



Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciências

Faculdade de Engenharia

Yuri Campos Bacelar

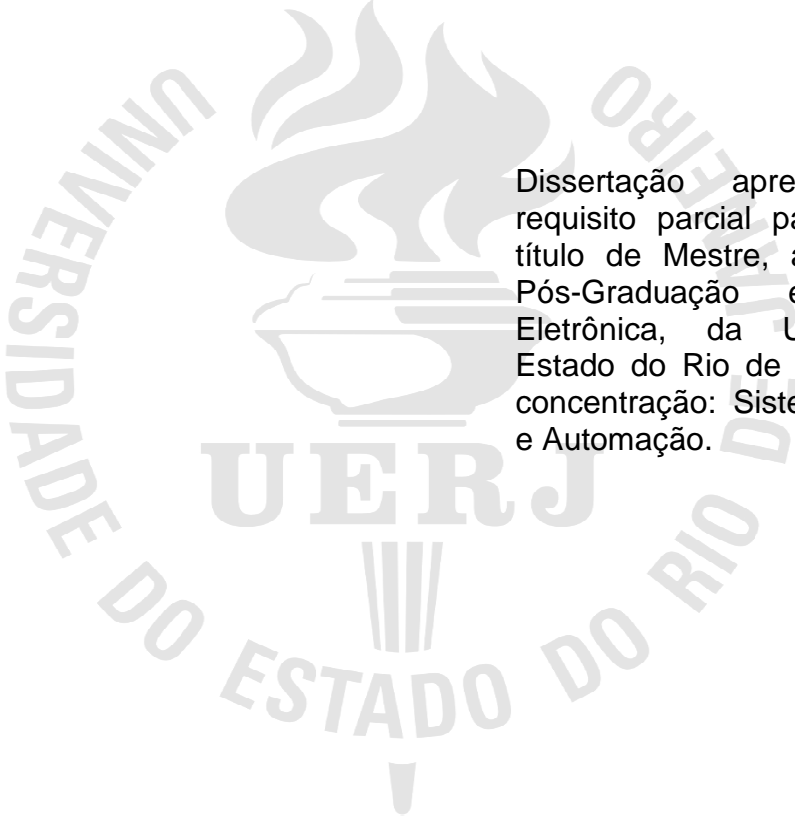
**Evolução de Circuitos Eletrônicos Analógicos com Avaliação de
Múltiplos Objetivos baseada em Sistema Fuzzy**

Rio de Janeiro

2017

Yuri Campos Bacelar

**Evolução de Circuitos Eletrônicos Analógicos com Avaliação de Múltiplos
Objetivos baseada em Sistema Fuzzy**



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Orientador: Prof. Dr. José Franco Machado do Amaral

Rio de Janeiro

2017

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

B116 Bacelar, Yuri Campos.
Evolução de circuitos eletrônicos analógicos com avaliação de múltiplos objetivos baseada em sistemas fuzzy / Yuri Campos Bacelar. – 2017.
100f.

Orientador: José Franco Machado do Amaral.
Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.

1. Engenharia Eletrônica - Teses. 2. Circuitos eletrônicos - Teses. 3. Sistemas difusos - Teses. 4. Algoritmos genéticos - Teses. I. Amaral, José Franco Machado do. II. Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia. III. Título.

CDU 007.52

Bibliotecária: Júlia Vieira – CRB7/6022

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta tese, desde que citada a fonte.

Assinatura

Data

Yuri Campos Bacelar

**Evolução de Circuitos Eletrônicos Analógicos com Avaliação de Múltiplos
Objetivos baseada em Sistema Fuzzy**

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Aprovado em 20 de dezembro de 2017.

Banca Examinadora:

Prof. Dr. José Franco Machado do Amaral (Orientador)
Faculdade de Engenharia – UERJ

Prof. Dr. Pedro Henrique Gouvêa Coelho
Faculdade de Engenharia – UERJ

Prof. Dr. Ricardo Tanscheit
Departamento de Engenharia Elétrica – PUC-RJ

Rio de Janeiro

2017

DEDICATÓRIA

Aos meus pais e à minha namorada.

AGRADECIMENTOS

Agradeço de modo especial aos meus pais pela educação que me proporcionaram, por todo amor, apoio e carinho.

Ao meu orientador, Prof. José Franco Machado do Amaral, pela orientação no desenvolvimento deste trabalho ao longo desses anos.

Aos professores do Programa de Pós-Graduação em Engenharia Eletrônica por compartilharem seus conhecimentos.

Aos amigos do mestrado pelo companheirismo e apoio.

Aos membros da banca examinadora pela disponibilidade e contribuição.

À UERJ e ao PEL que me proporcionaram a oportunidade de realizar o mestrado.

A todos aqueles que contribuíram direta e indiretamente durante o período de execução deste trabalho.

A mente que se abre a uma nova ideia
jamais voltará ao seu tamanho original.

Albert Einstein

RESUMO

BACELAR, Yuri Campos. *Evolução de circuitos eletrônicos analógicos com avaliação de múltiplos objetivos baseada em sistema fuzzy*. 2017. 100f. Dissertação (Mestrado em Engenharia Eletrônica) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2017.

Este trabalho apresenta a aplicação de um modelo híbrido para viabilizar a evolução de circuitos eletrônicos, baseando-se em um algoritmo genético e utilizando um sistema fuzzy para avaliação de múltiplos objetivos. A avaliação de aptidão tradicional dos algoritmos genéticos é modificada, de forma que um sistema fuzzy é efetivamente o responsável pela avaliação, sendo assim capaz de agregar os diversos objetivos do projeto eletrônico e gerando um valor de aptidão para cada circuito da população. O modelo proposto apresenta uma forma mais simples e interpretável de inserir preferências e/ou especificações, pois utiliza a lógica fuzzy. Tais especificações são inseridas antes da evolução do circuito, garantindo que ela seja guiada na direção desejada, evitando que o projetista tenha que efetuar ao final do processo a escolha da solução mais adequada. Optou-se por uma implementação baseada puramente em simulação de modelos de circuitos, possibilitando um ambiente flexível para estudo de casos e viabilizando futuras aplicações. Evoluções de circuitos eletrônicos analógicos em áreas de aplicações distintas são avaliadas através de simulações computacionais. Entre os estudos de casos são incluídos o projeto de um simples divisor de tensão, o projeto de circuitos de funções de pertinência para sistemas fuzzy e o projeto de controladores PID analógicos. O trabalho desenvolvido para evolução, avaliação e implementação apresentou bom desempenho nos estudos de casos analisados, podendo ser utilizado como base para novas aplicações e implementações de outros circuitos.

Palavras-chave: Circuitos Eletrônicos; Sistemas fuzzy; Algoritmos genéticos; Otimização multiobjetivo; Sistemas híbridos.

ABSTRACT

BACELAR, Yuri Campos. *Multiple objective analog electronic circuits evolution based on fuzzy system evaluation*. 2017. 100f. Dissertação (Mestrado em Engenharia Eletrônica) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2017.

This work presents an evolutionary model to enable the evolution of analog electronic circuits. It is based on a genetic algorithm and employs a fuzzy system in the evaluation process of multiple objectives. The traditional evaluation method of genetic algorithms is replaced by a fuzzy system is executed during the evaluation process, aggregating the many objectives of the electronic design and generating a fitness for each individual. The proposed model presents a simpler and more interpretable way to insert preferences specifications. These specifications are introduced before the circuit evolution process, ensuring that the evolution is guided in the desired direction and thus avoiding the need of a designer intervention to choose the most appropriate circuit. A simulation based on models of the circuits allows a flexible environment for case studies and future applications. Case studies in different application areas are analyzed: a voltage divider design, membership functions for fuzzy systems and evolutions of analog PID controllers. The work developed for evolution, evaluation and implementation presented good performance in the case studies and can be used as a basis for new applications and for other electronic circuit designs.

Keywords: Fuzzy systems; Genetic algorithms; Multiobjective optimization; Hybrid systems.

LISTA DE FIGURAS

Figura 1 – Variável linguística “Temperatura”.....	21
Figura 2 – Exemplo com os operadores máximo e mínimo.	22
Figura 3 – Sistema de inferência fuzzy (SIF).....	23
Figura 4 – Curva de compromisso entre acurácia e complexidade (ISHIBUCHI, 2007).	25
Figura 5 – Fluxograma de execução de um algoritmo genético.	26
Figura 6 - Cromossomo com representação binária.	27
Figura 7 – Operador <i>crossover</i> de dois pontos.	29
Figura 8 – Operador de mutação simples.	29
Figura 9 – Conceito básico de Evolvable Hardware (HIGUCHI et al., 1999).	32
Figura 10 - Representação do espaço de decisão e espaço objetivo (FONSECA, 2017).	40
Figura 11 – Ilustração do conceito de dominância de Pareto (ARROYO, 2002).	42
Figura 12 - Exemplo da localização e proporção entre soluções dominadas, não dominadas e indiferentes (FONSECA, 2017).	43
Figura 13 – Representação do espaço de soluções para um problema bi-dimensional (ANDERSSON, 2000).	43
Figura 14 – Fronteiras ótimas de Pareto (DEB, 2001).	44
Figura 15 – Etapas de execução do algoritmo genético.	51
Figura 16 – Modelo de avaliação da aptidão com Sistema Agregador Fuzzy.	53
Figura 17 – Funções de pertinência base para entradas.	54
Figura 18 – Funções de pertinência base para saída.	55
Figura 19 – Diagrama de Blocos.	57
Figura 20 – Circuito do divisor de tensão.	58
Figura 21 – FPs das entradas do agregador.	60
Figura 22 – FPs da Aptidão.	60
Figura 23 – V_o X V_i para a Função de Pertinência “S”.....	63
Figura 24 – Topologia selecionada para a Função de Pertinência “S”.....	64
Figura 25 – Evolução do circuito da FP “S”.....	67
Figura 26 – V_o X V_i para a Função de Pertinência “Z”.....	68

Figura 27 – Topologia selecionada para o Circuito da FP “Z”	69
Figura 28 – Evolução para o Circuito da FP “Z”	71
Figura 29 – Vo X Vi para o Circuito da FP Triangular	72
Figura 30 – Topologia para evolução do Circuito da FP Triangular	73
Figura 31 – Resposta de um sistema de controle.	77
Figura 32 – Função de pertinência da variável de entrada Overshoot.....	78
Figura 33 - Função de pertinência da variável de entrada Tempo de Subida.	78
Figura 34 - Função de pertinência da variável de entrada Tempo de Acomodação.	79
Figura 35 – Topologia do Circuito base para os Controladores PID analógicos	80
Figura 36 – Cromossomo para Evolução dos Controladores PID	81
Figura 37 - Diagrama do sistema de controle de 2ª ordem.	82
Figura 38 - Resposta a um degrau unitário pelas três técnicas analisadas.	84
Figura 39 – Controlador analógico PID evoluído.....	85
Figura 40 – Diagrama do sistema de controle de 3ª ordem.	85
Figura 41 – Resposta a um degrau unitário pelas quatro técnicas de sintonia.	87
Figura 42 – Circuito controlador PID Analógico para a planta de 3ª ordem	88
Figura 43 – Diagrama do servossistema de um motor de corrente contínua (OGATA, 2003).	89
Figura 44 – Diagrama do sistema de controle para servossistema do motor CC.....	91
Figura 45 – Resposta ao degrau unitário obtida pelos controladores.	93
Figura 46 – Circuito do controlador PID Analógico para o controle do motor CC.....	93

LISTA DE TABELAS

Tabela 1 – Modelo base para regras de minimização.....	56
Tabela 2 – Valores de R1, R2, Vi e Vo para Circuito divisor	59
Tabela 3 – Parâmetros os Algoritmo Genético para o Circuito Divisor.....	59
Tabela 4 – Regras para minimização dos 2 objetivos do Circuito Divisor	61
Tabela 5 – Resultados para o Circuito Divisor de Tensão	62
Tabela 6 – Valores de R1, R2, R3 e Vi para a FP “S”	65
Tabela 7 – Parâmetros dos Algoritmos Genéticos	65
Tabela 8 – Matriz de Regras para Circuito FP “S”	66
Tabela 9 – Resultados para o circuito da FP “S”	67
Tabela 10 – Valores de R1-R4 e Vi.....	70
Tabela 11 – Parâmetros para os AGs de evolução do circuito para FP “Z”	70
Tabela 12 – Resultados para o circuito da FP “Z”	72
Tabela 13 – Valores a serem evoluídos para o Circuito da FP Triangular	74
Tabela 14 – Parâmetros do AG para evolução da FP Triangular.....	75
Tabela 15 – Resultados para o circuito da FP Triangular	75
Tabela 16 – Regras do agregador fuzzy para ajuste de controladores.	79
Tabela 17 – Parâmetros de evolução do AG para sistemas de controle.....	82
Tabela 18 – Comparação de ganhos para planta de 2ª ordem.....	83
Tabela 19 – Comparação dos parâmetros de avaliação para planta de 2ª ordem....	83
Tabela 20 – Comparação de ganhos para planta de 3ª ordem.....	86
Tabela 21 – Comparação dos parâmetros de avaliação para planta de 3ª ordem....	86
Tabela 22 – Comparação dos ganhos PID para planta do motor CC.	92
Tabela 23 – Comparação entre os controladores PID para planta do motor CC.	92

LISTA DE ABREVIATURAS E SIGLAS

AG	Algoritmo Genético
BR	Base de Regras
CC	Corrente contínua
FP	Função de Pertinência
GAOT	<i>Genetic Algorithm Optimization Toolbox</i>
GPU	<i>Graphics Processing Unit</i>
GPGPU	<i>General Purpose Graphics Processing Unit</i>
Kd	Ganho derivativo
Ki	Ganho integral
Kp	Ganho proporcional
MATLAB	<i>Matrix Laboratory</i>
MSE	<i>Mean Squared Error</i>
PID	Proporcional Integral Derivativo
POM	Problema de Otimização Multiobjetivo
RMSE	<i>Root Mean Squared Error</i>
SF	Sistema Fuzzy
SFBR	Sistema Fuzzy baseado em regras
SFG	Sistemas Fuzzy Genéticos
SIF	Sistema de Inferência Fuzzy

SUMÁRIO

INTRODUÇÃO	14
1 SISTEMAS FUZZY E ALGORITMOS GENÉTICOS	19
1.1 Sistemas Fuzzy.....	19
1.2 Algoritmos Genéticos	25
2 ELETRÔNICA EVOLUCIONÁRIA	31
2.1 Apresentação.....	31
2.2 Tipo de Projeto	33
2.3 Natureza do Projeto.....	34
2.4 Tipo de Evolução.....	35
2.4.1 Evolução Intrínseca.....	36
2.4.2 Evolução Extrínseca.....	37
3 AVALIAÇÃO DE MÚLTIPLOS OBJETIVOS	39
3.1 Conceito de Dominância de Pareto	41
3.2 Métodos de Avaliação de Múltiplos Objetivos.....	45
3.2.1 Métodos sem preferência	45
3.2.2 Métodos <i>a-priori</i>	46
3.2.2.1 Agregação de objetivos	46
3.2.2.2 Lógica Fuzzy	47
3.2.3 Métodos <i>a-posteriori</i>	48
3.2.3.1 Agregação de objetivos (múltiplas execuções)	48
3.2.3.2 Algoritmos evolucionários multiobjetivo.....	48
3.2.4 Métodos Interativos	49
4 IMPLEMENTAÇÃO DO AMBIENTE EVOLUTIVO	50
4.1 Características.....	51
4.2 Sistema Agregador Fuzzy.....	53
4.3 Evolução de Circuitos Eletrônicos	57
5 ESTUDOS DE CASOS	58
5.1 Circuito divisor de tensão	58
5.2 Circuitos para Funções de Pertinência	62
5.2.1 Função de Pertinência “S”	63

5.2.2 Função de Pertinência “Z”	68
5.2.3 Função de Pertinência Triangular	72
5.3 Circuitos de Controladores PID Analógicos	76
5.3.1 Planta de 2ª ordem.....	82
5.3.2 Planta de 3ª ordem.....	85
5.3.3 Motor CC.....	88
6 CONSIDERAÇÕES FINAIS	94
6.1 Conclusões	94
6.2 Trabalhos futuros.....	95
REFERÊNCIAS.....	96

INTRODUÇÃO

A chamada Eletrônica Evolucionária foi concebida em 1997 e teve origem no desejo de se formalizar um nome para esta nova área de pesquisa que aplicava Algoritmos Evolucionários no desenvolvimento de circuitos eletrônicos. Abrange os desenvolvimentos e assuntos relacionados a uso de Computação Evolucionária no projeto de circuitos eletrônicos (SALAZAR & MESQUITA, 2000) (ZEBULUM et al., 2001).

A Eletrônica Evolucionária viabiliza o desenvolvimento de práticas, métodos, algoritmos e estruturas de software e/ou hardware que nos permitam evoluir na concepção de circuitos mais robustos. Esta terminologia abrange um amplo campo de pesquisa de utilização de algoritmos evolutivos em otimização e síntese de circuitos eletrônicos.

Outro ponto de interesse é a crescente demanda pela síntese de circuitos analógicos mais complexos, para interagir com o meio ambiente, e a necessidade de projetá-los com mais rapidez para o mercado (AMARAL et al., 2007; SÁ, 2009; OTERO et al., 2011). Isto impõe práticas de projeto mais dinâmicas e que possam gerar produtos em tempo cada vez menor (LOHN et al., 1999).

