_{in}) em um

¹Programa de Simulação com Ênfase em Circuitos Integrados (*Simulation Program with Integrated Circuit Emphasis - SPICE*

quadripolo (SCHAUMANN, 2004, p. 136), ou seja,

$$g_m = \frac{\Delta I_{out}}{\Delta V_{in}}. \quad (2.1)$$

O OTA Ideal representado na Figura 2.1 possui a função de transferência definida pela equação 2.2 (SCHAUMANN, 2004, p. 136),

$$I_{out} = g_m \cdot (V_{in+} - V_{in-}), \quad (2.2)$$

onde V_{in+} e V_{in-} são as tensões de entrada positiva e negativa do OTA. A corrente de polarização do OTA I_{abc} é utilizada para controlar a transcondutância, sendo I_{abc} diretamente proporcional à g_m (SCHAUMANN, 2004).

2.2 OTAs implementados na Tecnologia CMOS

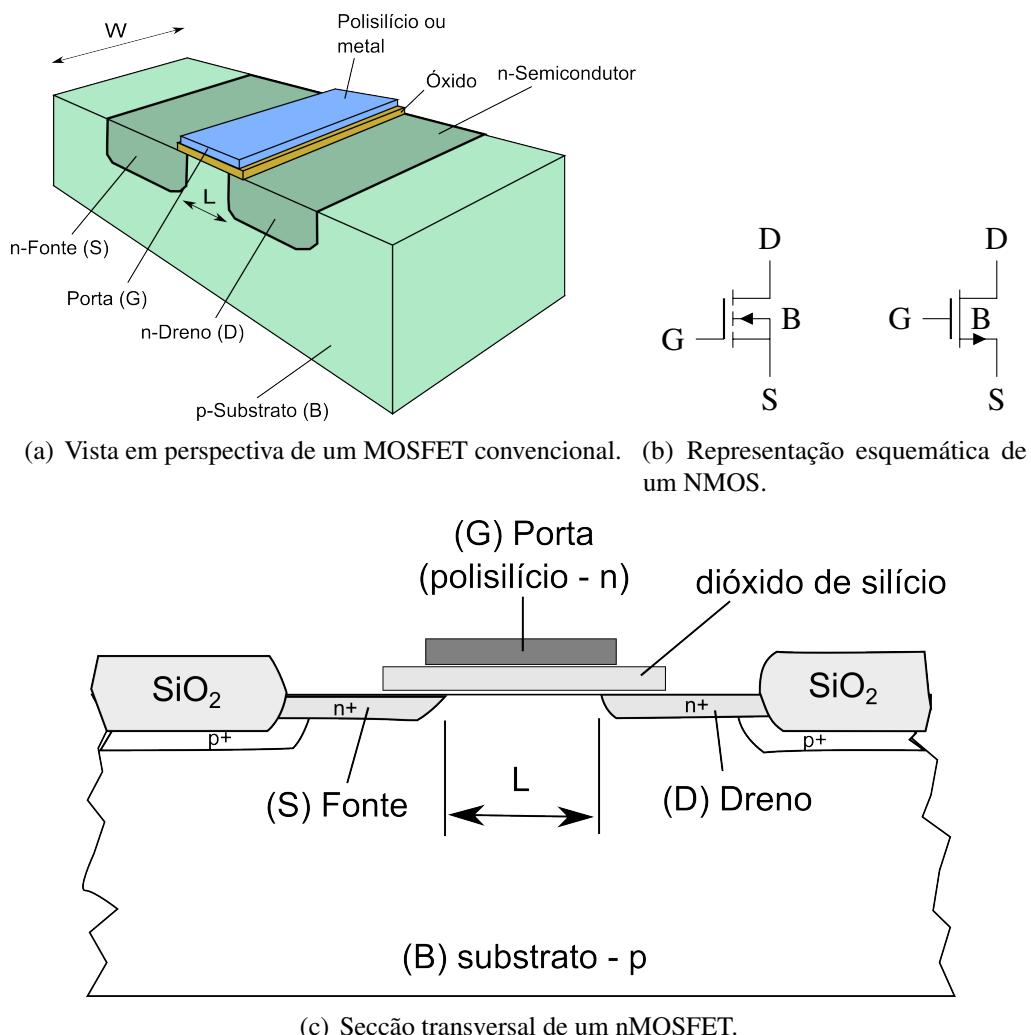
OTAs podem ser construídos em diversas tecnologias de fabricação de circuitos integrados (CIs). Como em Zebulum, Pacheco e Vellasco (2001, p. 106), tem-se a tecnologia *BiCMOS* que utiliza transistores bipolares e MOSFET ao mesmo tempo. Particularmente neste trabalho somente será utilizada a tecnologia CMOS para a implementação do OTA.

2.2.1 O Transistor de Efeito de Campo: MOSFET

Transistores MOSFET podem ser feitos de tal maneira que o transporte de corrente da fonte (source) ao dreno (drain) é feita por elétrons (NMOS) ou lacunas (PMOS), ou no caso da tecnologia CMOS, elétrons e lacunas em ambos dispositivos NMOS e PMOS (MISHRA; SINGH, 2008). A Figura 2.2(a) ilustra a vista em perspectiva de um Transistor NMOS, uma representação esquemática apresenta-se na Figura 2.2(b) e a sua secção transversal na Figura 2.2(c). Transistores NMOS e PMOS podem ser produzidos no mesmo substrato (MISHRA; SINGH, 2008). A Tecnologia CMOS é amplamente utilizada em memórias, microprocessadores, wireless e um grande número de aplicações, sendo sua principal característica a baixa dissipação de potência (MISHRA; SINGH, 2008).

O modo de operação dos transistores também é um fator importante a ser considerado no projeto de OTAs. Existem três modos de operação para transistores MOSFET, a saber (GENTINNE, 1996):

- a) Região de *Corte*: ocorre quando $V_{GS} < V_{TH}$, onde V_{GS} é a tensão entre porta (gate) e fonte (source) e V_{TH} é a tensão de limiar do MOSFET (threshold). Neste modo de operação não há condução de corrente entre dreno (drain) e fonte (source) (I_{DS});
- b) Região *Triodo* ou modo linear: Ocorre quando $V_{GS} > V_{TH}$ e $V_{DS} < V_{GS} - V_{TH}$, onde V_{DS} é a tensão entre dreno (drain) e fonte (source). Neste modo o transistor funciona como um resistor



controlado pela tensão de porta , e a corrente de dreno (I_{DS}) é proporcional a

$$I_{DS} \propto \frac{W}{L} [(V_{GS} - V_{TH}) \cdot V_{DS} - V_{DS}^2]; \quad (2.3)$$

c) Região de *Saturação* ou pinçamento (*pinch-off*): Ocorre quando $V_{GS} > V_{TH}$ e $V_{DS} > V_{GS} - V_{TH}$.

Neste modo a corrente de dreno (I_{DS}) depende somente da tensão de porta V_{GS} . O OTA utiliza os transistores configurados neste modo de operação. A corrente de dreno (I_{DS}) neste modo é proporcional a

$$I_{DS} \propto \frac{W}{L} (V_{GS} - V_{TH})^2. \quad (2.4)$$

As características de corrente e tensão (I-V) de um NMOS são apresentadas na Figura 2.3. A corrente de dreno(I_{DS})² relaciona-se com a tensão de porta (V_{GS}) de forma linear no Modo Triodo (Equação 2.3) e de forma quadrática no Modo de Saturação (Equação 2.4) (MISHRA; SINGH, 2008).

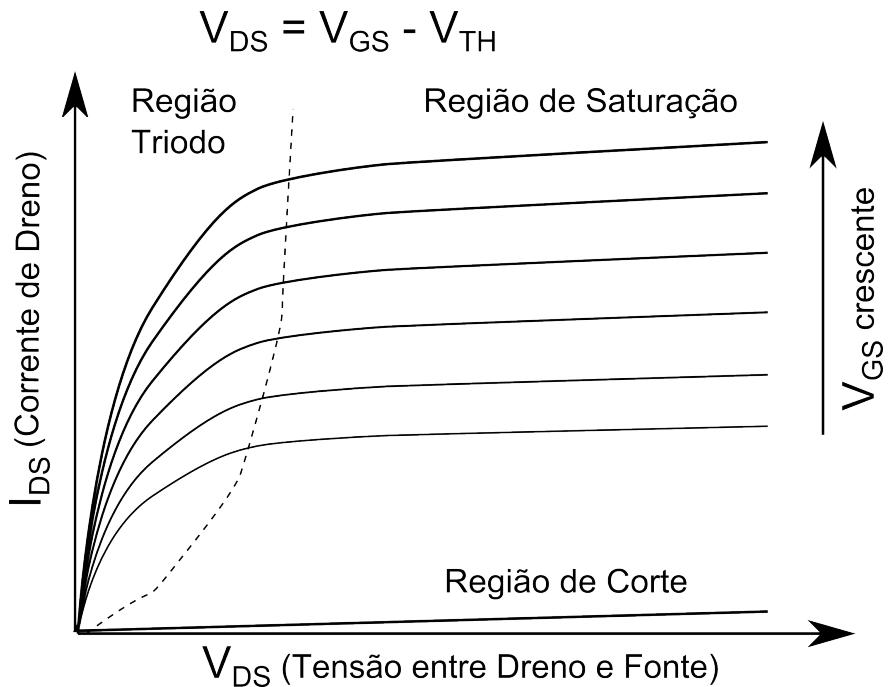


Figura 2.3: Curvas características I-V de um MOSFET de canal N.

Uma das características principais utilizadas para auxiliar no projeto de OTAs é a região de inversão dos MOSFETs, através da curva $g_m/I_{DS} \times I_{DS}/(W/L)$ ilustrada na Figura 2.4 (SILVEIRA; FLANDRE; JESPERS, 1996). Para obter esta curva, os autores mencionam dois métodos. Analiticamente através de um modelo do transistor da tecnologia a ser utilizada, ou por medidas de um transistor típico. Para realizar o trabalho de caracterização elétrica dos MOSFETs foram utilizados os arquivos SPICE dos anexos A.4 e A.5.

²A corrente de dreno-fonte (I_{DS}) , considerando que a corrente de porta (I_g) é relativamente pequena, é igual à corrente de dreno-fonte ($I_{DS} = I_d + I_g$)

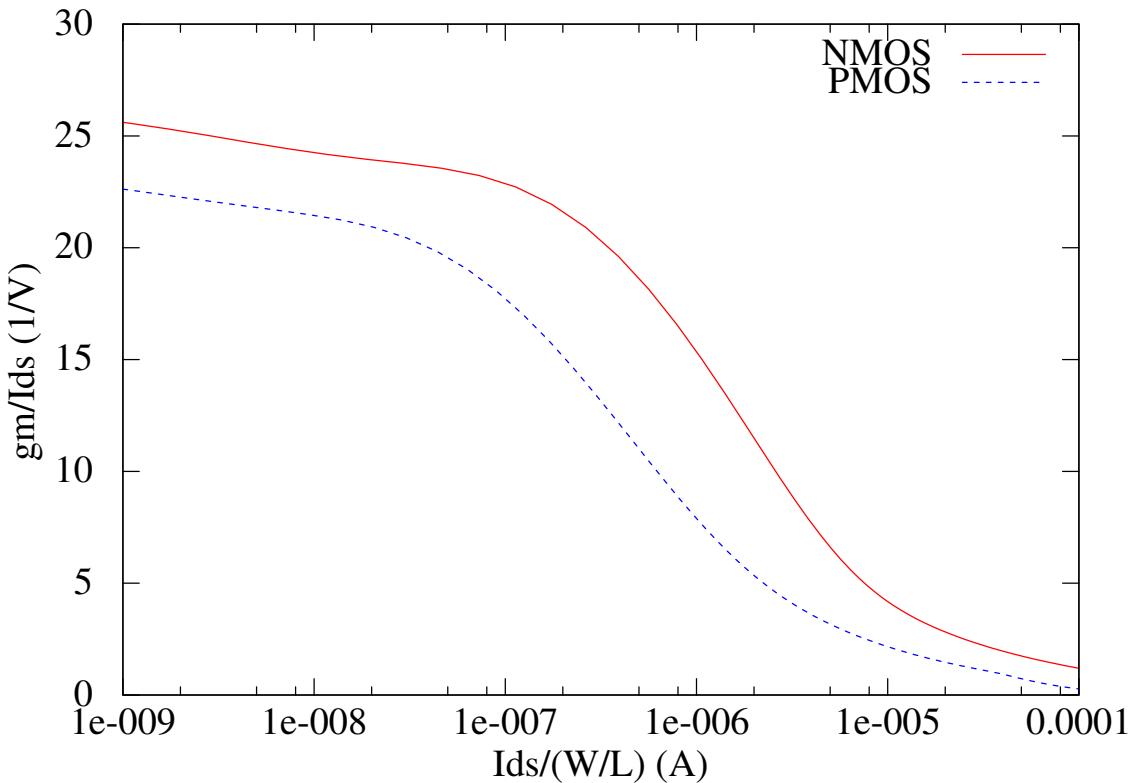


Figura 2.4: Curva de g_m/Ids em função de $Ids/(W/L)$ para transistores NMOS e PMOS utilizados.

As transições entre as regiões de inversão *Fraca-Moderada* e *Moderada-Forte* em termos de $Ids/(W/L)$ podem ser calculadas respectivamente nos pontos de 90% e 10% de g_m/Ids máximo (GENTINNE, 1996). A Tabela 2.1 descreve os valores de transição entre as regiões inversão Fraca-Moderada e Moderada-Forte para os transistores utilizados neste trabalho³.

Tabela 2.1: Limites entre as regiões de inversão dos transistores utilizados

Transistor	Inversão Fraca-Moderada (A)	Inversão Moderada-Forte (A)
NMOS	$4.812956e-008$	$2.256894e-005$
PMOS	$1.977102e-008$	$8.373005e-006$

2.2.2 Topologias de OTAs

O OTA mais básico que pode ser construído utilizando-se um único MOSFET está ilustrado na Figura 2.5 (GENTINNE, 1996). Nesta Figura, Gnd é o aterramento, M_1 é o MOSFET de canal N, C_L é a capacidade de carga, I_{abc} é a corrente de polarização, V_{in} é a tensão de entrada e V_{out} é a tensão de saída.

³Para todas os experimentos é utilizado o modelo BSIM3v3.1 para simulação SPICE com os parâmetros MOSIS da tecnologia SCN05 CMOS de $0.5\mu m$ disponível em: <http://www.mosis.com/cgi-bin/cgiwrap/umosis/swp/params/ami-c5/t99j-params.txt>, anexos A.2 e A.3

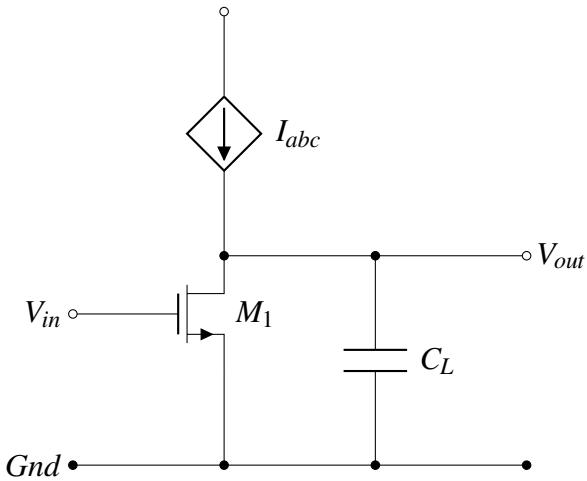


Figura 2.5: Esquema elétrico de um amplificador implementado com um único nMOSFET.

Outra implementação de OTA, de único estágio e única saída, é ilustrada na Figura 2.6. Esta é a implementação utilizada neste trabalho, onde M_1, M_2, M_7, M_8, M_9 e M_{10} são MOSFETs de canal N, M_3, M_4, M_5 e M_6 são MOSFETs de canal P e V_{dd} é a tensão de alimentação.

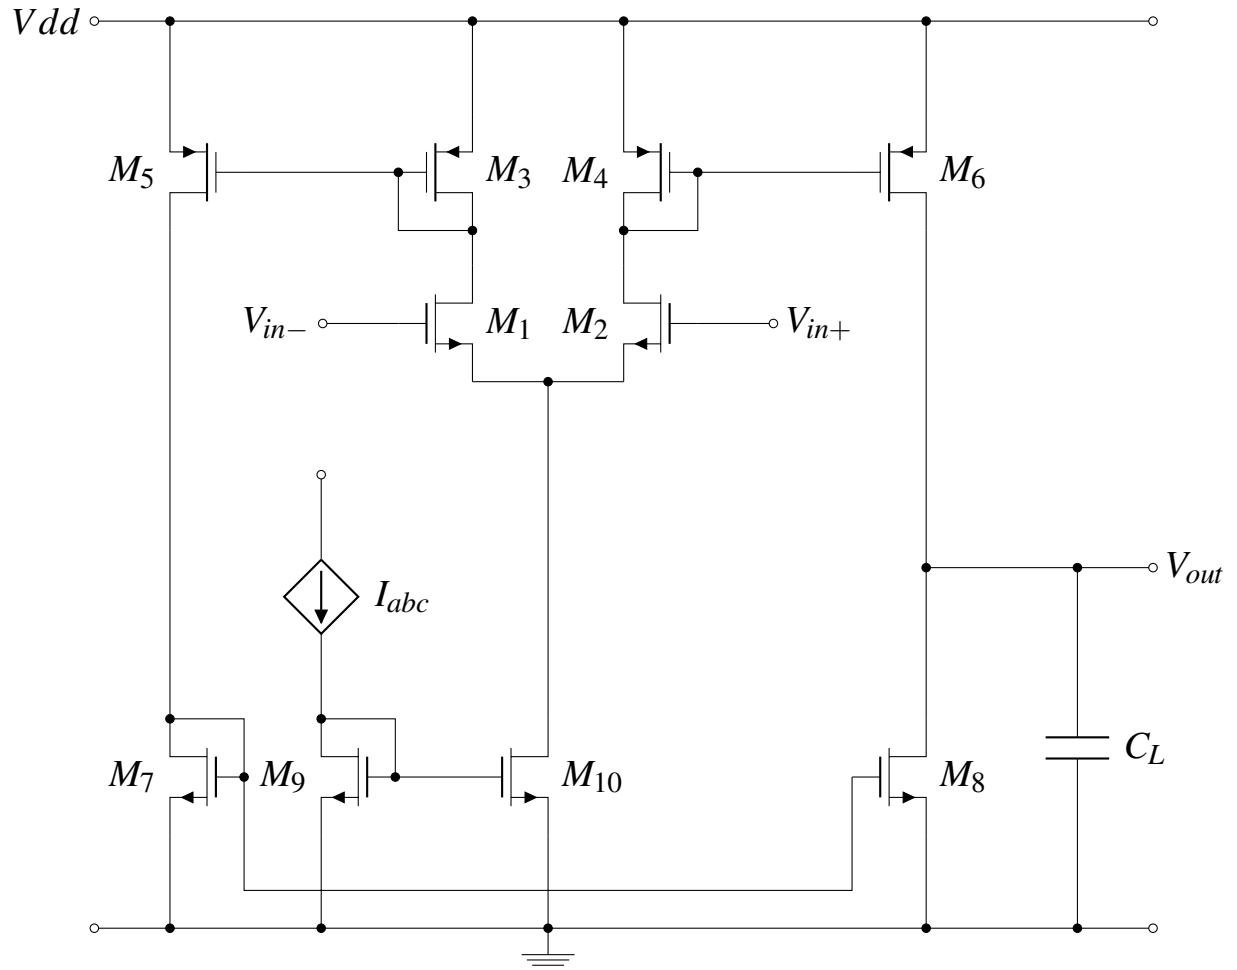


Figura 2.6: Esquema elétrico de um OTA de um único estágio e uma única saída.

Outro tipo de OTA é o OTA Miller, ilustrado na Figura 2.7, e que apresenta algumas melhorias em relação ao OTA de único estágio e única saída, onde o transistor M_5 constitui o segundo estágio de amplificação e C_p é a capacitância Miller (GENTINNE, 1996).

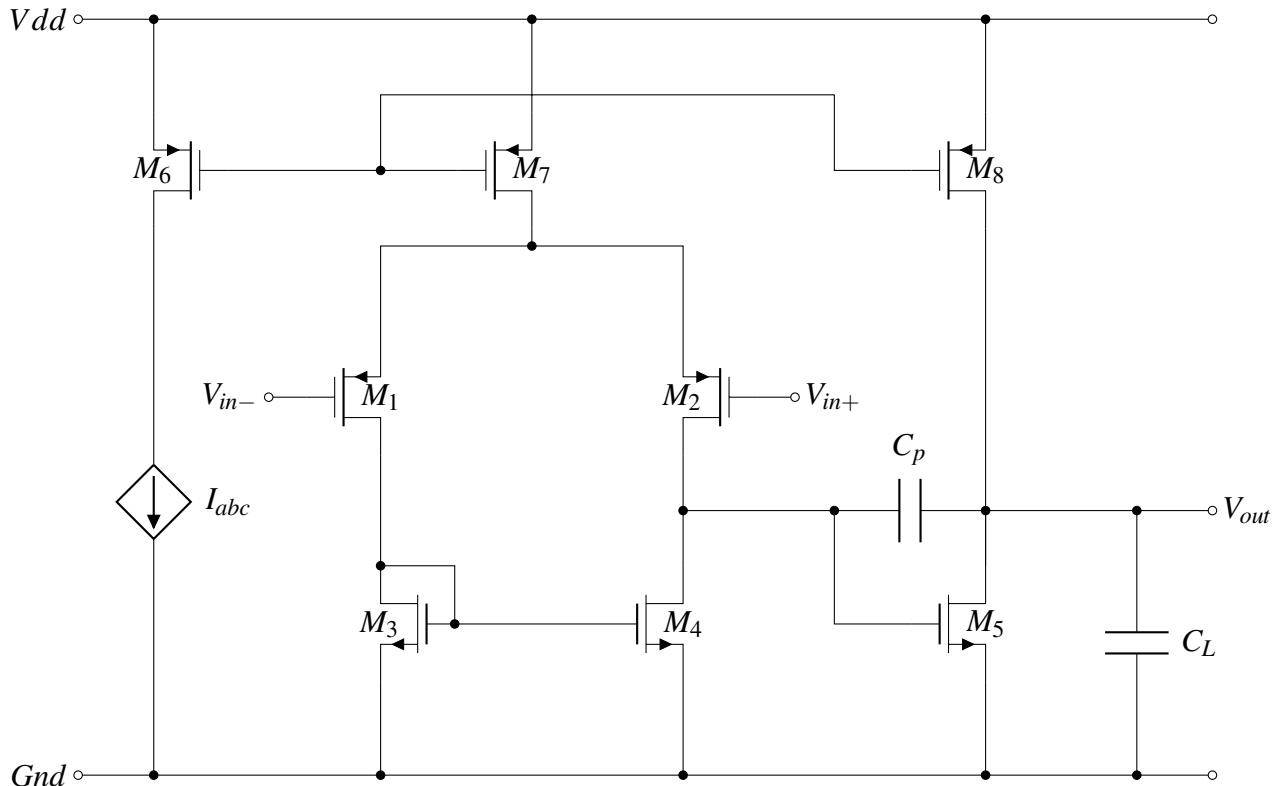


Figura 2.7: OTA Miller

Para o projeto de OTAs CMOS, dentro da topologia do circuito escolhido, é necessário que o projetista ajuste os seus diversos parâmetros, dentre eles a largura de canal W e comprimento de canal L para cada um dos transistores do circuito. Através do ajuste dos parâmetros, o projetista busca a otimização de diversas características do OTA como: ganho em malha aberta (A_{v0}), frequência de ganho unitário (f_T), *Slew Rate* (*SR*), potência dissipada (*Pwr*), área do circuito (A) e outros utilizando um simulador de circuitos como o SPICE (STEFANOVIĆ; KAYAL, 2008). O modelo dos **MOSFET!**s também precisa ser selecionado de acordo com a tecnologia de fabricação. Geralmente estes modelos são fornecidos por fabricantes, no caso deste trabalho utiliza-se os modelos BSIM3 da MOSIS de tecnologia SCN05 CMOS de $0.5\mu m$ disponível em: <http://www.mosis.com/cgi-bin/cgiwrap/umosis/swp/params/ami-c5/t99j-params.txt>.

O modelo BSIM3v3 é bastante preciso e foi desenvolvido para aproximar as características I-V do MOSFET pela solução das equações de Poisson que modelam o transporte de cargas. O Modelo BSIM3v3 engloba fenômenos importantes observados nos MOSFETs (LIU et al., 1998):

2.3 O Simulador de Circuitos SPICE

O SPICE é o simulador de circuitos mais recente desenvolvido pela Universidade da Califórnia em Berkeley, que tornou-se padrão na indústria e na Engenharia Eletrônica (NAGEL, 2008). O *Spice OPUS*, utilizado neste trabalho, é uma variante baseada no código aberto do *SPICE 3f4* da Berkeley, desenvolvida na Universidade de Ljubljana, Eslovênia (TUMA; BÜRMEN, 2009).

2.3.1 Avaliação do Ponto de Operação (comando SPICE .OP)

A primeira das avaliações a serem realizadas no OTA através do SPICE é o ponto de operação (.OP), que calcula as tensões e correntes contínuas (DC) em todos os nós e ramos do circuito respectivamente (TUMA; BÜRMEN, 2009). Através da análise do ponto de operação obtemos:

- a)** Potência do Circuito (I_{src} em função de V_{src}), onde I_{src} é a corrente de alimentação e V_{src} a tensão de alimentação;
- b)** Máxima Excursão do sinal de saída ($\min(|V_{dd} - V_{out}|, |V_{out} - G_{nd}|)$, máxima em $V_{out} = \frac{V_{dd}}{2}$);
- c)** Modo de operação dos transistores (Saturação, Triodo ou Corte);
- d)** Região de Inversão dos transistores extraída da curva de g_m/I_{DS} em função de $I_{DS}/(W/L)$.

2.3.2 Avaliação do Ganho em Malha Aberta, Frequência de Ganho Unitário e Margem de Fase (.AC)

Para a análise de pequenos sinais (comando SPICE .AC), o SPICE utiliza um modelo linearizado do circuito. Esta análise é conduzida no domínio de frequência (TUMA; BÜRMEN, 2009). Para realizar a simulação, utiliza-se o circuito em malha aberta ilustrado na Figura 2.8. Os parâmetros são:

- a)** Ganho de tensão em Malha Aberta (A_{v0}));
- b)** Frequência de Ganho de Tensão Unitário (f_T);
- c)** Margem de Fase (φ_T).

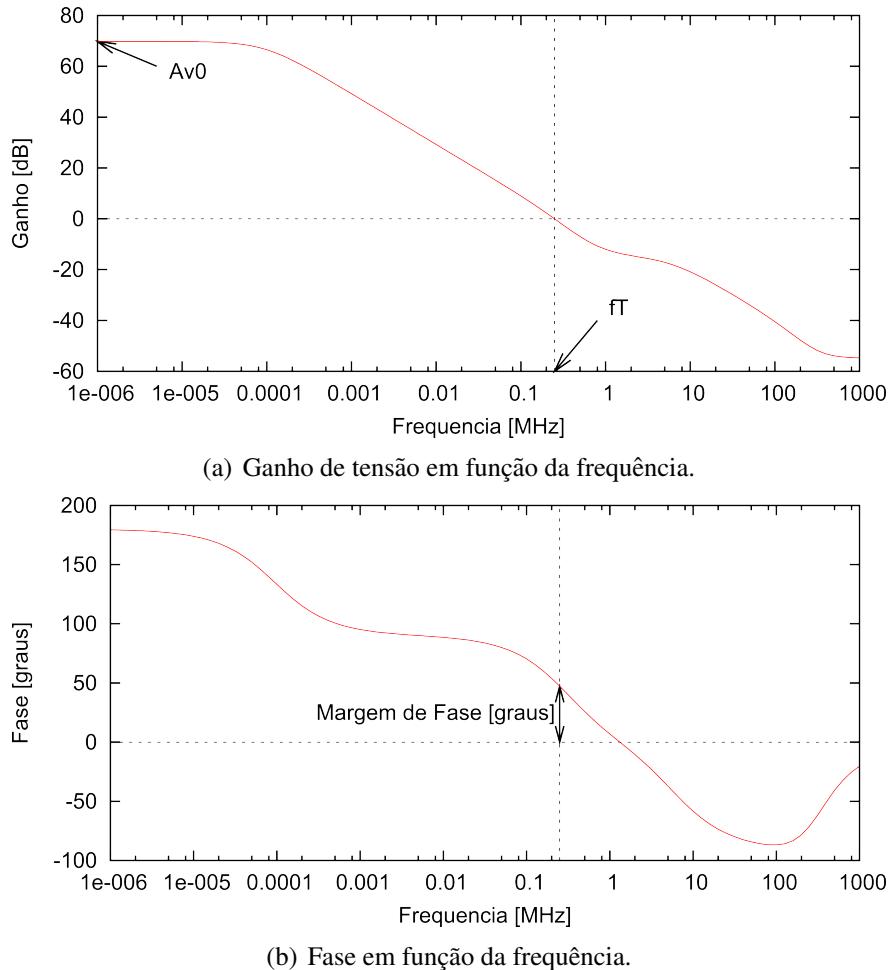


Figura 2.9: Resposta em frequência do OTA em malha aberta

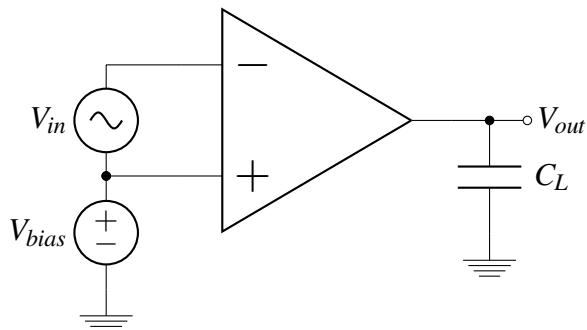


Figura 2.8: Circuito OTA em malha aberta.

O parâmetro A_{v0} é o ganho do OTA em baixa frequência, f_T é a frequência para o ganho unitário ($A_v = 0dB$), e a Margem de Fase⁴ φ_T é a fase para o ganho unitário ($A_v = 0dB$).

⁴ φ_T é utilizado como critério de estabilidade do OTA (GENTINNE, 1996). Os limites de aceitação utilizados neste trabalho são $55^\circ < \varphi_T < 75^\circ$.

2.3.3 Avaliação do *Slew-Rate* (.TRAN)

Para este estudo utiliza-se o circuito em malha fechada ilustrado na Figura 2.10. Esta configuração mantém o ganho igual a um ($A_{v0} = 0dB$). A análise de transiente (comando SPICE .TRAN) ocorre no domínio do tempo.

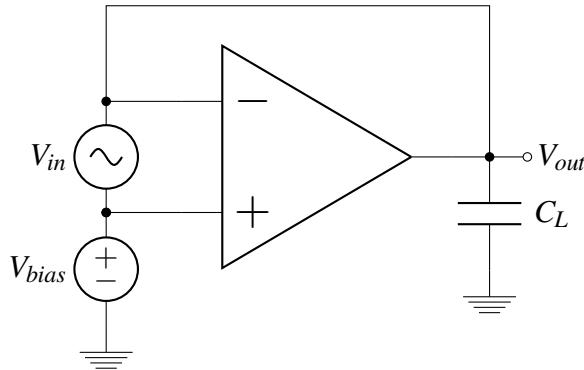


Figura 2.10: Circuito OTA em malha fechada.