Devido aos bons resultados obtidos com a utilização das diversas técnicas de inteligência computacional, o número de pesquisas relacionadas vem crescendo ainda mais nos últimos anos. Além disso, a área de sistemas inteligentes é bastante ampla e abrange diversas aplicações (COELHO et al., 2017)(SANTOS, 2016) (FIGUEIREDO et al., 2014) (SANTOS et al., 2012).

Os sistemas fuzzy são baseados na lógica fuzzy e são amplamente utilizados, especialmente em sistemas de controle e em modelos de apoio a decisão. Além disso, existem diversas aplicações relacionadas na literatura, como, por exemplo, na área de saúde e estudo da locomoção humana, em processamento de sinais da fala, no reconhecimento de informações e emoções, em economia e em sistemas de roteamento (LUCA et al., 2015). Sua característica de exprimir o comportamento de inferência humano possibilita um alto nível de compreensão, sendo a interpretabilidade um ponto forte dos sistemas fuzzy.

Dentre os pontos geralmente abordados na área de sistemas inteligentes, um ponto importante é a otimização, que consiste na busca da melhor solução para um dado problema. Neste ponto, os algoritmos evolutivos são uma técnica de inteligência computacional usualmente utilizada devido à sua grande capacidade de busca. A otimização em algoritmos evolutivos consiste em tentar várias soluções e utilizar a informação obtida neste processo de forma a encontrar soluções cada vez melhores (LACERDA et al., 1999).

Inicialmente, a grande concentração de esforços na área de otimização consistiu em entender, desenvolver e aplicar métodos para a otimização de uma única função objetivo. No entanto, grande parte dos problemas reais de otimização, como em um projeto eletrônico ou em ajustes de componentes em sistemas eletrônicos, envolve objetivos múltiplos e não se pode aplicar a ideia de otimizar cada objetivo (especificação) de maneira isolada. Cada objetivo (especificação) tem seu grau de importância e muitas vezes os objetivos são conflitantes entre si, ou seja, a melhora de um objetivo provoca um pior resultado em outro (OLIVEIRA, 2005).

Em situações cotidianas é comum encontrar contextos que apresentam diversos objetivos. Por exemplo, em um meio industrial, geralmente, busca-se a maximização da qualidade de um produto ao mesmo tempo em que o custo deve ser minimizado.

Motivação

Atualmente, existem diversas técnicas e algoritmos computacionais desenvolvidos para aplicação em problemas de otimização multiobjetivo (POM) motivados pela vasta área de aplicação. Grande número de trabalhos mostram bons resultados obtidos ao longo dos anos neste campo (FONSECA et al., 1995) (ALTINOZ et al., 2015) (JIANG et al., 2016).

As metodologias mais utilizadas incluem o uso de algoritmos genéticos e são baseadas no conceito da otimalidade de Pareto. Tal abordagem compreende uma fronteira com diversas soluções consideradas “ótimas” em relação aos objetivos analisados. Esta metodologia é caracterizada por ter uma articulação a-posteriori, ou

seja, o processo de busca é executado de forma autônoma, e após a obtenção das soluções, um especialista deverá realizar uma escolha para decidir qual é a melhor solução para ser empregada ao problema. O processo de escolha da solução considerada aceitável, com um grande número de possibilidades e variáveis envolvidas, não é uma tarefa trivial e requer experiência e conhecimento do especialista. Desta forma, a articulação de preferências do projetista feita a-priori, ou seja, antes da execução do algoritmo, e a utilização de uma técnica capaz de traduzir as preferências de forma mais simples e compreensível tornaram-se motivações para pesquisa e aplicação neste trabalho.

A proposta deste trabalho para o projeto de circuitos eletrônicos visa modificar a forma de avaliação tradicional de um algoritmo genético para possibilitar a avaliação de múltiplos objetivos. Para isso, foi escolhido utilizar um sistema fuzzy que agrega os diversos objetivos (AMARAL, 2003)(FONSECA, 2017). O uso de sistemas fuzzy viabiliza avaliar simultaneamente todos os objetivos, integrando as preferências do usuário em relação a cada objetivo e a cada situação. Tal característica é uma vantagem em relação aos métodos multiobjetivos baseados na otimalidade de Pareto, pois este tipo de modelo não necessita da interferência do usuário para escolha da melhor solução ao final do processo, visto que as preferências são inseridas antes da evolução de forma mais simples e interpretável através da lógica fuzzy e assim o processo de evolução é guiado na direção das preferências ou especificações pré-estabelecidas.

A partir dos fatos acima, este trabalho pretende contribuir na evolução de circuitos com a aplicação de uma ferramenta de otimização baseada em algoritmos genéticos com avaliação multiobjetivo que utiliza um sistema de inferência fuzzy como agregador de objetivos. Tal ferramenta apresenta a vantagem de não necessitar de intervenção do projetista ao final do processo de evolução para a escolha do circuito mais adequado, pois o método de avaliação utilizando a lógica fuzzy permite inserir as especificações do circuito de forma mais simples e interpretável quando comparado a outros métodos de otimização baseados em algoritmos genéticos.

Objetivos

A proposta deste trabalho é o estudo sobre a aplicação de um modelo evolucionário, que utiliza algoritmos genéticos com a capacidade de avaliação de múltiplos objetivos baseada em um sistema fuzzy, para otimização de circuitos eletrônicos.

O foco principal é a aplicação de um modelo de avaliação capaz de considerar a otimização de mais de um objetivo no processo de evolutivo, de modo que as preferências ou especificações do projeto sejam inseridas no início do processo de uma forma mais simples e interpretável. Para isso, o método proposto para avaliação multiobjetivo utiliza um sistema fuzzy para agregar os objetivos.

A técnica é avaliada em um ambiente puramente baseado em simulação que é utilizado para o projeto dos circuitos eletrônicos.

Estrutura da dissertação

Esta dissertação está dividida em seis capítulos.

No primeiro capítulo apresenta de forma sucinta os conceitos básicos de Sistemas Fuzzy e de Algoritmos Genéticos visando introduzir estes tópicos fundamentais do trabalho.

O capítulo 2 apresenta importantes conceitos relativos à Eletrônica Evolucionária, que são fundamentais para a compreensão deste trabalho.

O capítulo 3 aborda conceitos básicos relacionados aos problemas multiobjetivos e alguns métodos tradicionais de otimização multiobjetivo.

O capítulo 4 apresenta as características do modelo híbrido aplicado para avaliação de problemas multiobjetivos baseado em um sistema de inferência fuzzy, apresentando sua arquitetura e suas características aplicadas na evolução de circuitos eletrônicos.

No capítulo 5 são apresentados os estudos de casos desenvolvidos, as considerações e os resultados obtidos. Entre os estudos de casos são incluídos projetos: de um simples divisor de tensão, de circuitos de funções de pertinência para sistemas fuzzy e projetos de controladores PID analógicos.

Finalmente, a conclusão deste trabalho é apresentada no capítulo 6 juntamente com sugestões de trabalhos futuros.

1 SISTEMAS FUZZY E ALGORITMOS GENÉTICOS

A inteligência computacional é uma área de pesquisa que trata de forma abrangente sistemas complexos e possui grande importância na atualidade em diversos campos de aplicação (EREMIA et al., 2016) (LABATI et al., 2016) (NEOCLEOUS et al., 2016). Ela engloba as redes neurais artificiais, a computação evolutiva e os sistemas fuzzy, além de diversas outras técnicas, como, a inteligência coletiva, os sistemas imunológicos artificiais, dentre outras.

Os sistemas fuzzy são atualmente utilizados na resolução de diversos tipos de problemas e têm demonstrado ao longo dos anos a sua eficiência em diferentes aplicações. Eles são capazes de representar situações reais em uma linguagem natural e interpretável. No entanto, a construção de sistemas fuzzy pode ser difícil em alguns casos em que não existe um conhecimento prévio e amplo do comportamento do sistema, dificultando a obtenção da base de regras e das funções de pertinência.

A partir desta necessidade, a união de técnicas de inteligência computacional, como redes neurais e algoritmos genéticos, com sistemas fuzzy tem se mostrado eficiente, pois integra a capacidade de aprendizado aos sistemas fuzzy. Estes modelos são chamados de sistemas híbridos.

Existem diferentes formas de sistemas híbridos fuzzy-genéticos. A utilização de sistemas fuzzy no processo de avaliação de algoritmos genéticos é um exemplo de hibridização e é abordada mais detalhadamente no capítulo 4 deste trabalho.

1.1 Sistemas Fuzzy

A lógica nebulosa ou lógica fuzzy é uma área de pesquisa relacionada à linguística e à ciência da cognição (TANSCHKEIT, 2007)(MAMDANI e ASSILIAN, 1975). Foi introduzida por Lotfi A. Zadeh na década de 1960 e é caracterizada por apresentar uma boa relação de compromisso entre significância e precisão, fornecendo um ferramental matemático para o tratamento de informações de caráter

impreciso ou vago, e para auxiliar no controle e tomada de decisão, algo que os pesquisadores vêm buscando há um longo tempo. A lógica fuzzy permite lidar com informações imprecisas para tomada de decisão de problemas complexos e, assim, possui grande aplicabilidade em problemas de classificação, regressão, modelagem e controle inseridos em diversas áreas de conhecimento.

Os Sistemas Fuzzy (SF) são compostos por um conjunto de fundamentos que vão desde a teoria de conjuntos fuzzy, funções de pertinência, lógica fuzzy, passando pelas regras do tipo “*se-então*” e terminando nos Sistemas de Inferência Fuzzy (SIF).

Na teoria clássica de conjuntos, um determinado elemento pertence ou não a um certo conjunto. Na teoria de conjuntos fuzzy, essa caracterização é generalizada de forma que um elemento pode assumir infinitos valores no intervalo $[0,1]$. Um conjunto fuzzy A em um universo U é definido por uma função de pertinência (FP) e por um conjunto de pares ordenados, representando seus elementos. A função de pertinência é uma curva que associa cada elemento de um conjunto fuzzy a um grau de pertinência, μ_A , que indica o quanto determinado elemento pertence ao conjunto fuzzy. Dessa forma, um determinado elemento pode vir a pertencer a mais de um conjunto fuzzy com diferentes graus de pertinência (TANSCHKEIT, 2007).

As funções de pertinência podem ter diversos formatos, sendo os mais comuns o formato triangular, trapezoidal, gaussiano, sino e sigmoide. A escolha do formato da FP depende do contexto do problema estudado e da experiência e perspectiva do projetista. Levando em consideração a lógica fuzzy, qualquer uma das funções de pertinência tem potencial para representar um conjunto fuzzy, porém, deve ser notado que cada uma das funções produz conjuntos fuzzy distintos e não existe uma regra única para o uso das funções de pertinência.

Um conceito importante na lógica fuzzy é o de variável linguística que é aquela cujos valores aparecem em sentenças na forma de linguagem "natural". A cada variável linguística são associados termos linguísticos como: baixo, médio, alto, pequeno, grande e muito grande, que correspondem às características da variável linguística. A questão semântica é muito importante e uma associação feita de forma adequada possibilita um melhor entendimento do problema que está sendo analisado.

A Figura 1 apresenta um exemplo onde é avaliada a temperatura ambiente. Nele, funções de pertinência trapezoidais e triangulares representam os conjuntos correspondentes aos termos linguísticos *Muito Frio*, *Frio*, *Agradável*, *Quente* e *Muito Quente* da variável linguística *Temperatura* em um universo de discurso de 0 a 45°C.




Figura 1 – Variável linguística “Temperatura”.

Com os conjuntos fuzzy é possível realizar operações que são utilizadas na inferência dos sistemas. Existem diversos operadores que podem ser empregados para as operações de união e interseção de conjuntos fuzzy, porém o operador mais empregado para a interseção é o *mínimo*, enquanto que para a união é comum utilizar o operador *máximo*.

Uma ampla classe de modelos para operadores de interseção e união de conjuntos fuzzy é formada pelas normas triangulares ou t-normas e conormas triangulares ou t-conormas (TANSCHKEIT, 2007).

A Figura 2 ilustra o uso dos operadores de união (máximo) e de interseção (mínimo) aplicados a dois conjuntos fuzzy A e B.

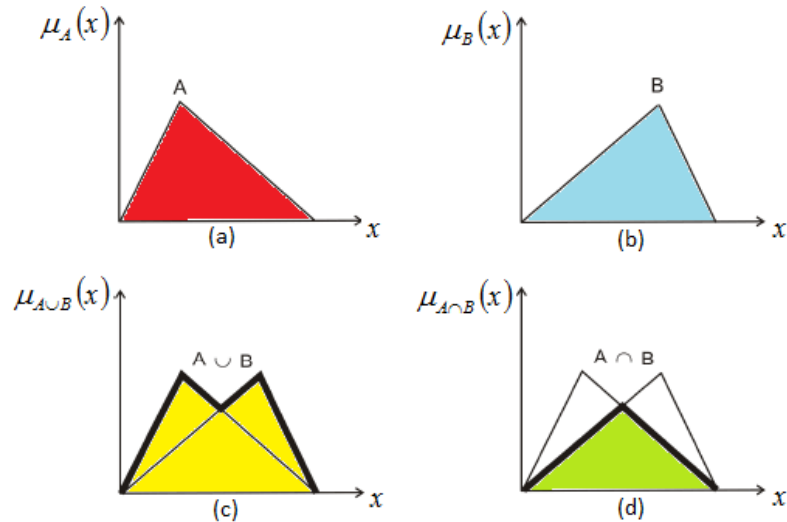


Figura 2 – Exemplo com os operadores máximo e mínimo.

Existem dois tipos principais de sistemas fuzzy: Mamdani e Takagi-Sugeno-Kang (TSK), que se diferenciam basicamente pelo tipo de conseqüente e pelo processo de defuzzificação.

Os sistemas fuzzy baseados em regras (SFBR) utilizam uma estrutura de regras do tipo “se-então”. Os antecedentes e conseqüentes das regras para sistemas do tipo Mamdani são proposições fuzzy que utilizam as variáveis e os termos linguísticos. Um exemplo de uma regra é mostrado a seguir:

SE x é baixo E y é alto ENTÃO z é médio

onde x e y são variáveis de entrada, z é a variável de saída, “baixo”, “alto” e “médio” são os termos linguísticos definidos por funções de pertinência em x , y e z , respectivamente. O antecedente (premissa da regra) estima com que grau a regra se aplica, enquanto o conseqüente (conclusão da regra) associa uma função de pertinência a uma dada variável de saída (AMARAL, 2003).

Um sistema de inferência fuzzy (SIF) é um sistema que usa um conjunto de funções de pertinência e regras para inferir algo a partir de dados. Um SIF é formado

pelo fuzzificador, um bloco de inferência, o defuzzificador e por regras, conforme ilustrado no diagrama da Figura 3.

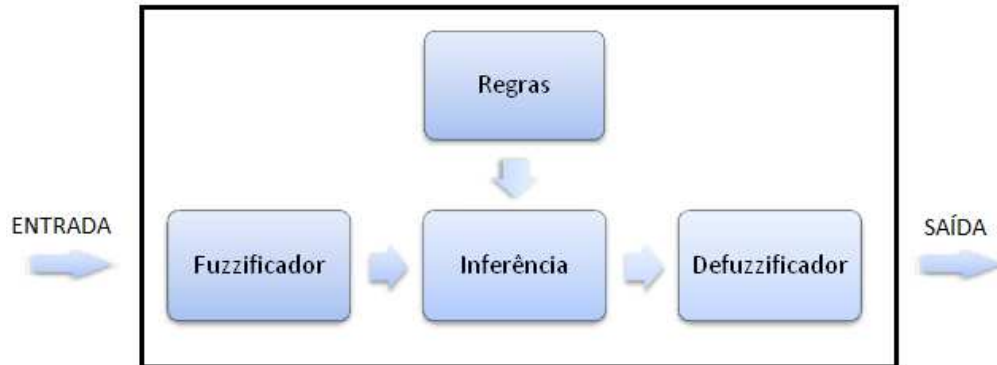


Figura 3 – Sistema de inferência fuzzy (SIF).

O fuzzificador recebe os valores reais de cada entrada. Para cada uma delas, através das funções de pertinência definidas previamente, obtém-se o grau de pertinência com que a entrada pertence a cada conjunto fuzzy. As entradas do bloco são valores numéricos dentro do domínio da variável e a saída valores entre 0 e 1.

As regras formam parte fundamental da estrutura de conhecimento em um SIF. O bloco de regras fornece ao bloco de inferência as regras que descrevem o sistema. As regras podem ser obtidas através do conhecimento de um especialista ou podem ser extraídas de dados numéricos.

No bloco de inferência as regras são ativadas com as entradas fuzzificadas fornecidas pelo fuzzificador e é aplicado um processo de composição para gerar uma saída que será empregada como entrada no defuzzificador.

No modelo Mamdani, a saída z é obtida pela defuzzificação do conjunto fuzzy de saída resultante da aplicação de uma operação de t-conorma sobre os conjuntos dos consequentes, que, por sua vez, foram modificados via t-norma, pelo grau de disparo fornecido pelos antecedentes. Existem diversos métodos para defuzzificação; os mais comuns são o centro de gravidade ou centroide, a média dos máximos e a média ponderada.

No modelo TSK, o consequente de cada regra não é uma proposição fuzzy e sim uma função das variáveis de entrada. Geralmente, a função que faz o mapeamento de entrada e saída para cada regra, é uma combinação linear das

entradas, isto é $z = px + qy + r$. No caso em que $p = q = 0$, temos $z=r$ (fuzzy singleton). A saída do sistema é obtida pela média ponderada (defuzzificação) das saídas de cada regra, usando-se o grau de disparo destas como pesos da ponderação.

Dois pontos de grande importância para avaliação da qualidade de um modelo em sistemas fuzzy são a *acurácia* e a *interpretabilidade* (SHUKLA et al., 2012).

A *acurácia* indica a capacidade de representar o sistema real de uma forma fiel e pode ser definida pela relação de similaridade entre o sistema real e o sistema modelado. Uma possibilidade para esta avaliação é a porcentagem de padrões corretamente classificados, em um problema de classificação, ou o MSE (*Mean Squared Error*) para problemas de regressão ou de aproximação de funções.

A *interpretabilidade* descreve a capacidade do sistema de representar o comportamento de um sistema real de forma compreensível. É uma propriedade subjetiva que depende de quem faz a avaliação e está relacionada a vários fatores, como a estrutura do modelo, o número de variáveis de entrada, o número de regras fuzzy, o número de termos linguísticos e a forma dos conjuntos fuzzy. Não há uma medida padrão para avaliar a *interpretabilidade* de um sistema (GACTO et al., 2011).

A *interpretabilidade* e a *acurácia* tendem a ser aspectos contraditórios no desenvolvimento de sistemas fuzzy, pois uma melhoria em um deles, geralmente, só acontece com a perda do outro. Esse compromisso entre *acurácia* e *interpretabilidade* é um motivador para diversas pesquisas nesta área.

O compromisso entre estes critérios pode ser observado na Figura 4, que mostra uma curva com as melhores soluções, relacionando o erro e a complexidade entre elas. Observa-se que as soluções mais precisas, ou seja, com menor erro, são as mais complicadas, enquanto as soluções mais simples e de melhor compreensão possuem uma *acurácia* menor.

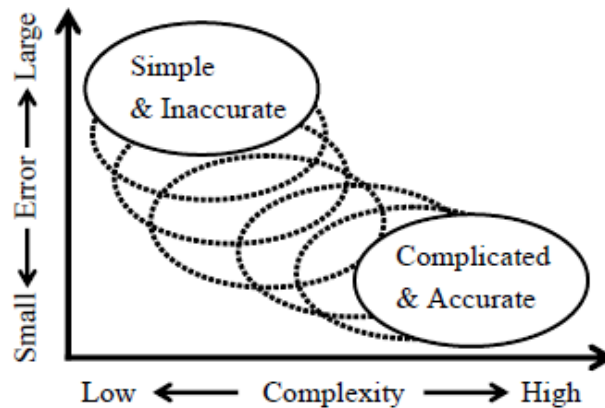


Figura 4 – Curva de compromisso entre acurácia e complexidade (ISHIBUCHI, 2007).

Desta forma, para certas aplicações é de extrema importância que um sistema fuzzy possua um bom desempenho aliado a uma boa interpretabilidade da sua base de conhecimento.

Em sistemas híbridos, que utilizam algoritmos evolutivos para geração da base de conhecimento fuzzy, podem ser aplicadas técnicas de evolução multiobjetivo possibilitando a obtenção de soluções que atendam aos dois critérios de acordo com as necessidades do projetista.

1.2 Algoritmos Genéticos

Os algoritmos genéticos (AG) são algoritmos matemáticos inspirados no princípio Darwiniano de evolução das espécies e da genética. Eles compreendem uma área de pesquisa dentro da computação evolucionária. Tais algoritmos usam o conceito de que indivíduos mais aptos e adaptados ao ambiente possuem mais chances de sobreviver e deixar descendentes. Para isso, o AG utiliza um mecanismo de busca adaptativa baseado no processo de evolução natural e recombinação genética.

A principal aplicação de algoritmos genéticos é em problemas de otimização com espaços de busca muito grandes ou complexos, o que pode inviabilizar o uso de técnicas tradicionais (AMARAL, 2003). Matematicamente, a otimização consiste em encontrar uma solução correspondente ao ponto mínimo ou máximo de uma função.

Os AGs privilegiam as melhores soluções encontradas a cada ciclo de forma a direcionar a busca para regiões onde é mais provável que estejam localizadas as soluções ótimas. Assim, o AG explora de forma inteligente as informações disponíveis para buscar melhores soluções para um determinado problema.

O funcionamento do algoritmo acontece através de um processo de evolução, em que cada iteração corresponde a uma geração. Uma população de indivíduos (possíveis soluções), identificados por cromossomos, são avaliados e associados a uma aptidão e submetidos a um processo de evolução, através de seleção e reprodução, durante várias gerações.

O fluxograma típico de um AG é apresentado na Figura 5.

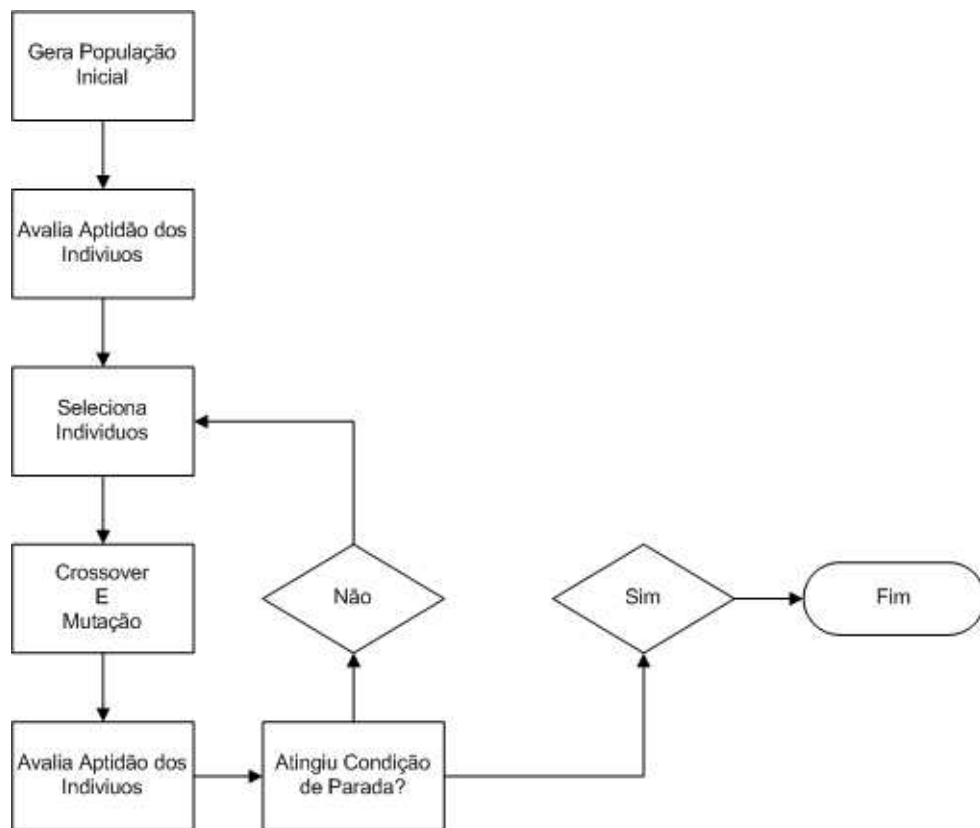


Figura 5 – Fluxograma de execução de um algoritmo genético.

Os aspectos que devem ser definidos para execução do AG são: a representação do problema e inicialização de uma população; a definição de uma função objetivo para avaliação dos indivíduos; e a escolha dos operadores genéticos e dos parâmetros gerais do AG.

A representação do problema corresponde ao mapeamento das possíveis soluções em uma estrutura de dados que possa ser manipulada computacionalmente. Tal estrutura é denominada cromossomo, o qual é composto por diversos genes. A representação pode ocorrer de duas formas: com tamanho fixo ou variável. Na representação de tamanho fixo, os cromossomos que representam os indivíduos da população possuem um número de genes constante. Por outro lado, na representação com tamanho variável, o número de genes pode variar ao longo do processo evolutivo, o que proporciona maior flexibilidade, porém necessita da inclusão de mecanismos de controle de tamanho adicionais. A representação é comumente realizada através de uma codificação binária (Figura 6), por ser de fácil manipulação e análise, porém também podem ser utilizados números inteiros ou reais.

0	1	1	0	1	0	0	1
---	---	---	---	---	---	---	---

Figura 6 - Cromossomo com representação binária.

A inicialização da população corresponde à geração de uma população de n indivíduos que será a base para a evolução. A geração da população inicial é geralmente realizada de forma aleatória, porém também pode ocorrer de forma determinística dentro do espaço de busca.

A fim de avaliar a qualidade dos indivíduos, após cada nova população formada é aplicado a cada indivíduo um processo de avaliação e cada um recebe um valor de aptidão. A função objetivo ou função de avaliação de aptidão é definida com base na especificação do problema e é fundamental para uma execução bem-sucedida. Em geral, a função objetivo envolve apenas um único critério. Porém, grande parte dos problemas reais envolve mais de um objetivo a ser considerado, desta forma a função objetivo deve utilizar métodos para conversão de uma medida de aptidão vetorial em um escalar (DAVIS, 1990).

Os três operadores genéticos empregados em AG são os de seleção, *crossover* e mutação. São eles que proporcionam melhores soluções entre a população ao longo das gerações e possibilitam a evolução em problemas de otimização.

A seleção é o processo responsável por selecionar os indivíduos da população para formar uma nova geração de indivíduos. O operador exerce uma função similar ao do processo de seleção natural biológica, em que indivíduos mais aptos possuem maiores chances de sobrevivência. Os métodos mais comuns de seleção são a roleta, o torneio e a normalização.

O método da roleta é o mais simples e o mais utilizado (GOLDBERG, 1989) e assemelha-se à roleta utilizada em jogos de azar. Cada indivíduo é representado na roleta conforme sua aptidão, isto é, indivíduos com aptidão alta ocupam uma parte maior da roleta que indivíduos com baixa aptidão, fazendo com que a probabilidade de seleção seja proporcional à aptidão de cada indivíduo. Após isso, gera-se um número aleatório no intervalo compreendido entre 0 e a soma das aptidões de todos os indivíduos. O indivíduo que possuir o número gerado é selecionado. O processo é repetido até a seleção de um determinado número de indivíduos requerido.

No método do torneio, há uma escolha aleatória de um determinado número de indivíduos da população para participar de um torneio em que o indivíduo que possuir maior aptidão é selecionado para preencher a nova população. O processo é repetido N vezes até a seleção de N indivíduos.

Na seleção por normalização os indivíduos são ordenados de acordo com suas aptidões. Em seguida é realizado um escalonamento das aptidões, onde as aptidões originais são substituídas. Ao indivíduo de menor aptidão é atribuído o índice 1 e uma nova aptidão η^- , e ao indivíduo de maior aptidão o índice N e uma nova aptidão η^+ . Assim, a probabilidade de seleção usando este mecanismo é uma função do índice do indivíduo e não da sua aptidão original como ocorre na seleção por roleta. De acordo com a função utilizada a seleção por normalização pode ser linear ou exponencial.

Além disso, o elitismo também é um importante recurso que está presente em grande parte dos algoritmos genéticos. Ele consiste em manter o(s) melhor(es) indivíduo(s) na formação da população seguinte. Esse processo contribui para o aumento do desempenho do algoritmo, pois evita que bons indivíduos sejam eliminados ou modificados pelos operadores de *crossover* e mutação.

O operador de *crossover* ou cruzamento possibilita a recombinação da informação de dois cromossomos diferentes a fim de gerar dois novos indivíduos. O

resultado desta operação são indivíduos que, potencialmente, combinem as características dos indivíduos usados como base. O crossover pode ser realizado a partir de um ponto de corte ou mais.

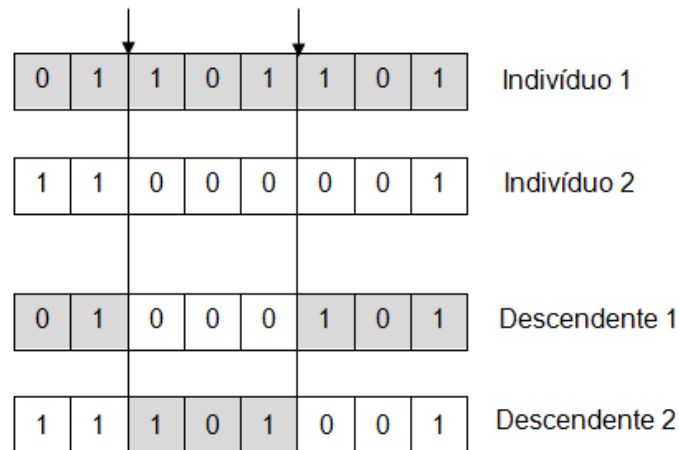


Figura 7 – Operador *crossover* de dois pontos.

A Figura 7 mostra o operador de cruzamento binário em dois pontos, em que um dos descendentes fica com as partes extremas do indivíduo 1 e a parte central do indivíduo 2 enquanto o outro descendente fica com as partes restantes.

O operador de mutação consiste na variação aleatória de um ou mais genes dos indivíduos e representa uma característica exploratória dentro do espaço de busca, pois insere novas características na população. A Figura 8 representa o operador de mutação aplicado ao terceiro gene de um determinado indivíduo.




Figura 8 – Operador de mutação simples.

Os parâmetros gerais do AG exercem influência no seu desempenho e estabelecem um critério de parada para execução do algoritmo. Tais parâmetros incluem o tamanho da população, número máximo de gerações e taxa de aplicação

dos operadores. A escolha dos parâmetros deve atender aos critérios empíricos estabelecidos ou às características específicas do problema em questão.

É possível destacar três principais vantagens dos algoritmos genéticos: a boa capacidade de busca global; a independência do domínio, pois trabalham sobre a codificação do problema possibilitando a elaboração de modelos para diferentes problemas; e a natureza paralela, que facilita a implementação em um processamento paralelo (ISHIBASHI, 2013).

Como principais desvantagens cita-se a possibilidade de obtenção de resultados sub-ótimos e o tempo de processamento que pode ser alto quando são utilizados muitos parâmetros.

2 ELETRÔNICA EVOLUCIONÁRIA

2.1 Apresentação

A aplicação de Algoritmos Evolucionários no projeto de circuitos eletrônicos recebe o nome de Eletrônica Evolucionária ou Hardware Evolucionário (*Evolvable Hardware* - EHW) (ZEBULUM et al., 2001). A Eletrônica Evolucionária compreende o amplo campo de pesquisa relacionado com a aplicação de algoritmos evolucionários no projeto de circuitos eletrônicos, mais especificamente, na síntese, otimização e/ou auto-reparo.

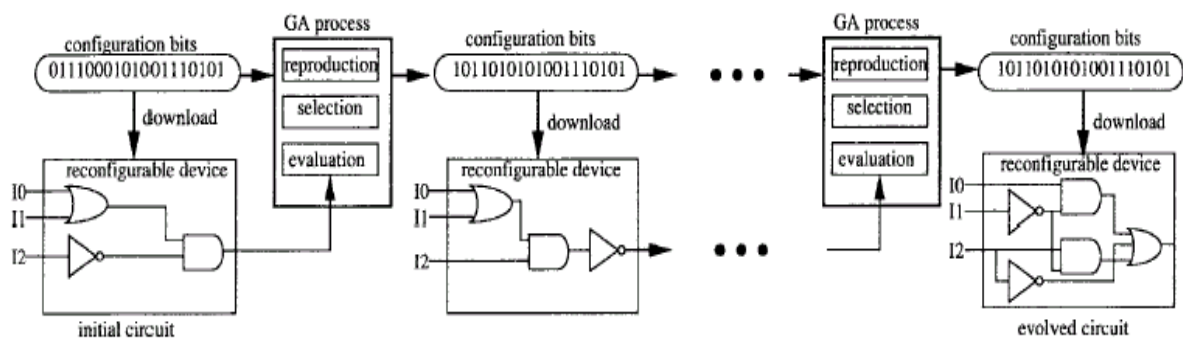
O projeto de um circuito eletrônico envolve a concepção de sua topologia e a seleção dos componentes necessários para sua implementação. Quando se trata de circuitos eletrônicos analógicos, o projeto é baseado principalmente na experiência e na criatividade do projetista, devidamente apoiado por um sistema de CAD (*Computer Aided Design*). No entanto, grandes avanços têm sido obtidos em Eletrônica Evolucionária, o que representa um novo modo de projetar circuitos e uma alternativa interessante para o desenvolvimento de circuitos eletrônicos analógicos para as mais diversas aplicações.

A geração automática ou semi-automática de circuitos adequados ao projeto almejado torna o seu desenvolvimento menos dependente da habilidade e da experiência dos projetistas, além de apresentar uma abordagem não convencional para tratar os circuitos (MESQUITA et al., 2002). Os resultados obtidos em diversas aplicações (GREENWOOD & TYRREL, 2007)(AMARAL, 2003)(HIGUCHI et al., 1999) ressaltam o potencial desta ferramenta quando comparados aos obtidos pelas técnicas tradicionais.

A área de Computação Evolucionária teve início com Fogel na década de 60 (FOGEL et al., 1966) e tem como premissa a utilização de aspectos da teoria evolutiva darwiniana como inspiração na concepção de sistemas artificiais. Na década de 70, estas ideias foram organizadas por John Holland (HOLLAND, 1975), que propôs a técnica denominada de Algoritmos Genéticos. Especificamente, Eletrônica Evolutiva se refere à concepção de sistemas eletrônicos sob o controle de algoritmos evolutivos, usualmente de Algoritmos Genéticos.