O *Slew Rate* (SR) é uma medida da velocidade de resposta do circuito (TUMA; BÜRMEN, 2009), sua unidade é volt por microsegundo ($V/\mu s$). Para realizar a medida de SR, aplica-se uma função degrau na entrada do circuito e mede-se a máxima inclinação ($\Delta V/\Delta t$) da resposta, geralmente obtidas dos pontos 10% e 90% da rampa de subida como ilustrado na Figura 2.11.

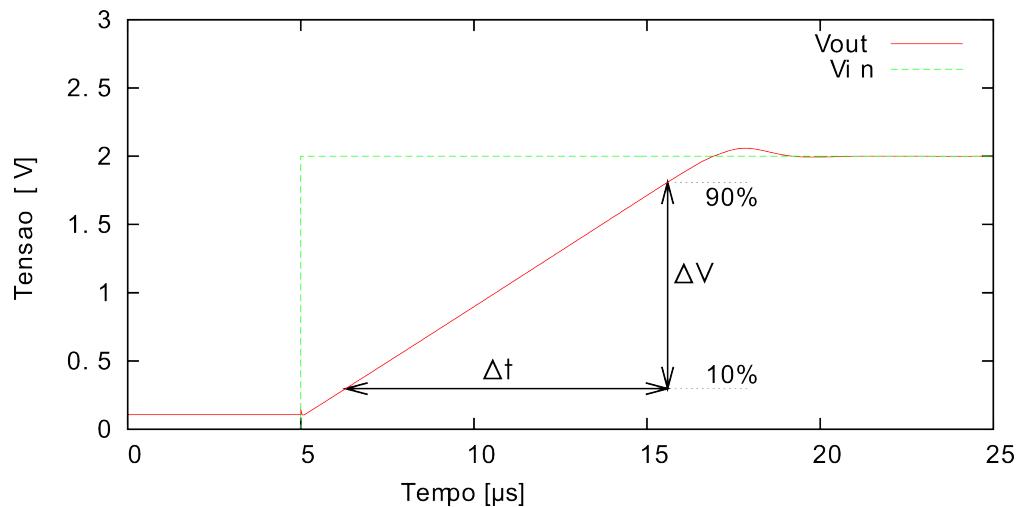


Figura 2.11: Resposta à função degrau de grandes sinais utilizada para a extração do *Slew Rate*.

2.4 O ciclo manual de projetos

Hjalmarson (2003) divide o desenvolvimento eletrônico em três níveis:

1. Componente;

2. Circuito (ou célula);

3. Sistema.

O projeto do OTA encontra-se ao nível de Circuito e requer semanas para ser executado (HJALMARSON, 2003). Dentro do contexto de sistemas *Mixed-Signal*, o desenvolvimento de células analógicas é um gargalo considerável. Podem existir dezenas de métricas de desempenho e o projetista precisa conhecer o efeito dos parâmetros de dimensionamento do circuito sobre estas métricas. Mesmo conhecendo todas as relações é difícil para o ser humano identificar o resultado que uma sequência de ajustes de parâmetros irá causar (HJALMARSON, 2003). O ciclo manual de projetos, com seus muitos ciclos de revisão, é ilustrado na Figura 2.12, onde a região assinalada mostra o escopo de otimização adotado neste trabalho, com foco no dimensionamento de componentes.



Figura 2.12: Fluxo de projeto manual de circuitos integrados analógicos e o escopo de otimização adotado neste trabalho, adaptado de Hjalmarson (2003).

A *Simulação SPICE* é utilizada como etapa de verificação, não como ferramenta de otimização. O projetista dispõe de simplificações, equações de primeira ordem, para fazer o ajuste de parâmetros do projeto do OTA. Segundo Hjalmarson (2003) outra questão fundamental é o desempenho do processo de produção: as variações de processo precisam ser consideradas dentro da simulação

com o método de Monte Carlo, ou o resultado pode não ser adequado⁵. Ainda segundo Hjalmarson (2003), os principais inconvenientes do projeto manual são:

1. Demorado e portanto caro;
2. Exploração insuficiente do espaço de busca (baixa utilização da tecnologia existente de processo);
3. Baixo reaproveitamento de projetos anteriores;
4. Alto risco de introdução de erros;
5. Variações de processo não são consideradas na fase de projeto.

A abordagem desenvolvida neste trabalho engloba os quatro primeiros itens desta lista, sendo o quinto item uma questão a ser abordada em trabalhos futuros.

⁵Variações de Processo não são consideradas neste trabalho, mas colocadas como uma questão para trabalhos futuros.

3 FUNDAMENTAÇÃO TEÓRICA E CONTEXTUALIZAÇÃO

“There is the genetical or evolutionary search by which a combination of genes is looked for; the criterion being the survival value. The remarkable success of this search confirms to some extent the idea that intellectual activity consists mainly of various kinds of search.”

*Intelligent Machines
Alan Turing, 1942*

3.1 Algoritmos Evolucionários

O termo *Computação Evolucionária*, relativamente novo, foi criado em 1991, e representa os esforços de unificação entre as três linhas principais de pesquisa em *Algoritmos Genéticos* (*Genetic Algorithms* - GA), *Estratégias de Evolução* (*Evolution Strategies* - ES) e *Programação Evolucionária* (*Evolutionary Programming* - EP)(FOGEL, 1994). Atribui-se aos seguintes autores o pioneirismo em cada uma destas linha de pesquisa:

- a) GA: John Holland, 1967;
- b) ES: Ingo Rechenberg, 1965;
- c) EP: Lawrence Fogel, 1966.

O termo *Algoritmos Evolucionários* (*Evolutionary Algorithms* - EA) aplica-se igualmente a GA, ES e EP e às variações destes algoritmos que seguem o paradigma computacional *neo-darwiniano* de simulação computacional da evolução de sistemas naturais. Este paradigma, conforme Bäck, Hammel e Schwefel (1997), se baseia nos princípios de evolução natural de Darwin que são *reprodução, variação e seleção*. Os EAs são algoritmos estocásticos porque a variação aleatória é um aspecto importante deste paradigma computacional. A estrutura básica de um EA é dada pelo Algoritmo 1, onde t é número da geração e $P(t)$ é a população da geração t .

Conforme o autor De Jong (2002, pg.23), pode-se encontrar nas idéias influentes de Sewall Wright (1932) a conexão entre o processo evolutivo e a *otimização*. Sendo o genótipo o espaço

Algoritmo 1: Algoritmo Evolucionário

início

```

 $t := 0$ 
inicialize[ $P(t)$ ]
avalie[ $P(t)$ ]
enquanto  $\neg$  termino faça
     $P'(t) := \text{variação}[P(t)]$ 
    avalie[ $P'(t)$ ]
     $P[(t + 1)] := \text{selecione}[P'(t)]$ 
     $t := t + 1$ 
  
```

de busca e a *função de aptidão* uma convolução do genótipo ao fenótipo, Wright visualizava um sistema evolucionário explorando o espaço de genótipos em busca de picos de uma *função de aptidão* multi-modal. A busca pela sobrevivência leva as populações a se aglomerarem em regiões próximas aos picos, formando nichos e especiação. A função de Schwefel na Figura 3.1 é um exemplo de paisagem artificial dada por uma *função de aptidão*.

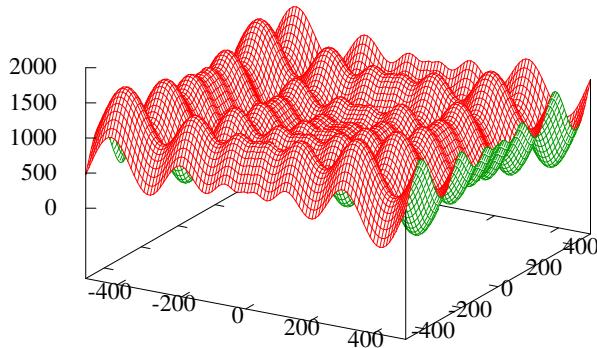


Figura 3.1: Função de aptidão artificial de Schwefel dada pela equação

$$\mathbf{f}(x) = 418.9829 \cdot n - \sum_{i=1}^n \sin\left(\sqrt{|x_i|}\right).$$

O processo de evolução simulado por computador e aplicado a problemas de otimização resulta em uma técnica de otimização estocástica eficiente em problemas complexos (FOGEL, 1994). Contudo, o Teorema da Inexistência do Almoço Grátis (*There is No Free Lunch* - NFL) (WOLPERT; MACREADY, 1997) determina que a superioridade relativa de desempenho de um algoritmo em uma determinada classe de problemas implica em uma compensação de ineficiência relativa em outras classes. Schwefel (1997) considera que, para um determinado domínio de problemas, na existência de algoritmos tradicionais os EAs não devem ser utilizados devido às implicações do NFL. Os EAs são, no entanto, uma excelente alternativa quando depara-se com problemas *não diferenciáveis*, *descontínuos*, *multimodais*, *ruidosos* ou com múltiplos objetivos.

3.1.1 Representação Genética

A representação é um aspecto fundamental dos EAs. A sua escolha correta deve permitir a codificação de parâmetros e a avaliação das soluções. Segundo De Jong (2002, p. 185), as propriedades de uma boa representação são: a) deve capturar as características importantes do domínio de aplicação que são necessárias para a solução efetiva de problemas e; b) deve permitir a utilização de operadores de reprodução efetivos. Estes operadores de reprodução são *cruzamento* e *mutação* (GOLDBERG, 1989).

Os sistemas biológicos possuem sua codificação através das cadeias de DNA e RNA, chamadas de *cromossomos*. O espaço de soluções possíveis de sistemas biológicos chama-se *genoma* e a sua realização *genótipo*. Antes de manifestar as características do *fenótipo*, relacionadas aos sistemas artificiais com a *função de aptidão*, os indivíduos biológicos passam por um processo de desenvolvimento chamado *ontogenia* até manifestar as características de indivíduos adultos (BANZHAF et al., 1998). Na Tabela 3.1 apresenta-se a comparação da terminologia Biológica e a correspondência em GAs.

Tabela 3.1: Terminologia Biológica e os significados correspondentes em GAs (GOLDBERG, 1989, p. 22).

Biologia	Algoritmos Genéticos
cromossomo	cadeia de caracteres
gene	característica
alelo	valor da característica
locus	posição na cadeia de caracteres
genótipo	estrutura/conjunto de parâmetros
fenótipo	decodificação da estrutura/parâmetros
epistase	não linearidade

Os sistemas de evolução artificial, os EAs, não obrigatoriamente necessitam da simulação do processo de *ontogenia*, segundo Banzhaf et al. (1998). Os aspectos necessários à evolução apontados por este autor são:

- a)** Uma população de indivíduos capazes de se reproduzir;
- b)** Variação de indivíduos, afetando a probabilidade de sobrevivência;
- c)** Hereditariedade na reprodução;
- d)** Competição pela sobrevivência.

Os operadores de reprodução, *cruzamento* e *mutação*, correspondem respectivamente às habilidades de *aproveitamento* (*exploit*) e *exploração* (*explore*) dos EAs. Ainda, segundo De Jong (2002), o operador de *cruzamento* deve ser pensado como um meio de aproveitamento de características interessantes de duas ou mais soluções da população para uma nova solução¹. O operador de *mutação*, por sua vez, deve ser pensado como um operador de *perturbação*, permitindo a busca nas vizinhanças da solução.

As representações comuns de EAs são:

- a)** Sequência Binária;
- b)** Vetores de Números Reais;
- c)** Sequências de Números Inteiros;
- d)** Estruturas de Grafos e Árvores;
- e)** Representações Híbridas.

Para o problema de otimização apresentado neste trabalho as representações adequadas são *Sequência Binária* e *Vetores de Números Reais*. Os demais tipos de representação encontram aplicação em problemas combinatoriais (Sequências de Números Inteiros) e topológicos (Grafos e Árvores), como no caso específico de Programação Genética (*Genetic Programming - GP*) aplicado à evolução de topologias de circuitos eletrônicos.

3.1.2 O Algoritmo Genético Canônico

Os GAs, conforme Goldberg (1989, p. 7), possuem as seguintes características:

- a)** GAs trabalham com codificações de parâmetros, não com os parâmetros diretamente;
- b)** GAs trabalham com populações de pontos (soluções codificadas), não com um único ponto;
- c)** GAs utilizam informação da *função de aptidão*, não derivadas ou outro conhecimento auxiliar;
- d)** GAs utilizam regras de transição probabilísticas, não regras determinísticas.

¹Esta troca de segmentos de informação é particularmente difícil em estruturas complexas como grafos (EP desenvolvida sobre Máquinas de Estado Finito é um bom exemplo: utiliza apenas *mutação*)

Os parâmetros no GA original são representados por uma cadeia de bits ou por caracteres de um alfabeto finito². O GA canônico é apresentado no Algoritmo 2, que é inicializado com uma população formada aleatoriamente dentro do espaço de busca, então cada indivíduo da população é avaliado por uma *função de aptidão* e selecionados para a reprodução através de *cruzamento* e *mutação*, formando a população descendente que será novamente avaliada e selecionada em um ciclo geracional até que atinja-se um critério de término. O critério de término pode ser, por exemplo, um determinado número de gerações ou um nível de aptidão escolhido previamente.

Algoritmo 2: O Algoritmo Genético Canônico.

```

início
     $t = 0$ 
    initialize aleatoriamente  $P(t)$ 
    enquanto  $\neg$  término faça
        para cada  $i, 1 \leq i \leq n$  /*  $n = \langle$  tamanho da população  $\rangle$  */
        faça
             $\sqsubset$  avalie a aptidão  $f_i(x_i), x_i \in P(t)$ 
        para cada  $i, 1 \leq i \leq n$  faça
             $\sqsubset$  obtenha através de seleção proporcional  $x_{sel} \in P(t)$  e armazene em  $O(t)$ 
        para cada  $i, 0 \leq i \leq (\frac{n}{2} - 1)$  faça
             $\sqsubset$  com probabilidade  $p_{cross}$  aplique cruzamento em  $x_{2i+1}, x_{2i+2} \in O(t)$ 
             $\sqsubset$  com probabilidade  $p_{mut}$  aplique mutação em  $x_{2i+1}, x_{2i+2} \in O(t)$ 
         $P(t + 1) = O(t)$ 
         $t = t + 1$ 

```

O primeiro passo do GA é criar uma população aleatória de soluções e obter a avaliação de cada solução (*função de aptidão*).

O segundo passo é fazer a seleção dos indivíduos mais aptos para a geração seguinte. No GA canônico isto é feito estocasticamente através da *seleção proporcional* ou *método da roleta*. Indivíduos são selecionados com probabilidade proporcional à sua *aptidão*, até que a população de descendentes tenha o mesmo tamanho da população de ancestrais. A amostragem é feita com reposição, isto significa que o mesmo indivíduo pode ser selecionado mais de uma vez.

O passo seguinte do GA é realizar o *cruzamento* e *mutação* dos indivíduos selecionados. Por exemplo, supondo que o processo de *Seleção* produziu uma cópia do indivíduo A_1 duas cópias do indivíduo A_2 e uma cópia do indivíduo A_4 , os pares para cruzamento são selecionados aleatoriamente com uma probabilidade de cruzamento escolhida como parâmetro do GA. O cruzamento de um ponto é ilustrado na Tabela 3.2, tendo a função de fragmentar o cromossomo de cada ascendente e recombiná-los para produzir os descendentes.

²O Teorema dos Esquemas de Holland implica que alfabetos de baixa cardinalidade produzem melhor desempenho nos GAs. Esta implicação é objecionada por Altenberg (1994), como será discutido adiante.

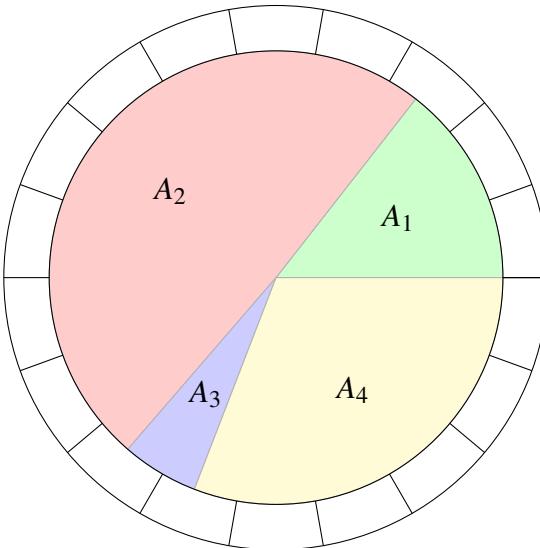


Figura 3.2: Método da Roleta ou Seleção Proporcional adaptado de Goldberg (1989).

Tabela 3.2: Exemplo de cruzamento em um GA simples ($t=0$) (GOLDBERG, 1989).

Seleção	Cruzamento	Ponto de Cruzamento	Novo Indivíduo	x	Aptidão $f(x)$
0110 1	A_2	4	01100	12	144
1100 0	A_1	4	11001	25	625
11 000	A_4	2	11011	27	729
10 011	A_2	2	10000	16	256
Total					1754

Após realizado o cruzamento dos indivíduos, aplica-se o operador de *mutação* que consiste em alterar estes indivíduos aleatoriamente com uma baixa probabilidade. O processo é repetido até que atinja-se um critério de término do algoritmo.

Segundo De Jong (2002, p. 68–69) não há uma regra explícita para os mecanismos de reprodução, estes operadores devem ser utilizados através de um balanço adequado entre *aproveitamento* (*exploit*) e *exploração* (*explore*) para produzir uma boa evolução da *aptidão* da população, conforme mencionado anteriormente.

3.1.2.1 Módulos de População

O modelo apresentado de GA chama-se *Geracional*, onde entre duas gerações a população de ascendentes é substituída completamente pela população de descendentes. Os módulos de população podem ser os seguintes (De Jong, 2002):

- a) *Geracional*: a população de descendentes substitui completamente a população de ascendentes;
- b) *Elitismo*: os k melhores indivíduos são copiados para a população de descendentes, geralmente

$k = 1$ (De Jong, 2002);

- c) *Estática(Steady State)*: os piores ascendentes são substituídos por novos descendentes, em algumas implementações a seleção é probabilística. Neste caso perde-se o conceito de geração;
- d) *Estratégia ($\mu + \lambda$)*: introduzido pelas Estratégias de Evolução (*Evolution Strategies - ES*), a população de ascendentes de tamanho μ gera λ descendentes e a seleção é feita sobre a união das duas populações de tamanho $\mu + \lambda$;

3.1.3 Teorema dos Esquemas de Holland

A prova da convergência dos GAs é um dos pontos centrais da teoria dos EAs e foi originalmente feita através do teorema aqui apresentado. Através deste teorema justifica-se a aplicabilidade dos GAs como algoritmos de otimização.

O Teorema dos Esquemas de Holland, conforme os autores Langdon e Poli (2002, p. 33), aplica-se somente ao contexto dos GAs mais simples que utilizam representação binária, seleção proporcional, mutação de bits e cruzamento de um único ponto. Fora deste contexto a utilidade do Teorema dos Esquemas é questionável (ALTENBERG, 1994). Apesar disto estes autores esclarecem que não há exatamente um problema com o teorema, mas na sua superinterpretação: uma das suas *consequências* é que os alfabetos de baixa cardinalidade promovem a reprodução dos esquemas favoráveis mais rapidamente do que alfabetos de alta cardinalidade, sugerindo que a representação binária é superior para a convergência do que a representação em ponto flutuante. Hoje muitos EAs utilizam representação em ponto flutuante com excelente desempenho. Conforme LANGDON; POLI a maior utilidade do Teorema dos Esquemas é sua forma concisa de descrever o funcionamento dos GAs.

Um esquema (ou padrão de similaridade), no contexto dos GAs mais simples, consiste em uma sequência de símbolos do conjunto $\{0, 1, *\}$, onde * significa “não importa”, ou seja: pode assumir qualquer valor. Por exemplo um esquema $*10*1$ representa igualmente: 01001, 01011, 11001 e 11011. O número de elementos diferentes de * em um esquema é chamado de *ordem* do esquema e é representado por $\mathcal{O}(H)$. A maior distância entre dois elementos diferentes de * é chamada de *comprimento* do esquema e é representada por $\mathcal{L}(H)$. O número esperado de cromossomos em uma população pertencendo ao esquema H então é (LANGDON; POLI, 2002):

$$E[m(H, t+1)] \geq m(H, t) \cdot \frac{f(H, t)}{\bar{f}(t)} \cdot (1 - p_m)^{\mathcal{O}(H)} \cdot \left[1 - p_{xo} \frac{\mathcal{L}(H)}{N-1} \left(1 - \frac{m(H, t)f(H, t)}{M\bar{f}(t)} \right) \right] \quad (3.1)$$

onde,

- a) $m(H, t)$ = Número de sequências que pertencem ao esquema H na geração t ;
- b) $f(H, t)$ = Função de aptidão média das sequências que pertencem ao esquema H ;
- c) $\bar{f}(t)$ = Função de aptidão média da população;
- d) p_m = Probabilidade de mutação (por bit);
- e) p_{xo} = Probabilidade de cruzamento;
- f) N = Número de bits dos cromossomos;
- g) M = Número de indivíduos na população;
- h) $E[m(H, t + 1)] =$ Número esperado de sequências pertencentes ao esquema H na próxima geração.

Os efeitos da seleção correspondem ao termo $\frac{f(H,t)}{\bar{f}(t)}$ que corresponde à probabilidade de seleção do esquema H , os efeitos da mutação são contabilizados por $(1 - p_m)^{\mathcal{O}(H)}$ e corresponde à probabilidade do esquema H não sofrer mutação e os efeitos do cruzamento são contabilizados por $\left[1 - p_{xo} \frac{\mathcal{L}(H)}{N-1} \left(1 - \frac{m(H,t)f(H,t)}{M\bar{f}(t)}\right)\right]$ e correspondem à probabilidade do esquema H não ser dividido pela operação de cruzamento. O Teorema dos Esquemas evita a ambiguidade dos eventos aleatórios de seleção, recombinação e mutação utilizando a média da ocorrência destes eventos.

A Equação (3.1) sugere que os esquemas com melhor *aptidão* são preservados para a próxima geração baseados na pressão seletiva e considera de forma pessimista os efeitos de variação causada pelo *cruzamento* e *mutação*, considerando como efeito possível somente o rompimento do esquema.

3.1.4 Teorema da Seleção e Covariância de Price

Altenberg (1994) demonstrou que o Teorema dos Esquemas de Holland pode ser derivado do Teorema da Seleção e Covariância de Price. O autor critica o Teorema dos Esquemas porque ele falha em capturar o conceito de desempenho dos GAs, onde descendentes com *aptidão* acima da média podem ser produzidos pela recombinação de ascendentes também com *aptidão* acima da média. O Teorema de Price preenche esta lacuna porque mostra como as propriedades macroscópicas de uma população podem ser derivadas da dinâmica microscópica do GA, combinadas com uma métrica apropriada: a *aptidão*³. Quando a métrica é a *aptidão*, obtém-se a evolução da *aptidão*

³A *aptidão* está diretamente relacionada com *seleção* e *reprodução*. Indivíduos com maior *aptidão* são capazes de gerar mais descendentes. Na equação de Price, a quantidade de descendentes z está diretamente relacionada com a *aptidão*.

sobre uma geração, quando a métrica é a frequência de um *esquema*, obtém-se a evolução de um *esquema* sobre uma geração. Desta forma, mudando a métrica do Teorema de Price para frequências de *esquemas* o Teorema de Price expressa o Teorema dos Esquemas.

O Teorema da Seleção e Covariância de Price, conforme o original e Altenberg (1994), Langdon e Poli (2002) aplica-se à toda sorte de sistemas evolutivos em particular aos *Algoritmos Genéticos* (GA).

“Gene frequency change is the basic event in biological evolution. The following equation, which gives frequency change under selection from one generation to the next for a single gene or for any linear function of any number of genes at any number of loci, holds for any sort of dominance or epistasis, for sexual or asexual reproduction, for random or nonrandom mating, for diploid, haploid or polyploid species, and even for imaginary species with more than two sexes.”

Price (1970)

O Teorema da Seleção e Covariância é formulado por,

$$\Delta Q = \frac{cov(z, q)}{\bar{z}} + \frac{\sum z_i q_i}{N \bar{z}}, \quad (3.2)$$

onde ΔQ é a variação da frequência de um gene A entre as populações de ascendentes P_1 e descendentes P_2 , z é o número de descendentes na população P_2 que possuem o gene A , z_i é o número de descendentes do indivíduo i , q é a frequência do gene A nos descendentes z , q_i é a frequência do gene A nos descendentes de z_i , N é o número de indivíduos na população P_1 e \bar{z} é a média de descendentes gerados entre P_1 e P_2 .

O termo $\frac{\sum z_i q_i}{N \bar{z}}$ refere-se à *deriva genética* causada pelos operadores de recombinação e mutação. Se estes operadores são aleatórios a respeito do gene A , então em grandes populações este termo tende à zero (PRICE, 1970). Neste caso, temos

$$\Delta Q = \frac{cov(z, q)}{\bar{z}}. \quad (3.3)$$

Conforme De Jong (2002, p. 162–163), o Teorema de Price oferece uma heurística para o desenho de EAs, com objetivo no desempenho da evolução. Apesar de Price focar-se na frequência de genes, a equação é mais geral e pode ser utilizada para qualquer característica mensurável entre as populações de ascendentes e descendentes. Se estamos interessados na variação da aptidão média entre as populações, o termo da covariância na Equação (3.2) representa a contribuição feita pela seleção. O segundo termo representa a contribuição feita pelos operadores de reprodução.

A perspectiva de Price permite avaliar o impacto das combinações entre os métodos de seleção e reprodução para o desempenho evolutivo dos EAs (De Jong, 2002).

3.1.5 Codificação Genética por números Reais

Em espaços de busca contínuos, são encontrados alguns problemas com a representação binária (DEB, 2001). Dentre eles temos os abismos de Hamming (por exemplo entre as sequências 01111 e 10000) onde para uma transição vizinha no espaço real necessitamos a alteração de muitos bits. Os abismos de Hamming impedem a busca gradual no espaço contínuo. Outra dificuldade causada pela representação binária é a impossibilidade de alcançar uma precisão arbitrária para a solução ótima, a granulação do espaço de busca binário é determinada a priori em GAs.

Por outro lado, a representação através de números reais possui implicações quanto ao processamento de perturbações, sejam mutações ou cruzamentos (DEB, 2001). Enquanto a representação binária requer a simples inversão de bits para mutação e cópia de segmentos para o cruzamento, GAs com representação real requerem tratamento especial.

GOLDBERG introduziu o conceito de alfabetos virtuais criados pelo mecanismo de seleção de GAs. O argumento de GOLDBERG é que soluções acima da média, sobrevidentes do processo de seleção, concentram-se em sub-regiões do espaço de decisão criando *caracteres virtuais* de um alfabeto finito. Após algumas gerações de codificação real tratam o espaço de busca contínuo como se fosse um espaço de busca discreto, atuando da mesma maneira que GAs binários (Figura 3.3).

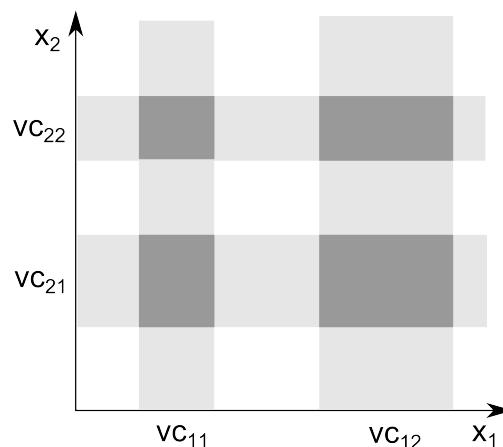
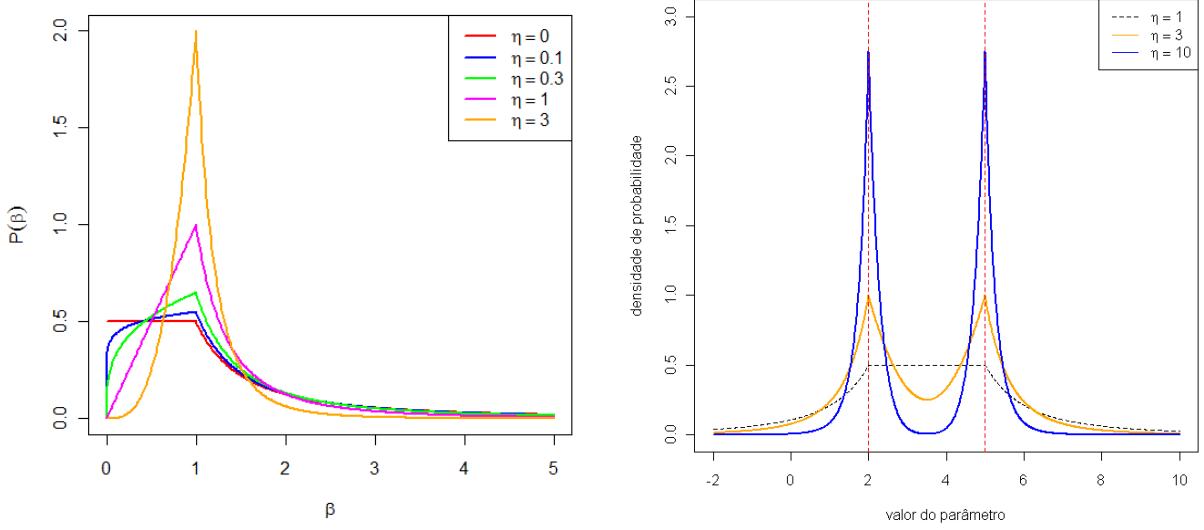


Figura 3.3: Caracteres virtuais em um espaço contínuo de busca de 2 variáveis (GOLDBERG, 1990).

3.1.5.1 Cruzamento Binário Simulado (SBX)

Dentre os vários métodos de cruzamento para GAs com representação através de vetores de números reais, destaca-se o Cruzamento Binário Simulado (SBX) (DEB; AGRAWAL, 1994). Como seu nome indica, este operador simula o cruzamento de um ponto entre sequências binárias. O conceito básico deste operador é respeitar os intervalos entre *schemata* preservando-os nos descendentes.



(a) Distribuição probabilística do operador SBX em função de β para vários valores de η .
(b) Exemplo da distribuição probabilística do operador SBX, para cruzamento de pais com valores 2.0 e 5.0 e vários valores de η .

Figura 3.4: Distribuição probabilística do operador SBX.