Na Eletrônica Evolucionária, um Algoritmo Genético é usado para buscar (ou otimizar), dentre todos os possíveis circuitos do espaço de busca, a solução, isto é, o circuito, que obedece ao critério de avaliação de aptidão estabelecido - por exemplo, a configuração de um circuito que apresente uma saída pré-determinada. Os circuitos eletrônicos são geralmente representados por uma codificação binária, o cromossomo. Inicialmente, uma população é criada, e todos os indivíduos (circuitos candidatos) avaliados. Uma parcela desta população é mantida, sendo que os melhores indivíduos têm mais chances de serem selecionados para reproduzir e formar a população subsequente, até que o objetivo seja atingido ou algum critério de parada interrompa a evolução.

A Figura 9 ilustra o processo básico de evolução quando aplicado ao desenvolvimento de circuitos digitais.



Basic concept of evolvable hardware.

Figura 9 – Conceito básico de Evolvable Hardware (HIGUCHI et al., 1999).

A Eletrônica Evolucionária pode ser classificada (ZEBULUM et al., 1997) de acordo com os seguintes aspectos:

- Tipo de Projeto
- Natureza do Projeto
- Tipo de Evolução.

2.2 Tipo de Projeto

Quanto ao tipo de projeto, a eletrônica evolucionária é dividida em:

- *Otimização*
- *Síntese*
- *Auto-reparo.*

A *otimização* está relacionada diretamente com a atribuição de valores adequados de componentes a um circuito com topologia definida. Por exemplo, Higuchi (HIGUCHI et al., 1999) apresenta uma aplicação industrial relacionada com a diminuição significativa da rejeição de telefones celulares no fim da linha de produção. O problema é o ajuste de um filtro de FI (Frequência Intermediária) utilizado nos celulares e que possui especificações de resposta em frequência extremamente rígidas. A solução proposta pela equipe do Professor Higuchi foi um chip de hardware evolucionário analógico capaz de permitir o ajuste dos filtros na linha de produção. Com este procedimento foi possível corrigir as variações de fabricação na maioria dos filtros, o que acarretou um maior rendimento e a diminuição dos custos de produção.

A *síntese* é um processo mais complexo que busca o circuito mais adequado para determinada tarefa, incluindo-se tanto a sua configuração topológica como a sua implementação (ZEBULUM et al., 2001; SALAZAR & MESQUITA, 2000). Os espaços de busca são, via de regra, muito grandes e, como consequência, a evolução é bastante lenta.

O *auto-reparo* abrange os circuitos tolerantes a falhas e aqueles auto-regeneráveis. Para corrigir uma anomalia em um circuito, um técnico deve ser capaz de compreender o seu funcionamento, além de conhecer ou entender o defeito em questão (experiência de bancada). Com o desenvolvimento da eletrônica torna-se cada vez mais difícil para um técnico capacitar-se para consertar uma grande variedade de circuitos, sendo necessária a especialização em determinados tipos de circuito. Surgiu então a necessidade de criar ferramentas para auxiliar o reparo automático ou semi-automático de circuitos (PACHECO et al., 2002).

2.3 Natureza do Projeto

O circuito eletrônico a ser projetado pode ser um circuito:

- Digital
- Analógico
- Misto

A síntese de circuitos digitais é feita basicamente por duas formas básicas de representação: portas e funções lógicas (HIGUCHI et al., 1999).

No primeiro caso, a unidade básica manipulada pelo sistema evolucionário é uma porta lógica, isto é, AND, OR, etc. No segundo caso, a unidade é uma função digital mais complexa, como uma unidade lógica aritmética ou um produto de variáveis lógicas. Em geral, cada gene codifica a natureza do bloco de construção do circuito e a origem das entradas do mesmo (THOMPSON, 1996). Tipicamente, para circuitos combinacionais, a avaliação consiste na comparação com a especificação do circuito digital, dada na forma de uma tabela verdade (TOCCI & WIDMER, 2000).

Enquanto os circuitos digitais possuem metodologias de projeto bem definidas, o projeto de circuitos analógicos é mais complexo e se caracteriza por depender em maior grau da experiência e intuição do projetista (WILLIAMS, 1991; HOROWITZ, 1994).

O projeto de circuitos analógicos é muito importante pois todos os circuitos eletrônicos são implicitamente analógicos. Além disso, circuitos analógicos são necessários para a interface dos circuitos digitais com o resto do mundo.

Com a crescente integração viabilizada pelos avanços da microeletrônica, temos os chamados circuitos mistos (*Mixed-Mode Circuits*) que possuem em sua arquitetura partes digitais e partes analógicas.

Progressos foram obtidos na automação da síntese de certas categorias de circuitos digitais; no entanto, a síntese de circuitos analógicos e circuitos mistos é bem mais difícil de automatizar (KOZA et al., 1998). O projeto do circuito analógico é caracterizado por uma combinação de experiência e intuição, muitas vezes de genialidade, e requer conhecimento das características do processo e das

especificações detalhadas do produto. Assim, a complexidade desta classe de projetos, associada à escassez de projetistas experientes, caracteriza uma motivação econômica para a automação desta área (AMARAL, 2003).

A automação dos circuitos analógicos começou há algum tempo e somente nos últimos anos apareceram trabalhos utilizando técnicas evolucionárias. Nestes trabalhos, Algoritmos Genéticos tradicionais foram usados para determinar os valores dos componentes de um filtro (HORROCKS & SPITTLE, 1996), para determinar a topologia do filtro (GRIMBLEBY, 1995) e para sintetizar amplificadores operacionais utilizando um pequeno número de topologias (KRUISKAMP, 1996). Recentemente, mostrou-se possível a utilização de Programação Genética (KOZA et al., 1998) no projeto de circuitos analógicos complexos. A partir de um circuito embrionário simples que contém partes fixas apropriadas para o problema e certas conexões capazes de subsequente modificação o projeto é realizado. Este procedimento, na verdade, insere algum conhecimento prévio específico sobre o problema. O comportamento de cada circuito é então avaliado através de um simulador. Esta técnica apresenta um altíssimo custo computacional.

A automação do projeto de circuitos analógicos continua sendo uma promissora área de pesquisa e aplicação de Eletrônica Evolucionária.

2.4 Tipo de Evolução

Um projeto eletrônico pode ser desenvolvido de maneira:

- Intrínseca
- Extrínseca

Nas chamadas aplicações intrínsecas, a avaliação é realizada com base no comportamento dos circuitos ao serem carregados em circuitos integrados programáveis (ZEBULUM et al., 1999) ou plataformas reconfiguráveis (AMARAL, 2003). Deste modo o circuito real é desenvolvido, sendo que, no entanto, a flexibilidade e as possibilidades de experimentação ficam mais limitadas.

Por outro lado, as aplicações extrínsecas são aquelas nas quais os circuitos são avaliados através de seus modelos equivalentes. Por exemplo, um filtro analógico linear pode ser desenvolvido utilizando-se sua função de transferência. Também é possível a utilização de simuladores de circuitos, como, por exemplo, o *Spice*, sendo que neste caso as evoluções tendem a se tornar muito lentas.

2.4.1 Evolução Intrínseca

A utilização de plataformas reconfiguráveis garante que as propriedades físicas dos componentes eletrônicos estejam disponíveis, sem restrições, para ser exploradas pelo processo evolucionário.

Na evolução intrínseca o circuito que está sendo avaliado durante a evolução é o circuito real, e não uma simulação baseada em seu modelo – como ocorre na evolução extrínseca. A avaliação do circuito é então baseada em sinais analógicos reais. O tempo necessário para a avaliação de um circuito é limitado somente pelo tempo necessário para fornecer ao circuito o conjunto de entradas fornecido na sua especificação.

Ambientes de Eletrônica Evolucionária para evolução intrínseca consistem em duas partes: um hardware programável, como uma FPGA (*Field Programmable Gate Array*) ou uma FPAA (*Field Programmable Analog Array*), e alguma técnica de evolucionária, como os Algoritmos Genéticos. O hardware programável é reconfigurado pelos bits de configuração determinados pelo algoritmo evolucionário implementado em software.

Na síntese de circuitos por evolução intrínseca, cada indivíduo (cromossoma) é avaliado de acordo com o seu comportamento ao ser configurado em uma plataforma reconfigurável. As plataformas dividem-se em digitais e analógicas. As plataformas FPAA e FPGA estão estabelecendo uma nova tendência na síntese de circuitos eletrônicos (ZEBULUM et al., 2000). Enquanto FPGAs estão sendo desenvolvidas para aplicações no domínio do processamento digital de sinais e computação reconfigurável, a maioria dos modelos de FPAA está sendo desenvolvida para aplicações em circuitos analógico-digitais programáveis e em filtragem. As FPGAs e FPAAs são motivo de pesquisa na área de sistemas auto-

programáveis (RIBEIRO, 2012). Geralmente, a evolução nestas plataformas é realizada com AG.

Uma interessante discussão a respeito dos prós e contras dos diferentes níveis de granularidade e interconexões das plataformas destinadas à evolução intrínseca de circuitos analógicos é apresentada em (SHEEHAN & FLOCKTON, 2000). Outra interessante consideração é a de que a utilização de blocos construtores especialmente projetados para suas propriedades analógicas seria mais adequada para a evolução analógica, já que é mais provável que estes blocos construtores apresentem um comportamento estável.

2.4.2 Evolução Extrínseca

Na síntese de circuitos por evolução extrínseca, a avaliação é feita através de modelos equivalentes dos circuitos. Pode-se utilizar modelagem matemática direta ou simuladores de circuitos, como o SPICE (*Simulation Program with Integrated Circuit Emphasis*) (FENICAL, 1992) também podem ser usados.

Um dos problemas para o projeto de circuitos eletrônicos analógicos por evolução extrínseca é que eles têm um conjunto muito maior de dinâmicas possíveis quando comparados com circuitos digitais. Cabe ressaltar que, a não ser que sejam usados modelos matemáticos mais diretos ou simplificados, os circuitos analógicos também são também mais difíceis de ser simulados e necessitam de muito mais poder computacional para sua avaliação. Os simuladores precisam resolver equações diferenciais e requerem muito tempo para concluir a avaliação de um circuito. Tendo em vista que para sintetizar circuitos através de um método evolucionário, o comportamento de vários indivíduos deve ser avaliado, o processo extrínseco que utiliza simuladores geralmente é muito longo. Outro problema em evolução extrínseca, é que o resultado é somente um modelo (simples ou sofisticado) do circuito real. É difícil prever o comportamento de um sistema analógico, o que faz com que a diferença entre o projeto e sua implementação possa ser significativa, a não ser que se tomem cuidados especiais.

As principais vantagens da evolução extrínseca de circuitos estão relacionadas com a flexibilidade, a possibilidade de avaliar novas ideias de modo

mais simples e a liberdade para experimentação de novas representações e avaliações.

Neste trabalho optou-se pela evolução extrínseca baseada em modelos dos circuitos eletrônicos analógicos para flexibilizar a experimentação do método de avaliação de múltiplos objetivos utilizado.

3 AVALIAÇÃO DE MÚLTIPLOS OBJETIVOS

Existem problemas que requerem a maximização ou minimização de mais de um objetivo simultaneamente. Eles são chamados de problemas de otimização com avaliação de múltiplos objetivos, ou de modo mais compacto, *problemas de otimização multiobjetivo* (POM). Dentre os diversos exemplos de problemas com múltiplos objetivos, podemos citar uma linha de produção industrial em que é desejado maximizar a qualidade do produto ao mesmo tempo em que se minimiza o custo, ou a otimização de um circuito eletrônico no qual se quer minimizar o erro de mapeamento e minimizar a soma do valor dos resistores para minimizar a área de circuito integrado.

Em problemas com diversos objetivos é comum a existência de objetivos conflitantes. Eles devem ser analisados e uma única solução ótima para o problema dificilmente é encontrada. Existe um conjunto de soluções “melhores” ou superiores que atendem em graus diferentes a cada objetivo. Assim, uma *boa solução* é aquela que *não é dominada por nenhuma outra solução*. Estas configurações superiores são chamadas de soluções não dominadas.

Grande parte dos problemas do mundo real envolve a otimização multicritério que é uma ampla área de pesquisa com diversas questões em aberto. É o caso da paralelização dos algoritmos pois atualmente a técnica GPGPU (*General Purpose Graphics Processing Unit*) utiliza a GPU (*Graphics Processing Unit*) para processamento de imagem, inteligência computacional, cálculo numérico dentre outras aplicações, além da tradicional renderização gráfica. Esta técnica abre novas oportunidades de pesquisas nesta área, em especial no que diz respeito aos problemas do mundo real que, tipicamente, possuem funções objetivo computacionalmente custosas (LOPEZ, 2014).

Os sistemas híbridos também merecem destaque pois nos últimos anos, algoritmos híbridos utilizando diferentes técnicas inteligentes têm sido propostos (MARTÍNEZ et al., 2013) (LARA et al., 2010). A utilização de tais abordagens híbridas em aplicações no mundo real é promissora à medida que mais resultados de pesquisas se tornem disponíveis (COELLO COELLO, 2013).

A otimização de múltiplos objetivos pode ser compreendida como um problema de busca por um vetor de variáveis de decisão que satisfaz às restrições e otimiza uma função vetorial cujos elementos representam as funções objetivo. Estas funções formam uma descrição matemática dos critérios de desempenho que podem ser, inclusive, conflitantes uns com os outros. Assim, o termo "otimizar" significa encontrar uma solução que forneça valores aceitáveis ao usuário para todas as funções objetivo (OSYCZKA, 1985).

Desta forma, um problema de otimização multiobjetivo é definido por um conjunto de k funções objetivo e n variáveis de decisão (FONSECA, 2017). Matematicamente, podemos definir as equações (1) e (2):

$$F(X) = (f_1(X), f_2(X), \dots, f_k(X))^T \quad \text{sendo } X \in S \quad (1)$$

$$X = (x_1, x_2, \dots, x_n)^T \quad (2)$$

Onde X é o vetor de variáveis, $F(X)$ é o vetor objetivo formado por k funções objetivo e S é o espaço de decisão.

A Figura 10 ilustra o espaço de decisão e objetivo em um problema com três variáveis de decisão e duas funções objetivo.




Figura 10 - Representação do espaço de decisão e espaço objetivo (FONSECA, 2017).

Diversas técnicas podem ser utilizadas para determinar quais pontos compõem a solução de um problema multicritério, porém um conceito importante e uma das abordagens mais comum é o *conceito de dominância de Pareto*.

3.1 Conceito de Dominância de Pareto

Vilfredo Pareto generalizou a noção de soluções ótimas para problemas de múltiplos objetivos que ficaram conhecidas como soluções ótimas de Pareto ou soluções Pareto ótimas (*Pareto-optimum*).

O método de Pareto utiliza o conceito de dominância para comparar duas possíveis soluções do problema.

Dados dois vetores de variáveis de decisão quaisquer, $x, y \in S$, existem três possibilidades de classificação para os seus correspondentes vetores objetivo em um problema de minimização:

- Se $f_i(x) \leq f_i(y) \quad \forall i$ o vetor objetivo $f(x)$ domina $f(y)$ e o vetor de decisão x domina y ;
- Se $f_i(x) \geq f_i(y) \quad \forall i$ o vetor objetivo $f(x)$ é dominado por $f(y)$ e o vetor de decisão x é dominado por y ;
- Se $f_i(x) \leq f_i(y)$ e $f_j(x) \geq f_j(y) \quad i \neq j$ o vetor objetivo $f(x)$ é indiferente com $f(y)$ e o vetor de decisão x é indiferente com y e vice-versa.

Onde $i, j \in [1, 2, \dots, k]$ e $k =$ número de funções objetivo.

Deste modo, de uma forma geral, em um problema de minimização, diz-se que um vetor de decisão x domina um vetor y se, e somente se, as seguintes condições forem satisfeitas:

- O vetor objetivo $f(x)$ é menor ou pelo menos igual a $f(y)$ em todos os objetivos;
- O vetor $f(x)$ possui valor menor que $f(y)$ em pelo menos um dos objetivos.

Formalmente, define-se:

$$\forall i \in \{1, \dots, k\}, f_i(x) \leq f_i(y) \cap \exists j \in \{1, \dots, k\}, f_j(x) < f_j(y)$$

Para problemas de maximização as definições são análogas.




Figura 11 – Ilustração do conceito de dominância de Pareto (ARROYO, 2002).

Assim, diferentes pontos em um espaço de objetivos factível podem ser comparados e divididos em regiões de dominação. A Figura 11 (a) apresenta diferentes possíveis soluções em um espaço objetivo. Em (b) são mostradas as regiões de dominação em relação a um ponto C, para um POM de minimização. Por exemplo, os pontos G e D alcançaram uma melhor minimização de um dos objetivos, porém obtiveram valores mais elevados em outro, assim se tornam indiferentes. Os pontos E e F constituem soluções dominadas, enquanto os pontos A e B são soluções superiores e não dominadas.

A Figura 12 ilustra a comparação da distribuição de soluções dominadas, não dominadas e indiferentes em problemas com dois e três objetivos. A partir da figura é possível observar que a proporção da área de soluções indiferentes aumenta à medida que o número de objetivos analisados aumenta.




Figura 12 - Exemplo da localização e proporção entre soluções dominadas, não dominadas e indiferentes (FONSECA, 2017).

É possível estender o conceito de soluções não dominadas para caracterizar as soluções ótimas de Pareto. Assim, dado um conjunto de soluções factíveis, todas as soluções desse conjunto que são não dominadas formam o conjunto de soluções ótimas de Pareto. Pode-se dizer que X^* é uma solução ótima de Pareto se não existe outra solução X que melhore algum objetivo sem simultaneamente piorar pelo menos um outro objetivo. *Todas as soluções ótimas de Pareto de um problema são indiferentes entre si* e apresentam o melhor compromisso com as funções objetivo definidas. Na Figura 11 as soluções A e B não são dominadas por nenhum outro ponto do espaço, logo são soluções ótimas de Pareto.

A partir do conjunto de soluções, é obtida a fronteira ou frente de Pareto \mathcal{P} , definida por $F(X)$. Na Figura 11 (a) e na Figura 13 é possível observar a fronteira ótima de Pareto.




Figura 13 – Representação do espaço de soluções para um problema bi-dimensional (ANDERSSON, 2000).

Na Figura 13 também é possível observar os pontos ideais ou utópicos. Os pontos f_1^* e f_2^* pertencem à fronteira de Pareto e são as soluções ideais para a minimização individual dos objetivos f_1 e f_2 , respectivamente. O ponto F^* é o ponto ideal que minimizaria os dois objetivos simultaneamente, ou seja, $F^* = (f_1^*, f_2^*)$. É importante observar que a existência desse ponto ideal seria a solução do problema. Porém, esta situação é extremamente improvável se o problema envolve objetivos conflitantes.

As quatro possibilidades de fronteiras ótimas de Pareto para um hipotético POM com dois objetivos, f_1 e f_2 , estão ilustradas na Figura 14 para cada caso de otimização possível das funções objetivo (minimização ou maximização).




Figura 14 – Fronteiras ótimas de Pareto (DEB, 2001).

3.2 Métodos de Avaliação de Múltiplos Objetivos

Há uma grande variedade de abordagens e métodos para lidar com problemas de otimização com múltiplos objetivos. Uma taxonomia possível para classificação destes métodos abrange quatro classes que se diferenciam pelo momento no qual se realiza a escolha de preferência entre os objetivos. As classes são:

- Métodos sem preferência
- Métodos a-priori
- Métodos a-posteriori
- Métodos Interativos

3.2.1 Métodos sem preferência

Os chamados métodos sem preferência não utilizam nenhuma informação *a-priori* ou *a-posteriori* sobre preferência entre os objetivos. A formulação *min-max* é um exemplo clássico de método em que não é utilizada nenhuma informação sobre pesos ou preferência entre os objetivos. Ela é baseado na minimização da distância entre uma possível solução e o ponto ideal F^* (Figura 13). A equação (3) descreve o método.

$$F = \left[\sum_{i=1}^k \left(\frac{f_i(x) - f_i^*}{f_i^*} \right)^p \right]^{\frac{1}{p}} \quad (3)$$

$$x \in S$$

$$1 \leq p \leq \infty$$

onde S é o espaço de soluções.

A variação do expoente p gera diferentes formas para o cálculo da distância. Os valores mais frequentes são 1 para formulações simples e 2 para a tradicional distância euclidiana (ANDERSSON, 2000).

Através deste método, a solução encontrada representa um ponto na fronteira de Pareto que não utiliza qualquer informação prévia, sendo necessário que o usuário faça uma avaliação posterior sobre a qualidade da solução encontrada de acordo com o seu problema.

Este método pode ser utilizado em métodos iterativos, abordados na seção 3.2.4, junto com outras técnicas, a fim de encontrar diversos pontos da fronteira de Pareto.

3.2.2 Métodos *a-priori*

Esta classe envolve métodos que utilizam informação prévia obtida do especialista, ou seja, de alguma forma é realizada a ponderação ou agregação dos objetivos antes de ser realizada a otimização. Neste trabalho vamos apresentar sucintamente apenas dois desses métodos.

3.2.2.1 Agregação de objetivos

Um dos métodos mais simples, direto e bastante utilizado é o método de agregação de objetivos. Neste método a avaliação de uma solução é calculada pela média ponderada em relação a cada objetivo conforme a equação (4):

$$F = \sum_{i=1}^k \omega_i f_i$$

$$x \in S \tag{4}$$

$$\omega \in R^k \mid \omega_i > 0, \sum \omega_i = 1$$

onde f_i representa a avaliação da solução em relação a um determinado objetivo i , e ω_i é o respectivo peso, para um total de k objetivos.

A simplicidade de implementação e a possibilidade de inserção em técnicas tradicionais de otimização são algumas vantagens deste método. Por outro lado, uma desvantagem é a dificuldade de determinar quais são os pesos adequados para cada problema. Em alguns casos é possível considerar os diferentes objetivos como

sendo de mesma importância, e, portanto, com pesos iguais. Entretanto, na maioria dos casos a otimização de um determinado objetivo pode ser mais importante que a de outro e ser difícil a definição de quais são os pesos ideais (SINOHARA, 2002). Logo, a aplicação do método de agregação de objetivos exige um custoso processo de ajuste, no qual diferentes conjuntos de pesos são testados até a obtenção de resultados satisfatórios (JONATHAN et al., 2010). Uma atualização dinâmica dos valores dos pesos seria uma forma de permitir um ajuste, ao longo do processo, de forma a atender todos os objetivos (ZEBULUM, 1999). Existe a necessidade de normalizar as avaliações dos objetivos a fim de obter valores comparáveis entre si.

3.2.2.2 Lógica Fuzzy

A lógica fuzzy pode ser utilizada em um problema de otimização multiobjetivo para associar a cada objetivo um valor de pertinência $\mu_i(f_i(x))$ que corresponda ao grau de satisfação do objetivo considerado, variando no intervalo entre 0 e 1. Para isso, as funções de pertinência devem ser definidas a partir do conhecimento de um especialista de acordo com o problema a ser resolvido.

Após a obtenção da pertinência referente a cada objetivo, é necessário obter um valor único correspondente à uma avaliação geral de todos os objetivos. Para isso, os valores de pertinência de cada objetivo são agregados através da aplicação de um operador de interseção e oferecem um valor único a ser otimizado. Assim, a função objetivo pode ser caracterizada de acordo com a equação (5) utilizando o operador mínimo ou (6) utilizando o operador produto.

$$F_{fuzzy}(x) = \min [\mu_1(f_1(x)), \mu_2(f_2(x)), \dots, \mu_k(f_k(x))] \quad (5)$$

$$F_{fuzzy}(x) = \prod_{i=1}^k \mu_i(f_i(x)) \quad (6)$$

A lógica fuzzy ou os conjuntos fuzzy podem também ser utilizados com outros métodos. De forma similar e baseando-se nos conceitos dos sistemas fuzzy e algoritmos genéticos foi desenvolvida a ideia utilizada neste trabalho, que é descrita no Capítulo 4.

3.2.3 Métodos *a-posteriori*

Esta classe de métodos permite a obtenção de um conjunto de soluções ótimas de Pareto que são apresentadas para uma posterior decisão sobre qual é mais adequada.

A vantagem destes métodos é o fato da solução não depender de preferências do projetista antes e durante a obtenção do conjunto de possíveis soluções. O conjunto ótimo de Pareto é obtido uma vez e diversas soluções podem ser consideradas a partir dele, de acordo com os objetivos necessários em cada situação a ser analisada.

Por outro lado, pode ser uma tarefa difícil para o projetista decidir qual a melhor solução em meio a diversas opções. Outra desvantagem é o grande custo computacional. A seguir são descritos dois dentre os métodos mais utilizados.

3.2.3.1 Agregação de objetivos (múltiplas execuções)

A agregação de objetivos, quando executada diversas vezes para diferentes valores de pesos, pode ser utilizada para encontrar diversos pontos na fronteira de Pareto. Trata-se de uma busca exaustiva, sendo um método mais direto, porém apresenta algumas desvantagens, pois dependendo das dimensões dos diferentes objetivos e da forma da fronteira de Pareto, é difícil selecionar a variação dos pesos para garantir que os pontos estejam espalhados uniformemente na fronteira. Outro problema ocorre quando o espaço de soluções não é convexo, impossibilitando a obtenção de todas as soluções ótimas de Pareto.

3.2.3.2 Algoritmos evolucionários multiobjetivo

Algoritmos evolutivos são eficientes na resolução de problemas de otimização multicritério. Uma variedade de técnicas utilizando algoritmos genéticos tem sido desenvolvida nas últimas décadas. A grande vantagem obtida na utilização de AGs é o fato deles avaliarem simultaneamente um conjunto de possíveis soluções que permite encontrar o conjunto total de soluções da fronteira de Pareto em uma única

rodada do algoritmo sem que haja a necessidade da realização de diversas iterações como nos outros métodos (COELLO COELLO, 1999). Além disso, apresentam facilidade e flexibilidade de modelagem, são menos susceptíveis às características da fronteira de Pareto não convexa e descontínua e podem trabalhar em espaços de busca que são intratáveis pelas abordagens tradicionais.

3.2.4 Métodos Interativos

Os métodos conhecidos como interativos são utilizados em situações em que não há total determinação de pesos ou preferências entre os objetivos em um primeiro momento, mas ao longo do processo de otimização é possível que o projetista inclua informações. Nestes métodos, o responsável pela decisão intervém durante o processo de otimização articulando preferências e guiando a busca para regiões onde existem soluções de interesse.

4 IMPLEMENTAÇÃO DO AMBIENTE EVOLUTIVO

A proposta deste trabalho é a aplicação de um modelo híbrido para viabilizar a evolução de circuitos eletrônicos, baseando-se em um algoritmo genético e utilizando um sistema fuzzy para avaliação de múltiplos objetivos.

A avaliação de aptidão tradicional dos algoritmos genéticos é modificada, de forma que um sistema fuzzy é efetivamente o responsável pela avaliação, sendo assim capaz de agregar os diversos objetivos do projeto eletrônico e gerando um valor de aptidão para cada circuito da população. Uma das vantagens mais importantes dos sistemas fuzzy é a interpretabilidade. Esta característica possibilita inserir preferências e adaptar o sistema a diferentes situações utilizando uma linguagem natural e fácil de ser entendida (AMARAL, 2003).

Deste modo, o ambiente evolutivo apresenta uma forma mais simples e interpretável de inserir preferências e/ou especificações, pois utiliza um sistema fuzzy. Tais especificações são inseridas antes da evolução do circuito, isto é, *a-priori*, garantindo que ela seja guiada na direção desejada, evitando que o projetista tenha que efetuar ao final do processo a escolha da solução mais adequada. A possibilidade de incluir entradas possivelmente conflitantes mas que resultam em uma única saída que visa a atender a ambas, também é um ponto forte que permite sua utilização na resolução de problemas com múltiplos objetivos. Optou-se por uma implementação baseada puramente em simulação de modelos de circuitos, possibilitando um ambiente flexível para estudo de casos e viabilizando futuras aplicações. Assim, um método para avaliação através de sistemas fuzzy (FONSECA, 2017) se tornou o foco de aplicação deste trabalho para a evolução de circuitos eletrônicos.

A capacidade de busca dos algoritmos genéticos motivou a escolha desta técnica inteligente como base para utilização neste trabalho. Assim, foi desenvolvido um algoritmo genético capaz de obter uma solução (circuito desenvolvido) de acordo com preferências estabelecidas conforme os diversos objetivos do problema, sendo que, para isso, utiliza-se um sistema de agregação fuzzy.

Com isso, a grande vantagem do modelo aqui aplicado é a inclusão de preferências e/ou especificações do usuário no início do processo de uma forma

mais simples e interpretável, pois utiliza um sistema fuzzy para inserir essas preferências/especificações. Comparando o modelo com os algoritmos que utilizam o conceito de Pareto, este fato é de grande importância pois evita que sejam apresentadas diversas soluções para posterior seleção da melhor dentre elas pelo projetista no final do processo.

4.1 Características

A metodologia utilizada no presente trabalho possibilita a evolução de circuitos eletrônicos com características a serem minimizadas ou maximizadas, com foco no ajustes dos valores dos componentes de topologias pré-definidas e cujo modelo esteja disponível ou possa ser construído.

Basicamente um algoritmo evolutivo é utilizado para busca do melhor circuito que atenda a mais de um objetivo. O algoritmo evolutivo utilizado é um algoritmo genético baseado no GAOT (*Genetic Algorithm Optimization Toolbox*) (HOUCK et al., 1996) e executado no Matlab. Para as simulações utilizou-se modelos matemáticos dos circuitos. O algoritmo genético empregado no trabalho segue o modelo apresentado na Figura 15.



Figura 15 – Etapas de execução do algoritmo genético.

O algoritmo é iniciado com uma população normalmente gerada de modo aleatório mas que também pode ser gerada a partir de uma semente com soluções potencialmente boas obtidas a partir de outros métodos.

A avaliação *tradicional* de aptidão é realizada a partir de uma função *fitness* definida pelo projetista. Tal função gera um número escalar para cada indivíduo avaliado, que corresponde à aptidão do indivíduo em relação ao objetivo estabelecido pela função definida. Caso não seja aplicado método algum de agregação, ela possibilita a avaliação de apenas um único objetivo. Neste trabalho a avaliação é realizada por um sistemas fuzzy, chamado de Agregador Fuzzy, que é capaz de agregar outros objetivos e que é descrito na próxima seção.

Uma escolha comum para a função de avaliação de aptidão é o cálculo do erro entre o resultado obtido para o indivíduo e a resposta esperada, que pode ser, por exemplo, o *MSE (Mean Squared Error)* ou o *RMSE (Root Mean Squared Error)*. A análise de erro pode ser realizada através de uma base de dados pré-existente, que pode ser obtida através de cálculo, experimentalmente ou pela execução de um sistema real, ou ainda através de dados experimentais obtidos durante o processo de evolução. Por exemplo, em sistemas de controle nos quais a planta é conhecida, pode-se utilizar o *Simulink* para simular o comportamento do sistema e obter uma resposta que é utilizada no cálculo da aptidão do controlador proposto.

O processo evolucionário é iniciado executando as operações de seleção, *crossover* e mutação sobre a população atual. As taxas destas operações são definidas pelo projetista antes do início do algoritmo. Analogamente, o tamanho da população e o número máximo de gerações são ajustados de acordo com a aplicação.

A evolução termina quando um determinado critério de parada é atingido. O critério de parada mais frequente é especificado por um certo número máximo de gerações. Outra possibilidade é estabelecer um valor de aptidão a ser atingido ou parar a execução do algoritmo quando não há evolução por um determinado número de gerações.

Tendo em vista que o GAOT apenas maximiza funções, em casos onde se deseja a minimização, pode ser usada a estratégia de inverter a função, ou seja, multiplica-se a função por -1 e busca-se o ponto máximo desta nova função.

4.2 Sistema Agregador Fuzzy

O método de avaliação de múltiplos objetivos utilizado neste trabalho é o chamado agregador fuzzy. Para isso deve ser concebido um sistema fuzzy capaz de agregar os diversos objetivos do projeto eletrônico. A proposta basicamente modifica a forma de avaliação tradicional dos AGs aplicados em eletrônica evolucionária e viabiliza a avaliação de múltiplos objetivos/especificações.

O sistema agregador fuzzy possibilita avaliar simultaneamente todos os objetivos, integrando as preferências e ou especificações do usuário em relação a cada objetivo e a cada situação, de modo natural. Tal característica é muito interessante em relação aos métodos multiobjetivos baseados na otimalidade de Pareto, pois não necessita da interferência do projetista para escolha da melhor solução ao final do processo evolutivo, visto que as preferências e/ou especificações são inseridas antes da evolução, de forma mais simples e interpretável através do sistema agregador fuzzy e assim o processo de evolucionário é guiado na direção de preferências pré-estabelecidas.

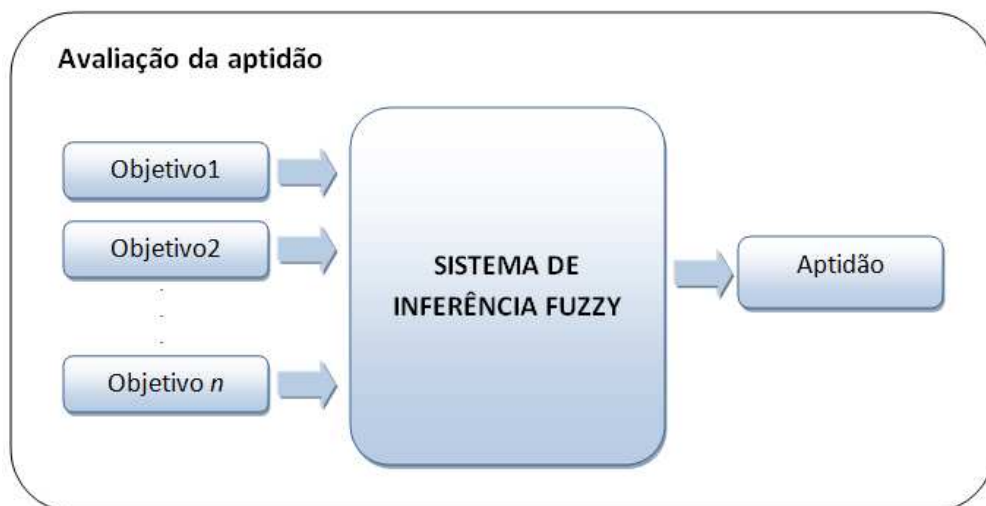


Figura 16 – Modelo de avaliação da aptidão com Sistema Agregador Fuzzy.

A Figura 16 ilustra o modelo da avaliação proposta.

Cada indivíduo da população do AG representa uma possível solução do problema. Durante o processo de avaliação, os indivíduos são aplicados à função ou modelo que descreve o problema e os resultados obtidos em relação a cada objetivo são utilizados como entradas do sistema fuzzy. Para cada indivíduo da população é aplicado o agregador fuzzy resultando em um valor de aptidão.