Sejam $x_i^{(1,t)}$ e $x_i^{(2,t)}$ os valores do i-ésimo parâmetro de dois vetores selecionados para cruzamento na geração t . O fator β_i é definido como a razão absoluta entre a diferença dos i-ésimos valores entre descendentes e pais,

$$\beta_i = \left| \frac{x_i^{(2,t+1)} - x_i^{(1,t+1)}}{x_i^{(2,t)} - x_i^{(1,t)}} \right|. \quad (3.4)$$

Os descendentes de uma operação de cruzamento através do operador SBX são determinados pela função probabilística

$$P(\beta_i) = \begin{cases} 0.5(\eta_c + 1)\beta_i^{\eta_c}, & \text{se } \beta_i \leq 1; \\ 0.5(\eta_c + 1)\frac{1}{\beta_i^{\eta_c+2}}, & \text{em outro caso,} \end{cases} \quad (3.5)$$

ilustrada na Figura 3.4(a) e exemplificada na Figura 3.4(b).

3.1.5.2 Mutação Polinomial

A *Mutação Polinomial* foi utilizada pela primeira vez no algoritmo *GeneAS*, introduzido por Deb e Goyal (1996), para a utilização em conjunto do operador SBX. É dada pela função probabilística

$$P(\delta) = 0.5(\eta_m + 1)(1 - |\delta|)^{\eta_m}, \quad (3.6)$$

onde:

$$\delta = \begin{cases} (2r)^{1/(\eta_m+1)} - 1, & \text{se } r < 0.5 \\ 1 - [2(1-r)]^{1/(\eta_m+1)}, & \text{se } r \geq 0.5 \end{cases}, \quad (3.7)$$

e r é um número aleatório de distribuição uniforme no intervalo $0 \leq r < 1$.

3.2 Algoritmos Evolucionários de Múltiplos Objetivos

Algoritmos Evolucionários de Múltiplos Objetivos (*Multi-Objective Evolutionary Algorithms* MOEA), de acordo com Coello (2006), surgiram pela primeira vez em 1983 por David Schaffer através de seu *Vector Evaluated Genetic Algorithm* (VEGA), Algoritmo 3. Este MOEA consiste de um GA com um mecanismo de seleção modificado: A cada geração sub-populações são criadas para cada objetivo e sobre estas sub-populações é aplicada seleção proporcional. Estas sub-populações são embaralhadas após a seleção e então aplica-se *cruzamento* e *mutação* de modo usual. VEGA possui a habilidade de reter soluções acima da média e boas candidatas à *Fronteira de Pareto*, mas conforme GOLDBERG as soluções extremas de cada objetivo são perdidas, restando somente as soluções próximas ao centro da *Fronteira de Pareto*. Nesta crítica ao VEGA, Goldberg (1989, p. 199–201) propõe originalmente a utilização de *dominância Pareto* para MOEAs aplicados a problemas de múltiplos objetivos.

Algoritmo 3: *Vector Evaluated Genetic Algorithm* (SCHAFFER, 1984 apud DEB, 2001, p. 179–184)

```

início
     $t = 0$ 
    para cada  $i, 1 \leq i \leq n$  faça
           initialize  $x_i \in P(t)$                                 /*  $n = \langle$  tamanho da população  $\rangle$  */
         $q = n/m$                                               /*  $m = \langle$  número de objetivos  $\rangle$  */

    enquanto  $\neg$  término faça
           embaralhe  $P(t)$ 
           divida  $P(t)$  em  $q$  subpopulações
           para cada  $j, 1 \leq j \leq q$  faça
                 para cada  $i, 1 \leq i \leq q$  faça
                      avalie a aptidão  $f_i^j(x_i)$ 
                      faça seleção proporcional em  $P^j(t)$  armazenando em  $O^j(t)$ 
                  $O(t) = \bigcup_{j=1}^q O^j(t)$ 
                 aplique cruzamento e mutação em  $O(t)$ 
                  $P(t+1) = O(t)$ 
                  $t = t + 1$ 

```

Conforme Coello (2006), por muitos anos após a introdução do VEGA, os pesquisadores adotaram soluções como: funções de agregação lineares, funções de agregação não-lineares e ordenação lexicográfica. Na perspectiva deste autor, os verdadeiros MOEAs surgiram entre 1989 e 1998 e compõem a primeira geração. Estes MOEAs seguem basicamente as idéias de Goldberg (1989, p. 199) utilizando a ordenação por *dominância Pareto* e uma técnica de manutenção da diversidade para evitar a convergência em um único ponto. As principais técnicas de tratamento de objetivos são mostradas na Figura 3.5. As técnicas principais de manutenção da diversidade utilizadas nos MOEAs são *Modelo de Apinhamento* e *Compartilhamento de Aptidão*.

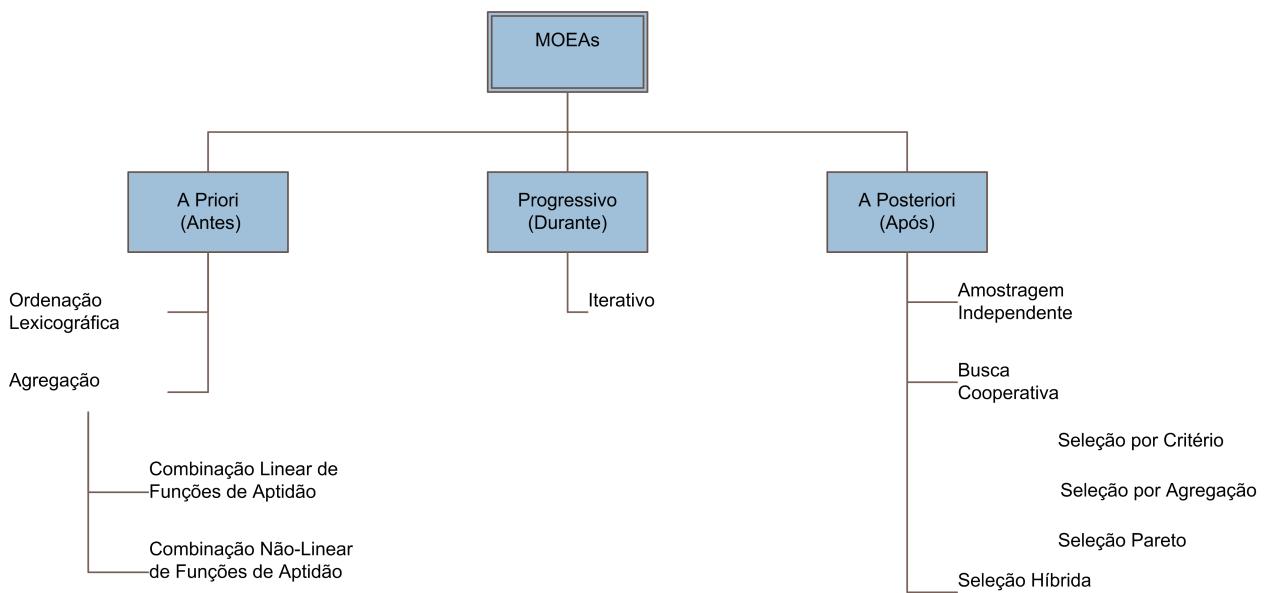


Figura 3.5: Classificação de MOEAs quanto ao tratamento de relações de compromisso entre os objetivos (COELLO; LAMONT; VELDHUIZEN, 2006).

3.2.1 Modelo de Apinhamento

Conforme Deb (2001, p. 149), esta técnica foi introduzida por De Jong (1975) em sua tese de doutorado. Como o nome sugere, esta técnica desfavorecia o *apinhamento* de soluções em qualquer região do espaço de objetivos. No GA de De Jong, somente uma proporção da população era permitida reproduzir a cada geração. Soluções com um *fator de apinhamento* escolhido aleatoriamente eram comparadas com o novo descendente e este substituía a solução com maior similaridade, desta forma a diversidade era preservada. A principal contribuição da tese de De Jong foi a sugestão de substituição de uma solução por outra similar na manutenção de soluções ótimas em problemas multi-modais.

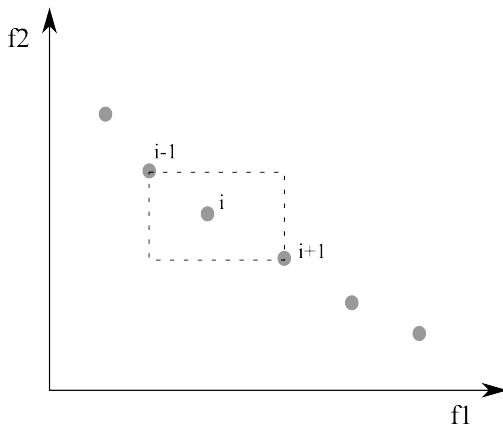


Figura 3.6: Distância de apinhamento, adaptado de Deb (2001).

A métrica *distância de apinhamento*, descrita em detalhes no algoritmo 6, é a implementação deste modelo. A figura 3.6 ilustra o conceito de distância de apinhamento, dada pelo semiperímetro normalizado formado pelas soluções vizinhas e no caso de soluções extremas, é atribuído um valor infinito. Para evitar-se o efeito de magnitudes diferentes entre os objetivos, as distâncias devem ser normalizadas.

3.2.2 Modelo de Compartilhamento de Aptidão

Goldberg e Richardson (1987) apud (DEB, 2001, p. 149), sugeriram que ao invés de substituir uma solução por outra similar, deveria-se degradar a aptidão de soluções similares. Este modelo foi utilizado na maioria dos estudos subsequentes de GAs envolvendo problemas multimodais. Neste cenário o interesse é encontrar q soluções ótimas, correspondentes aos picos da função de aptidão multimodal, utilizando-se uma população de tamanho N . Se $q \ll N$, o EA para trabalhar adequadamente com cada q (nicho) precisa de uma subpopulação de tamanho adequado. Sendo m_i o tamanho da subpopulação i e f_i a aptidão da solução ótima i , $i \in 1 \dots q$, então,

$$\frac{f_1}{m_1} = \frac{f_2}{m_2} = \dots = \frac{f_q}{m_q} \quad (3.8)$$

apesar do princípio ser razoável para manter a diversidade de uma população ele esbarra em um problema prático que é o conhecimento de antemão sobre as soluções ótimas verdadeiras. De acordo com Deb (2001) a solução é utilizar uma estratégia adaptativa onde o compartilhamento de aptidão é utilizado para estimar o número de soluções pertencentes a cada ótimo.

3.3 Múltiplos Objetivos e Dominância Pareto

A *Dominância Pareto* aplica-se aos problemas de otimização de múltiplos objetivos quando estes são conflitantes e não estabelecemos preferências *à priori*. Quando os objetivos não são conflitantes, a cardinalidade do conjunto Pareto ótimo (\mathcal{PF}^*) reduz-se a uma única solução no espaço de objetivos. A Figura 3.7 ilustra o contexto do mapeamento do *espaço de decisão* ao *espaço de objetivos*.

Os conceitos e definições apresentados a seguir, comuns a diversos autores da área de Algoritmos Evolucionários de Múltiplos Objetivos(MOEAs), são baseados nos trabalhos de Knowles, Thiele e Zitzler (2006) e Zitzler et al. (2002).

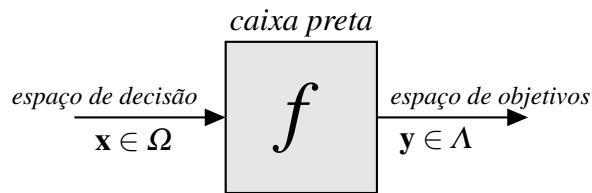


Figura 3.7: Função de mapeamento do *espaço de decisão* ao *espaço de objetivos*. Adaptado de (ZITZLER et al., 2002)

Definição 1. Um problema de otimização consiste em encontrar o vetor ótimo do espaço de decisão $\mathbf{x}^* \in \Omega$ que minimize (ou maximize) a sua avaliação correspondente $\mathbf{y}^* \in \Lambda$ mapeada pela função $f : \Omega \rightarrow \Lambda$ tal que $\forall \mathbf{x} \in \Omega : f(\mathbf{x}^*) < f(\mathbf{x})$ (no caso de minimização) (Figura 3.7).

Quando o resultado da avaliação é um número escalar, ou seja: $\Lambda \subseteq \mathbb{R}^m$ e $m = 1$, o conceito de ótimo é trivial conforme a definição 1. Quando a função de avaliação retorna um vetor do *espaço de objetivos*, $\Lambda \subseteq \mathbb{R}^m$ e $m > 1$, a comparação escalar não é mais possível. Para definir um problema de múltiplos objetivos precisamos recorrer às relações de *Dominância Pareto*.

3.3.1 Relações Binárias Pareto

As relações binárias Pareto aplicam-se a vetores do *espaço de objetivos* e a conjuntos destes vetores, chamados de *conjuntos de aproximação Pareto*. Estas relações, no caso particular de vetores, estão ilustradas na Figura 3.8. Em seguimento são apresentadas as definições de cada relação.

Observa-se na Figura 3.8, para dois objetivos a serem minimizados, que a possui pelo menos um dos componentes melhor do que b ou c , portanto $a \prec b$ e $a \prec c$. O vetor a possui todos os componentes melhores que d , portanto $a \ll d$. Os vetores b e c são melhores em objetivos distintos, portanto são incomparáveis $b \parallel c$ pois não há preferências estabelecidas entre os objetivos.

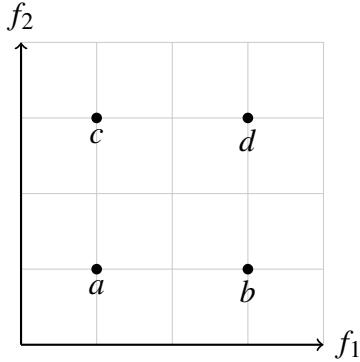


Figura 3.8: Relações binárias Pareto, considerando *minimização* dos objetivos f_1 e f_2 , verifica-se que: $a \prec b$, $a \prec c$, $a \prec d$, $a \ll d$, $a \preccurlyeq a$, $a \preccurlyeq b$, $a \preccurlyeq c$, $a \preccurlyeq d$, $b \prec d$, $b \preccurlyeq b$, $b \parallel c$, $c \prec d$, $c \preccurlyeq c$ e $c \parallel b$.

Quando são comparados vetores contendo múltiplos objetivos, as seguintes relações Pareto são aplicáveis (ZITZLER et al., 2002)(Tabela 3.3):

Tabela 3.3: Relações Pareto binárias para vetores objetivo.

relação	notação
dominância estrita	$u \ll v$
dominância	$u \prec v$
dominância fraca	$u \preccurlyeq v$
incomparável	$u \parallel v$

Definição 2. Dominância Pareto Estrita: Um vetor $u = [u_1, u_2, \dots, u_k]^T$ domina estritamente outro vetor $v = [v_1, v_2, \dots, v_k]^T$, denotado por $u \ll v$, se e somente se todos os componentes vetoriais de u são melhores que os componentes vetoriais correspondentes de v .

Definição 3. Dominância Pareto: Um vetor $u = [u_1, u_2, \dots, u_k]^T$ domina outro vetor $v = [v_1, v_2, \dots, v_k]^T$, denotado por $u \prec v$, se e somente se não existe componente vetorial em v melhor do que o correspondente em u e existe pelo menos um componente vetorial em u melhor do que seu correspondente em v .

Definição 4. Dominância Pareto Fraca: Um vetor $u = [u_1, u_2, \dots, u_k]^T$ domina fracamente outro vetor $v = [v_1, v_2, \dots, v_k]^T$, denotado por $u \preccurlyeq v$, se e somente se não existe componente vetorial em v melhor do que o correspondente em u .

Definição 5. Incomparabilidade Pareto: Um vetor $u = [u_1, u_2, \dots, u_k]^T$ é incomparável a outro vetor $v = [v_1, v_2, \dots, v_k]^T$, denotado por $u \parallel v$, se e somente se não $u \preccurlyeq v$ e não $v \preccurlyeq u$.

3.3.2 Conjunto Pareto e Fronteira de Pareto Ótimos

O *Conjunto Pareto Ótimo*, denotado por \mathcal{P}^* , é um conjunto de soluções no espaço de decisão Ω , que resultam na *Fronteira de Pareto Ótima*, denotada por \mathcal{PF}^* , quando mapeadas ao espaço de

objetivos Λ por uma função de avaliação $\mathbf{f} : \Omega \rightarrow \Lambda$ (COELLO; LAMONT; VELDHUIZEN, 2006).

Definição 6. Conjunto Pareto Ótimo

$$\mathcal{P}^* = \{x \in \Omega \mid \nexists x' \in \Omega : \mathbf{f}(x') \preccurlyeq \mathbf{f}(x)\}.$$

Definição 7. Fronteira de Pareto Ótima

$$\mathcal{PF}^* = \{y = \mathbf{f}(x) \mid \forall x \in \mathcal{P}^*\}.$$

3.3.3 Conjuntos de Aproximação Pareto

Os resultados obtidos através dos MOEAs são conjuntos de aproximação à *Fronteira de Pareto* \mathcal{PF}^* . Estes conjuntos possuem propriedades conforme a Definição 8.

Definição 8. Conjunto de Aproximação Pareto: *Seja $\mathcal{A} \subseteq \Lambda$ um conjunto de vetores no espaço de objetivos. \mathcal{A} é chamado de Conjunto de Aproximação Pareto se $\forall y \in \mathcal{A} \mid \nexists y' \in \mathcal{A} : y \preccurlyeq y'$.*

As relações entre os *Conjuntos de Aproximação Pareto*, visualizadas na Figura 3.9, são definidas na Tabela 3.4 (ZITZLER et al., 2002).

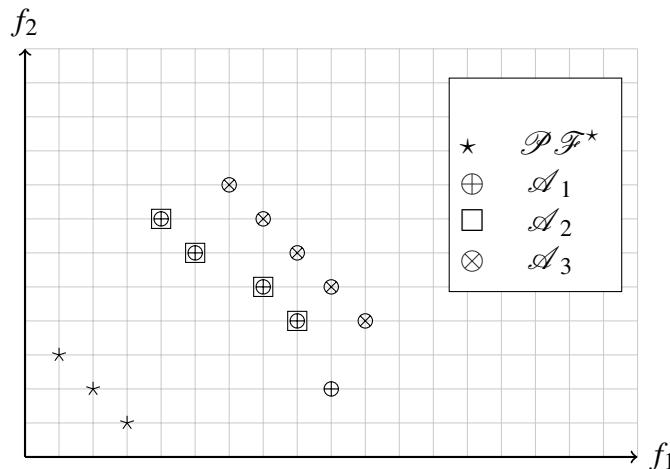


Figura 3.9: Relações entre Conjuntos de Aproximação para um problema de minimização de dois objetivos f_1 e f_2 . Observa-se que $\mathcal{A}_1 \ll \mathcal{A}_3$, $\mathcal{A}_1 \prec \mathcal{A}_3$, $\mathcal{A}_2 \prec \mathcal{A}_3$, $\mathcal{A}_1 \preccurlyeq \mathcal{A}_1$, $\mathcal{A}_1 \preccurlyeq \mathcal{A}_2$, $\mathcal{A}_1 \preccurlyeq \mathcal{A}_3$, $\mathcal{A}_2 \preccurlyeq \mathcal{A}_2$, $\mathcal{A}_2 \preccurlyeq \mathcal{A}_3$, $\mathcal{A}_3 \preccurlyeq \mathcal{A}_3$, $\mathcal{A}_1 \triangleleft \mathcal{A}_2$, $\mathcal{A}_1 \triangleleft \mathcal{A}_3$ e $\mathcal{A}_2 \triangleleft \mathcal{A}_3$.

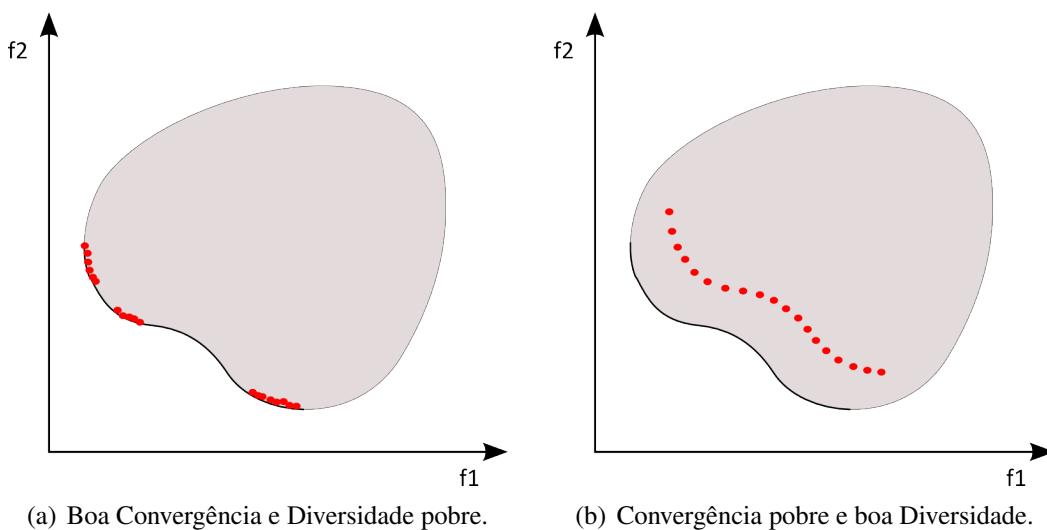
3.3.4 Indicadores de Qualidade para Conjuntos de Aproximação Pareto

Uma das questões centrais ao estudo de MOEAs é a comparação entre os resultados obtidos entre as variantes de algoritmos. De acordo com Deb (2001) os MOEAs possuem dois critérios básicos para a obtenção do Conjunto de Aproximação Pareto resultante da otimização:

Tabela 3.4: Relações entre Conjuntos de Aproximação Pareto.

relação	notação	condição
dominância estrita	$\mathcal{A} \ll \mathcal{B}$	$\forall y' \in \mathcal{B} \exists y \in \mathcal{A} : y \ll y'$
dominância	$\mathcal{A} \prec \mathcal{B}$	$\forall y' \in \mathcal{B} \exists y \in \mathcal{A} : y \prec y'$
melhor	$\mathcal{A} \triangleleft \mathcal{B}$	$\forall y' \in \mathcal{B} \exists y \in \mathcal{A} : y \preccurlyeq y' \wedge \mathcal{A} \neq \mathcal{B}$
dominância fraca	$\mathcal{A} \preccurlyeq \mathcal{B}$	$\forall y' \in \mathcal{B} \exists y \in \mathcal{A} : y \preccurlyeq y'$
incomparável	$\mathcal{A} \parallel \mathcal{B}$	$\mathcal{A} \not\ll \mathcal{B} \wedge \mathcal{B} \not\ll \mathcal{A}$

- a) Obter um conjunto de soluções no espaço de objetivos o mais próximo possível da Fronteira de Pareto Ótima (\mathcal{PF}^*) (Figura 3.10(a));
- b) Obter um conjunto de soluções no espaço de objetivos o mais diverso possível (maior cobertura à Fronteira de Pareto, Figura 3.10(b)).

**Figura 3.10:** Deficiências na obtenção de Conjuntos de Aproximação Pareto.

Os autores Zitzler et al. (2002) demonstram que não é possível determinar se um Conjunto de Aproximação \mathcal{A} é melhor do que outro conjunto \mathcal{B} utilizando-se um número finito de indicadores de qualidade unários, por exemplo um para convergência e um para a diversidade. A comparação deve incluir indicadores de qualidade binários. A seguir são descritos quatro indicadores (DEB, 2001).

3.3.4.1 Distância Geracional (Veldhuinzer, 1999)

Este indicador unário encontra a distância média de soluções no conjunto de aproximação \mathcal{A} em relação à \mathcal{PF}^* e é calculado por

$$I_{\mathcal{G}\mathcal{D}}(\mathcal{A}) = \frac{(\sum_{i=1}^{|\mathcal{A}|} d_i^2)^{\frac{1}{2}}}{|\mathcal{A}|}, \quad (3.9)$$

onde d_i é a distância euclidiana entre a solução $y_i \in \mathcal{A}$ e o elemento mais próximo de \mathcal{PF}^* :

$$d_i = \min_{k=1}^{|\mathcal{PF}^*|} \sqrt{\sum_{j=1}^m (y_j^{(i)} - y_j^{\star(k)})^2}. \quad (3.10)$$

O parâmetro $y_j^{\star(k)}$ é o j-ésimo valor do k-ésimo vetor de \mathcal{PF}^* e o parâmetro $y_j^{(i)}$ é o j-ésimo valor do i-ésimo vetor de \mathcal{A} .

3.3.4.2 Espalhamento (Deb et al., 2000)

A métrica unária criada por Deb (2001) utiliza a medida de distância d_i que pode ser tanto uma distância euclidiana como a *distância de apinhamento*, que é descrita na abordagem sobre o algoritmo NSGA-II utilizado neste trabalho, tal que

$$I_{\Delta}(\mathcal{A}) = \frac{\sum_{j=1}^m d_j^e + \sum_{i=1}^{|\mathcal{A}|} |d_i - \bar{d}|}{\sum_{j=1}^m d_j^e + |\mathcal{A}| \bar{d}}. \quad (3.11)$$

O parâmetro d_j^e é a distância entre os vetores extremos de \mathcal{PF}^* e \mathcal{A} correspondentes ao j-ésimo objetivo. O parâmetro \bar{d} é a média das distâncias entre $x_i \in \mathcal{A}$ e $x_j \in \mathcal{PF}^*$.

3.3.4.3 Hipervolume (Veldhuinzer, 1999)

A métrica unária de Hipervolume necessita a normalização dos valores das funções objetivo para evitar os efeitos das diferentes magnitudes entre os objetivos. Esta métrica também necessita de um ponto de referência chamado *nadir*, que é construído a partir dos piores valores das funções objetivo no conjunto da *Fronteira de Pareto*. A Figura 3.11 ilustra o conceito de hipervolume para a minimização de dois objetivos.

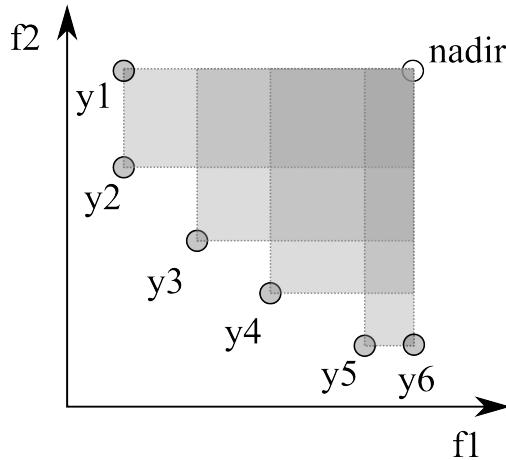


Figura 3.11: O Hipervolume, exemplificado para o caso de minimização de dois objetivos, corresponde a área delimitada pelos pontos da *Fronteira de Pareto* e o ponto de referência nadir.

Matematicamente, para cada solução $y_i \in \mathcal{A}$ um hipercubo v_i é construído sobre o ponto de referência *nadir*. A união dos volumes dos hipercubos dá o resultado final, ou seja,

$$I_{\mathcal{H}\mathcal{V}}(\mathcal{A}) = \text{volume} \left(\bigcup_{i=1}^{|\mathcal{A}|} v_i \right). \quad (3.12)$$

O cálculo desta métrica é bastante custoso computacionalmente. Um dos algoritmos mais rápidos para o seu cálculo exato é denominado Hipervolume por Divisão de Objetivos (*Hypervolume by Slicing Objectives* - HSO)(BRADSTREET; WHILE; BARONE, 2008). A complexidade computacional do HSO é $\mathcal{O}(n^{m-1})$ no pior caso e no melhor $\mathcal{O}(n \log n + n^{m/2})$, onde $n = |\mathcal{A}|$ e m a cardinalidade do espaço de objetivos.

3.3.4.4 Cobertura do Conjunto (Zitzler, 1999)

A métrica binária $I_{\mathcal{C}}(\mathcal{A}, \mathcal{B})$ calcula a proporção de vetores em \mathcal{B} que são dominados fracamente pelos vetores em \mathcal{A} da seguinte forma:

$$I_{\mathcal{C}}(\mathcal{A}, \mathcal{B}) = \frac{|\{y^{(b)} \in \mathcal{B} | \exists y^{(a)} \in \mathcal{A} : y^{(a)} \preccurlyeq y^{(b)}\}|}{|\mathcal{B}|}. \quad (3.13)$$

Esta métrica não é simétrica, portanto o cálculo de ambos $I_{\mathcal{C}}(\mathcal{A}, \mathcal{B})$ e $I_{\mathcal{C}}(\mathcal{B}, \mathcal{A})$ é necessário. Se $I_{\mathcal{C}}(\mathcal{A}, \mathcal{B}) = 1$ significa que todos os vetores de \mathcal{B} são dominados fracamente por \mathcal{A} , também verifica-se que $I_{\mathcal{C}}(\mathcal{A}, \mathcal{B}) = 1 \Leftrightarrow \mathcal{A} \triangleleft \mathcal{B}$. Por outro lado, se $I_{\mathcal{C}}(\mathcal{A}, \mathcal{B}) = 0$, nenhum vetor de \mathcal{B} é dominado fracamente por \mathcal{A} .

3.4 Eletrônica Evolucionária

A *Eletrônica Evolucionária* (*Evolutionary Electronics* - EE) foi formalmente estabelecida como área de pesquisa em 1997 na Universidade de Napier, Escócia, englobando *Computação Evolucionária e Eletrônica* (ZEBULUM; PACHECO; VELLASCO, 2001, p. 1). A expansão da EE ocorreu fortemente na década de 1990 por dois motivos: a) surgimento da idéia de evoluir o circuito como um todo, desde a topologia, *layout*, roteamento e dimensionamento de componentes, como em Bennett III et al. (2000); b) surgimento de dispositivos eletrônicos reconfiguráveis como *Field Programmable Gate Arrays* (FPGA).

A *Evolução de Circuitos Eletrônicos* possui uma grande variedade de abordagens. Dentro da taxonomia de EE podemos classificar os trabalhos sobre *circuitos integrados analógicos*, *circuitos integrados digitais* e *mixed-signal*. Outra classificação considera as abordagens que utilizam simuladores como o SPICE, chamada de *evolução extrínseca*, e aquelas que utilizam dispositivos eletrônicos reconfiguráveis, chamada de *evolução intrínseca* (ZEBULUM; PACHECO; VELLASCO, 2001).

Greenwood e Tyrrel (2007, p. 9) fazem a distinção entre Hardware *Evoluído* e Hardware *Evoluível*, respectivamente relacionados à *evolução extrínseca* e *evolução intrínseca*. No primeiro caso a evolução ocorre até a obtenção de uma boa solução, após isto a realização é estática, imutável. No segundo caso a evolução é contínua, durante a operação: encontrando uma falha o sistema muda rapidamente sua configuração, guiado pelo algoritmo genético e submetido a alterações de ambiente - temperatura, radiação, falha de sensores - e adapta-se às novas condições.

3.4.1 Hardware Evolucionário - EHW

Segundo Higuchi et al. (2006) o paradigma chamado Hardware Evolucionário (*Evolvable Hardware* - EHW), e conforme Zebulum, Pacheco e Vellasco (2001, p. 205), consiste na aplicação de *Computação Evolucionária* em conjunção com dispositivos reprogramáveis como *Field Programmable Gate Arrays* (FPGA, *Field Programmable Analog Arrays* (FPAAs), *Field Programmable Transistor Arrays* (FPTA), *Programmable Logic Devices* (PLD) e *Programmable Transistor Array* (PTA) para a obtenção de sistemas com capacidade de reconfiguração *autônoma*.