No Sistema Agregador Fuzzy cada entrada corresponde a um objetivo e as funções de pertinência são concebidas pelo projetista de acordo com o objetivo analisado. As funções de pertinência possuem formato triangular e trapezoidal.

Foi desenvolvido um modelo geral para agregação de dois objetivos, que pode ser usado como base para aplicação em qualquer problema. O modelo possui cinco funções de pertinência triangulares distribuídas uniformemente dentro do intervalo de 0 a 1 para as entradas, correspondendo aos limites de variação de cada entrada que deve ser normalizada para facilitar e generalizar a aplicação, conforme Figura 17.




Figura 17 – Funções de pertinência base para entradas.

Com base neste modelo de FPs podem ser feitas alterações de acordo com a aplicação. Por exemplo, ajustar os limites de alguma FP específica em uma determinada faixa desejada, reduzir o suporte ou alterar o valor em que a pertinência é máxima. Estes ajustes são realizados em casos em que há uma especificação bem definida ou se deseja melhorar o resultado obtido.

A saída defuzzificada do sistema fuzzy representa a avaliação geral de aptidão do indivíduo que está sendo avaliado. Para as funções de pertinência da saída é usado como padrão o formato mostrado na Figura 18, composto por cinco funções de pertinência.




Figura 18 – Funções de pertinência base para saída.

O sistema agregador fuzzy é do tipo Mamdani, caracterizado por ser mais simples e interpretável que sistemas do tipo TSK e todas as regras possuem o mesmo grau de importância, ou seja, peso igual a um.

As regras do sistema agregador fuzzy são elaboradas de modo a atender as especificações do problema considerando cada um dos objetivos.

Para exemplificar o processo de criação de regras, são mostradas na Tabela 1 regras básicas para minimização de dois objetivos sem preferência entre a minimização deles, ou seja, busca-se a minimização de ambos de forma igual. Assim, quando as entradas correspondem a um valor Muito Baixo geram uma avaliação de aptidão Muito Boa. Da mesma forma, entradas com um valor Muito Alto possuem uma avaliação de aptidão Muito Ruim.

Tabela 1 – Modelo base para regras de minimização.

Entrada 1 \ Entrada 2	<i>Muito Baixo</i>	<i>Baixo</i>	<i>Médio</i>	<i>Alto</i>	<i>Muito Alto</i>
<i>Muito Baixo</i>	Muito Boa	Muito Boa	Boa	Média	Ruim
<i>Baixo</i>	Muito Boa	Boa	Média	Média	Ruim
<i>Médio</i>	Boa	Média	Média	Ruim	Muito Ruim
<i>Alto</i>	Média	Média	Ruim	Muito Ruim	Muito Ruim
<i>Muito Alto</i>	Ruim	Ruim	Muito Ruim	Muito Ruim	Muito Ruim

No caso em que se deseja priorizar a minimização de um objetivo em relação ao outro, as regras devem ser modificadas para atender a esta preferência. Da mesma forma, caso o problema envolva a maximização, as mesmas regras podem ser utilizadas invertendo-se apenas os termos linguísticos dos antecedentes, ou o projetista pode criar um novo conjunto de regras. Os operadores utilizados no sistema são os operadores mínimo e máximo e a defuzzificação é realizada através do método do centro de gravidade.

Após a avaliação de todos os indivíduos da população da geração atual, o AG continua o processo de evolução da forma tradicional, até a avaliação da geração seguinte, onde o processo de avaliação através do sistema agregador fuzzy é novamente executado para todos os indivíduos, até que o critério de parada seja atingido.

A técnica apresentada neste trabalho é aplicada na evolução de circuitos e diversos estudos de caso são abordados no capítulo seguinte.

4.3 Evolução de Circuitos Eletrônicos

Para realizar a evolução de circuitos com múltiplos objetivos e o agregador fuzzy, o projeto deve ser realizado num ambiente simulado. A Figura 19 mostra um diagrama de blocos da proposta, ilustrando de uma forma geral as interligações existentes entre os componentes utilizados.

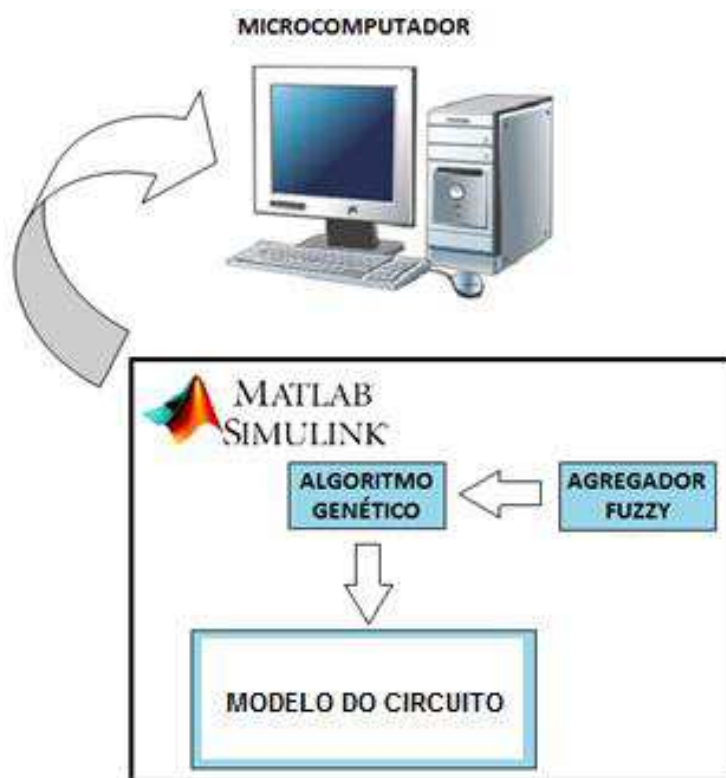


Figura 19 – Diagrama de Blocos.

Optou-se por uma implementação baseada puramente em simulação de modelos de circuitos, possibilitando um ambiente flexível para estudo de casos e viabilizando futuras aplicações. Evoluções de circuitos eletrônicos analógicos em áreas de aplicações distintas são avaliadas através de simulações computacionais.

5 ESTUDOS DE CASOS

Entre os estudos de casos são incluídos o projeto de um simples divisor de tensão, projeto de circuitos para sistemas fuzzy e o projeto de controladores PIDs analógicos.

Foram realizados os seguintes estudos de caso:

- Circuito divisor de tensão
- Circuitos para sistemas fuzzy
 - Circuito de função de pertinência “S”.
 - Circuito de função de pertinência “Z”
 - Circuito de função de pertinência triangular
- Controladores analógicos PID
 - Planta de 2ª ordem
 - Planta de 3ª ordem
 - Motor de Corrente Contínua

5.1 Circuito divisor de tensão

Como desenvolvimento inicial foi selecionado um circuito simples de um divisor de tensão. O circuito divisor está ilustrado na Figura 20.




Figura 20 – Circuito do divisor de tensão.

O algoritmo genético com agregador fuzzy multiobjetivo foi configurado para encontrar os melhores parâmetros (R1 e R2) deste simples divisor de tensão.

Os objetivos do projeto são *minimizar* o RMSE para uma saída equivalente à metade do sinal de entrada e também *minimizar* a soma dos resistores. Os resistores podem assumir valores entre 1kΩ e 10KΩ. A Tabela 2 ilustra os possíveis valores dos resistores R1 e R2, além dos valores ideais.

Tabela 2 – Valores de R1, R2, Vi e Vo para Circuito divisor

<i>Parâmetro</i>	<i>Possíveis Valores</i>	<i>Valores Ideais</i>
R1	1 kΩ - 10 kΩ	1 kΩ
R2	1 kΩ - 10 kΩ	1 kΩ
Vi	0 v – 10 v	-----
Vo	-----	$\frac{1}{2} .Vi$

Os parâmetros do algoritmo genético estão na Tabela 3.

Tabela 3 – Parâmetros os Algoritmo Genético para o Circuito Divisor

<i>Parâmetro</i>	<i>Valor</i>
Número de gerações	100
Número de indivíduos da população	100
Taxa de Cruzamento	80%
Taxa de Mutação	1%

A configuração utilizada para o sistema agregador fuzzy foi a sugerida na seção 4.2 para minimização de dois objetivos, repetida aqui por conveniência.

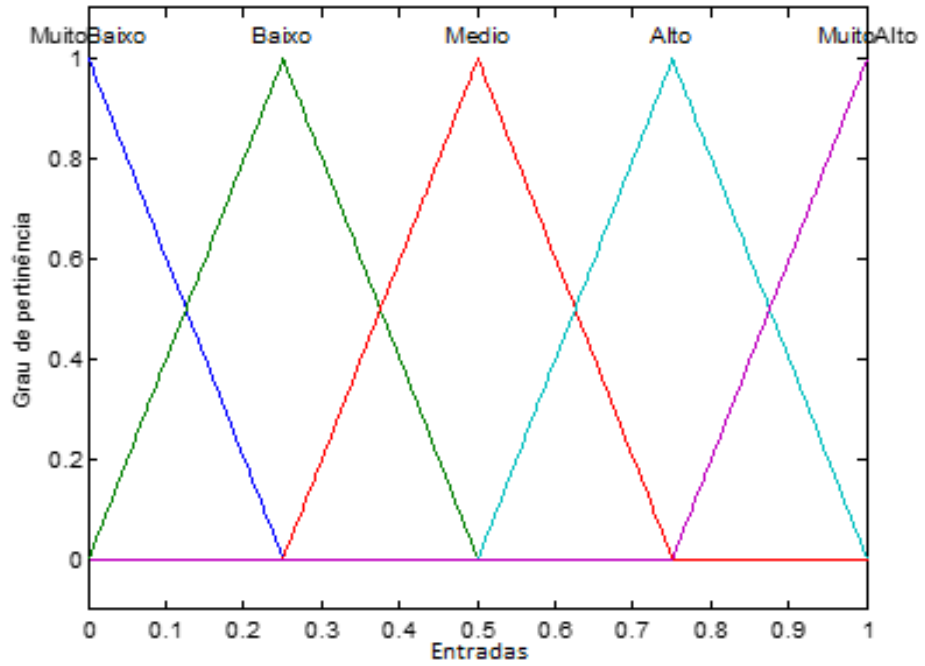


Figura 21 – FPs das entradas do agregador




Figura 22 – FPs da Aptidão

Tabela 4 – Regras para minimização dos 2 objetivos do Circuito Divisor

Entrada RMSE Entrada $\sum R$	<i>Muito Baixo</i>	<i>Baixo</i>	<i>Médio</i>	<i>Alto</i>	<i>Muito Alto</i>
<i>Muito Baixo</i>	Muito Boa	Muito Boa	Boa	Média	Ruim
<i>Baixo</i>	Muito Boa	Boa	Média	Média	Ruim
<i>Médio</i>	Boa	Média	Média	Ruim	Muito Ruim
<i>Alto</i>	Média	Média	Ruim	Muito Ruim	Muito Ruim
<i>Muito Alto</i>	Ruim	Ruim	Muito Ruim	Muito Ruim	Muito Ruim

Para o AG multiobjetivo com agregação ponderada utilizou-se a seguinte avaliação de aptidão:

$$\text{Aptidão} = 0.5 \times \frac{1}{1 + RMSE} + 0.5 \times \frac{\sum R_{\max} - \sum R}{\sum R_{\max}} \quad (7)$$

Para o sistema agregador fuzzy os objetivos foram normalizados entre 0 e 1 do seguinte modo:

$$\text{Entrada RMSE} = \frac{RMSE}{RMSE + 1} \quad (8)$$

$$\text{Entrada } \sum R = \frac{\sum R - \sum R_{\min}}{\sum R_{\max}} \quad (9)$$

Os resultados do teste estão dispostos na Tabela 5.

Tabela 5 – Resultados para o Circuito Divisor de Tensão

	AG Monoobjetivo	AG MULTIOBJETIVO	AG MULTIOBJETIVO COM AGREGADOR FUZZY
RMSE	0	0	0
$\sum R$	9,4k Ω	4,4k Ω	2k Ω

Observando os resultados, percebe-se que o AG Monoobjetivo foi capaz de minimizar o RMSE, no entanto, devido a existência de apenas um objetivo neste tipo de técnica, sua resposta, obviamente, não foi satisfatória na minimização da soma dos resistores do circuito. Contudo, nos algoritmos com multiobjetivo é possível afirmar que foram capazes de minimizar o RMSE para a saída e também foram capazes de encontrar bons valores para a soma dos resistores, principalmente quando se verifica a soma encontrada pelo algoritmo que possui agregador fuzzy, que foi capaz de encontrar os valores ideais.

Esta etapa de estudo com este circuito simples foi importante para investigar a viabilidade da aplicação da técnica proposta neste trabalho.

5.2 Circuitos para Funções de Pertinência

Com o grande avanço em pesquisas relacionadas a aplicações de sistemas fuzzy como controladores de sistemas cada vez mais complexos, torna-se interessante viabilizar a produção de circuitos analógicos capazes de implementar lógica fuzzy.

O objetivo aqui foi evoluir os valores dos componentes de topologias de circuitos conhecidas para realizar funções de pertinência.

5.2.1 Função de Pertinência “S”

Para a evolução de um circuito de função de pertinência “S” é necessária uma topologia capaz de gerar em sua saída uma tensão similar à apresentada na Figura 23.




Figura 23 – $V_o \times V_i$ para a Função de Pertinência “S”

A partir da Figura 23, é possível obter a descrição matemática que define a função, a saber:

$$V_o = \begin{cases} 0 & \text{se } V_i < 1 \\ 3V_i - 3 & \text{se } 1 \leq V_i \leq 2 \\ 3 & \text{se } V_i > 2 \end{cases} \quad (10)$$

Com isso, para dar prosseguimento a proposta, foi necessário utilizar um circuito que se comportasse de maneira linear quando a sua entrada do mesmo estivesse contida no intervalo $[1 , 2]$, além de fornecer 0v na saída quando a tensão aplicada na entrada estivesse em $[0 , 1]$ e 3v no intervalo $[2 , 3]$.

Um circuito adequado que possui essas características pode ser observado na Figura 24.




Figura 24 – Topologia selecionada para a Função de Pertinência “S”

O cálculo para a tensão de saída deste circuito, na região linear, é dado por:

$$V_o = \left(1 + \frac{R_1}{R_2} + \frac{R_1}{R_3}\right) \cdot V_i - 3 \frac{R_1}{R_2} \quad (11)$$

Para satisfazer os casos dos limites superior e inferior de 3V e 0V, respectivamente, é levada em consideração a saturação do AmpOp. Logo a alimentação superior no AmpOp é ajustada para 3,5v, devido à queda de tensão no CI em aproximadamente 0,5v, e a alimentação inferior é mantida em 0v.

Na região linear do AmpOp os valores das resistências são fundamentais para obtenção da curva desejada. Se observarmos novamente a equação 11, o comportamento do circuito é matematicamente representado por uma função do primeiro grau, onde ($y = ax + b$). Assim o foco da evolução é voltado para esta reta, definida por:

$$V_o = 3(V_i - 1) \quad (12)$$

Portanto, um dos objetivos para a busca dos valores dos resistores será minimizar o RMSE em relação a esta reta, onde V_i varia de 1v até 2v.

O outro objetivo será minimizar o consumo na fonte de +3V, para isso basta maximizar o valor do resistor R2, já que a corrente fornecida pela fonte é inversamente proporcional ao valor de R2:

$$I_{+3} = \frac{V_{+3}}{R2} \quad (13)$$

A tabela 6 apresenta os possíveis valores dos resistores R1, R2 e R3 assim como os seus valores ideais, de acordo com os objetivos previamente definidos.

Tabela 6 – Valores de R1, R2, R3 e V_i para a FP “S”

<i>Parâmetro</i>	<i>Possíveis Valores</i>	<i>Valores Ideais</i>
R1	1 k Ω - 10 k Ω	10 k Ω
R2	1 k Ω - 10 k Ω	10 k Ω
R3	1 k Ω - 10 k Ω	10 k Ω
V_i	0 v – 3 v	-----

Para esta evolução, os parâmetros utilizados encontram-se na Tabela 7.

Tabela 7 – Parâmetros dos Algoritmos Genéticos

<i>Parâmetro</i>	<i>Valor</i>
Número de gerações	100
Número de indivíduos da população	100
Taxa de Cruzamento	80%
Taxa de Mutação	1%

A configuração do sistema agregador fuzzy foi similar à que foi utilizada no estudo de caso do Divisor de Tensão, sendo que as regras foram alteradas de forma a *minimizar* o RMSE e *maximizar* R2. A matriz de regras está apresentada na Tabela 8.