A conexão entre *Algoritmos Genéticos* (*Genetic Algorithms* - GA) e *Hardware Reconfigurável* são os cromossomos do GA, as cadeias de bits, que atuam como parâmetros de configuração do dispositivo. Através de uma *função de aptidão* capaz de avaliar o correto funcionamento do circuito, o GA torna-se um meio de reconfiguração automática (HIGUCHI et al., 2006). Esta característica permite a construção de sistemas capazes de operar em ambientes extremos com capacidade de

recuperação de falhas como demonstrado por Stoica et al. (2006).

EHW possui vantagens sobre a evolução *extrínseca*, como demonstrado por STOICA et al. na evolução de um circuito Gaussiano que utiliza ao mesmo tempo o SPICE e um FPGA. Os resultados obtidos através de evolução *extrínseca* demonstraram que a evolução em hardware nem sempre é equivalente à evolução realizada por software (STOICA et al., 1999). Entretanto, EHW possui outras dificuldades de ordem prática, como por exemplo a necessidade de uma plataforma reconfigurável como FPGA.

3.4.2 Evolução Extrínseca de Circuitos Analógicos

A abordagem deste trabalho foca a evolução *extrínseca* de circuitos analógicos. A seguir são apresentados alguns trabalhos de destaque nesta sub-área da *Eletrônica Evolucionária*.

3.4.2.1 A abordagem de ZEBULUM; PACHECO; VELLASCO: *Energy Minimization Strategy*

Zebulum, Pacheco e Vellasco (2001, p. 91–107) demonstram a *evolução extrínseca* de três topologias distintas de OTAs: *OTA Miller*, *OTA Simples* e *OTA “Cascade”*.

A abordagem desta implementação de GA consiste na utilização de uma *função de aptidão* que agrupa múltiplos objetivos na forma $f(x) = \sum w_i \cdot f_i(x)$, onde w_i e f_i são respectivamente o peso e a *função de aptidão* normalizada do i -ésimo objetivo. Os autores utilizam uma estratégia de atualização iterativa dos pesos de objetivos w_i onde os mesmos são inversamente proporcionais ao atendimento dos objetivos correspondentes, fazendo com que os pesos para os objetivos menos atendidos dominem a equação.

A atualização dos pesos é feita por: $w_{i,t+1} = k_1 \cdot \alpha \cdot w_{i,t} + k_2(1 - \alpha)e_{i,t}$, onde $w_{i,t}$ é o peso do objetivo i no tempo t , α é uma constante no intervalo $(0, 1]$ ou *momentum*, $e_{i,t}$ é o erro entre a especificação do objetivo i desejado e a média das soluções obtidas no instante t e k_1 e k_2 são constantes de normalização.

Os parâmetros de largura (W_i) e comprimento (L_i) de canal compõem os cromossomas dos indivíduos na população do GA e estes são decodificados na forma de uma linguagem de descrição de circuitos para avaliação das *funções de aptidão*. Estas são obtidas pelo simulador comercial SMASH, baseado no SPICE. Os resultados do GA de Zebulum, Pacheco e Vellasco (2001) convergem para um único ponto no espaço de objetivos e seus resultados são comparáveis aos de projetistas humanos.

Esta abordagem é bastante prática na obtenção de um único objetivo que atenda as preferências entre objetivos estabelecidos *a priori*.

3.4.2.2 A abordagem de KRUISKAMP; LEENAERTS: “DARWIN”

Kruiskamp e Leenaerts (1995) desenvolveram uma ferramenta para síntese de Amplificadores Operacionais em tecnologia CMOS chamada “DARWIN”, capaz de otimizar a topologia e o dimensionamento de componentes ao mesmo tempo utilizando um GA. A topologia do Amplificador Operacional nesta abordagem é separada em três blocos de construção:

- a)** um estágio amplificador de entrada;
- b)** um estágio amplificador intermediário (opcional);
- c)** um estágio amplificador de saída (opcional).

Por meio de uma matriz de construção, ilustrada na Tabela 3.5, identifica-se uma topologia válida para o amplificador. A marcação X na posição (i, j) significa que o bloco i deve ser sucedido pelo bloco j .

Tabela 3.5: Matriz de construção de topologias de amplificadores operacionais utilizada por Kruiskamp e Leenaerts (1995).

	2	3	4	5	6	7	8	9	10	11	12	13
1	X	X	X	X								
2						X			X			X
3					X					X		X
4							X			X		X
5								X	X			X
6									X	X	X	X
7									X	X	X	X
8									X	X	X	X
9									X	X	X	X
10												X
11												X
12												X

1.entrada
2.nMOS par dif. (simples)
3.pMOS par dif. (simples)
4.nMOS folded cascode
5.pMOS foldec cascode
6.nMOS CS
7.pMOS CS
8.nMOS CS (level shift)
9.pMOS CS (level shift)
10.nMOS source follower
11.pMOS source follower
12.classe AB buffer saída
13.saída

Após a determinação da topologia, “DARWIN” realiza uma verificação de violação de restrições: transistores em saturação, ganho mínimo, margem de fase, *slew rate* mínimo e frequência de ganho unitário mínima. Estas restrições são utilizadas para construir analiticamente uma equação linearizada da topologia do amplificador operacional, utilizando como variáveis os parâmetros de largura (W_i) e comprimento (L_i) de canal. Esta equação, chamada de vetor α , satisfaz a todas as restrições para valores de α_i não negativos. Limitando o espaço de busca, o algoritmo utiliza somente os valores ‘0’ e ‘1’, que constituem a representação binária de um GA. A Equação 3.14 mostra como exemplo uma saída do modelo e um vetor α para um bloco de construção de um OTA,

e a Equação 3.15 mostra o cálculo dos parâmetros W_i e L_i a partir da representação binária utilizada no GA.

$$\begin{pmatrix} W_i \\ L_i \end{pmatrix} = \frac{\alpha_1 \cdot \begin{pmatrix} 1 \\ 1 \end{pmatrix} + \alpha_2 \cdot \begin{pmatrix} 3 \\ 1 \end{pmatrix} + \alpha_3 \cdot \begin{pmatrix} 4 \\ 4 \end{pmatrix} + \alpha_4 \cdot \begin{pmatrix} 3 \\ 5 \end{pmatrix} + \alpha_5 \cdot \begin{pmatrix} 1 \\ 3 \end{pmatrix}}{\sum_i \alpha_i} \quad (3.14)$$

$$\alpha = (0, 1, 1, 1, 0) \Rightarrow \begin{pmatrix} W_i \\ L_i \end{pmatrix} = \left(3\frac{1}{3}, 3\frac{1}{3} \right) \quad (3.15)$$

Na inicialização do algoritmo genético de KRUISKAMP; LEENAERTS, topologias aleatórias baseadas na Tabela 3.5 são geradas somente para a população inicial, não existindo operações que permitam a alteração de topologia durante a evolução. A representação genética de cada solução é uma sequência de vetores α e a operação de cruzamento é permitida somente entre blocos equivalentes. A *função de aptidão* é calculada analiticamente e é baseada na dissipação de potência do circuito e há também a penalização proporcional sobre a violação de restrições.

A abordagem de KRUISKAMP; LEENAERTS permite a síntese de amplificadores operacionais utilizando equações de primeira ordem, minimizando a potência de dissipação do circuito e lidando com as demais características como restrições. O espaço de busca é restringido devido às limitações da representação e o modelo linearizado não utiliza a precisão do SPICE.

3.4.2.3 A abordagem de KOZA et al.: *Genetic Programming*

Koza et al. (1999, p. 383-390, 391-513) desenvolveram uma metodologia utilizando Programação Genética (*Genetic Programming* - GP) capaz de realizar a evolução da topologia e dimensionamento de circuitos analógicos. Utilizando um circuito *embrionário* como ilustrado na Figura 3.12 que consiste em uma ou mais conexões modificáveis, uma representação de programas para a construção de circuitos elétricos, ilustrado na Figura 3.13, os autores demonstraram a evolução de vários tipos de circuitos analógicos como filtros, amplificadores e geradores de funções especiais. Koza et al. (1999) demonstraram também que esta metodologia é competitiva com projetistas humanos, através da reinvenção de circuitos eletrônicos pelo GP.

A representação de circuitos ilustrada na Figura 3.13 utiliza funções de criação de componentes, funções de alteração de topologia e terminais para o dimensionamento de componentes. A sua decodificação, que é a execução do programa que representa, altera as conexões embrionárias Z_1 e Z_2 da Figura 3.12 criando uma listagem para simulação SPICE e obtenção da *função de aptidão*.

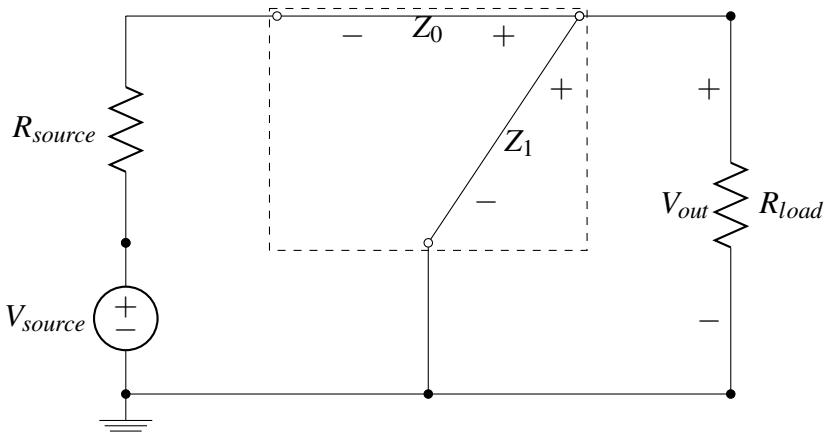


Figura 3.12: Circuito Embryonário de Koza et al. (1999, p. 403).

Durante o processo evolucionário esta estrutura pode utilizar os operadores de GA comuns como *cruzamento*, realizado através da troca de ramos de árvore entre indivíduos ou *mutação*, realizada através da reconstrução de um ramo da árvore.

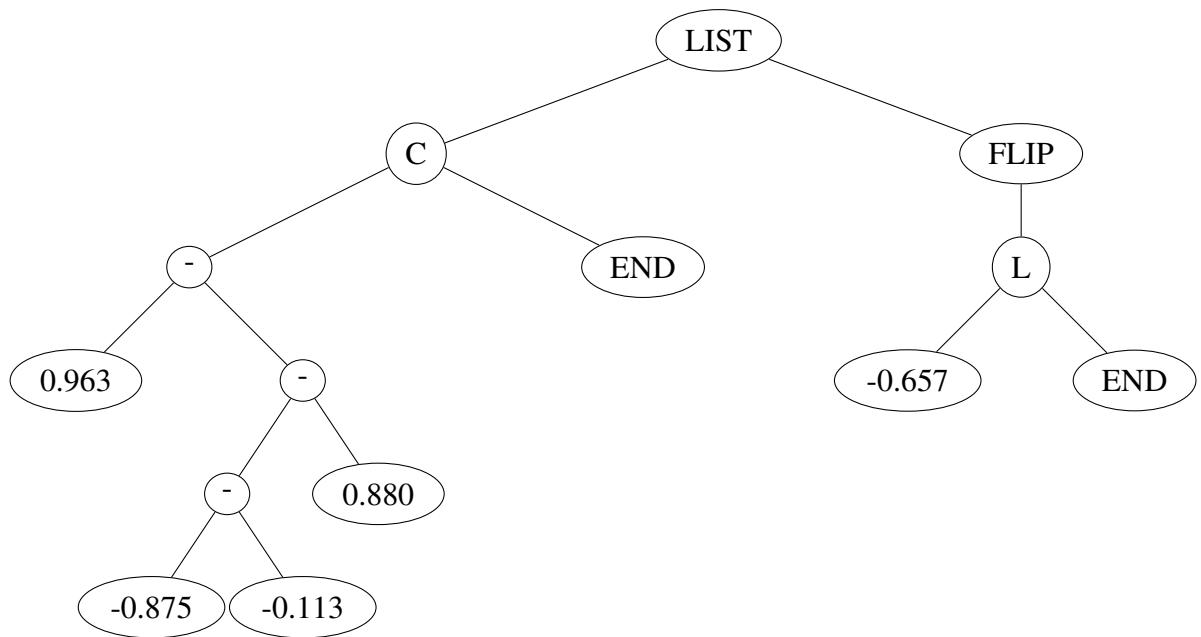


Figura 3.13: Exemplo de programa GP para a construção de um circuito eletrônico(KOZA et al., 1999)

3.4.2.4 A abordagem de MATTIUSSI; FLOREANO:*Analog Genetic Encoding*

A abordagem de Mattiussi e Floreano (2004, 2007), chamada *Analog Genetic Encoding* (AGE), assim como o GP, é capaz de evoluir ao mesmo tempo a topologia e o dimensionamento de circuitos eletrônicos analógicos. Contudo, ao invés de evoluir programas com instruções explícitas de

construção de circuitos como o GP, o AGE utiliza o mecanismo de Redes de Regulação Genética⁴ (*Genetic Regulatory Networks* - GRNs) inspirado na biologia (Figura 3.14). AGE utiliza um *cromossomo* de tamanho variável construído a partir de um alfabeto finito para representar as soluções.

A decodificação do *cromossomo* é feita pela leitura de toda a sua extensão. Encontrando uma sequência de ativação os componentes com seus respectivos parâmetros e conexões são criados e adicionados ao circuito. Esta decodificação imita a *regulação genética* biológica que produz proteínas para interação indireta entre os genes. Existem regiões dos cromossomas chamadas de *introns* que não codificam quaisquer parâmetros, assim como nos cromossomas biológicos.

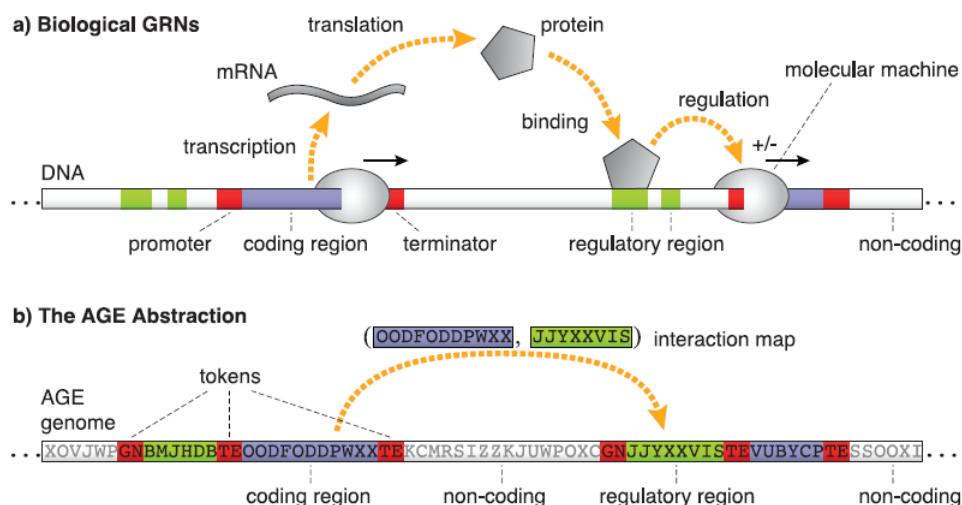


Figura 3.14: A abstração do AGE comparada ao mecanismo biológico equivalente, adaptado de Mattiussi et al. (2008).

Mattiussi e Floreano (2007) demonstraram que a eficiência do AGE para síntese de circuitos analógicos é equivalente ao GP.

⁴GRN é uma coleção de segmentos de DNA de uma célula que interagem uns com os outros indiretamente através de seu RNA e expressão de proteínas.

4 MÉTODOS

“Essentially, all models are wrong, but some are useful.”

George Edward Pelham Box, 1987

Revisitando a proposta fundamental do trabalho de otimização evolucionária extrínseca do OTA de uma saída e único estágio, tem-se o objetivo desdobrado em duas metas principais:

- a) *Otimização Evolucionária*: Obtenção de uma aproximação da *Fronteira de Pareto*;
- b) *Extração de Conhecimento*: Exploração do conjunto de dados formado pela *Fronteira de Pareto*.

Para alcançar a primeira meta, propõe-se a utilização do conhecido algoritmo NSGA-II (DEB, 2001). A precisão adequada das avaliações é garantida pela utilização do simulador SPICE. A segunda meta é alcançada através da exploração da Fronteira de Pareto por análise exploratória de dados e técnicas de Aprendizagem de Máquina como: Agrupamentos de Variáveis (*Variable Clustering*), Agrupamentos de Observações (*Clustering*), Árvores de Regressão e Classificação (*Classification and Regression Trees*).

4.1 Otimização Evolucionária

O projeto de um OTA visa maximizar e minimizar objetivos que são conflitantes. O ganho de um amplificador operacional ideal é infinito, portanto devemos maximizar A_{v0} . A frequência de ganho unitário f_T determina o limite de frequência para a aplicação do OTA, portanto é interesse maximizá-la. O *Slew Rate* é um parâmetro de velocidade do OTA, quanto maior SR , melhor o OTA responderá a variações da entrada. Qualquer sistema de engenharia deve ser projetado para consumir a menor quantidade de energia possível, portanto a potência dissipada Pwr deve ser minimizada. A área de portas *Area* deve ser minimizada para a economia de material (silício) e miniaturização do circuito.

4.1.1 Formulação do Problema

O Problema de Otimização de Múltiplos Objetivos da topologia do OTA de interesse, mostrada anteriormente na Figura 2.6, foi formulado da seguinte forma:

Encontrar:

$$x^* = [V_{in}^*, I_{abc}^*, W_1^*, \dots, W_{10}^*, L_1^*, \dots, L_{10}^*]^T, \quad (4.1)$$

onde x^* é o vetor ótimo de parâmetros, V_{in}^* é a tensão de polarização do par diferencial ótima, $I_{abc}^* = i_{pol}^*$ é a corrente de polarização ótima, W_i^* e L_i^* são a largura e comprimento de canal ótimos do MOSFET i .

Maximizando:

$$f_1(x) = A_{v0}(x), \quad f_2(x) = f_T(x) \text{ e } f_3(x) = SR(x) , \quad (4.2)$$

onde A_{v0} é o ganho de tensão em malha aberta em baixas frequências, f_T é a frequência do ganho de tensão unitário e SR é o *Slew Rate*.

Minimizando:

$$f_4(x) = Pwr(x) \text{ e } f_5(\mathbf{x}) = Area(x) , \quad (4.3)$$

onde Pwr é a potência dissipada e $Area$ é a área de silício da região de porta do OTA.

Sujeito às Restrições:

$$\left| V_{out} - \frac{V_{dd}}{2} \right| < 0.3, \quad V_{DS}^{<i>} - V_{GS}^{<i>} + V_{TH}^{<i>} > 0 \quad (i = 1 \dots 10) \text{ e } 45^\circ < \varphi_M(x) < 75^\circ, \quad (4.4)$$

onde V_{out} é a tensão *bias* de saída, V_{dd} é a tensão de alimentação, $V_{DS}^{<i>}$, $V_{GS}^{<i>}$ e $V_{TH}^{<i>}$ a tensão de dreno-fonte, tensão porta-fonte e tensão *threshold* do MOSFET i e φ a Margem de Fase.

$$W_1 = W_2, \quad W_3 = W_4, \quad W_5 = W_6, \quad W_7 = W_8, \quad L_1 = L_2, \quad L_3 = L_4, \quad L_5 = L_6, \quad L_7 = L_8 \quad (4.5)$$

$$0.5\mu\text{m} \leq w_k \leq 100\mu\text{m} \text{ e } 0.5\mu\text{m} \leq l_k \leq 100\mu\text{m}, \quad (k = 1 \dots 10) \quad (4.6)$$

$$0.7\text{V} \leq v_{in} \leq 2.3\text{V} \text{ e } 0.1\mu\text{A} \leq i_{pol} \leq 100\mu\text{A} \quad (4.7)$$

O vetor ótimo x^* na Equação (4.1) é um vetor ideal que maximiza a Equação (4.2) e minimiza a Equação (4.3). O Vetor do Espaço de Decisão $x = [V_{in}, I_{abc}, W_1, \dots, W_{10}, L_1, \dots, L_{10}]^T$ é composto por:

a) Tensão de polarização do par diferencial (V_{in});

b) Corrente de Polarização (I_{abc});

- c) Largura de Canal do Transistor MOS ($W_i, i = 1 \dots 10$);
- d) Comprimento de Canal do Transistor MOS ($L_i, i = 1 \dots 10$).

As funções nas Equações 4.2 e 4.3 mapeiam o vetor x do espaço de decisão (Ω) para o espaço de objetivos (Λ), e são obtidas utilizando as análises .OP, .AC e .TRAN da simulação SPICE. As restrições das inequações 4.4 são obtidas da mesma forma. As restrições da Equação 4.5 e inequações 4.6 e 4.7 são mapeadas diretamente do vetor do espaço de decisão x . As variáveis do espaço de objetivos são:

- a) $f_1(x) = A_{v0}(x)$, Ganho de tensão em malha aberta (análise SPICE .AC);
- b) $f_2(x) = f_T(x)$, Frequência de ganho tensão unitário (análise SPICE .AC);
- c) $f_3(x) = SR(x)$, Slew Rate (análise SPICE .TRAN);
- d) $f_4(x) = Pwr(x)$, Potência dissipada do OTA (análise SPICE .OP);
- e) $f_5(x) = Area(x)$, Área de silício da região de porta, a soma de $w_i \cdot l_i$;
- f) $V_{out,bias}$, nível de tensão DC na saída (análise SPICE .OP)¹;
- g) $V_{DS}^i - V_{GS}^i + V_{TH}^i > 0$, condição de saturação do MOSFET (análise SPICE .OP)²;
- h) $45^\circ < \varphi_M(x) < 75^\circ$, margem de fase (análise SPICE .AC)³.

Outras restrições: Nas Equações 4.5 os pares de MOSFETs: $[(M_1, M_2), (M_3, M_4), (M_5, M_6), (M_7, M_8)]$ possuem restrições de terem as mesmas larguras e comprimentos de canais⁴. Na Inequação (4.6) os limites de dimensionamento dos canais são estabelecidos de acordo com a tecnologia CMOS $0.5\mu\text{m}$. Nas inequações 4.7 são estabelecidos os limites da tensão de entrada⁵ e os limites da corrente de polarização.

4.1.2 Nondominated Sorting Genetic Algorithm II (NSGA-II)

O NSGA-II utiliza como função de aptidão a ordenação por dominância Pareto seguida por distância de apinhamento. Estes dois parâmetros são utilizados em um torneio do tipo “todos contra todos”

¹Quando $V_{out} = \frac{V_{dd}}{2}$ temos a máxima excursão do sinal de saída.

²Se esta condição é violada, o Transistor está operando em modo Triodo, o que é indesejável.

³A margem de fase entre 45° e 75° é um critério de estabilidade do OTA.

⁴ M_9 e M_{10} não formam pares com outros transistores.

⁵No mínimo 0,7V dos limites Gnd e V_{dd} são mantidos para permitir certa excursão do sinal de entrada.

onde o resultado é uma lista ordenada de indivíduos, primeiro em relação à dominância Pareto e depois em relação à distância de apinhamento (DEB, 2001).

Conforme Coello (2006), Deb (2001) o NSGA-II pertence a segunda geração de MOEAs, que surgiu quando o *elitismo* se tornou um mecanismo padrão. Uma das variações de elitismo que surgiram na segunda geração foi a incorporação de um arquivo auxiliar externo para manter as melhores soluções. Segundo os autores, o uso do elitismo é um requisito teórico para garantir a convergência de um MOEA.

O NSGA-II de Deb et al. (2000) é um MOEA elitista que introduz o conceito de *Distância de Apinhamento* para a manutenção da diversidade. Ainda conforme Deb (2001) o NSGA-II, em muitos aspectos, não possui similaridade com o NSGA, mantendo o nome NSGA-II devido apenas a uma perspectiva sobre sua origem.

Algoritmo 4: *Non-dominated Sorting Genetic Algorithm II*

início

Inicialize Aleatoriamente a População $P, P = N$ Crie uma população de descendentes $O, O = N$ usando cruzamento e mutação sobre P	enquanto \neg <i>término</i> faça $R \leftarrow P \cup O, R = 2N$ ordene R pela não-dominância pareto e operador $<_c$ $P \leftarrow \emptyset$ $P \leftarrow P \cup R_i, i = 1 \dots N$ Crie uma população de descendentes $O, O = N$ usando cruzamento e mutação sobre P
---	---

No NSGA-II (Algoritmo 4) a seleção é realizada sobre a união da população de ascendentes e descendentes, como na *Estratégia de Evolução* $(\mu + \lambda)$ -ES⁶, formando uma população de tamanho $2N(\mu = \lambda = N)$. O mecanismo de preservação de diversidade criado por Deb et al. (2000) é a *Distância de Apinhamento* (Algoritmo 6), em substituição ao *Compartilhamento de Aptidão* predominante nos demais MOEAs. Outra inovação do NSGA-II foi a introdução da ordenação Pareto com complexidade $\mathcal{O}(mn^2)$ (Algoritmo 5).

Deb et al. (2000) utilizam um operador específico para considerar a não-dominância pareto e a distância de apinhamento. Este operador chama-se “*Crowded Tournament Selection Operator*” e denota-se $<_c$. Utilizando a classificação de não-dominância pareto r , onde $r = 0$ corresponde às soluções não-dominadas por nenhuma outra na população (melhor fronteira de pareto), e d é a distância de apinhamento onde $d = \infty$ corresponde às soluções extremas,

⁶As Estratégias de Evolução (ES) utilizam a nomenclatura $(\mu + \lambda)$ -ES para denominar um algoritmo ES cuja população de μ ascendentes compete com λ descendentes e (μ, λ) -ES para o modelo geracional.

Algoritmo 5: Non-dominated Sorting de complexidade $\mathcal{O}(mn^2)$ (DEB et al., 2000)

```

início
  para cada  $p \in \mathcal{P}$  faça
    para cada  $q \in \mathcal{P}, p \neq q$  faça
      se  $p \prec q$  então
         $\mathcal{S}_p = \mathcal{S}_p \cup \{q\}$ 
      senão se  $q \prec p$  então
         $n_p = n_p + 1$ 
      se  $n_p = 0$  então
         $\mathcal{F}_1 = \mathcal{F}_1 \cup \{p\}$ 
   $i = 1$ 
  enquanto  $\mathcal{F}_i \neq \emptyset$  faça
    para cada  $p \in \mathcal{P}_i$  faça
      para cada  $q \in \mathcal{S}_p$  faça
         $n_q = n_q - 1$ 
        se  $n_q = 0$  então
           $\mathcal{H} = \mathcal{H} \cup \{q\}$ 
     $i = i + 1$ 
     $\mathcal{F}_i = \mathcal{H}$ 
  
```

Definição 9. Operador de Seleção por Torneio de Apinhamento ($<_c$): *Uma solução i vence o torneio sobre outra solução j se quaisquer das condições abaixo forem verdadeiras:*

1. Se a solução i tem melhor classificação Pareto, ou seja: $r_i < r_j$;
2. Se i e j possuem a mesma classificação Pareto, mas i possui melhor distância de apinhamento que j , ou seja: $d_i > d_j$.

4.1.3 Tratamento de Restrições

O espaço de decisão, ou *espaço de busca* (Ω), para o problema de otimização do OTA é severamente reduzido pelas restrições impostas no espaço de objetivos (Λ). Conforme Deb (2001) as restrições dividem o espaço de busca em uma região factível e uma região infactível que podem ou não ser contínuas. As restrições frequentemente impõe limitações à Fronteira de Pareto, portanto o tratamento adequado de restrições deve ser considerado no algoritmo de busca.

Existem diversas abordagens para o tratamento de restrições em algoritmos evolucionários (EAs) (COELLO, 1999), sendo a abordagem mais simples ignorar soluções não factíveis seguida pela penalização desta soluções. Deb (2001) enfatiza que no primeiro caso, a exemplo do problema

Algoritmo 6: Distância de Apinhamento (DEB et al., 2000)

```

início
   $\mathcal{F} \leftarrow x \in \mathcal{P}$ 
  para cada  $i \in 1 \dots |\mathcal{F}|$  faca
     $d_i = 0$ 
  para cada  $j \in 1 \dots m$  /*  $m = \langle$ número de objetivos $\rangle$  */
  faca
    ordene  $\mathcal{F}$  do pior ao melhor objetivo
     $d_1 = d_{|\mathcal{F}|} = \infty$ 
    para cada  $i \in 2 \dots (|\mathcal{F}| - 1)$  faca
       $d_i = d_i + \frac{x_{i+1}^{(j)} - x_{i-1}^{(j)}}{\max x^{(j)} - \min x^{(j)}}$ 
  
```

do OTA, na maioria dos problemas reais encontrar soluções factíveis (que satisfazem a todas as restrições) é o maior problema, tornando-se uma grande dificuldade para o EA convergir ao ótimo. No caso da penalização e algoritmos de múltiplos objetivos, encontra-se maior dificuldade na determinação de equações de penalização para os diversos objetivos e restrições. Encontrar equações adequadas, visto que a Fronteira de Pareto não é conhecida *a priori*, torna-se um problema complexo.

Entre os métodos recomendados por Deb (2001), encontramos o método de Jiménez-Verdegay-Goméz-Skarmeta que consiste em incluir de forma sistemática as restrições no critério de dominância. Esta inclusão de restrições, possui a seguinte forma:

Definição 10. Dominância Pareto modificada: *Uma solução i domina outra solução j se e somente se:*

1. *i satisfaz todas as restrições e j não;*
2. *i e j satisfazem todas as restrições e $y_i \prec y_j$ no espaço de objetivos;*
3. *i e j não satisfazem uma ou mais restrições e $z_i \prec z_j$ no espaço de restrições.*

4.2 Extração de Conhecimentos

O processo de extração de conhecimento de um conjunto de dados envolve a utilização de técnicas e ferramentas das áreas de Aprendizagem de Máquina (*Machine Learning* - ML) e Estatística. A seguir apresenta-se uma breve discussão sobre as técnicas aqui utilizadas.

4.2.1 O Mapa de Aquecimento (*Heatmap*)

O Mapa de Aquecimento é uma forma gráfica engenhosa para mostrar relações de agrupamento (*clustering*) e é o gráfico mais utilizado em ciências biológicas (FRIENDLY, 2009). A Figura 4.1 ilustra um exemplo de Mapa de Aquecimento.