Tabela 8 – Matriz de Regras para Circuito FP “S”

Entrada RMSE Entrada R	<i>Muito Baixo</i>	<i>Baixo</i>	<i>Médio</i>	<i>Alto</i>	<i>Muito Alto</i>
<i>Muito Alto</i>	Muito Boa	Muito Boa	Boa	Média	Ruim
<i>Alto</i>	Muito Boa	Boa	Média	Média	Ruim
<i>Médio</i>	Boa	Média	Média	Ruim	Muito Ruim
<i>Baixo</i>	Média	Média	Ruim	Muito Ruim	Muito Ruim
<i>Muito Baixo</i>	Ruim	Ruim	Muito Ruim	Muito Ruim	Muito Ruim

Para o AG multiobjetivo com agregação ponderada utilizou-se a seguinte avaliação de aptidão:

$$\text{Aptidão} = 0,5 \times \frac{1}{1 + RMSE} + 0,5 \times \frac{R2}{R2_{\max}} \quad (14)$$

Para o sistema agregador fuzzy os objetivos foram normalizados entre 0 e 1 do seguinte modo:

$$\text{Entrada RMSE} = \frac{RMSE}{RMSE + 1} \quad (15)$$

$$\text{Entrada } R2 = \frac{R2}{R2_{\max}} \quad (16)$$

A Figura 25 apresenta um gráfico de avaliação do melhor indivíduo e da média dos indivíduos por geração do Algoritmo Genético Multiobjetivo com agregador fuzzy.

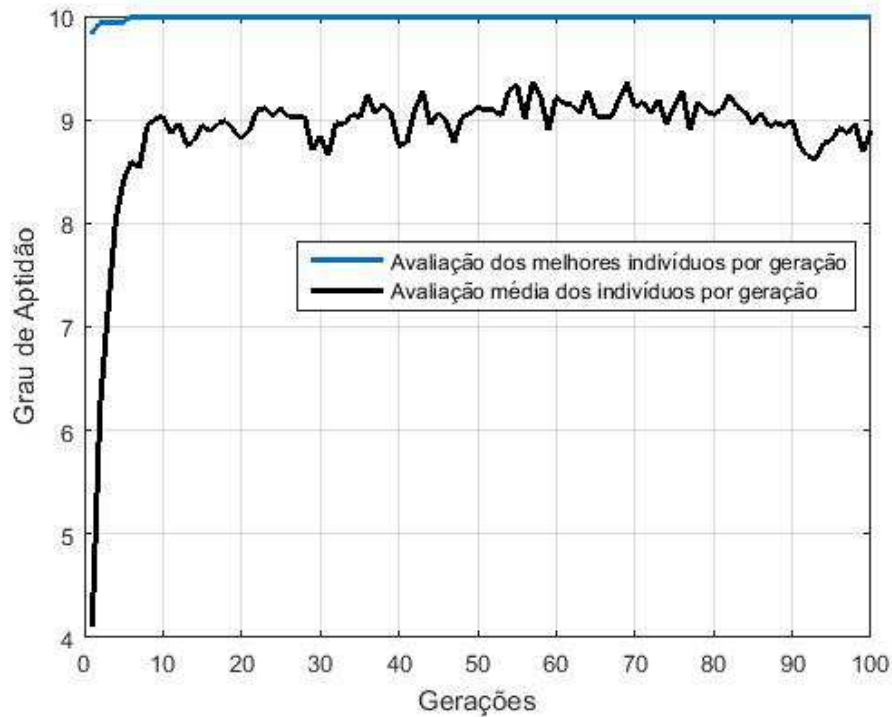


Figura 25 – Evolução do circuito da FP “S”

Os resultados das evoluções são apresentados na Tabela 9.

Tabela 9 – Resultados para o circuito da FP “S”

	AG Monoobjetivo	AG MULTIOBJETIVO	AG MULTIOBJETIVO COM AGREGADOR FUZZY
RMSE	0	0	0
R1	3,3 k Ω	8,2 k Ω	10 k Ω
R2	3,3 k Ω	8,2 k Ω	10 k Ω
R3	3,3 k Ω	8,2 k Ω	10 k Ω

5.2.2 Função de Pertinência “Z”

Para evolução de um circuito de função de pertinência “Z”, é necessário utilizar uma topologia de circuito capaz de gerar em sua saída uma tensão similar a apresentada na Figura 26.




Figura 26 – Vo X Vi para a Função de Pertinência “Z”

A FP “Z” pode ser representada matematicamente por::

$$V_o = \begin{cases} 3 & \text{se } V_i < 1 \\ -3(V_i - 2) & \text{se } 1 \leq V_i \leq 2 \\ 0 & \text{se } V_i > 2 \end{cases} \quad (17)$$

Com isso, assim como na FP “S”, basta utilizar um circuito que se comporte de maneira linear quando sua entrada estiver contida no intervalo [1 , 2], no entanto,

na FP “Z” sua saída deve fornecer 3v quando a tensão aplicada na entrada estiver em [0 , 1] e 0v no intervalo [2 , 3].

O circuito que possui essas características pode ser observado na Figura 27.




Figura 27 – Topologia selecionada para o Circuito da FP “Z”

Para este circuito, a equação para a tensão de saída é dada por:

$$V_o = -\frac{R_1}{R_4} V_i + 3 \cdot \frac{R_3}{R_4} \left(\frac{R_1 + R_4}{R_2 + R_3} \right) \quad (18)$$

De modo análogo ao que foi realizado para a função de pertinência “S”, analisa-se apenas a região linear do AmpOp, para então calcular o RMSE. A equação que caracteriza a relação da tensão de saída com a tensão de entrada durante a região linear no amplificador deve ser:

$$V_o = -3(V_i - 2) \quad (19)$$

O primeiro objetivo dessa evolução é o mesmo do circuito de FP “S”, ou seja, *minimizar* o RMSE em relação à reta da equação 19.

O segundo objetivo também é minimizar o consumo da fonte de +3v, porém neste caso, considerando que a corrente de entrada no polo positivo do Amp.Op é muito inferior a corrente fornecida pela fonte, obtém-se a seguinte expressão para esta corrente:

$$I_{+3} = \frac{V_{+3}}{R2 + R3} \quad (20)$$

Então a soma de R2 com R3 deverá ser *maximizada* para minimização do consumo.

A Tabela 10 apresenta os possíveis valores dos resistores R1, R2 e R3 e os seus valores ideais, de acordo com os objetivos previamente definidos.

Tabela 10 – Valores de R1-R4 e Vi

<i>Parâmetro</i>	<i>Possíveis Valores</i>	<i>Valores Ideais</i>
R1	1 kΩ - 10 kΩ	3 x R4
R2	1 kΩ - 10 kΩ	10 kΩ
R3	1 kΩ - 10 kΩ	10 kΩ
R4	1 kΩ - 10 kΩ	-----
Vi	0 v – 3 v	-----

Para esta evolução, os parâmetros utilizados encontram-se na Tabela 11.

Tabela 11 – Parâmetros para os AGs de evolução do circuito para FP “Z”

<i>Parâmetro</i>	<i>Valor</i>
Número de gerações	100
Número de indivíduos da população	100
Taxa de Cruzamento	80%
Taxa de Mutação	1%

A configuração do sistema agregador fuzzy foi similar à utilizada para o circuito FP “S”. Para este sistema os objetivos foram normalizados entre 0 e 1 do seguinte modo:

$$\text{Entrada RMSE} = \frac{RMSE}{RMSE + 1} \quad (21)$$

$$\text{Entrada (R2+R3)} = \frac{R2 + R3}{R2_{\max} + R2_{\max}} \quad (22)$$

Para o AG multiobjetivo com agregação ponderada utilizou-se a seguinte avaliação de aptidão:

$$\text{Aptidão} = 0.5 \times \frac{1}{1 + RMSE} + 0.5 \times \frac{R2 + R3}{R2_{\max} + R2_{\max}} \quad (23)$$

Na Figura 28 é apresentado um gráfico de avaliação do melhor indivíduo e da média dos indivíduos por geração do AG MO com agregador fuzzy.

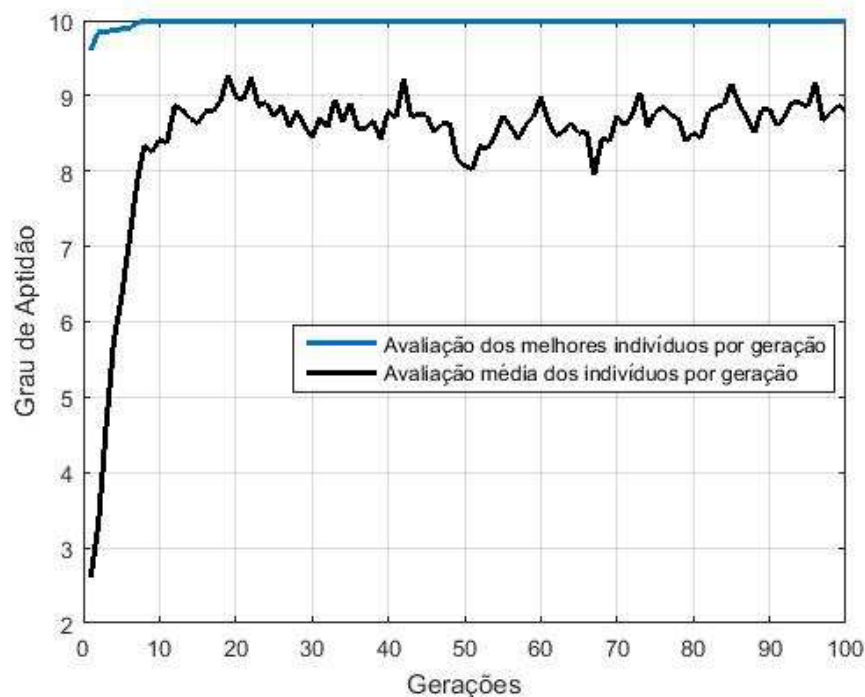


Figura 28 – Evolução para o Circuito da FP “Z”

O resultado final encontra-se na Tabela 12.

Tabela 12 – Resultados para o circuito da FP “Z”

	AG Monoobjetivo	AG MULTIOBJETIVO	AG MULTIOBJETIVO COM AGREGADOR FUZZY
RMSE	0,26	0,13	0,13
R1	6,8 kΩ	8,2 kΩ	8,2 kΩ
R2	3,9 kΩ	10 kΩ	10 kΩ
R3	3,9 kΩ	10 kΩ	10 kΩ
R4	2,2 kΩ	2,7 kΩ	2,7 kΩ

5.2.3 Função de Pertinência Triangular

Por fim, a topologia do último circuito de função de pertinência deverá fornecer uma tensão de saída em relação à tensão de entrada conforme ilustrado na Figura 29.




Figura 29 – $V_o \times V_i$ para o Circuito da FP Triangular

A partir da Figura 29, é possível definir a função matemática desejada para o circuito da FP triangular, conforme descrito em (24).

$$V_o = \begin{cases} 6V_i - 6 & \text{se } 1 \leq V_i < 1,5 \\ -6V_i + 12 & \text{se } 1,5 \leq V_i < 2 \\ 0 & \text{se } V_i < 2 \text{ ou } V_i > 1 \end{cases} \quad (24)$$

A função de pertinência triangular pode ser obtida como a soma das funções de pertinência “S” e “Z”, portanto para obter tal função é necessário implementar um circuito que some o circuito de função “S” e o circuito de função “Z” de tal forma que essa associação forneça uma tensão de saída no formato triangular.

A topologia de circuito implementada, que satisfaz essa condição está representada na Figura 30.




Figura 30 – Topologia para evolução do Circuito da FP Triangular

Note que nesta topologia, o AmpOp do bloco inferior é alimentado negativamente, pois é necessário que a função de pertinência “Z” aplicada para gerar a função triangular esteja deslocada verticalmente..

A tensão de saída possui a seguinte expressão:

$$V_o = \frac{1}{R_2} \left(\frac{R_2 + R_1}{R_3 + R_4} \right) \left[\left(R_4 + \frac{R_4 R_5}{R_6} + \frac{R_4 R_5}{R_7} - \frac{R_3 R_{11}}{R_{10}} \right) V_i + 3 \cdot \frac{R_3 R_9}{R_{10}} \left(\frac{R_{11} + R_{10}}{R_8 + R_9} \right) - 3 \cdot \frac{R_4 R_5}{R_6} \right] \quad (25)$$

O primeiro objetivo dessa evolução é *minimizar* o RMSE em relação à definição matemática apresentada em (24).

O segundo objetivo é minimizar o somatório de resistores do circuito.

Os parâmetros do circuito que devem ser evoluídos e os parâmetros do algoritmo genético são apresentados nas Tabela 13 e 14.

Tabela 13 – Valores a serem evoluídos para o Circuito da FP Triangular

<i>Parâmetro</i>	<i>Possíveis Valores</i>
R1	1 kΩ - 10 kΩ
R2	1 kΩ - 10 kΩ
R3	1 kΩ - 10 kΩ
R4	1 kΩ - 10 kΩ
R5	1 kΩ - 10 kΩ
R6	1 kΩ - 10 kΩ
R7	1 kΩ - 10 kΩ
R8	1 kΩ - 10 kΩ
R9	1 kΩ - 10 kΩ
R10	1 kΩ - 10 kΩ
R11	1 kΩ - 10 kΩ

Tabela 14 – Parâmetros do AG para evolução da FP Triangular

<i>Parâmetro</i>	<i>Valor</i>
Número de gerações	100
Número de indivíduos da população	100
Taxa de Cruzamento	80%
Taxa de Mutação	1%

A configuração do sistema agregador fuzzy foi similar à utilizada para o circuito FP “S”. Para este sistema os objetivos foram normalizados entre 0 e 1 do seguinte modo:

$$\text{Entrada RMSE} = \frac{RMSE}{RMSE+1} \quad (26)$$

$$\text{Entrada } (\sum R) = \frac{\sum R}{\sum R_{max}} \quad (27)$$

Para o AG multiobjetivo com agregação ponderada utilizou-se a seguinte avaliação de aptidão:

$$\text{Aptidão} = 0,5 \times \frac{1}{1+RMSE} + 0,5 \times \frac{\sum R_{max} - \sum R}{\sum R_{max}} \quad (28)$$

Os resultados obtidos são apresentados na Tabela 15:

Tabela 15 – Resultados para o circuito da FP Triangular

	AG Monoobjetivo	AG MULTIOBJETIVO	AG MULTIOBJETIVO COM AGREGADOR FUZZY
RMSE	0,16	0,21	0,13
$\sum R$	51,7 kΩ	24,2 kΩ	9,02 kΩ

5.3 Circuitos de Controladores PID Analógicos

Sistemas de controle são necessários em diversos campos de atuação. Obter um processo estável implica em resultados mais eficientes, produtos de melhor qualidade, diminuição do reprocessamento, economia de matéria prima, entre outros fatores altamente importantes, seja em uma indústria, laboratório ou qualquer ambiente que demanda um controle eficiente. Os controladores clássicos PID (Proporcional Integral Derivativo) possuem uma aplicabilidade geral na maioria dos sistemas de controle e correspondem a grande parte dos controladores industriais. Desta forma, um ajuste de seus parâmetros de controle é essencial para um processo estável.

Desde o aparecimento do primeiro método de sintonia para controladores, proposto por ZIEGLER & NICHOLS em 1942, várias técnicas de ajuste de PID têm sido propostas na literatura, entre elas técnicas de controle inteligente, como a lógica fuzzy, redes neurais e algoritmos genéticos.

Baseando-se nesta necessidade, foram desenvolvidos neste trabalho alguns estudos aplicados à sintonia de controladores PID para obter um desempenho adequado de controle. Para isso, utiliza-se a técnica de busca de um algoritmo genético para encontrar os melhores ganhos do controlador, ou seja, os ganhos proporcional, integral e derivativo (K_p , K_i e K_d).

A otimização multiobjetivo é aplicada neste problema com o intuito de obter o melhor sistema de acordo com cada necessidade de projeto.

O primeiro passo em projetos de sistemas de controle é a obtenção de um modelo matemático do sistema; a partir disso é possível analisar o seu desempenho.

Na análise do sistema de controle são utilizados sinais de entrada como referência que possibilitem uma comparação de desempenho com base em determinadas especificações. Entre as principais especificações consideradas no domínio do tempo destacam-se o *overshoot* ou máximo valor de ultrapassagem (M_p), o tempo de subida (t_r), o tempo de acomodação (t_s) e o tempo de atraso (t_d). A Figura 31 mostra esses quatro parâmetros.




Figura 31 – Resposta de um sistema de controle.

Neste trabalho, optou-se por analisar três objetivos: o *overshoot*, o tempo de subida e o tempo de acomodação. Assim, o agregador fuzzy implementado possui três entradas e uma saída.

O *overshoot* corresponde ao ponto máximo obtido além do sinal de referência. O tempo de subida é o tempo necessário para o sinal de saída variar de 10 a 90% do valor final. O tempo de acomodação corresponde ao tempo gasto para o valor se acomodar em uma faixa (e_{ss}), geralmente 2% ou 5%, do valor final e o tempo de atraso é o tempo gasto para o sinal alcançar 50% do valor final.

As funções de pertinência utilizadas para avaliação foram criadas a partir das especificações requeridas. Como o *overshoot* é medido em porcentagem foi utilizada uma escala de 0 a 100% como mostrado na Figura 32.




Figura 32 – Função de pertinência da variável de entrada Overshoot.

Para valores acima de 45% o *overshoot* é considerado *Muito Alto* e acima de 55% não é mais aceitável. Valores abaixo de 12% são considerados ideais e, portanto, caracterizam o termo linguístico *Baixo*. Valores em faixas intermediárias são considerados *Médio* ou *Alto*.

Para o tempo de subida foi considerado que um tempo acima de 1 segundo começa a ser *Muito Alto*, assim como um tempo abaixo de 0,4 segundo é *Baixo* e desejável, conforme ilustrado na Figura 33.




Figura 33 - Função de pertinência da variável de entrada Tempo de Subida.

O tempo de acomodação foi representado pelos três conjuntos (*Baixo*, *Médio* e *Alto*), mostrados na Figura 34.




Figura 34 - Função de pertinência da variável de entrada Tempo de Acomodação.