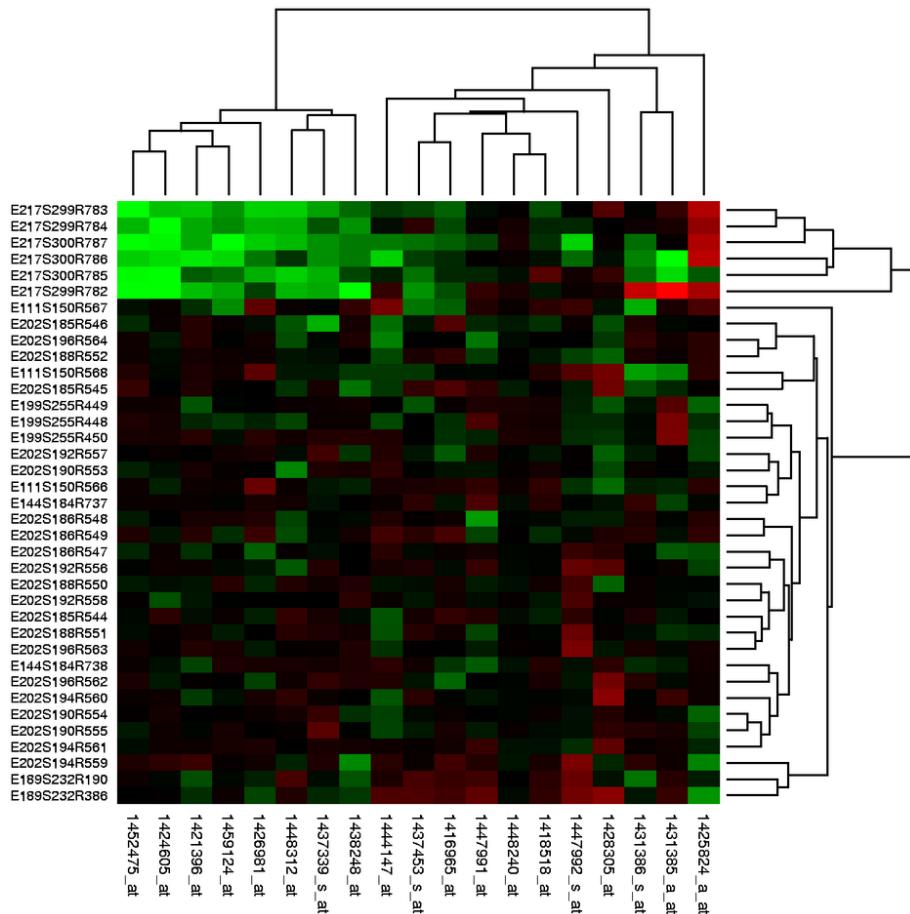


Figura 4.1: Heatmap de Andrade (2008) utilizado para exemplificação por Friendly (2009). As linhas (ou colunas) representam os genes e as colunas (ou linhas) representam as amostras. Os gradientes de cores representam a intensidade da expressão do gene na amostra. Os dendrogramas lateral e superior representam os *Agrupamentos* entre genes e entre amostras.

No caso do problema apresentado neste trabalho, queremos descobrir relações entre objetivos e parâmetros. Estas relações podem ser reveladas pelo *Agrupamento de Variáveis*, o que é feito através da correlação de Spearman ao quadrado (ρ^2) discutida a seguir.

4.2.1.1 Correlação de Spearman

A correlação é uma métrica entre variáveis aleatórias, que assume valores contínuos no intervalo $[-1, 1]$, conhecida em sua forma mais comum pela correlação de Pearson. A correlação de Spearman

(ρ) é um caso especial da correlação de Pearson (\mathbf{r}) (CHEN; POPOVICH, 2002). Pela definição clássica, a correlação de Pearson para duas variáveis X e Y é dada pela covariância normalizada,

$$\mathbf{r} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{s_X s_Y}, \quad (4.8)$$

onde n é o número de observações (pares X e Y) e s_X e s_Y são os desvios padrão de X e Y (CHEN; POPOVICH, 2002).

Para o cálculo da correlação de Spearman, ao invés de utilizar-se diretamente os valores de X e Y , utiliza-se os índices da ordenação de X e Y , assim temos

$$\rho = 1 - \frac{6(\sum(Ordem(X_i) - Ordem(Y_i))^2)}{n^3 - n}. \quad (4.9)$$

Enquanto a correlação de Pearson mede a força das relações lineares entre variáveis, a correlação de Spearman mede a força das relações monotônicas entre variáveis (CHEN; POPOVICH, 2002). Assim como no *Agrupamento de Observações (Clustering)* utilizamos uma métrica de distância (ou similaridade) entre observações, para o *Agrupamento de Variáveis (Variable Clustering)*, utilizamos a correlação ao quadrado como métrica.

4.2.2 Agrupamento de Observações (*Clustering*)

O *Agrupamento de Observações*, ou simplesmente *Clustering*, consiste na partição de um conjunto de dados em classes. Existem inúmeras técnicas de *clustering*, mas não há uma descrição universalmente aceita sobre o que é um *cluster*, mas pode-se dizer que um *cluster* é um conjunto de entidades similares. Neste trabalho utiliza-se o algoritmo *K-medoids* que baseia-se no conhecido algoritmo *K-means*, contudo menos sensível a *outliers* e ruído (XU; WUNSCH, 2008).

Algoritmo 7: *k-means clustering*

início

Atribua aleatoriamente aos K *clusters* C_i , $i = 1, 2, \dots, K$ valores do conjunto de dados;

repita

para cada ponto do conjunto de dados faça

Atribua para o ponto do conjunto de dados o *cluster* C_i mais próximo através de uma métrica de dissimilaridade;

para cada atribuição de cluster C_i faça

Atualize o valor do *cluster* C_i pela média do conjunto de pontos atribuídos ao *cluster*;

até até não houver variação dos C_i

Os algoritmos *k-means* e *k-medoids* pressupõe que o conhecimento do número de *K clusters* é conhecido. O Algoritmo 7 *k-means* é iniciado com uma atribuição aleatória dos *clusters* dentro do conjunto de dados e então segue-se um processo iterativo de atribuições de *clusters* para cada ponto e cálculo dos novos *clusters*. O Algoritmo 8 *k-medoids* diferencia-se do *k-means* porque ao invés de calcular a média para os *clusters*, utiliza o *medoid*, ou o ponto do conjunto de dados com menor dissimilaridade aos demais pontos (HASTIE; TIBSHIRANI; FRIEDMAN, 2003).

Algoritmo 8: *k-medoids clustering*

início

Atribua aleatoriamente aos *K clusters* C_i , $i = 1, 2, \dots, K$ valores do conjunto de dados;

repita

para cada atribuição de cluster C_i **faça**

Encontre a observação que minimiza a distância total aos outros pontos

pertencentes ao cluster e atualize C_i com o novo *medoid*;

até até não houver variação dos C_i

A métrica de dissimilaridade comumente utilizada é a distância euclidiana e os vetores precisam ser normalizados para evitar o efeito de diferentes magnitudes (HASTIE; TIBSHIRANI; FRIEDMAN, 2003).

4.2.3 Árvores de Classificação e Regressão

Árvores de Classificação e Regressão ("Classification and Regression Trees- CART) são algoritmos recursivos de construção de árvores binárias para as tarefas de classificação e regressão. CART partitiona o espaço de variáveis em regiões e ajustando um modelo simples (como uma constante) a cada uma (HASTIE; TIBSHIRANI; FRIEDMAN, 2003).

Neste trabalho utiliza-se o algoritmo *party* (HOTHORN et al., 2006), cuja implementação é disponível como biblioteca no software "R" (R Development Core Team, 2011). Seu algoritmo de recursão é baseado em relações de regressão sobre o modelo de distribuição condicional $D(Y|X) = D(Y|f(X_1, X_2, \dots, X_m))$ onde Y é a resposta e $X = \{X_1, X_2, \dots, X_m\}$ é um vetor de m covariáveis.

Para um conjunto de n exemplos de aprendizagem ($\mathcal{L}_i = \{(Y_i|X_{1i}, \dots, X_{mi}), 1, \dots, n\}$) e uma representação vetorial ($\mathbf{w} = (w_1, \dots, w_n)$) para cada nó da árvore, onde $w_i \in \{0, 1, \}$ é um para as observações correspondentes ao nó, temos os seguintes passos de recursão (HOTHORN et al., 2006):

1. Para um dado vetor \mathbf{w} , teste a hipótese de independência $H_0 = \bigcap_{j=1}^m H_0^j : D(Y|X) = D(Y)$ entre todas as m covariáveis de interesse. Se H_0 não puder ser rejeitada em um nível de significância α pré estabelecido, pare o algoritmo. Senão escolha a j -ésima covariável X_j *

com a associação mais forte a Y .

2. Escolha um conjunto $A^* \subset X_{j^*}$ para que divida X_{j^*} em dois subconjuntos denotados pelos vetores $\mathbf{w}_{esquerdo}$ e $\mathbf{w}_{direito}$, que representam os nós filhos do nó em uso.
3. Repita recursivamente os passos 1 e 2 para os vetores $\mathbf{w}_{esquerdo}$ e $\mathbf{w}_{direito}$.

4.3 Implementação

Para a implementação do algoritmo evolucionário de otimização de múltiplos objetivos MOEA, utiliza-se a linguagem C++ e a biblioteca “Shark”(IGEL et al., 2008). O programa Spice OPUS (TUMA; BÜRMEN, 2009), é executado em *batch* a partir do programa escrito em C++ a cada geração do MOEA, executando a simulação sobre os arquivos de *netlist* (ou arquivos de SPICE) configurados pelos vetores de parâmetros de cada indivíduo da geração. Os arquivos de resultado das simulações são lidos pelo programa e os vetores de objetivos e restrições atribuídos aos indivíduos correspondentes da população do MOEA. Então o MOEA executa os operadores evolucionários de seleção, cruzamento e mutação para gerar uma nova população. Este processo é ilustrado na Figura 4.2 e o arquivo *netlist* é apresentado no Apêndice A.1.

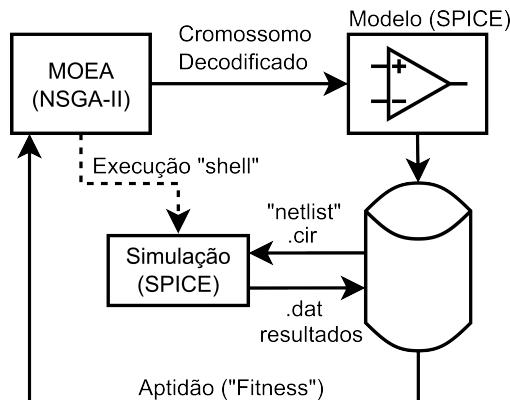


Figura 4.2: Integração do MOEA ao SPICE.

A Figura 4.3 ilustra a metodologia computacional proposta neste trabalho: Otimização Evolucionária Extrínseca seguida de Agrupamento de Variáveis, Agrupamento de Observações e Árvores de Regressão e Classificação para a extração de conhecimentos. Portanto, em linhas gerais, a Figura 4.3 representa a proposta central deste trabalho.

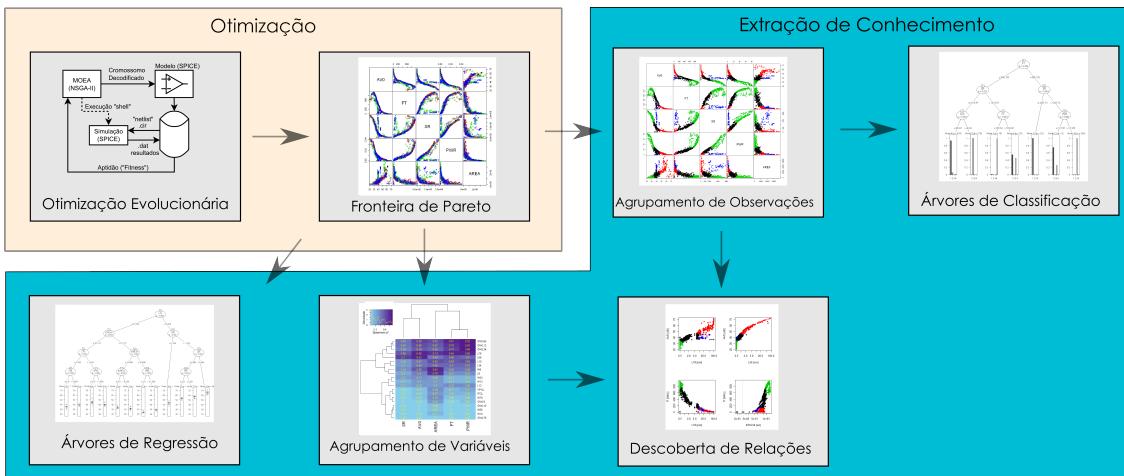


Figura 4.3: Processo proposto por este trabalho: Otimização e Extração de Conhecimentos.

Observa-se na Figura 4.3 a sequência de cada passo envolvido no processo:

1. Otimização Evolucionária utilizando-se o algoritmo NSGA-II integrado ao Spice OPUS para o cálculo dos objetivos e violações, o resultado é uma aproximação da fronteira de Pareto;
2. O *heatmap*, que é uma análise de sensibilidade global, é criado através do cálculo da correlação de Spearman ao quadrado;
3. A fronteira de Pareto é particionada pelo algoritmo *k-medoids* em um número K de *clusters* escolhido manualmente;
4. Os objetivos e parâmetros com alta correlação de Spearman são analisados por gráficos e pelos *clusters*;
5. A fronteira de Pareto com *clusters* calculados é analisada através de Árvores de Classificação para a descoberta de relações entre as categorias (*clusters*) e parâmetros;
6. A fronteira de Pareto é analisada através de Árvores de Regressão para a descoberta de relações a partir dos parâmetros aos objetivos.

O resultado destas análises é um conjunto de informações a respeito do dimensionamento da topologia escolhida do OTA que pode ser re-utilizado em novos projetos.

5 RESULTADOS EXPERIMENTAIS

“All our knowledge begins with the senses, proceeds then to the understanding, and ends with reason. There is nothing higher than reason.”

Critique of Pure Reason
Immanuel Kant, 1781

A seleção do NSGA-II não foi resultado de uma análise teórica através da pesquisa bibliográfica, mas resultado de uma série de experimentos com ajustes de parâmetros, representação, tratamento de violações das restrições e da utilização de um segundo algoritmo, descrito no Capítulo 3, chamado VEGA. Tanto o NSGA-II quanto o VEGA não foram desenvolvidos para problemas com o tratamento de restrições, foi necessário inseri-lo no NSGA-II com o método de Jiménez-Verdegay-Goméz-Skarmeta, descrito na sub-seção 4.1.3, e no VEGA com o método de Recozimento Simulado das penalizações de Carlson e Shonkwiler (1998).

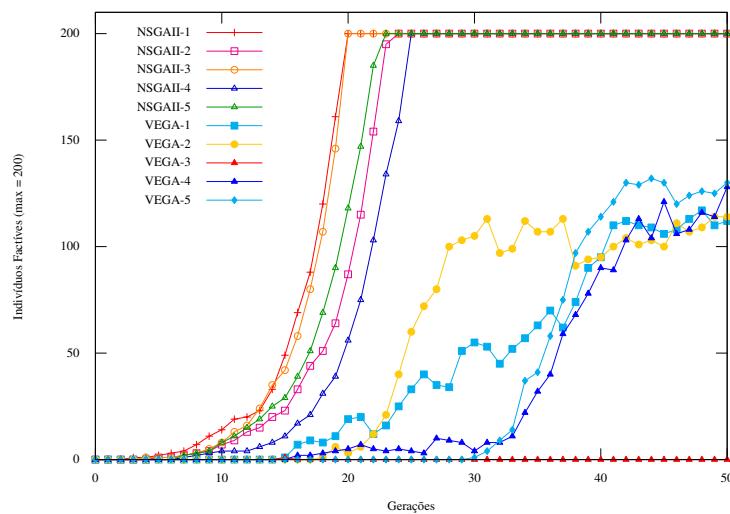


Figura 5.1: Quantidade de indivíduos factíveis obtidos com VEGA e NSGA-II.

Os resultados com o VEGA foram bastante insatisfatórios. Além de não atingir um número razoável de soluções factíveis (Figura 5.1), apresentou o problema descrito por Goldberg (1989, p. 199–201) de não espalhamento de soluções ao longo da fronteira de Pareto e consequentemente uma convergência pobre.

5.1 Parametrizações

O OTA de único estágio e única saída foi configurado com $V_{dd} = 3V$ e $C_L = 3pF$. Os modelos de transistores MOSFET utilizados são de tecnologia AMS $0,5\mu m$ SCN05 (MOSIS)¹.

A configuração do algoritmo NSGA-II de codificação genética por números reais (ponto flutuante), cruzamento binário simulado SBX e mutação polinomial, foram determinadas empiricamente e apresentam-se na Tabela 5.1.

Tabela 5.1: Parametrização do Algoritmo

Tamanho da População (N)	200
Número de Gerações (t)	6000
Probabilidade de Cruzamento (p_c)	0,8
Probabilidade de Mutação (p_m)	0,07
SBX (η_c)	20,0
Mutação Polinomial (η_m)	12,0

Para os experimentos com NSGA-II, utiliza-se diferentes inicializações da função geradora de números pseudo-aleatórios.

A nomenclatura dos símbolos utilizados nos gráficos deste capítulo é apresentada na Tabela 5.2.

5.2 Factibilidade dos Resultados Experimentais

Para avaliar a capacidade de convergência do método proposto, pode-se comparar os resultados obtidos com uma amostragem aleatória de 200400 soluções. Somente as soluções factíveis foram preservadas, onde somente 6 soluções factíveis foram obtidas (Tabela 5.3). Estima-se que a probabilidade de obter-se uma solução factível ao acaso é $\hat{p} = 0,0000299$ com intervalo de confiança de 95% entre $0,00000598 \leq \hat{p} \leq 0,00005389$ (HINES; MONTGOMERY, 1990, p. 273–274). Todos os 5 experimentos com NSGA-II apresentaram 100% da população de pais $N = 200$ satisfazendo a todas restrições próximas da centésima geração. A proporção da população contida na primeira fronteira de Pareto $r = 1$ também sobe rapidamente após atingir 100% de satisfação das restrições, sendo o resultado final um conjunto de 200 soluções não-dominadas ($r = 1$).

¹Para todas os experimentos é utilizado o modelo BSIM3v3.1 para simulação SPICE com os parâmetros MOSIS da tecnologia SCN05 CMOS de $0.5\mu m$ disponível em: <http://www.mosis.com/cgi-bin/cgiwrap/umosis/swp/params/ami-c5/t99j-params.txt>, anexos A.2 e A.3

Tabela 5.2: Simbologia utilizada nos gráficos dos resultados experimentais

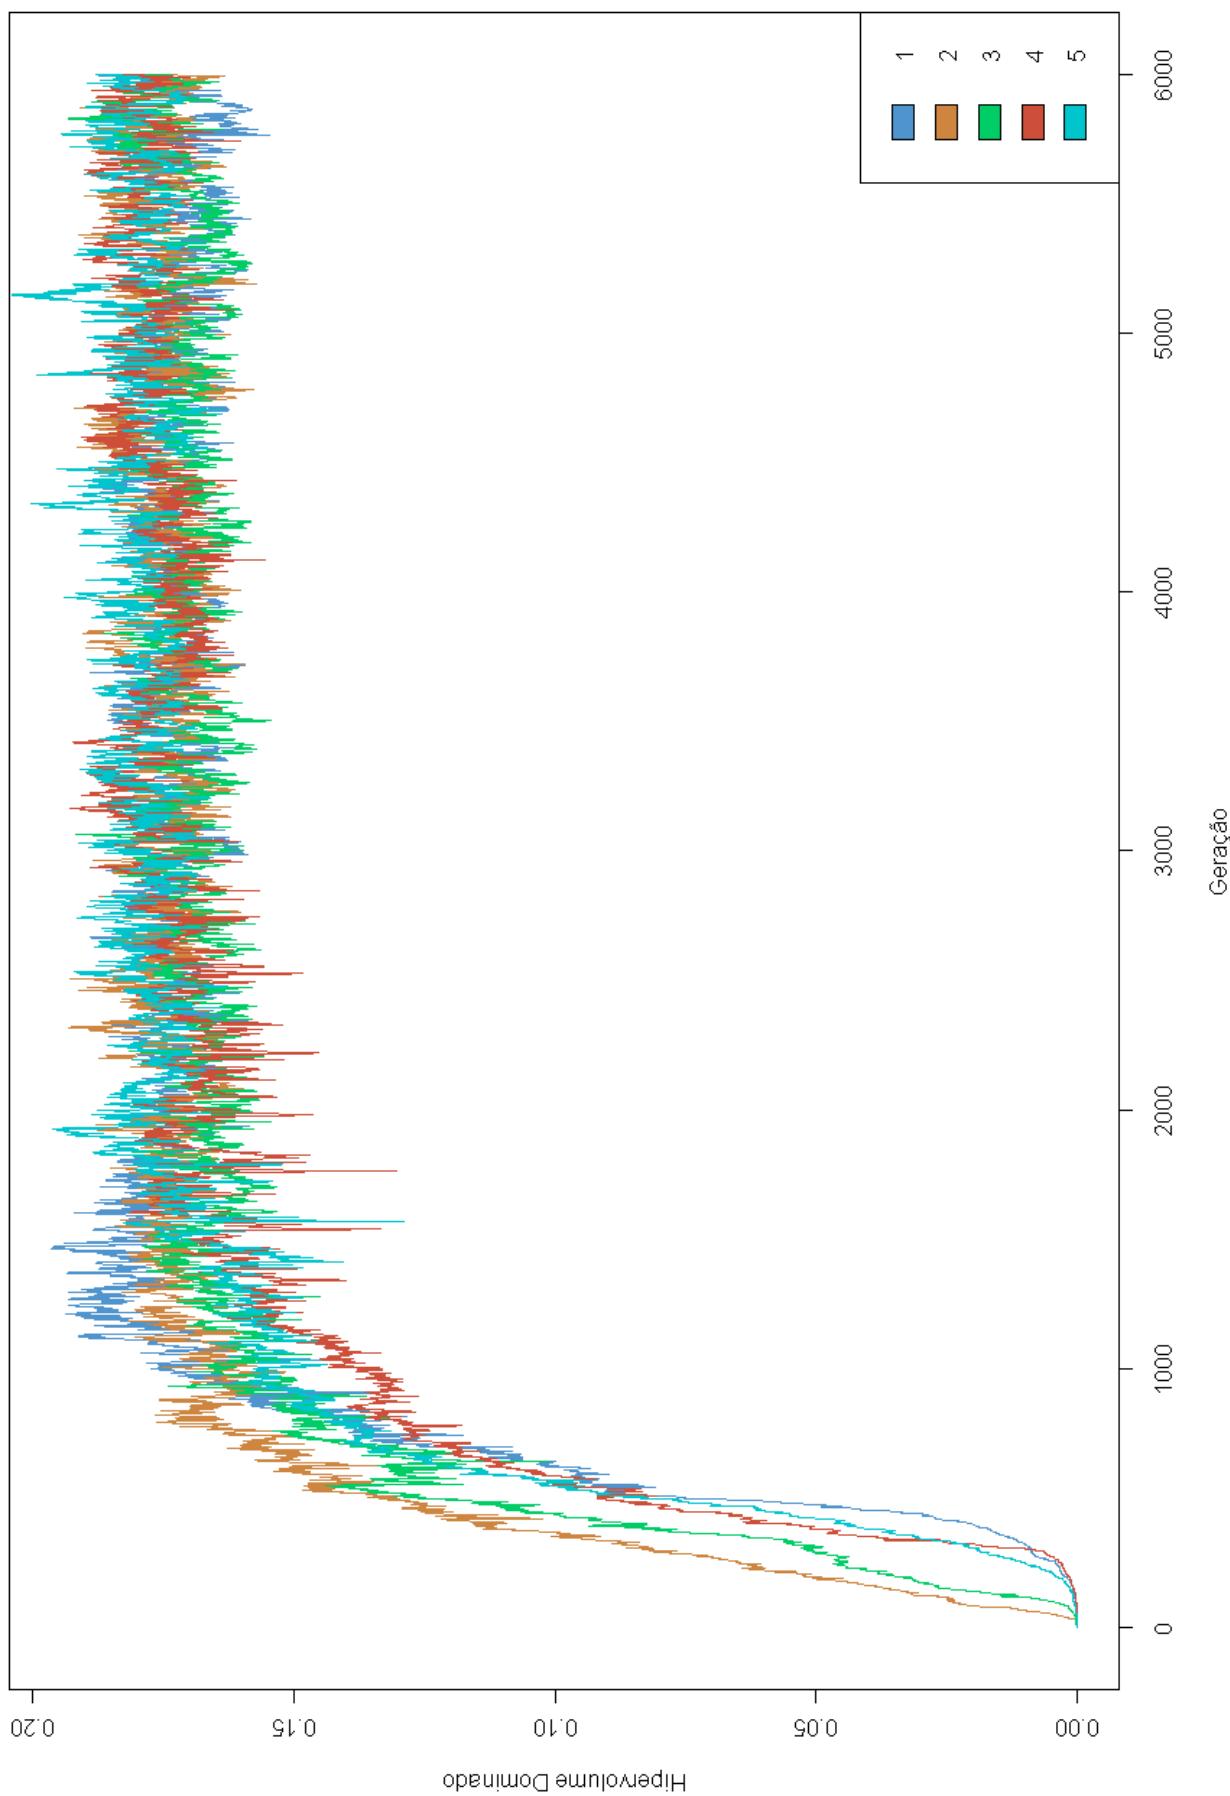
Símbolo	Transistor	Significado	Unidade
AV0	OTA	Ganho de tensão em malha aberta	dB
FT	OTA	Frequência de ganho de tensão unitário	MHz
SR	OTA	<i>Slew rate</i>	$V/\mu s$
PWR	OTA	Potência Dissipada	mW
AREA	OTA	Área de silício da região de portas	μm^2
IPOL	Dreno de M_9	Corrente de Polarização	μA
VPOL	Porta de M_1 e M_2	Tensão de Polarização	V
W12	M_1 e M_2	Largura de Canal	μm
W34	M_3 e M_4	Largura de Canal	μm
W56	M_5 e M_6	Largura de Canal	μm
W78	M_7 e M_8	Largura de Canal	μm
W9	M_9	Largura de Canal	μm
W10	M_{10}	Largura de Canal	μm
L12	M_1 e M_2	Comprimento de Canal	μm
L34	M_3 e M_4	Comprimento de Canal	μm
L56	M_5 e M_6	Comprimento de Canal	μm
L78	M_7 e M_8	Comprimento de Canal	μm
L9	M_9	Comprimento de Canal	μm
L10	M_{10}	Comprimento de Canal	μm
IDWL12	M_1 e M_2	Corrente de Inversão	μA
IDWL34	M_3 e M_4	Corrente de Inversão	μA
IDWL56	M_5 e M_6	Corrente de Inversão	μA
IDWL78	M_7 e M_8	Corrente de Inversão	μA
IDWL9	M_9	Corrente de Inversão	μA
IDWL10	M_{10}	Corrente de Inversão	μA

Tabela 5.3: Resultados do experimento de busca aleatória.

A_{v0} (dB)	f_T (MHz)	SR (V/ μ s)	Pwr (mW)	$Area$ (μ m 2)
58,78	6,00	12,00	0,15	7940
55,64	3,25	5,55	0,06	11300
45,06	0,98	4,11	0,08	11600
56,51	1,32	2,56	0,17	13300
54,18	1,75	3,43	0,15	15200
49,04	1,60	3,96	0,25	14100

O hipervolume dominado pelo conjunto de resultados do experimento aleatório é $I_{\mathcal{HV}} = 1,68E - 5$, enquanto os demais experimentos com algoritmo NSGA-II apresentaram 100% da população de pais $N = 200$ satisfazendo a todas restrições próximos da centésima geração. A proporção da população com $r = 1$ também sobe rapidamente após atingir 100% de satisfação das restrições, sendo o resultado final um conjunto de 200 soluções não-dominadas ($r = 1$). Na Figura 5.2 ilustra-se a evolução do hipervolume para os 5 experimentos com NSGA-II.

Nota-se que o hipervolume, a única métrica monotônica para conjuntos Pareto (ZITZLER et al., 2002), não converge para um valor estável, mas oscila em um limite máximo. Este efeito deve-se ao critério *distância de apinhamento*, observável em gerações avançadas da população onde a sua totalidade pertence a uma única fronteira de Pareto, sendo a *distância de apinhamento* a única métrica para a seleção, e esta não é monotônica em relação ao hipervolume.



O conjunto final de 1000 soluções dos 5 experimentos apresentou para as restrições da condição de Saturação de Transistores, Tensão *Bias* de Saída e Margem de Fase (φ_M), as distribuições conforme a Figura 5.3, ou seja: atendendo às restrições. A factibilidade para uma solução é um critério extremamente difícil de ser alcançado, entretanto o tratamento de restrições proposto alcança resultados bastante satisfatórios.

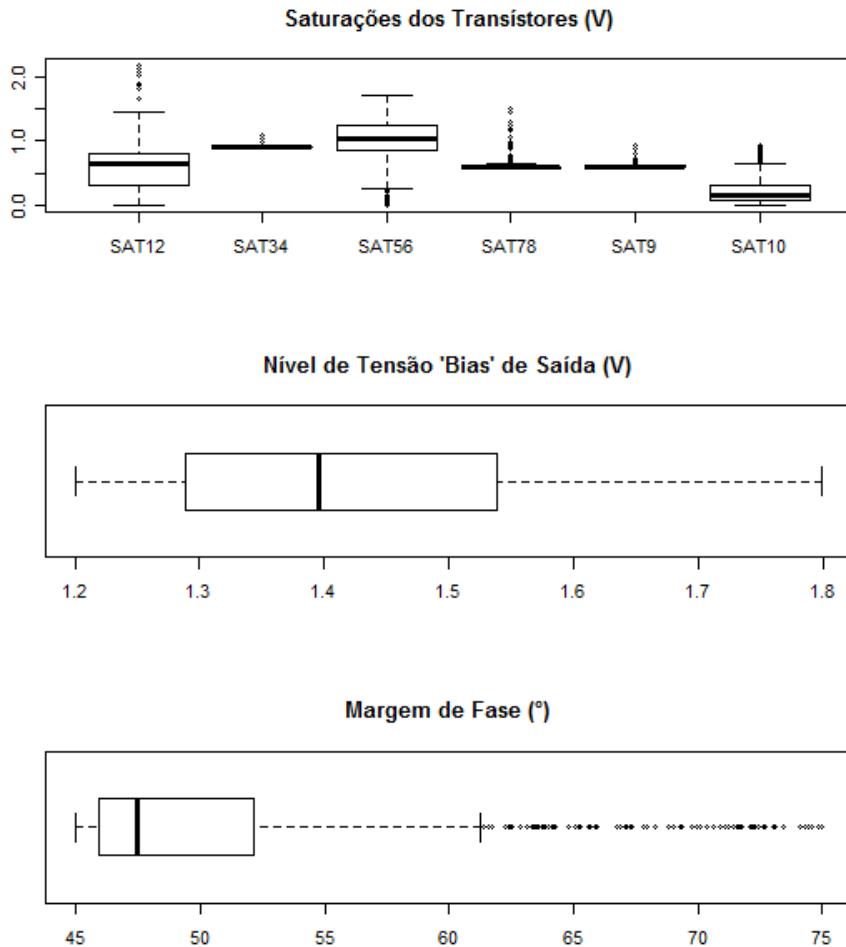


Figura 5.3: Saturação ($SAT = V_{DS} - V_{GS} + V_{TH}$), Tensão *Bias* de Saída ($\left| \frac{V_{dd}}{2} - V_{out} \right| \leq 0,1 \cdot V_{dd} \right)$ e Margem de Fase ($45^\circ \leq \varphi_M \leq 75^\circ$).

O atendimento à restrição de uma janela de resposta transiente é ilustrado na Figura 5.4. Esta janela impõe condição de factibilidade da realização do OTA em resposta à função degrau, garantindo desta forma, níveis mínimos e máximos de excursão do sinal de saída.

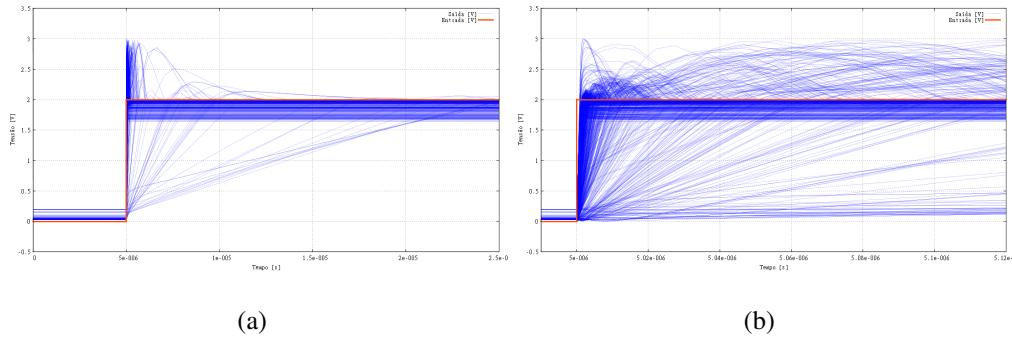


Figura 5.4: Resposta Transiente das soluções obtidas no Apendice B.

A validade de realizações de OTAs também pode ser verificada através da inspeção visual do Diagrama de Bode . SANSEN, por exemplo, utiliza esta representação gráfica para verificar diversas anormalidades que podem estar presentes em amplificadores. A Figura 5.5 apresenta o Diagrama de Bode das 1000 soluções encontradas nas 5 rodadas do algoritmo NSGA-II.

Verifica-se para as curvas de ganho que não existem picos ao final da Largura de Banda², e o decréscimo, a partir desta frequência é constante. As curvas de fase, apesar de serem mais úteis quando utilizadas em pares com suas curvas de ganho correspondentes, apresentam o comportamento esperado.

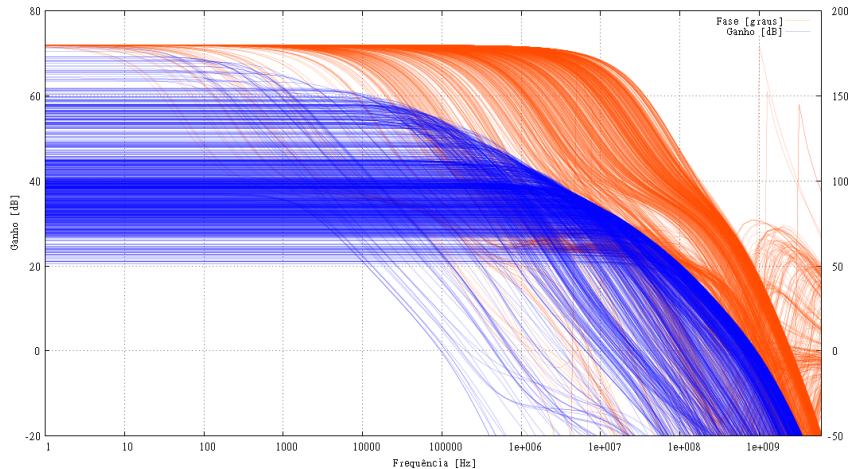


Figura 5.5: Diagrama de Bode das soluções obtidas do Apendice B.

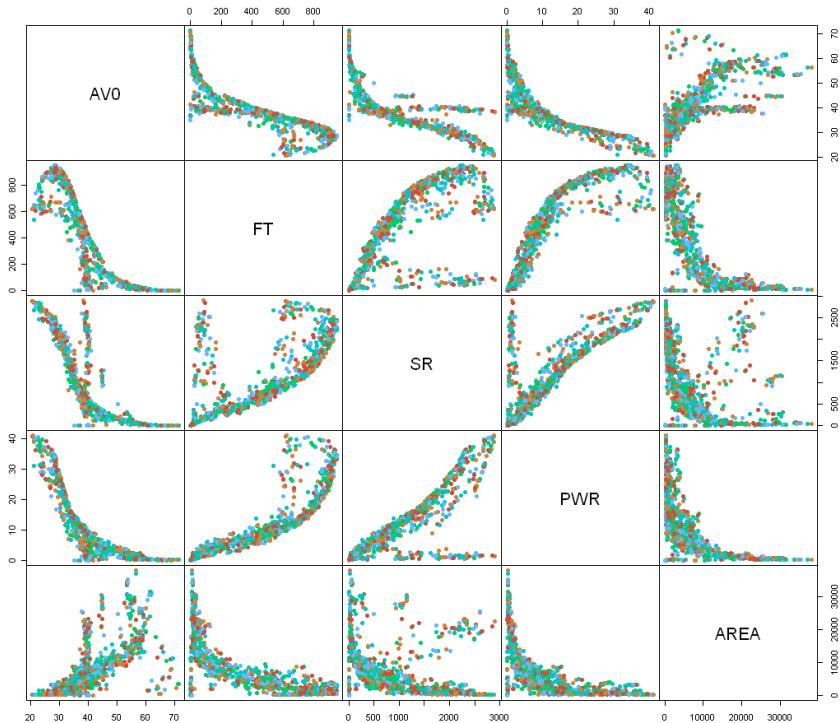
5.3 Fronteira de Pareto

Os limites mínimos e máximos das aproximações da Fronteira de Pareto obtidas nos 5 experimentos com NSGA-II são apresentados na Tabela 5.4 e Figura 5.6 e suas projeções na Figura 5.6.

²Largura de Banda, é a frequência onde o ganho decresce $-3dB$ a partir do ganho em baixas freqüências (A_{v0}).

Tabela 5.4: Limites máximos e mínimos obtidos para os 5 experimentos.

Objetivo	Mínimo	Máximo
A_{v0} (dB)	20,59	71,38
f_T (MHz)	0,978	949,0
SR (V/ μ s)	0,0886	2900,0
Pwr (mW)	0,000585	40,99
$Area$ (μ m 2)	4,63	38100,0

**Figura 5.6:** Projeções das aproximações da Fronteira de Pareto resultantes dos 5 experimentos com NSGA-II para cada par de objetivos: A_{v0} [dB], f_T [MHz], SR [V/ μ s], Pwr [mW] e $Area$ [μ m 2].

Os resultados dos 5 experimentos, através da métrica de Hipervolume e comparação gráfica, podem ser considerados como equivalentes.

Observa-se na Figura 5.6 comportamentos entre objetivos, conhecidos intuitivamente pelos projetistas de CIs analógicos: A_{v0} decresce com o aumento de f_T , f_T e Pwr possuem uma grande correlação positiva, f_T e SR possuem correlação positiva mas uma bifurcação mostra um comportamento distinto que pode ser esclarecido com o Agrupamento de Variáveis.

5.4 Extração de Conhecimentos

A extração de conhecimentos proposta é iniciada pela realização do Mapa de Aquecimento ou *Heatmap* 5.7, utilizando-se a correlação de Spearman ao quadrado (ρ^2) para o Agrupamento de Variáveis. A correlação de Spearman também pode ser vista como uma análise de sensibilidade global. Apesar de não constituir prova de relação causal, este mapeamento estatístico pode ser utilizado como guia de configuração do OTA (LEME; GIMENEZ; TOMAZ, 2011).

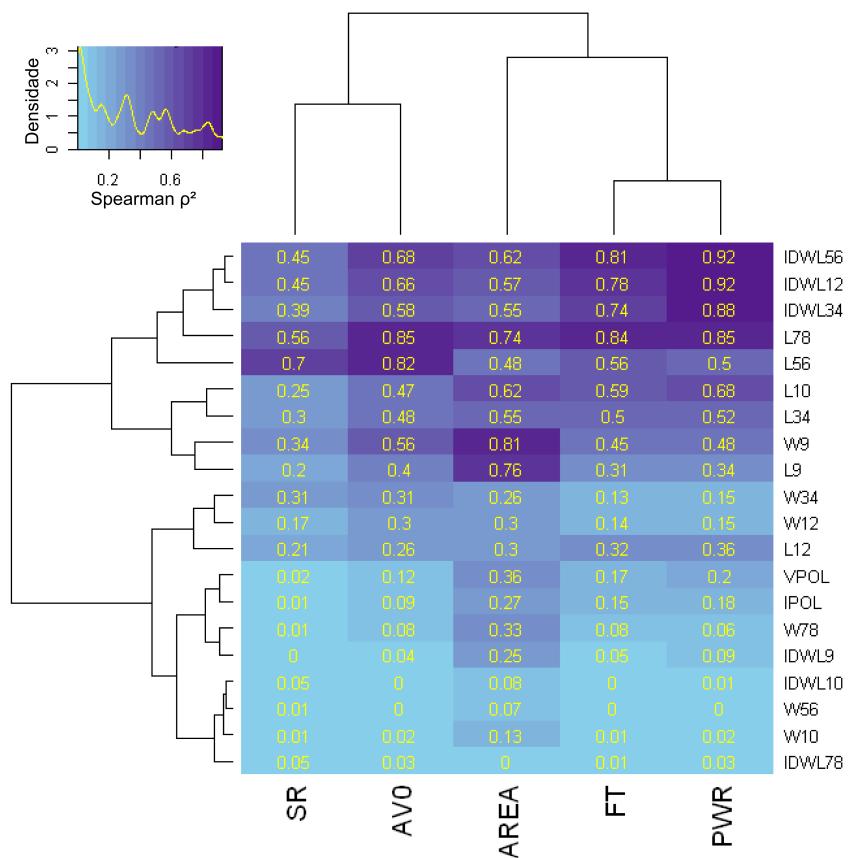


Figura 5.7: *Heatmap* e dendrogramas da correlação de Spearman ao quadrado (ρ^2) entre os parâmetros e os objetivos. IDWL [$I_{DS}/(W/L)$] é a medida da região de inversão do MOSFET.

O *Heatmap* mostra quais são as variáveis com maior correlação. Entre parâmetros e objetivos pelo mapa de cores e entre objetivos e entre parâmetros pelos dendrogramas superior e lateral respectivamente. A observação destas correlações leva a conclusões interessantes como por exemplo a correlação entre a corrente de inversão do par de entrada $I_{DS}/(W/L)$ (IDWL12), Potência dissipada *Pwr* e Frequência de ganho unitário f_T : é prática comum colocar o par diferencial em inversão forte para atingir-se altos f_T , o *Heatmap* mostra que a maior correlação desta ação é um efeito indesejado de aumento da Potência dissipada. Para maximizar f_T o projetista deve olhar primeiro para o comprimento de canal (L78) do par M_7-M_8 .

O segundo passo da proposta de extração de conhecimento é o Agrupamento de Observações (*Clustering*) das observações de vetor de objetivos (Λ), onde observações são agrupadas por similaridade. A escolha do número de clusters é feita empiricamente, neste caso quatro grupos de observações foram estabelecidos. Estes quatro agrupamentos caracterizam classes conhecidas dentro do jargão de microeletrônica como: OTAs de Alto Ganho, OTAs de Alta Frequência, OTAs de Micropotência, OTAs de uso geral. A Figura 5.8 ilustra estas divisões do espaço de objetivos (Λ).

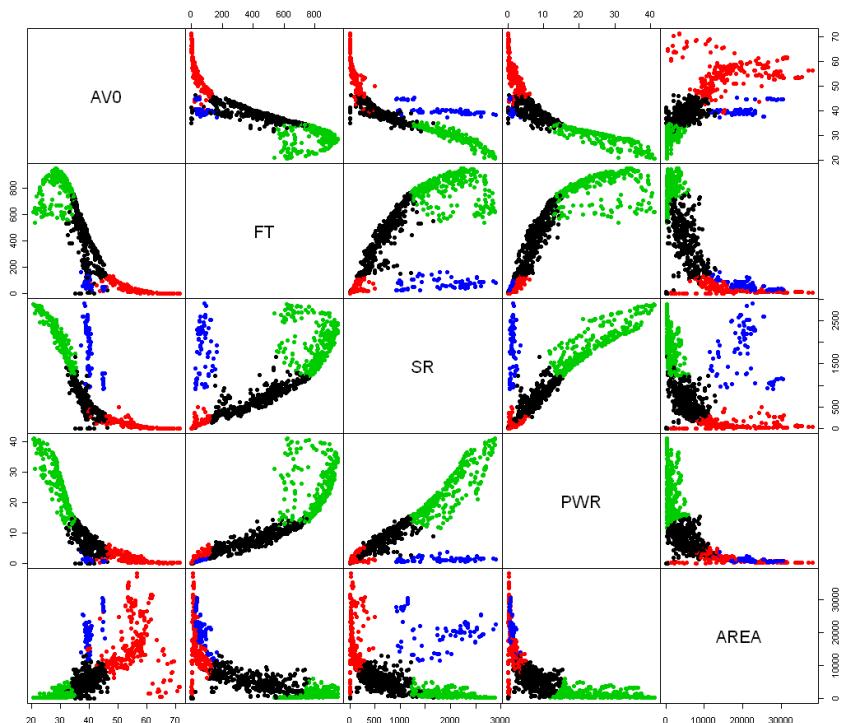


Figura 5.8: Agrupamento de Observações das Fronteiras de Pareto (\mathcal{PF}^*) das soluções obtidas no Apêndice B. (1) Preto: *Soluções de Médio Compromisso entre Objetivos*, (2) Vermelho: *Alto Ganho*, (3) Verde: *Alta Frequência*, (4) Azul: *Baixa Potência*.

Com os agrupamentos de variáveis e observações, torna-se possível a investigação aprofundada das relações entre objetivos e parâmetros. Observa-se no *Heatmap*, nas regiões em vermelho, as variáveis com maior correlação. A investigação desta correlação é desdobrada através de gráficos como ilustrado na Figura 5.9, onde temos pares de variáveis (objetivo/parâmetro) de alta correlação segmentados pelo agrupamento de observações.

Através dos *clusters* é possível revelar questões importantes da fronteira de Pareto. Por exemplo, na bifurcação no gráfico SR-FT encontramos a categoria (4) Azul: *Baixa Potência* que possui comportamento distinto das demais soluções. Esta observação é esclarecedora quanto a natureza da bifurcação, de fato uma relação modal como observado no artigo Leme, Gimenez e Tomaz (2011).

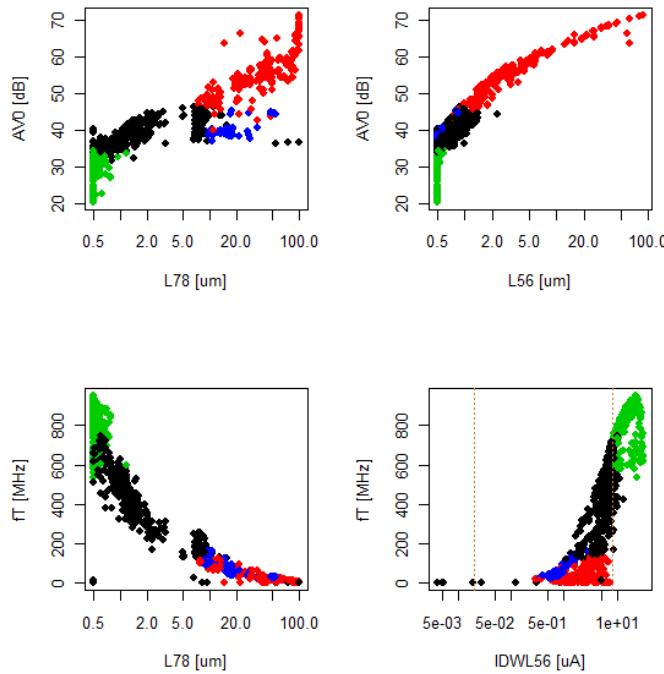
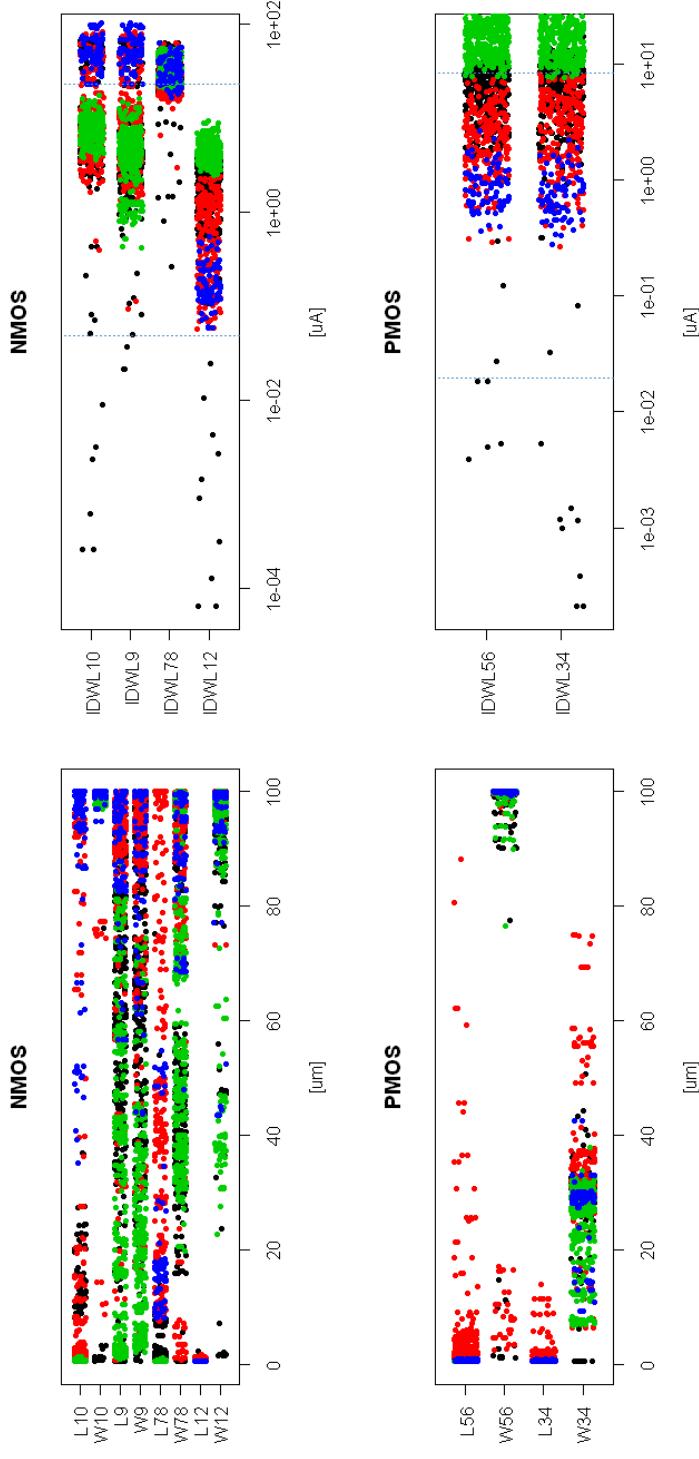


Figura 5.9: Exemplos de relações extraídas da observação do *Heatmap* e Agrupamento de Observações.

Os parâmetros de configuração direta dos MOSFET são apresentados na Figura 5.10(a) e os parâmetros indiretos (regime de inversão) são apresentados na Figura 5.10(b). A observação destes parâmetros mostra relações de interesse do projetista de CIs analógicos. Observa-se para toda solução ótima, um valor constante do comprimento de canal do par de entrada (L_{12}) igual a $0,5\mu m$, segue a observação de L_{34} que possui uma dispersão um pouco maior, mas pode ser considerada constante para a maioria das soluções ótimas, também com valor de $0,5\mu m$. L_{56} possui uma dispersão maior que os parâmetros anteriores especialmente para soluções da classe Alto Ganho (cor vermelha) que possuem dispersão em valores mais altos. Esta observação corrobora com resultados de otimização manual no artigo de Gimenez et al. (2005), onde o OTA otimizado possui comprimento de canal mínimo para todos os MOSFET exceto o par M_7 e M_8 que possui um valor ligeiramente superior aos parâmetros anteriores. Observa-se, de fato, que para L_{78} as soluções ótimas exigem valores mais altos.

Os regimes de inversão ilustrados na Figura 5.10(b) também contém informações de projeto importantes. Por exemplo, observa-se que o par de entrada em todas as configurações ótimas não precisa estar na região de inversão forte, a região de inversão moderada é suficiente. Esta observação é contra-intuitiva ao procedimento de iniciar-se o projeto configurando os MOSFET na região de inversão forte (STEFANOVIĆ; KAYAL, 2008).



(a) Larguras (W) e Comprimentos (L) de canal dos Transistores MOS-(b) Inversão ($I_{DS} / (W/L)$) dos Transistores MOSFET. As linhas verticais delimitam a transição das regiões de Inversão Fraca-Moderada e Inversão Moderada-Forte.

Figura 5.10: Parâmetros dos Transistores MOSFET. (1) Preto: Soluções de Médio Compromisso entre Objetivos, (2) Vermelho: Alto Ganho, (3) Verde: Alta Frequência, (4) Azul: Baixa Potência.

5.4.1 Automação da Extração de Conhecimentos

As árvores de regressão e classificação constituem uma proposta de automação da extração de conhecimento pela indução de *Regras* a partir das fronteiras de Pareto. A Figura 5.11 ilustra uma árvore de classificação com regras induzidas no espaço de parâmetros (Ω). A expansão da árvore foi limitada à minima divisão de nós com 200 exemplos e as folhas representam a probabilidade condicional da solução pertencer a uma das quatro classes (1-Soluções de Médio Compromisso entre Objetivos, 2-Alto Ganho, 3-Alta Frequência ou 4-Baixa Potência) dada a configuração do espaço de parâmetros (Ω).

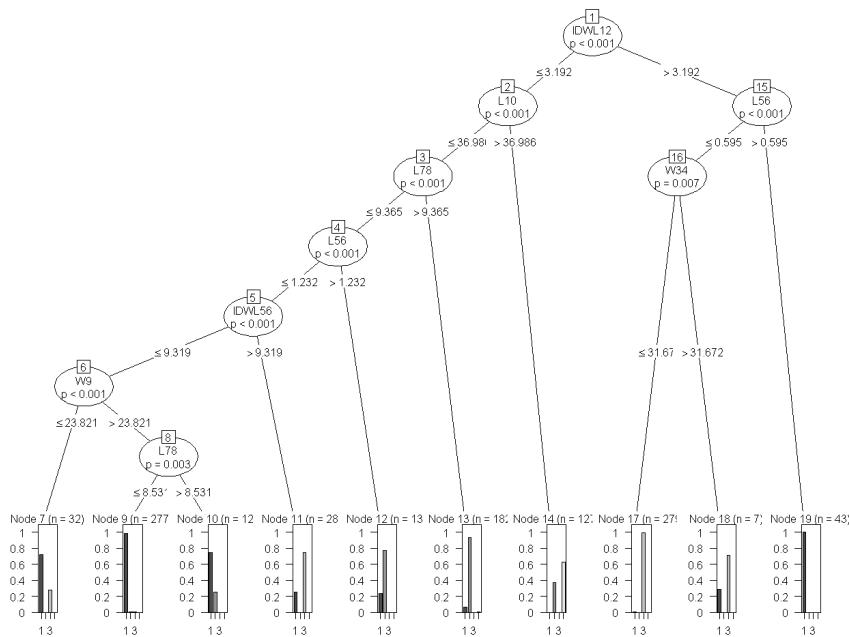
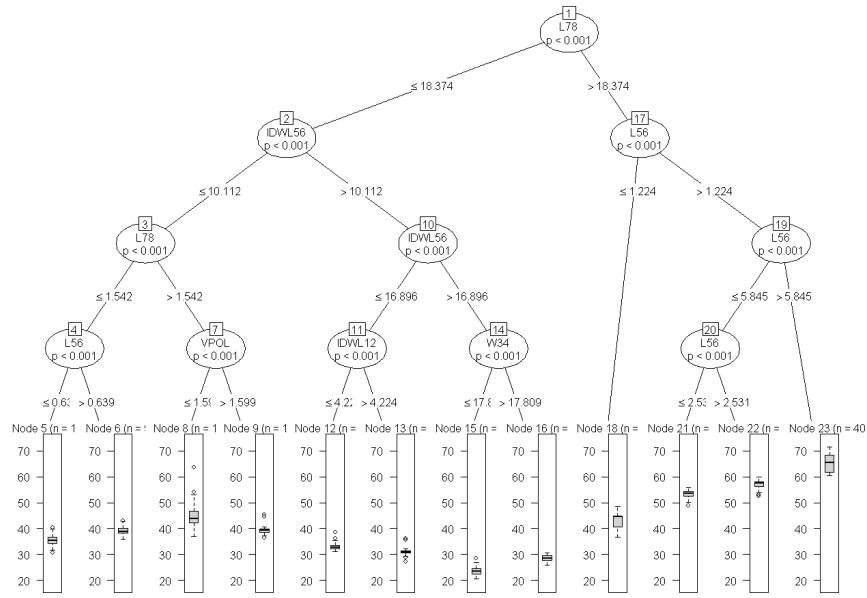
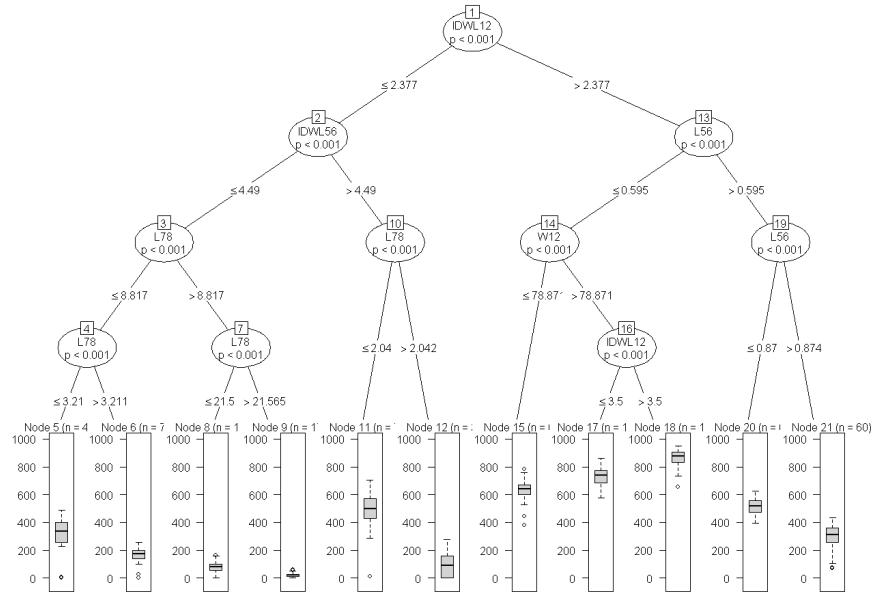


Figura 5.11: Árvore de Classificação para as Classes: (1) Preto: *Soluções de Médio Compromisso entre Objetivos*, (2) Vermelho: *Alto Ganho*, (3) Verde: *Alta Frequência*, (4) Azul: *Baixa Potência*.

A Árvore de Classificação da Figura 5.11 deve ser interpretada a partir do nó raiz até a folha com a classe de interesse correspondente. Por exemplo, observamos que para a classe (3)*Alta Frequência*, a folha ou nó 17, apresenta a maior probabilidade de realizações de OTAs pertencentes a esta classe. Os parâmetros $IDWL12 > 3.192\mu A$, $L56 < 0.595\mu m$ e $W34 < 31.67\mu m$ são as configurações que levam a obtenção da classe *Alta Frequência* dentro das relações de otimalidade da aproximação da fronteira Pareto.

De maneira similar à Árvore de Classificação, temos na Figura 5.12 as Árvores de Regressão para o objetivo A_{v0} (Figura 5.12(a)) e f_T (Figura 5.12(b)).

(a) Árvore de Regressão para o Objetivo A_{v0} .(b) Árvore de Regressão para o Objetivo f_T .**Figura 5.12:** Árvores de Regressão.

As Árvores de Classificação permitem observar relações quantitativas entre os parâmetros e objetivos. Estas são construídas individualmente para cada objetivo e as folhas apresentam a probabilidade posterior do objetivo, dados os parâmetros na forma gráfica de *boxplot*. Por exemplo para a configuração $L_{78} > 18,374\mu m$ (Nó 1), $L_{56} > 1,224\mu m$ (Nó 17) e $L_{56} > 5,845\mu m$ (Nó 19) temos a folha do Nô 23 com A_{v0} distribuído entre aproximadamente 60dB e 70dB. Esta

probabilidade condicional está ilustrada na Figura 5.13.

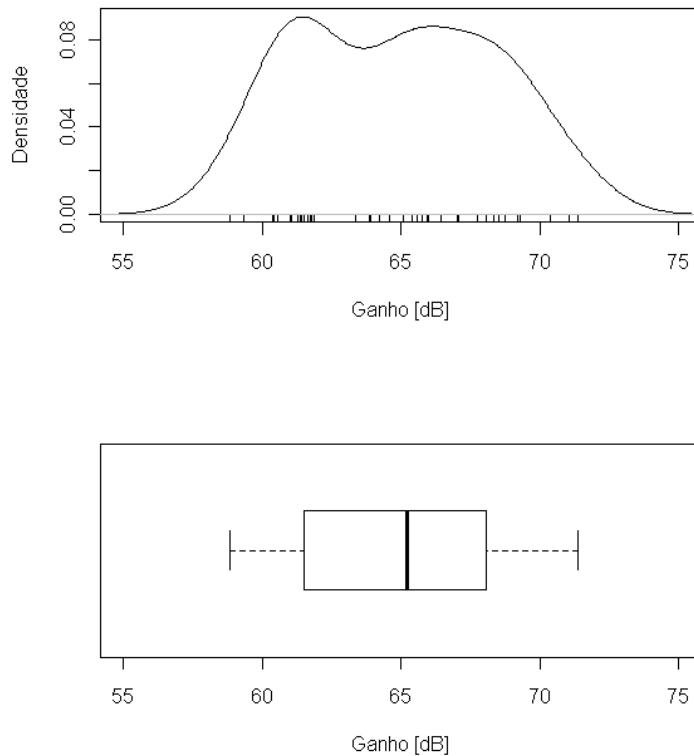


Figura 5.13: Densidade de A_{v0} (Nó 23) para soluções restritas pelas inequações $L_{78} > 18,374\mu m$ (Nó 1), $L_{56} > 1,224\mu m$ (Nó 17) e $L_{56} > 5,845\mu m$ (Nó 19) da árvore de regressão de A_{v0} .

Para a obtenção de uma realização de OTA com A_{v0} entre $60dB$ e $70dB$, na condição de optimalidade da fronteira de Pareto, podemos dizer que o OTA deve ser configurado com $L_{78} > 18,374\mu m$, $L_{56} > 1,224\mu m$ e $L_{56} > 5,845\mu m$.

6 CONCLUSÃO

“There is no true interpretation of anything; interpretation is a vehicle in the service of human comprehension. The value of interpretation is in enabling others to fruitfully think about an idea.”

Andreas Buja

Sendo a Fronteira de Pareto o conjunto das melhores relações de compromisso entre os objetivos, a observação e extração de conhecimentos a partir desta, tem o significado de extração de conhecimento sobre a condição de otimalidade. Os resultados experimentais, ainda que a fronteira de Pareto não tenha sido explorada completamente, demonstram que os métodos apresentados constituem um importante guia para o dimensionamento de OTAs aprimorados. A principal constatação é que o processo de busca evolucionário pode prover não somente resultados equiparáveis a projetistas humanos (ZEBULUM; PACHECO; VELLASCO, 2001; KOZA et al., 1999), mas através das Fronteiras de Pareto, relações antes desconhecidas até mesmo aos projetistas de CIs analógicos mais experientes.

Enquanto obter uma única solução ótima tem as suas vantagens de ordem prática, o custo computacional extra para a obtenção da Fronteira de Pareto compensa-se pelo conhecimento tácito que pode ser extraído destas. Este conhecimento também pode levantar questões relevantes de pesquisa na área de Microeletrônica.

O processo evolucionário não é limitado pelas regras de projeto convencionais, mas pelo princípio de sobrevivência do mais apto, desta forma explora-se regiões do espaço de busca antes inexploradas pelos projetistas humanos e permitindo o surgimento de soluções não convencionais (THOMPSON; LAYZELL, 1999). Aliado à condição de otimalidade da Fronteira de Pareto, pode-se dizer que é possível obter-se relações de otimalidade não convencionais, ou mesmo desconhecidas dentro da metodologia convencional.

O processo de exploração de dados manual está bem sedimentado sobre o *Heatmap* (Agrupamento de Variáveis) e *Clusters* (Agrupamento de Observações), permitindo a extração de relações importantes, mas as árvores de regressão e classificação possuem um grande potencial de automação, capazes de extrair a totalidade de regras do conjunto de dados da Fronteira de Pareto. Este conjunto

de regras pode ser utilizado para a síntese automática de sistemas analógicos (HJALMARSON, 2003).

A metodologia deste trabalho apresenta resultados interessantes, entretanto existem certas deficiências a serem abordadas em trabalhos futuros, dentre elas podemos citar:

- a) A instabilidade da convergência do Hipervolume: O critério de distância de apinhamento deve ser re-avaliado. Uma proposta é inserir a métrica *Contribuição de Hipervolume* de maior custo computacional, entretanto com grande probabilidade de resolver o problema;
- b) O custo computacional do experimento é elevado. São necessárias duas semanas em um computador equipado com CPU Intel i5 de 2.3 GHz para os 5 experimentos com 6000 gerações cada. Propõe-se utilizar aproximações (*surrogates*) das funções de aptidão baseadas como Redes Neurais, Regressões Polinomiais ou Kriging com o objetivo de acelerar este processo;
- c) As variações de processo são um aspecto fundamental quando transita-se em direção a nanoscalas (HJALMARSON, 2003). Estas variações necessitam ser consideradas para a obtenção soluções robustas e também necessárias devido ao avanço tecnológico. Uma proposta plausível é utilizar métodos de Monte Carlo para o tratamento destas variações;
- d) A indução de regras através de árvores de regressão e classificação é apenas um dos métodos possíveis de extração automática de conhecimentos. A utilização de outros algoritmos como MARS (*Multiple Adaptive Regression Splines*) e PRIM (*Patient Rule Induction*) são alternativas para estudo. (HASTIE; TIBSHIRANI; FRIEDMAN, 2003).
- d) Somente uma tecnologia CMOS e uma topologia de OTA foi abordada neste experimento. Propõe-se estender este estudo para outras topologias e outras tecnologias.

REFERÊNCIAS

- ALTENBERG, L. The schema theorem and price's theorem. In: WHITLEY, L. D.; VOSE, M. D. (Ed.). **Foundations of Genetic Algorithms**. Estes Park, Colorado, USA: Morgan Kaufmann Publishers Inc., 1994. p. 23–49. ISBN 1-55860-356-5.
- BÄCK, T.; HAMMEL, U.; SCHWEFEL, H. P. An introduction to simulated evolutionary optimization. **IEEE Transactions on Evolutionary Computation**, v. 1, n. 1, p. 3–17, 1997.
- BANDARU, S.; DEB, K. Automated discovery of vital knowledge from pareto-optimal solutions: First results from engineering design. In: **Evolutionary Computation (CEC), 2010 IEEE Congress on**. Barcelona, Spain: [s.n.], 2010. p. 1 –8.
- BANZHAFF, W. et al. **Genetic Programming: An Introduction**. San Francisco, California, USA: Morgan Kaufmann Publishers Inc., 1998.
- Bennett III, F. H. et al. Automatic synthesis, placement, and routing of an amplifier circuit by means of genetic programming. In: MILLER, J. et al. (Ed.). **Evolvable Systems: From Biology to Hardware**. [S.I.]: Springer, 2000. (Lecture Notes in Computer Science, v. 1801), p. 1–10.
- BRADSTREET, L.; WHILE, R. L.; BARONE, L. A fast incremental hypervolume algorithm. **IEEE Transactions on Evolutionary Computation**, v. 12, n. 6, p. 714–723, 2008.
- CARLSON, S. E.; SHONKWILER, R. Annealing a genetic algorithm over constraints. In: **in Proceedings of 1998 IEEE International Conference on Systems, Man, and Cybernetics**. [s.n.], 1998. p. 3931–3936. Disponível em: <<http://vlead.mech.virginia.edu/publications/shekpaper/shenkpaper.html>>.
- CHEN, P. Y.; POPOVICH, P. M. **Correlation: parametric and nonparametric measures**. Thousand Oaks, CA, USA, 2002. (SAGE University Papers).
- COELLO, C. A. C. **A Survey of Constraint Handling Techniques used with Evolutionary Algorithms**. [S.I.], 1999.
- COELLO, C. A. C. Evolutionary multi-objective optimization: a historical view of the field. **Computational Intelligence Magazine, IEEE**, v. 1, n. 1, p. 28–36, 2006.
- COELLO, C. A. C.; LAMONT, G. B.; VELDHUIZEN, D. A. V. **Evolutionary Algorithms for Solving Multi-Objective Problems (Genetic and Evolutionary Computation)**. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN 0387332545.
- De Jong, K. A. **Evolutionary Computation: A Unified Approach**. 1st. ed. Cambridge, Massachusetts, USA: The MIT Press, 2002. ISBN 0262041944.
- DEB, K. **Multi-Objective Optimization Using Evolutionary Algorithms**. 1. ed. Chichester, West Sussex, UK: John Wiley & Sons, 2001. ISBN 978-0-470-74361-4 (P/B).
- DEB, K.; AGRAWAL, R. B. **Simulated Binary Crossover for Continuous Search Space**. [S.I.], 1994. v. 9, 1–34 p.

- DEB, K. et al. A fast elitist non-dominated sorting genetic algorithm: Nsga-ii. In: **Proceedings of the Parallel Problem Solving from Nature VI (PPSN-VI)**. [S.l.: s.n.], 2000. p. 849–858.
- DEB, K.; GOYAL, M. A combined genetic adaptive search (geneas) for engineering design. **Computer Science and Informatics**, v. 26, p. 30–45, 1996.
- DEB, K.; SRINIVASAN, A. **Innovization: Innovative Design Principles Through Optimization**. Kanpur, India, 2005.
- FOGEL, D. B. An introduction to simulated evolutionary optimization. **IEEE Transactions on Neural Networks**, v. 5, n. 1, p. 3–14, 1994.
- FRIENDLY, M. The history of the cluster heat map. **The American Statistician**, 2009.
- GENTINNE, B. **A study of the potential of SOI technology for analog applications**. Tese (Doutorado) — Université catholique de Louvain, 1996.
- GIMENEZ, S. P. et al. Potential of Improved Gain in Operational Transconductance Amplifier using 0.5 mm graded-channel SOI nMOSFET for Applications in the Gigahertz Range. In: **SBMICRO 2005 - 20TH INTERNATIONAL SYMPOSIUM ON MICROELECTRONICS TECHNOLOGY AND DEVICES**. Florianópolis, SC. **Microelectronics Technology and Devices - SBMICRO 2005**. Pennington, NJ, USA: The Electrochemical Society, Inc., 2005. v. 2005-8, p. 502–511.
- GLISSON, J. T. H. **Introduction to Circuit Analysis and Design**. Raleigh, NC, USA: Springer, 2011. ISBN 978-90-481-9442-1.
- GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1989. ISBN 0201157675.
- GOLDBERG, D. E. Real-coded genetic algorithms, virtual alphabets, and blocking. **Complex Systems**, v. 5, p. 139–167, 1990.
- GREENWOOD, G. W.; TYRREL, A. M. **Introduction to Evolvable Hardware: A Practical Guide for Designing Self-Adaptive Systems**. Piscataway, NJ, USA: IEEE Press, 2007.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning**. 2. ed. [S.l.]: Springer, 2003. Hardcover. ISBN 0387952845.
- HIGUCHI, T. et al. Introduction to evolvable hardware. In: _____. **Evolvable Hardware**. USA: Springer, 2006. (Genetic and Evolutionary Computation), cap. 1.
- HINES, W. W.; MONTGOMERY, D. C. **Probability and Statistics in Engineering and Management Science**. 3. ed. New York, NY, USA: John Wiley & Sons, 1990.
- HJALMARSON, E. **STUDIES ON DESIGN AUTOMATION OF ANALOG CIRCUITS: THE DESIGN FLOW**. Dissertação (Mestrado) — Linköpings universitet, SE-581 83 Linköping, Sweden, 2003.
- HOTHORN, T. et al. **party: A Laboratory for Recursive Partytioning**. 2006.
- IBS Corporation. **industry reports**. 2002.
- IGEL, C. et al. Shark. **Journal of Machine Learning**, v. 9, 2008.

- KNOWLES, J.; THIELE, L.; ZITZLER, E. **A Tutorial on the Performance Assessment of Stochastic Multiobjective Optimizers.** [S.l.], Fev. 2006.
- KOZA, J. R. et al. **Genetic Programming III: Darwinian Invention and Problem Solving.** San Francisco, California, USA: Morgan Kaufmann Publishers Inc., 1999.
- KRUISKAMP, W.; LEENAERTS, D. Darwin: Cmos opamp synthesis by means of a genetic algorithm. **Design Automation Conference**, IEEE Computer Society, v. 0, p. 433–438, 1995.
- LANGDON, W. B.; POLI, R. **Foundations of Genetic Programming.** 1. ed. Berlim, Germany: Springer-Verlag, 2002. ISBN 3540424512.
- LEME, A. P. M.; GIMENEZ, S. P.; TOMAZ, C. E. Desvendando os limites de otimização de um ota cmos por meio da eletrônica evolucionária extrínseca. In: X SBAI - SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE. UFSJ, São João Del Rei, MG, 2011.
- LIU, W. et al. **BSIM 3v3.2 MOSFET Model Users' Manual.** [S.l.], 1998. Disponível em: <<http://www.eecs.berkeley.edu/Pubs/TechRpts/1998/3486.html>>.
- MATTIUSSI, C.; FLOREANO, D. Evolution of analog networks using local string alignment on highly reorganizable genomes. **Evolvable Hardware, NASA/DoD Conference on**, IEEE Computer Society, Los Alamitos, CA, USA, v. 0, p. 30, 2004.
- MATTIUSSI, C.; FLOREANO, D. Analog genetic encoding for the evolution of circuits and networks. **IEEE Transactions on Evolutionary Computation**, v. 11, n. 5, p. 596–607, Oct. 2007.
- MATTIUSSI, C. et al. The Age of Analog Networks. **AI Magazine**, v. 29, n. 3, p. 63–76, 2008.
- MCCONAGHY, T. et al. **Variation-Aware Analog Structural Synthesis: A Computational Intelligence Approach.** Dordrecht, Holland: Springer, 2009. (Analog Circuits and Signal Processing). ISBN 9789048129058.
- MISHRA, U. K.; SINGH, J. **SEMICONDUCTOR DEVICE PHYSICS AND DESIGN.** [S.l.]: Springer, 2008.
- NAGEL, L. W. **The Life of SPICE, A talk given at BCTM'96.** Jan. 2008. Disponível em: <<http://www.designers-guide.org/Perspective/life-of-spice.pdf>>.
- PRICE, G. R. Selection and covariance. **Nature**, v. 227, p. 520–521, 1970.
- R Development Core Team. **R: A Language and Environment for Statistical Computing.** Vienna, Austria, 2011. ISBN 3-900051-07-0. Disponível em: <<http://www.R-project.org/>>.
- SANSEN, W. M. C. **Analog Design Essentials (The International Series in Engineering and Computer Science).** Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN 0387257462.
- SANTOS, L. et al. **Electronic System Level Design: An Open-Source Approach.** [S.l.]: Springer, 2011.
- SCHAFFER, J. D. **Some Experiments in Machine Learning Using Vector Evaluated Genetic Algorithms.** Tese (Doutorado) — Nashville, TN: Vanderbilt University, 1984.

- SCHAUMANN, R. The Electrical Engineering Handbook. In: _____. [S.I.]: Elsevier, 2004. cap. Active Filters, p. 127–138.
- SCHWEFEL, H. P. Handbook of evolutionary computation. In: _____. [S.I.]: IOP Publishing Ltd and Oxford University Press, 1997. cap. Advantages (and disadvantages) of evolutionary computation over other approaches.
- SILVEIRA, F.; FLANDRE, D.; JESPERS, P. G. A. A g_m/i_d based methodology for the design of cmos analog circuits and its application to the synthesis of a silicon-on-insulator micropower ota. **IEEE Journal of Solid-State Circuits**, v. 31, n. 9, 1996.
- STEFANOVIĆ, D.; KAYAL, M. **Structured Analog CMOS Design**. Ecole Polytechnique Fédérale de Lausanne, Switzerland: Springer, 2008. ISBN 978-1-4020-8572-7.
- STOICA, A. et al. Reconfigurable electronics for extreme environments. In: _____. **Evolvable Hardware**. [S.I.]: Springer, 2006. (Genetic and Evolutionary Computation), cap. 8.
- STOICA, A. et al. Evolution of CMOS circuits in simulations and directly in hardware on a programmable chip. In: BANZHAF, W. et al. (Ed.). **Proceedings of the Genetic and Evolutionary Computation Conference**. Orlando, Florida, USA: Morgan Kaufmann Publishers Inc., 1999. v. 2, p. 1198–1203. Disponível em: <<http://www.cs.bham.ac.uk/wbl/biblio/gecco1999/GP-440.ps>>.
- THOMPSON, A.; LAYZELL, P. Analysis of unconventional evolved electronics. **Commun. ACM**, ACM, New York, NY, USA, v. 42, n. 4, p. 71–79, 1999. ISSN 0001-0782. Disponível em: <<http://doi.acm.org/10.1145/299157.299174>>.
- TUMA, T.; BÜRMEN, A. **Circuit Simulation with SPICE OPUS: Theory and Practice**. 1st. ed. Berlim, Germany: Birkhäuser Basel, 2009. ISBN 0817648666.
- WOLPERT, D. H.; MACREADY, W. G. No free lunch theorems for optimization. **IEEE Transactions on Evolutionary Computation**, v. 1, n. 1, p. 67–82, 1997.
- XU, R.; WUNSCH, D. **Clustering (IEEE Press Series on Computational Intelligence)**. illustrated edition. Hoboken, NJ, USA: Wiley-IEEE Press, 2008. Hardcover. ISBN 0470276800.
- ZEBULUM, R. S.; PACHECO, M. A.; VELLASCO, M. M. B. **Evolutionary Electronics: Automatic Design of Electronic Circuits and Systems by Genetic Algorithms**. Boca Raton, FL, USA: CRC Press, Inc., 2001. ISBN 0849308658.
- ZITZLER, E. et al. **Performance Assessment of Multiobjective Optimizers: An Analysis and Review**. Zurich, Switzerland, Jun 2002.

APÊNDICE A – LISTAGENS SPICE

A.1 Listagem para SIMULAÇÃO

```

*OTA optimization - Spice netlist - Leme, 2010
Vsrc (src 0) 3
Cload (4 0) 3p
Ipol (0 3) dc=<TOKEN::IPOL>u
.netclass otasim openloop
Vpol (2 0) dc=<TOKEN::VPOL>
Vac (1 2) dc=0 acmag=1
X0 (0 src 1 2 3 4) OTAMOSFET
.endn
.netclass otasim closedloop
Vpulse (2 0) dc=0 pulse=(0.0 2.0 5u 1p)
X0 (0 src 5 2 3 4) OTAMOSFET
RL (4 5) 0.001
Vupr (upr 0) pw1=(0 0.2 4.99u 0.2 5u 3.0 25u 3.0)
Vlwr (lwr 0) pw1=(0 0.00 20u 0.00 20.01u 1.6 25u 1.6)
.endn
.subckt OTAMOSFET gnd vdd inn inp ipol out
X1 (n01 inn n02 n02) nMOSFET w=<TOKEN::W1&2>u l=<TOKEN::L1&2>u
X2 (n03 inp n02 n02) nMOSFET w=<TOKEN::W1&2>u l=<TOKEN::L1&2>u
X3 (n01 n01 vdd vdd) pMOSFET w=<TOKEN::W3&4>u l=<TOKEN::L3&4>u
X4 (n03 n03 vdd vdd) pMOSFET w=<TOKEN::W3&4>u l=<TOKEN::L3&4>u
X5 (n04 n01 vdd vdd) pMOSFET w=<TOKEN::W5&6>u l=<TOKEN::L5&6>u
X6 (out n03 vdd vdd) pMOSFET w=<TOKEN::W5&6>u l=<TOKEN::L5&6>u
X7 (n04 n04 gnd gnd) nMOSFET w=<TOKEN::W7&8>u l=<TOKEN::L7&8>u
X8 (out n04 gnd gnd) nMOSFET w=<TOKEN::W7&8>u l=<TOKEN::L7&8>u
X9 (ipol ipol gnd gnd) nMOSFET w=<TOKEN::W9>u l=<TOKEN::L9>u

```

```

X10 (n02 ipol gnd gnd) nMOSFET w=<TOKEN::W10>u l=<TOKEN::L10>u
.ends

.subckt nMOSFET drain gate source bulk param: w l m=1
m0 (drain gate source bulk) nmosmod w={w} l={l} m={m}
+ ad={w*0.5u} as={w*0.5u}
+ pd={2*(w+0.5u)} ps={2*(w+0.5u)}
+ nrd={0.5u/w} nrs={0.5u/w}
.ends

.subckt pMOSFET drain gate source bulk param: w l m=1
m0 (drain gate source bulk) pmosmod w={w} l={l} m={m}
+ ad={w*0.5u} as={w*0.5u}
+ pd={2*(w+0.5u)} ps={2*(w+0.5u)}
+ nrd={0.5u/w} nrs={0.5u/w}
.ends

.include nmosmod.mod
.include pmosmod.mod
.control
set noconviter = 1
set units = degrees
set numdigit = 18
set width = 80
set forcebuild = 1
netclass select otasim::openloop
netclass rebuild
op
let vbias = V(4)
let pwr = -i(Vsrc)*V(src)
let area = 2*@x1:x0[w]*@x1:x0[1]+2*@x3:x0[w]*@x3:x0[1]
+ +2*@x5:x0[w]*@x5:x0[1]+2*@x7:x0[w]*@x7:x0[1]
+ +@x9:x0[w]*@x9:x0[1]+@x10:x0[w]*@x10:x0[1]
let id12 = @m0:x1:x0[id]
let id34 = @m0:x3:x0[id]
let id56 = @m0:x5:x0[id]
let id78 = @m0:x7:x0[id]
let id9 = @m0:x9:x0[id]
let id10 = @m0:x10:x0[id]

```

```

let sat12 = @m0:x1:x0[vds]-@m0:x1:x0[vgs]+@m0:x1:x0[vth]
let sat34 = @m0:x3:x0[vds]-@m0:x3:x0[vgs]+@m0:x3:x0[vth]
let sat56 = @m0:x5:x0[vds]-@m0:x5:x0[vgs]+@m0:x5:x0[vth]
let sat78 = @m0:x7:x0[vds]-@m0:x7:x0[vgs]+@m0:x7:x0[vth]
let sat9 = @m0:x9:x0[vds]-@m0:x9:x0[vgs]+@m0:x9:x0[vth]
let sat10 = @m0:x10:x0[vds]-@m0:x10:x0[vgs]+@m0:x10:x0[vth]
print vbias, pwr, area, id12, id34, id56, id78,
+ id9, id10, sat12, sat34, sat56, sat78,
+ sat9, sat10 > <TOKEN::OUTPUT>
ac dec 5 10 1g
let gainvec= mag(V(4)/V(1))
let av0= gainvec[0]
let cur=0
cursor cur right gainvec 1
let fT=real(frequency[%cur])
let p=unwrap(phase(V(4)/V(1)))
let pm=p[%cur]
print av0, fT, pm >> <TOKEN::OUTPUT>
netclass select otasim::closedloop
netclass rebuild
tran 0.1us 25us
let tupr = v(4) gt v(upr)
let tlwr = v(4) lt v(lwr)
if (tupr | tlwr)
  let sr = -sum(abs(v(4)*tupr) + abs(v(4)*tlwr))*1E6
else
  let out10=0.3
  let out90=1.5
  let c1=0
  let c2=0
  cursor c1 right V(4) out10 1
  cursor c2 right V(4) out90 1
  let trise=time[%c2]-time[%c1]
  let sr=(out90-out10)/trise
end
print sr >> <TOKEN::OUTPUT>

```

```
.endc
.end
```

A.2 Modelo nMOSFET

```
* T99J SPICE BSIM3 VERSION 3.1 PARAMETERS
* DATE: Dec 22/09
* LOT: T99J WAF: 7101
* TECHNOLOGY: SCN05
* URL: http://www.mosis.com/cgi-bin/cgiwrap/umosis/swp/params/
* ami-c5/t99j-params.txt
.model nmosmod nMOS
+ Level = 53
+ VERSION = 3.1 TNOM = 27 TOX = 1.42E-8
+ XJ = 1.5E-7 NCH = 1.7E17 VTH0 = 0.6066706
+ K1 = 0.8916583 K2 = -0.0984787 K3 = 23.6382023
+ K3B = -8.4234075 W0 = 3.807398E-8 NLX = 1.509888E-9
+ DVTOW = 0 DVT1W = 0 DVT2W = 0
+ DVT0 = 0.7849492 DVT1 = 0.3994002 DVT2 = -0.5
+ U0 = 452.2685957 UA = 1E-13 UB = 1.176277E-18
+ UC = -5.73121E-14 VSAT = 1.841184E5 A0 = 0.5371856
+ AGS = 0.0886407 B0 = 1.957761E-6 B1 = 5E-6
+ KETA = -2.530193E-3 A1 = 7.230825E-5 A2 = 0.315185
+ RDSW = 1.081837E3 PRWG = 0.112333 PRWB = -1.908309E-4
+ WR = 1 WINT = 1.761404E-7 LINT = 9.06256E-8
+ XL = 1E-7 XW = 0 DWG = -1.191345E-9
+ DWB = 5.413496E-8 VOFF = -1.406284E-4 NFACTOR = 0.8085791
+ CIT = 0 CDSC = 2.4E-4 CDSCD = 0
+ CDSCB = 0 ETA0 = 1.449343E-3 ETAB = 1
+ DSUB = 0.0129169 PCLM = 2.2363819 PDIBLC1 = 1.729314E-4
+ PDIBLC2 = 1.682325E-3 PDIBLCB = -0.5 DROUT = 1.01633E-4
+ PSCBE1 = 2.511791E9 PSCBE2 = 1E-3 PVAG = 0
+ DELTA = 0.01 RSH = 84.4 MOBMOD = 1
+ PRT = 0 UTE = -1.5 KT1 = -0.11
+ KT1L = 0 KT2 = 0.022 UA1 = 4.31E-9
+ UB1 = -7.61E-18 UC1 = -5.6E-11 AT = 3.3E4
```

```

+ WL = 0 WLN = 1 WW = 0
+ WWN = 1 WWL = 0 LL = 0
+ LLN = 1 LW = 0 LWN = 1
+ LWL = 0 CAPMOD = 2 XPART = 0.5
+ CGD0 = 1.82E-10 CGS0 = 1.82E-10 CGBO = 1E-9
+ CJ = 4.14902E-4 PB = 0.839007 MJ = 0.429248
+ CJSW = 3.600151E-10 PBSW = 0.8 MJSW = 0.2047744
+ CJSWG = 1.64E-10 PBSWG = 0.8 MJSWG = 0.2047744
+ CF = 0 PVTH0 = -0.0632742 PRDSW = 203.232232
+ PK2 = -0.07324 WKETA = 2.457772E-3 LKETA = -6.437462E-3

```

A.3 Modelo pMOSFET

```

* T99J SPICE BSIM3 VERSION 3.1 PARAMETERS
* DATE: Dec 22/09
* LOT: T99J WAF: 7101
* TECHNOLOGY: SCN05
* URL: http://www.mosis.com/cgi-bin/cgiwrap/umosis/swp/params/
* ami-c5/t99j-params.txt
.model pmosmod pMOS
+ Level = 53
+ VERSION = 3.1 TNOM = 27 TOX = 1.42E-8
+ XJ = 1.5E-7 NCH = 1.7E17 VTH0 = -0.9152268
+ K1 = 0.553472 K2 = 7.871921E-3 K3 = 6.2769786
+ K3B = -0.4898254 W0 = 1.23924E-7 NLX = 1.141647E-7
+ DVTOW = 0 DVT1W = 0 DVT2W = 0
+ DVT0 = 0.9353874 DVT1 = 0.3671023 DVT2 = -0.1875761
+ U0 = 201.3603195 UA = 2.408572E-9 UB = 1E-21
+ UC = -1E-10 VSAT = 1.202516E5 A0 = 0.8828557
+ AGS = 0.088966 B0 = 5.175071E-7 B1 = 0
+ KETA = -4.865785E-3 A1 = 1.370912E-4 A2 = 0.4773832
+ RDSW = 3E3 PRWG = -0.0281209 PRWB = -0.0479695
+ WR = 1 WINT = 2.309781E-7 LINT = 1.226577E-7
+ XL = 1E-7 XW = 0 DWG = -5.470108E-9
+ DWB = -1.983267E-8 VOFF = -0.0625678 NFACTOR = 1.1137245
+ CIT = 0 CDSC = 2.4E-4 CDSCD = 0

```

```

+ CDSCB = 0 ETA0 = 0 ETAB = -0.2
+ DSUB = 1 PCLM = 2.3939111 PDIBLC1 = 0.0494294
+ PDIBLC2 = 3.663793E-3 PDIBLCB = -0.0364718 DROUT = 0.2462657
+ PSCBE1 = 1E8 PSCBE2 = 3.359223E-9 PVAG = 0.0150055
+ DELTA = 0.01 RSH = 105.9 MOBMOD = 1
+ PRT = 0 UTE = -1.5 KT1 = -0.11
+ KT1L = 0 KT2 = 0.022 UA1 = 4.31E-9
+ UB1 = -7.61E-18 UC1 = -5.6E-11 AT = 3.3E4
+ WL = 0 WLN = 1 WW = 0
+ WWN = 1 WWL = 0 LL = 0
+ LLN = 1 LW = 0 LWN = 1
+ LWL = 0 CAPMOD = 2 XPART = 0.5
+ CGDO = 2.3E-10 CGSO = 2.3E-10 CGBO = 1E-9
+ CJ = 7.238228E-4 PB = 0.8735391 MJ = 0.4909204
+ CJSW = 2.545206E-10 PBSW = 0.8 MJSW = 0.1987115
+ CJSWG = 6.4E-11 PBSWG = 0.8 MJSWG = 0.1987115
+ CF = 0 PVTH0 = 5.98016E-3 PRDSW = 14.8598424
+ PK2 = 3.73981E-3 WKETA = 0.0104146 LKETA = -8.958097E-3

```

A.4 Extração de g_m/I_{ds} (NMOS)

```

*nMOSFET gm/Ids extraction - Leme, 2010
vds 1 0 dc = 1.5
vgs 2 0 dc = 0
x1 (1 2 0 0) nMOSFET w=10u l=10u
.subckt nMOSFET drain gate source bulk param: w l m=1
m0 (drain gate source bulk) nmosmod w={w} l={l} m={m}
+ ad={w*0.5u} as={w*0.5u}
+ pd={2*(w+0.5u)} ps={2*(w+0.5u)}
+ nrd={0.5u/w} nrs={0.5u/w}
.ends
.include nmosmod.mod
.control
dc vgs 0.38 10 lin 500
let gmids=deriv(ln(-i(vds)))
let ma = max(gmids)

```

```

let mi = min(gmids)
let wi=ma-(ma-mi)*0.1
let si=mi+(ma-mi)*0.1
let c=0
cursor c right gmids wi
let weakinv = -i(vds)[%c]
let c=0
cursor c right gmids si
let stronginv = -i(vds)[%c]
print weakinv, stronginv > nmosinv.txt
print -i(vds), gmids > nmosgmids.txt
.endc
.end

```

A.5 Extração de g_m/I_{ds} (PMOS)

```

*pMOSFET gm/Ids extraction - Leme, 2010
vds 1 0 dc = -1.5
vgs 2 0 dc = 0
x1 (1 2 0 0) pMOSFET w=10u l=10u
.subckt pMOSFET drain gate source bulk param: w l m=1
m0 (drain gate source bulk) pmosmod w={w} l={l} m={m}
+ ad={w*0.5u} as={w*0.5u}
+ pd={2*(w+0.5u)} ps={2*(w+0.5u)}
+ nrd={0.5u/w} nrs={0.5u/w}
.ends
.include pmosmod.mod
.control
dc vgs -0.65 -10 lin 500
let gmids=-deriv(ln(i(vds)))
let ma = max(gmids)
let mi = min(gmids)
let wi=ma-(ma-mi)*0.1
let si=mi+(ma-mi)*0.1
let c=0
cursor c right gmids wi

```

```
let weakinv = i(vds)[%c]
let c=0
cursor c right gmids si
let stronginv = i(vds)[%c]
print weakinv, stronginv > pmosinv.txt
print i(vds), gmids > pmosgmids.txt
.endc
.end
```


ANEXO A – TRABALHO PUBLICADO EM CONGRESSO

DESVENDANDO OS LIMITES DE OTIMIZAÇÃO DE UM OTA CMOS POR MEIO DA ELETRÔNICA EVOLUCIONÁRIA EXTRÍNSECA

ANTONIO PAULO DE MORAES LEME*, SALVADOR PINILLOS GIMENEZ*, CARLOS EDUARDO THOMAZ*

*Centro Universitário da FEI

Av. Humberto de Alencar Castelo Branco, 3972
 São Bernardo do Campo, São Paulo, Brasil

Emails: apmleme@ieee.org, sgimenez@fei.edu.br, cet@fei.edu.br

Abstract— The multiple objective optimization of the OTA is one of the most studied problems in microelectronics. Obtaining approximations of the Pareto Front, using the known evolutionary algorithm NSGA-II, integrated to SPICE simulator, reveals the relationship between the commitment to the goals often known only intuitively by analog integrated circuit designers. The results of this study suggest that the Multivariate Analysis of Pareto approximations is an important guide to getting more refined designs of OTAs.

Keywords— Evolutionary Electronics, Operational Transconductance Amplifier, Evolutionary Algorithms, Pareto Front, Multiple Objectives, Multivariate Analysis, Microelectronics.

Resumo— A otimização de múltiplos objetivos do OTA é um dos problemas mais estudados em microeletrônica. A obtenção de aproximações da fronteira de Pareto, através do conhecido algoritmo evolucionário NSGA-II, integrado ao simulador SPICE, revela relações de compromisso entre os objetivos conhecidas muitas vezes somente intuitivamente pelos projetistas de circuitos integrados analógicos. Os resultados obtidos neste trabalho sugerem que a Análise Multivariada das aproximações Pareto é um guia importante para a obtenção de projetos de OTA otimizados.

Palavras-chave— Eletrônica Evolucionária, Amplificador Operacional de Transcondutância, Algoritmos Evolucionários, Fronteira de Pareto, Múltiplos Objetivos, Análise Multivariada, Micro Eletrônica.

1 Introdução

A Eletrônica Evolucionária (EE) foi formalmente estabelecida como área de pesquisa em 1997 na Universidade de Napier, Escócia, englobando *Computação Evolucionária e Eletrônica* (Zebulum et al., 2001). As grandes áreas dentro da EE são *Evolução Intrínseca*, ou evolução direta em “hardware” reconfigurável também chamada de “*Evolvable Hardware*” (EHW), e a *Evolução Extrínseca* que consiste na utilização de Algoritmos Evolucionários guiados por *funções de aptidão* obtidas através de simuladores como o SPICE (“*Simulation Program with Integrated Circuit Emphasis*”) (Zebulum et al., 2001).

A abordagem neste trabalho consiste na *Evolução Extrínseca* de um *Amplificador Operacional de Transcondutância* (OTA) cujo esquema é ilustrado na Figura 1. As aproximações das *Fronteiras de Pareto* obtidas são utilizadas para a extração de conhecimentos através de *Análise Multivariada*. Esta é a principal contribuição deste artigo: a utilização das *Fronteiras de Pareto* como meio de extração de conhecimento sobre o comportamento do OTA em diferentes modos de operação por mapeamento estatístico.

Recentemente Deb e Koksalam (2010) sugeriram a utilização de métodos da área de “*Multi-Criteria Decision Making*” (MCDM) em conjunto dos “*Multi-Objective Evolutionary Algorithms*” (MOEA). Os métodos de MCDM permitem a elicitização de preferências entre múltiplos objetivos *a priori*, permitindo a convergência da otimização para uma única solução da *Fronteira de Pareto*, enquanto que os MOEAs clássicos que utilizam *Dominância Pareto* resultam em conjuntos de soluções que representam aproximações mais incompletas da *Fronteiras de Pareto*¹.

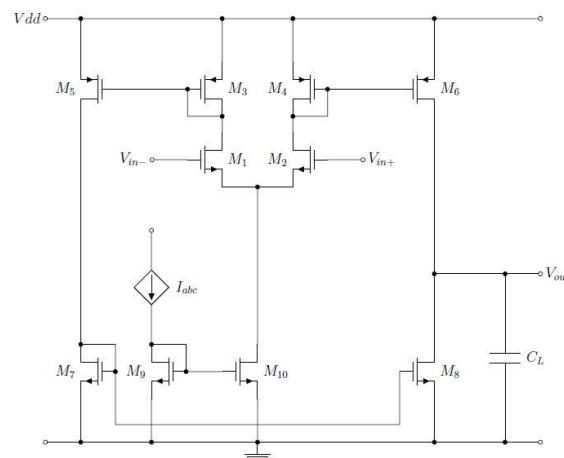


Figura 1: Esquema Elétrico do *Amplificador Operacional de Transcondutância* (OTA) de único estágio e única saída em tecnologia CMOS.

mização para uma única solução da *Fronteira de Pareto*, enquanto que os MOEAs clássicos que utilizam *Dominância Pareto* resultam em conjuntos de soluções que representam aproximações mais incompletas da *Fronteiras de Pareto*¹.

Enquanto obter apenas uma solução possui suas vantagens de ordem prática, o conhecimento tácito nas *Fronteiras de Pareto* muitas vezes é apenas intuitivo aos projetistas de circuitos integra-

¹A grande maioria dos MOEAs utiliza *Dominância Pareto*, onde o processo decisório é realizado *a posteriori* (Coello et al., 2006)

dos (CIs) analógicos mais experientes. As relações de compromisso entre os objetivos e parâmetros do projeto, uma vez explicitadas, podem permitir a construção de novas regras de projeto e abrir novas questões de pesquisa.

2 O Amplificador Operacional de Transcondutância

O OTA, esquematizado na Figura 1, é um amplificador de tensão-corrente caracterizado pela função de transferência ideal $I_{out} = g_m \cdot (V_{in+} - V_{in-})$, onde I_{out} é a corrente de saída, g_m é a transcondutância, V_{in+} e V_{in-} são respectivamente a entrada positiva e a entrada negativa do par diferencial. A corrente de polarização ($I_{abc} \equiv I_{pol}$) é utilizada para ajustar a transcondutância g_m (Schaumann, 2004).

O Projeto do OTA CMOS, conforme Silveira et al. (1996) e Gentinne (1996), requer o dimensionamento das larguras W e comprimentos L dos canais dos MOSFETs (“Transistor de Efeito de Campo Metal-Óxido Semicondutor”) M_1 a M_{10} , sendo que os pares de MOSFETs (M_1 , M_2), (M_3 , M_4), (M_5 , M_6) e (M_7 , M_8) são considerados idênticos neste trabalho. A corrente de polarização ($I_{abc} \equiv I_{pol}$) e tensão de polarização ($V_{bias} \equiv V_{pol}$) do par diferencial também devem ser ajustadas no projeto.

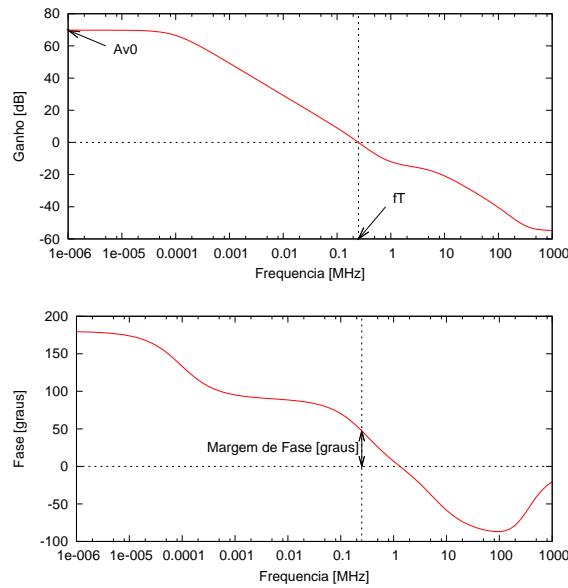


Figura 2: Diagrama de Bode ilustrando a resposta em frequência de um OTA configurado em *Malha Aberta*.

A resposta em frequência típica de um OTA, utilizando-se o modelo de pequenos sinais, é ilustrada pelo Diagrama de Bode da Figura 2. Neste diagrama, estão ilustradas as métricas de desempenho ganho de tensão (A_{v0}) e frequência de ganho de tensão unitário (f_T) e o critério de estabilidade do OTA dado pela Margem de Fase (φ_M). A

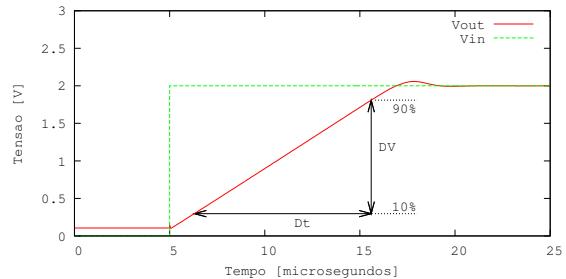


Figura 3: Resposta transiente de um OTA configurado em *Malha Fechada*.

resposta transiente típica de um OTA, utilizando-se o modelo de grandes sinais, é ilustrada na Figura 3, que representa a métrica “Slew Rate” (SR) dada pela máxima variação de tensão $\Delta V/\Delta t$. A métrica de desempenho potência Pwr é dada pela tensão de operação (V_{dd}) multiplicada pela corrente de consumo do OTA, enquanto que a métrica $Area$ é a somatória das áreas de portas dos transistores MOSFETs.

Parâmetro	Min.	Max.
I_{pol}	$0,1\mu A$	$100\mu A$
V_{pol}	$0,7V$	$2,3V$
W_i	$0,5\mu m$	$100\mu m$
L_i	$0,5\mu m$	$100\mu m$
V_{dd}	Fixo: 3 V	
C_L	Fixo: 3 pF	

Tabela 1: Parâmetros de configuração do OTA, onde: $I_{pol} \equiv I_{abc}$ é a corrente de polarização do par diferencial, $V_{pol} \equiv V_{bias}$ a tensão de polarização do par diferencial, W_i é a largura de canal do MOSFET M_i , $i \in 1, \dots, 10$, L_i é o comprimento de canal do MOSFET M_i , $i \in 1, \dots, 10$, V_{dd} é a tensão de alimentação do OTA e C_L é a capacidade de carga.

Objetivo	Min/Max	Unidade
A_{v0}	Maximizar	dB
f_T	Maximizar	MHz
SR	Maximizar	$V/\mu s$
Pwr	Minimizar	mW
$Area$	Minimizar	μm^2

Tabela 2: Objetivos de otimização do OTA, onde: A_{v0} é o Ganhos em malha aberta (Figura 2); f_T é a Frequência de ganho unitário (Figura 2); SR é o “Slew Rate” ou máxima variação de tensão $\Delta V/\Delta t$ (Figura 3); Pwr é a potência dissipada do OTA e $Area$ a área de portas ou somatória das áreas $W_i \cdot L_i$.

Nas Tabelas 1, 2 e 3 tem-se respectivamente os os faixas de valores dos Parâmetros, Objetivos

Restrições
$V_{ds}^i \geq V_{gs}^i + V_{th}^i, \forall M_i$
$45^\circ \leq \varphi_M \leq 75^\circ$
$\left \frac{V_{dd}}{2} - V_{out} \right \leq 0,1 \cdot V_{dd}$
$V_{out} \leq 0,5V, t \leq 0,5\mu s$
$V_{out} \geq 1,5V, t \geq 20\mu s$

Tabela 3: Restrições, onde: Para os MOSFETs M_i , V_{ds} é a tensão entre Dreno e Fonte, V_{gs} é a tensão entre Porta e Fonte e V_{th} é a tensão de Limiar; φ_M é a Margem de Fase; V_{out} é ajustado para a maior excursão do sinal de saída, próximo de $\frac{V_{dd}}{2}$.

e as Restrições de projeto para o problema de otimização do OTA.

3 Otimização Evolucionária do OTA

A otimização do OTA através do NSGA-II consiste na *Busca Direta* dos parâmetros do vetor \mathbf{x} do espaço de decisão Ω mapeados ao vetor \mathbf{y} do espaço de objetivos Λ através da simulação SPICE ($F : \Omega \rightarrow \Lambda$). A representação do cromossomo é o vetor de números reais:

$$\mathbf{x} = [I_{pol}, V_{pol}, W_{1\&2}, L_{1\&2}, \dots, W_{10}, L_{10}]^T, \quad (1)$$

O vetor \mathbf{x} é utilizado para parametrizar um arquivo de simulação SPICE escrito na linguagem NUTMEG (Tuma and Bürgen, 2009). Este arquivo de simulação é configurado para avaliar o OTA nas configurações de *Malha Aberta* e *Malha Fechada* e diferentes análises SPICE no domínio da frequência e do tempo, retornando um vetor \mathbf{y} com a avaliação dos objetivos e o vetor \mathbf{z} com as violações de restrições. Este processo é ilustrado na Figura 4.

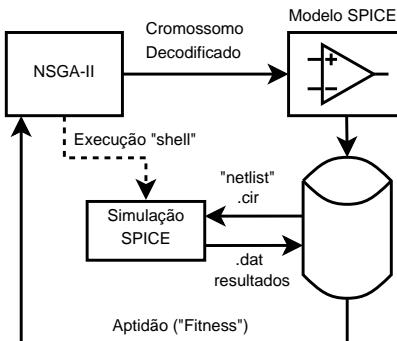


Figura 4: Integração do Simulador Spice ao NSGA-II para o cálculo da aptidão.

Os componentes de \mathbf{y} são os objetivos $[A_{v0}, f_T, SR, Pwr, Area]^T$ e os componentes de \mathbf{z} são as violações das restrições $[SR', V_{out}, \varphi'_M, Sat_{1\&2}, \dots, Sat_{10}]^T$, onde SR' é a violação da janela do Slew Rate (Figura 3), V_{out}

é a violação da tensão de saída em regime contínuo, φ'_M é a violação da Margem de Fase (Figura 2) e $Sat_{1\&2}$ a Sat_{10} são as violações de condição de operação dos transístores MOSFETs na região de saturação.

O NSGA-II utiliza a *Dominância Pareto* (Definição 1) para classificar as soluções por um número de ordem r , onde $r = 1$ representa as soluções não-dominadas da população. A classificação $r = 2$ segue o mesmo critério, excluindo as soluções com $r = 1$ e sucessivamente até a classificação completa da população através do algoritmo “Nondominated Sort” (Deb, 2001).

Definição 1 Dominância Pareto: Um vetor $\mathbf{y} = [y_1, y_2, \dots, y_k]^T$ domina outro vetor $\mathbf{y}' = [y'_1, y'_2, \dots, y'_k]^T$, denotado por $\mathbf{y} \prec \mathbf{y}'$, se e somente se não existe componente vetorial em \mathbf{y}' melhor do que o correspondente em \mathbf{y} e existe pelo menos um componente vetorial em \mathbf{y} melhor do que seu correspondente em \mathbf{y}' (Zitzler et al., 2002).

O segundo critério utilizado pelo NSGA-II é chamado *Distância de Apinhamento* (d) onde as soluções extremas possuem $d = \infty$ e as intermediárias tem o valor do semiperímetro normalizado do hipercubo do espaço de objetivos formado por suas soluções vizinhas (Deb, 2001). Este critério é utilizado para manter a diversidade de soluções.

Os dois critérios compõem o operador de seleção por torneio $<_c$ (Definição 2) (Deb, 2001).

Definição 2 Operador de Seleção por Torneio de Apinhamento ($<_c$): Uma solução i vence o torneio sobre outra solução j se quaisquer das condições abaixo forem verdadeiras:

1. Se a solução i tem melhor classificação Pareto, ou seja: $r_i < r_j$;
2. Se i e j possuem a mesma classificação Pareto, mas i possui melhor distância de apinhamento que j , ou seja: $d_i > d_j$.

Para lidar-se com as restrições do problema do OTA é necessário alterar o critério de dominância. Utiliza-se uma derivação do método de Ray-Tai-Seow (Deb, 2001, p. 308) conforme a (Definição 3).

Definição 3 Dominância Pareto modificada: Uma solução i domina outra solução j se e somente se

1. i satisfaz todas as restrições e j não;
2. i e j satisfazem todas as restrições e $\mathbf{y}_i \prec \mathbf{y}_j$ no espaço de objetivos;
3. i e j não satisfazem uma ou mais restrições e $\mathbf{z}_i \prec \mathbf{z}_j$ no espaço de restrições.

Para as operações genéticas nos cromossomos que utilizam representação em ponto flutuante utiliza-se o *Cruzamento Binário Simulado* (SBX) introduzido por Deb and Agrawal (1994) e a *Mutação Polinomial* introduzida por Deb and Goyal (1996).

Algoritmo 1: “Non-dominated Sorting Genetic Algorithm II”

```

início
    Inicialize aleatoriamente a
    população  $P, |P| = N$ 
    Avalie cada solução  $x_i \in \mathcal{P}$ , obtendo
     $y_i$  e  $z_i$ 
    enquanto  $\neg$ termino faça
        Crie uma população de
        descendentes  $O, |O| = N$  usando
        cruzamento e mutação sobre  $P$ 
        Avalie cada solução  $x_i \in \mathcal{O}$ ,
        obtendo  $y_i$  e  $z_i$ 
         $R \leftarrow P \cup O, |R| = 2N$ 
        ordene  $R$  pelo operador  $<_c$ 
         $P \leftarrow \emptyset$ 
         $P \leftarrow P \cup R^{(i)}, \text{ para } i = 1 \dots N$ 
    Retorne o conjunto de soluções  $P$ 

```

O Algoritmo 1 retorna uma aproximação da *Fronteira de Pareto* (Definições 4 e 5).

Definição 4 Conjunto Pareto Ótimo

$\mathcal{P}^* = \{x \in \Omega | \nexists x' \in \Omega : f(x') \leq f(x)\}$ (Coello et al., 2006).

Definição 5 Fronteira de Pareto Ótima

$\mathcal{PF}^* = \{y = f(x) | \forall x \in \mathcal{P}^*\}$ (Coello et al., 2006).

4 Experimentos e Resultados

O OTA é configurado com $V_{dd} = 3V$ e $C_L = 3pF$. Os modelos de transístores MOSFET utilizados são de tecnologia AMS $0,5\mu m$ SCN05² (MOSIS).

Os parâmetros do NSGA-II utilizados são: probabilidade de cruzamento $p_c = 0.8$, probabilidade de mutação $p_m = 0.07$, fator da distribuição do cruzamento SBX $\eta_c = 20$ e fator da distribuição da mutação polinomial $\eta_m = 12$. O tamanho da população é $N = 200$ e os experimentos são executados por $t = 1000$ gerações, totalizando 200400 soluções geradas³. Os 5 experimentos possuem inicializações diferentes do gerador de números pseudo-aleatórios. Somente as soluções que satisfazem as restrições são preservadas para a análise.

Para avaliar a capacidade de convergência do método proposto, pode-se comparar os resultados obtidos com uma amostragem aleatória de 200400 soluções. Somente as soluções factíveis foram preservadas, onde 6 soluções foram obtidas (Tabela 4). Estima-se que a probabilidade de obter-se uma solução factível ao acaso é $\hat{p} = 0,0000299$ com intervalo de confiança de 95% entre $0,00000598 \leq \hat{p} \leq 0,00005389$ (Hines and

Tabela 4: Resultados do experimento de busca aleatória.

A_{v0} (dB)	f_T (MHz)	SR (V/ μs)	Pwr (mW)	$Area$ (μm^2)
58,78	6,00	12,00	0,15	7940
55,64	3,25	5,55	0,06	11300
45,06	0,98	4,11	0,08	11600
56,51	1,32	2,56	0,17	13300
54,18	1,75	3,43	0,15	15200
49,04	1,60	3,96	0,25	14100

Montgomery, 1990, p. 273–274). Todos os 5 experimentos com NSGA-II apresentaram 100% da população de pais $N = 200$ satisfazendo a todas restrições próximas da centésima geração. A proporção da população com $r = 1$ também sobe rapidamente após atingir 100% de satisfação das restrições, sendo o resultado final um conjunto de 200 soluções não-dominadas ($r = 1$).

Os limites mínimos e máximos das aproximações das fronteiras de pareto obtidas nos 5 experimentos com NSGA-II são apresentados na Tabela 5.

Objetivo	Mínimo	Máximo
A_{v0} (dB)	20,2411	70,0856
f_T (MHz)	0,118518	924,088
SR (V/ μs)	0,09385	2813,33
Pwr (mW)	0,000658	39,4558
$Area$ (μm^2)	5,324	41378,4

Tabela 5: Limites máximos e mínimos obtidos para os 5 experimentos.

A comparação entre os conjuntos de soluções obtidos não é trivial. Conforme demonstrado por Zitzler et al. (2002) a comparação entre aproximações da *Fronteira de Pareto* requer pelo menos tantos indicadores unários quantos forem os objetivos e uma interpretação destes indicadores. Devido à complexidade em determinar qual a melhor aproximação, a prática usual é utilizar uma representação gráfica das *Fronteiras de Pareto* como a Figura 5 e alguns indicadores, sendo pelo menos um destes binário. Esta figura mostra a projeção das fronteiras de pareto para cada par de objetivos. As sub-figuras são simétricas a partir da diagonal. Os indicadores para a comparação de podem ser:

Hipervolume (Deb, 2001), que é uma métrica unária do volume dominado pelo conjunto \mathcal{A} . Para evitar o efeito de magnitudes diferentes entre os objetivos, o espaço de objetivos deve ser normalizado, ou seja,

$$I_{\mathcal{H}}(\mathcal{A}) = \bigcup_{i=1}^{|\mathcal{A}|} v_i, \quad (2)$$

onde v_i é o volume da área dominada por $y_i \in \mathcal{A}$;

²<http://www.mosis.com/cgi-bin/cgiwrap/umosis/swp/params/ami-c5/t99j-params.txt>

³400 soluções da geração 0 mais 200 soluções geradas a cada geração entre as gerações 1 e 1000

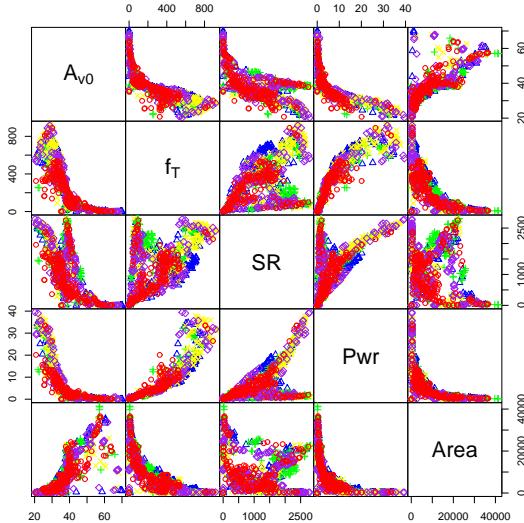


Figura 5: Projeções das aproximações da Frontera de Pareto resultantes dos 5 experimentos com NSGA-II para cada par de objetivos: A_{vo} [dB], f_T [MHz], SR [V/ μ s], Pwr [mW] e $Area$ [μ m 2].

Espalhamento (Deb, 2001), que é uma métrica unária da uniformidade do espalhamento das soluções,

$$I_\Delta(\mathcal{A}) = \frac{\sum_{j=1}^m d_j^e + \sum_{i=1}^{|\mathcal{A}|} |d_i - \bar{d}|}{\sum_{j=1}^m d_j^e + |\mathcal{A}| \bar{d}}, \quad (3)$$

onde o parâmetro d_j^e é a distância entre os vetores extremos \mathcal{A} correspondentes ao j -ésimo objetivo. O parâmetro \bar{d} é a média das distâncias entre as soluções $\mathbf{y}_i \in \mathcal{A}$.

Cobertura do Conjunto (Deb, 2001), que é uma métrica binária da proporção de soluções $\mathbf{y} \in \mathcal{B}$ fracamente dominadas por pelo menos uma solução $\mathbf{y} \in \mathcal{A}$,

$$I_C(\mathcal{A}, \mathcal{B}) = \frac{|\{y^{(b)} \in \mathcal{B} | \exists y^{(a)} \in \mathcal{A} : y^{(a)} \preceq y^{(b)}\}|}{|\mathcal{B}|}, \quad (4)$$

podemos afirmar que uma aproximação \mathcal{A} é melhor do que \mathcal{B} quando $I_C(\mathcal{A}, \mathcal{B}) = 1$ e $I_C(\mathcal{B}, \mathcal{A}) < 1$.

Os resultados são apresentados nas Tabelas 6 e 7, sugerindo que as aproximações dos 5 experimentos NSGA-II são equivalentes.

Experimento	I_H	I_Δ
NSGA-II/1	0,135	0,064
NSGA-II/2	0,157	0,045
NSGA-II/3	0,151	0,051
NSGA-II/4	0,169	0,050
NSGA-II/5	0,160	0,059
Aleatório/0	1,68E-5	0,036

Tabela 6: Hipervolume da região dominada pelos 5 experimentos.

I_C	1	2	3	4	5	0
1	#	0,020	0,051	0,005	0	0
2	0,114	#	0,097	0,021	0,061	0,5
3	0,098	0,076	#	0,005	0,061	0
4	0,212	0,192	0,240	#	0,102	0,5
5	0,109	0,061	0,138	0,036	#	0,17
0	0	0	0,005	0,005	0	#

Tabela 7: Cobertura de Conjunto entre as aproximações da Fronteira de Pareto. Experimentos NSGA-II 1 a 5, Experimento Aleatório 0.

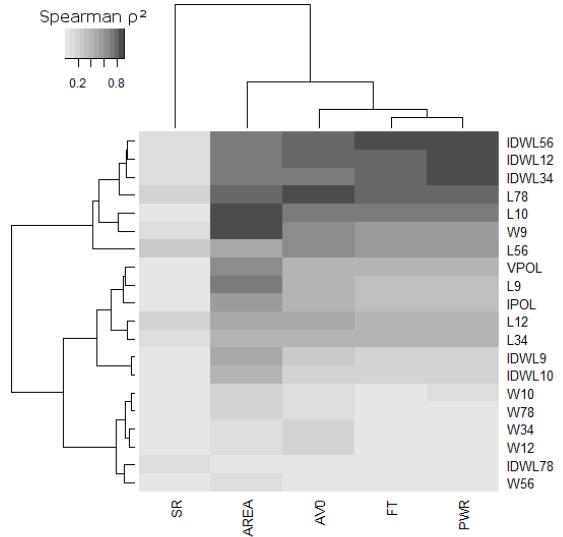


Figura 6: “Heatmap” e dendrogramas da correlação de Spearman entre os parâmetros e os objetivos. $IDWL$ [$I_{ds}/(W/L)$] é a medida de inversão do MOSFET.

Adicionalmente, através da correlação de Spearman⁴, o “Heatmap” (Hastie et al., 2003) da Figura 6 é calculado utilizando-se as *Fronteiras de Pareto*. Os dendrogramas lateral e superior agrupam hierarquicamente os parâmetros e objetivos que possuem maior correlação quadrática (ρ^2). Os gradientes escuros mostram maior correlação entre parâmetros e objetivos e os gradientes claros menor correlação. Apesar da correlação de Spearman não ser prova de relação causal, este tipo de mapeamento estatístico pode ser utilizado como guia de configuração do OTA apresentado neste artigo.

O “Slew Rate” (SR) possui uma baixa correlação com os demais objetivos e parâmetros e observado-se a projeção das *Fronteiras de Pareto* (Figura 5), nota-se que existe uma relação bimodal de SR com os demais objetivos, justificando a baixa correlação. Este resultado deve ser abordado mais detalhadamente em trabalhos subse-

⁴A correlação de Spearman revela relações de Monotonicidade, enquanto que a correlação de Pearson revela relações Lineares.

quentes. Outra observação válida é a alta correlação dos parâmetros de inversão de alguns transistores MOSFETs [$I_{ds}/(W/L)$] com os objetivos, sugerindo que os resultados obtidos neste artigo corroboram com a metodologia g_m/I_{ds} de Silveira et al. (1996).

5 Conclusões

A Eletrônica Analógica é “considerada por muitos uma forma de arte ao invés de uma ciência” (O. Aaserud and I. Ring Nielsen (1995) apud Koza et al. (1999, p. 383)), requerendo intuição, experiência e grande conhecimento. O OTA é um exemplo desta complexidade, como encontramos nas abordagens de Stefanović and Kayal (2008), Silveira et al. (1996), Gimenez et al. (2005) na área de Microeletrônica e nos resultados apresentados neste trabalho.

As possibilidades de análise dos dados obtidos são tão extensas quanto o volume de dados gerados nos experimentos, não podendo ser completamente exploradas na extensão deste artigo. Os resultados obtidos, entretanto, sugerem que a Análise Multivariada das Fronteiras de Pareto é um guia importante para a investigação de relações de otimalidade em modelos complexos como o OTA, revelando relações que são muitas vezes desconhecidas por projetistas experientes.

Referências

- Coello, C. A. C., Lamont, G. B. and Veldhuizen, D. A. V. (2006). *Evolutionary Algorithms for Solving Multi-Objective Problems (Genetic and Evolutionary Computation)*, Springer-Verlag New York, Inc., Secaucus, NJ, USA.
- Deb, K. (2001). *Multi-Objective Optimization Using Evolutionary Algorithms*, 1 edn, Wiley.
- Deb, K. and Agrawal, R. B. (1994). Simulated Binary Crossover for Continuous Search Space, *Technical report*, Departement of Mechanical Engineering, Indian Institute of Technology, Kanpur, India.
- Deb, K. and Goyal, M. (1996). A combined genetic adaptive search (geneas) for engineering design, *Computer Science and Informatics* **26**: 30–45.
- Deb, K. and Koksalan, M. (2010). Guest editorial special issue on preference-based multiobjective evolutionary algorithms, *Evolutionary Computation, IEEE Transactions on* **14**(5): 669 –670.
- Gentinne, B. (1996). *A study of the potential of SOI technology for analog applications*, PhD thesis, Université catholique de Louvain.
- Gimenez, S. P., Pavanello, M. A., ao Antonio Martino, J. and Flandre, D. (2005). Potential of Improved Gain in Operational Transconductance Amplifier using 0.5 mm graded-channel SOI nMOSFET for Applications in the Gigahertz Range, *Microelectronics Technology and Devices - SBMICRO 2005*, Vol. 2005-8, Microelectronics Technology and Devices - SBMICRO 2005, NJ, USA : The Electrochemical Society, Inc., pp. 502–511.
- Hastie, T., Tibshirani, R. and Friedman, J. H. (2003). *The Elements of Statistical Learning*, 2 edn, Springer.
- Hines, W. W. and Montgomery, D. C. (1990). *Probability and Statistics in Engineering and Management Science*, 3 edn, John Wiley & Sons.
- Igel, C., Heidrich-meisner, V., Glasmachers, T. and Sonnenburg, S. (2008). Shark, *Journal of Machine Learning* **9**.
- Koza, J. R., Bennett III, F. H., Andre, D. and Keane, M. A. (1999). *Genetic Programming III: Darwinian Invention and Problem Solving*, Morgan Kaufmann.
- R Development Core Team (2011). *R: A Language and Environment for Statistical Computing*, R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0.
- Schaumann, R. (2004). *The Electrical Engineering Handbook*, Elsevier, chapter Active Filters, pp. 127–138.
- Silveira, F., Flandre, D. and Jespers, P. G. A. (1996). A g_m/i_d based methodology for the design of cmos analog circuits and its application to the synthesis of a silicon-on-insulator micropower ota, *IEEE Journal of Solid-State Circuits* **31**(9).
- Stefanović, D. and Kayal, M. (2008). *Structured Analog CMOS Design*, Springer.
- Tuma, T. and Bürgen, A. (2009). *Circuit Simulation with SPICE OPUS: Theory and Practice*, 1st edn, Birkhäuser Basel Berlim.
- Zebulum, R. S., Pacheco, M. A. and Vellasco, M. M. B. (2001). *Evolutionary Electronics: Automatic Design of Electronic Circuits and Systems by Genetic Algorithms*, CRC Press, Inc., Boca Raton, FL, USA.
- Zitzler, E., Thiele, L., Laumanns, M., Fonseca, C. M. and Grunert da Fonseca, V. (2002). Performance Assessment of Multiobjective Optimizers: An Analysis and Review, *Technical Report 139*, Computer Engineering and Networks Laboratory, ETH Zurich.