As FPs para a saída são iguais às utilizadas nos estudos de casos anteriores.

As regras foram criadas de forma a minimizar os três objetivos. Um valor *Alto* em qualquer um dos objetivos é considerado *Ruim* e da mesma forma um valor *Muito Alto* é considerado *Muito Ruim*. As 11 regras criadas para o agregador fuzzy aplicado a sistemas de controle são mostradas na Tabela 16.

<i>Overshoot</i>	<i>Tempo de Subida</i>	<i>Tempo de Acomodação</i>	<i>Aptidão</i>
Baixo	Baixo	-	Muito Bom
Baixo	Médio	-	Bom
Médio	Baixo	-	Bom
Médio	Médio	-	Médio
Alto	-	-	Ruim
Muito Alto	-	-	Muito Ruim
-	Alto	-	Ruim
-	Muito Alto	-	Muito Ruim
-	-	Baixo	Muito Bom
-	-	Médio	Bom
-	-	Alto	Muito Ruim

A implementação eletrônica para a topologia dos controladores PID analógicos utilizados neste trabalho encontra-se em (OGATA, 2003) e está ilustrada na Figura 35.




Figura 35 – Topologia do Circuito base para os Controladores PID analógicos

A função de transferência desse circuito é dada por:

$$\frac{E_o(s)}{E_i(s)} = \frac{R_4 R_2 (R_1 C_1 s + 1)(R_2 C_2 s + 1)}{R_3 R_1 R_2 C_2 s} \quad (29)$$

A evolução é realizada considerando o cromossoma representando os seis componentes utilizados para o cálculo da função de transferência (29). O cromossoma está ilustrado na Figura 36. A partir desses parâmetros, é possível calcular K_p , K_i e K_d (equações 30, 31 e 32).

R_1	R_2	R_3	R_4	C_1	C_2
-------	-------	-------	-------	-------	-------

Figura 36 – Cromossomo para Evolução dos Controladores PID

$$K_p = \frac{R_4(R_1 C_1 + R_2 C_2)}{R_3 R_1 C_2} \quad (30)$$

$$K_i = \frac{R_4}{R_3 R_1 C_2} \quad (31)$$

$$K_d = \frac{R_4 R_2 C_1}{R_3} \quad (32)$$

O intervalo de busca situa-se entre 0 e 100k Ω para os resistores e de 1KpF até 100 μ F para os capacitores.

Os parâmetros utilizados para configuração da evolução do AG estão mostrados na Tabela 17.

Tabela 17 – Parâmetros de evolução do AG para sistemas de controle.

<i>Parâmetro</i>	<i>Valor</i>
Número de gerações	100
Número de indivíduos da população	100
Taxa de Cruzamento	70%
Taxa de Mutação	1%

Para as plantas analisadas foram feitas comparações com os resultados de um AG com avaliação tradicional e com resultados de técnicas tradicionais para sintonia de parâmetros.

5.3.1 Planta de 2ª ordem

Uma planta de 2ª ordem (33) foi utilizada como primeiro estudo de caso (OGATA, 2003).

$$G(s) = \frac{4}{s^2 + 0,5s} \quad (33)$$

A Figura 37 ilustra o sistema de controle implementado no *Simulink*, com a aplicação de um degrau unitário na entrada e é desejável que o controlador possibilite a obtenção de uma resposta próxima deste sinal de entrada aplicado.




Figura 37 - Diagrama do sistema de controle de 2ª ordem.

Em OGATA (2003) é desenvolvido um compensador analítico $G_c(s)$ para este sistema, cuja função de transferência é:

$$G_c(s) = \frac{10(2s+1)(5s+1)}{(0,1992s+1)(80,19s+1)} \quad (34)$$

Neste trabalho foram executados um algoritmo genético mono objetivo com a finalidade de minimizar o RMSE e o algoritmo multiobjetivo utilizando o agregador fuzzy para minimizar o *overshoot*, o tempo de subida e o tempo de acomodação. O compensador analítico apresentado em (34) foi usado para comparação com os controladores PID obtidos pelos algoritmos genéticos.

A Tabela 18 apresenta os valores dos ganhos encontrados pelos dois AGs:

Tabela 18 – Comparação de ganhos para planta de 2ª ordem.

	<i>AG Mono objetivo</i>	<i>AG com Agregador Fuzzy – Três objetivos</i>
<i>Kp</i>	100	99,9996
<i>Ki</i>	0,0001	0,2436
<i>Kd</i>	4,7514	8,3985

A Tabela 19 apresenta os valores para o *overshoot*, o tempo de subida e o tempo de acomodação que foram obtidos pelos três métodos considerados.

Tabela 19 – Comparação dos parâmetros de avaliação para planta de 2ª ordem.

	<i>Compensador Analítico</i>	<i>AG Mono objetivo</i>	<i>AG com Agregador Fuzzy - Três objetivos</i>
<i>Overshoot (%)</i>	21,1612	17,1186	0,4982
<i>Tempo de subida (s)</i>	0,3159	0,0806	0,1342
<i>Tempo de acomodação (s)</i>	3,4010	0,4041	0,2123

A Figura 38 apresenta as respostas a um degrau unitário obtidas em uma simulação de 15 segundos.

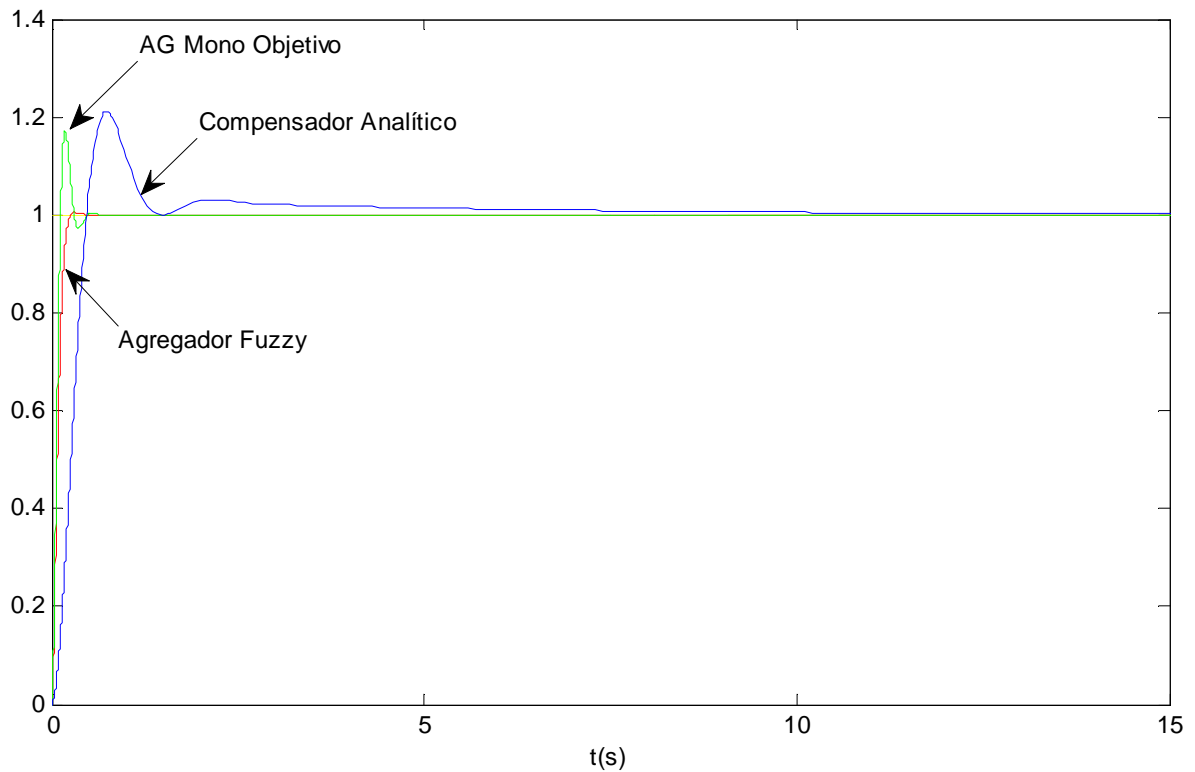


Figura 38 - Resposta a um degrau unitário pelas três técnicas analisadas.

Obseva-se que a resposta obtida pelo AG com agregação fuzzy obteve os menores *overshoot* e tempo de acomodação. O tempo de subida alcançado pelo AG mono objetivo foi o menor, porém o *overshoot* foi muito maior do que o obtido pelo agregador fuzzy, o que não é desejável. O compensador analítico obteve valores mais elevados nos três parâmetros analisados.

Deste modo, os resultados obtidos mostram que o método de agregação fuzzy conseguiu minimizar os três parâmetros de forma adequada e satisfatória obtendo bons resultados em comparação com demais controladores.

O circuito evoluído é amostrado na Figura 39.




Figura 39 – Controlador analógico PID evoluído

5.3.2 Planta de 3ª ordem

O segundo estudo de caso de controle corresponde a uma planta de 3ª ordem (35) apresentada em (OGATA, 2003).

$$G(s) = \frac{1}{s(s+1)(s+5)} \quad (35)$$

A Figura 40 mostra um diagrama do sistema de controle proposto, onde um degrau unitário é aplicado a entrada do sistema em malha fechada.




Figura 40 – Diagrama do sistema de controle de 3ª ordem.

Foram usados para comparação os valores de ganho obtidos pelo método de Ziegler-Nichols e estes valores ajustados por um especialista (OGATA, 2003). Além

disso, foram considerados os valores encontrados pelo algoritmo genético de um objetivo utilizando a minimização do RMSE para avaliação.

A comparação entre os valores de ganho obtidos para os quatro métodos analisados pode ser vista na Tabela 20:

Tabela 20 – Comparação de ganhos para planta de 3ª ordem.

	<i>Ziegler-Nichols</i>	<i>Ziegler-Nichols ajustado</i>	<i>AG Mono objetivo</i>	<i>Agregador Fuzzy Três objetivos</i>
<i>Kp</i>	18	39,42	49,9999	49,9995
<i>Ki</i>	12,81	12,81	0,0740	0,0069
<i>Kd</i>	6,32	30,32	20,6995	23,6521

A Tabela 21 apresenta os valores para o *overshoot*, tempo de subida e tempo de acomodação obtidos com os ganhos mostrados na Tabela 20.

Tabela 21 – Comparação dos parâmetros de avaliação para planta de 3ª ordem.

	<i>Ziegler-Nichols</i>	<i>Ziegler-Nichols ajustado</i>	<i>AG Mono objetivo</i>	<i>Agregador Fuzzy Três objetivos</i>
<i>Overshoot (%)</i>	75,4927	17,2373	10,1298	2,4089
<i>Tempo de subida (s)</i>	0,6523	0,8904	0,5469	0,5999
<i>Tempo de acomodação (s)</i>	10,4082	8,3869	2,2542	2,0993

A Figura 41 apresenta as respostas a um degrau unitário em uma simulação realizada no *Simulink* para um tempo total de simulação é igual a 20 segundos.




Figura 41 – Resposta a um degrau unitário pelas quatro técnicas de sintonia.

Os resultados mostram que o método de agregação fuzzy conseguiu minimizar os três parâmetros de forma adequada. Comparado aos outros métodos, obteve os menores *overshoot* e tempo de acomodação. O menor tempo de subida foi obtido pelo AG mono objetivo, porém bem próximo daquele obtido pelo agregador fuzzy. O método de Ziegler Nichols obteve os maiores valores para os três parâmetros analisados, porém após o ajuste conseguiu uma redução dos valores. Novos ajustes poderiam ser realizados, porém esta não é uma tarefa trivial e requer grande conhecimento do especialista.

Desta forma, conclui-se que o método de agregação fuzzy conseguiu obter valores satisfatórios para os ganhos de um controlador PID gerando um sistema de controle adequado.

O circuito do controlador PID analógico para a planta de 3ª ordem está ilustrado na Figura 42.




Figura 42 – Circuito controlador PID Analógico para a planta de 3^a ordem

5.3.3 Motor CC

Este estudo de caso envolve uma planta que representa um servomotor de corrente contínua controlado pela armadura com características não-lineares de saturação.

Os motores de corrente contínua (CC) são amplamente utilizados em servossistemas e são chamados de servomotores de corrente contínua.

Estes servomotores possuem a inércia do motor bastante reduzida, o que resulta em motores com alta relação entre o torque e o momento de inércia. Servomotores CC de baixa potência possuem aplicação em instrumentos e equipamentos periféricos de computadores, enquanto servomotores de média e alta potência são aplicados em sistemas robóticos, por exemplo.

A Figura 43 apresenta o modelo de um servossistema. O objetivo do sistema é controlar a posição da carga mecânica de acordo com a posição de referência.

O sistema opera com um par de potenciômetros que agem como dispositivo de erro, em que convertem as posições de entrada e saída em sinais elétricos proporcionais. O sinal de erro é amplificado pelo amplificador de ganho K_1 e a tensão é aplicada ao circuito de armadura do motor CC. Uma tensão fixa é aplicada ao enrolamento de campo e quando existe um erro, o motor desenvolve um torque para girar a carga de forma a reduzir o erro à zero.

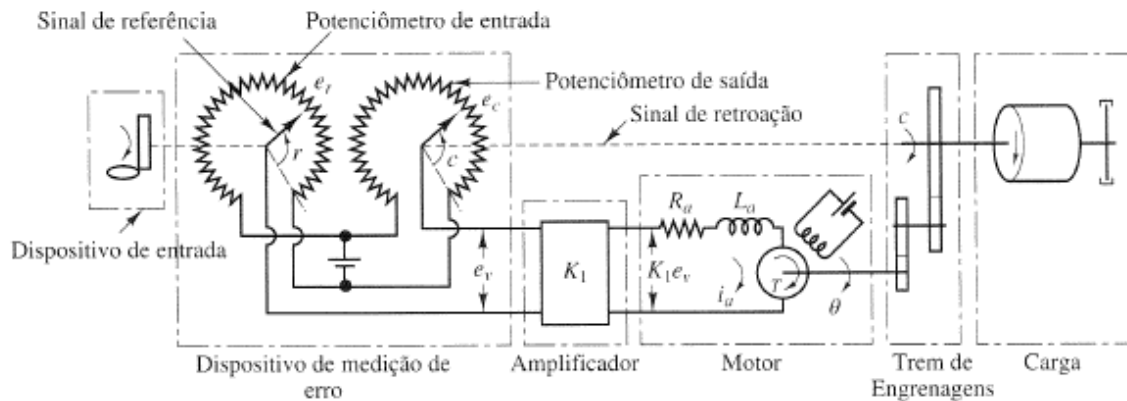


Figura 43 – Diagrama do servossistema de um motor de corrente contínua (OGATA, 2003).

Os procedimentos tradicionais para determinar as soluções de problemas envolvendo sistemas não lineares são, geralmente, bastante complexos. Para reduzir esta complexidade, muitas vezes utiliza-se um processo de linearização no qual o sistema é substituído por um sistema linear equivalente, válido para uma determinada faixa de operação.

Toda a descrição do funcionamento do motor e o desenvolvimento para obtenção da função de transferência estão descritos em detalhes em (OGATA, 2003).

Desta forma, a função de transferência do sistema é descrita pela equação (36):

$$G(s) = \frac{K_0 K_1 K_2 n}{s[(L_a s + R_a)(J_0 s + b_0) + K_2 K_3]} \quad (36)$$

Como o valor de L_a (indutância do enrolamento da armadura) é normalmente pequeno, ele pode ser desprezado. Assim, pode-se simplificar a função de transferência segundo a equação (37):

$$G(s) = \frac{K_m}{s(T_m s + 1)} \quad (37)$$

onde:

$$K_m = \frac{nK_0K_1K_2}{R_a b_0 + K_2K_3} \quad (38)$$

e

$$T_m = \frac{R_a J_0}{R_a b_0 + K_2K_3} \quad (39)$$

A definição dos parâmetros do modelo e das equações e os seus valores utilizados são conforme mostrados a seguir (OGATA, 2003):

r = deslocamento angular do eixo de entrada

c = deslocamento angular do eixo de saída

θ = deslocamento angular do eixo do motor

K_0 = ganho do potenciômetro detector de erro = $24 / \pi$

K_1 = ganho do amplificador = 10

e_a = tensão elétrica aplicada ao círculo de armadura

e_b = força eletromotriz

R_a = resistência do enrolamento de armadura = $0,2 \Omega$

L_a = indutância do enrolamento de armadura = desprezível

i_a = corrente no enrolamento de armadura

K_3 = constante de força eletromotriz = $5,5 \times 10^{-2} \text{Vs} / \text{rad}$

K_2 = constante de torque do motor = $6 \times 10^{-5} \text{Nm} / \text{A}$

J_m = momento de inércia do motor referido ao eixo do motor = $1 \times 10^5 \text{kgm}^2$

b_m = coeficiente de atrito viscoso do motor referido ao eixo do motor = desprezível

J_L = momento de inércia da carga referido ao eixo de saída = $4,4 \times 10^3 \text{kgm}^2$

b_L = coeficiente de atrito viscoso da carga referido ao eixo de saída = $4 \times 10^2 \text{Nm}(\text{rad} \cdot \text{s})$

n = relação de engrenagens $N_1 / N_2 = 1/10$

O momento de inércia equivalente J_0 e o coeficiente de amortecimento viscoso b_0 , referidos ao eixo do motor, são calculados conforme as equações a seguir:

$$J_0 = J_m + n^2 J_L \quad (40)$$

$$b_0 = b_m + n^2 b_L \quad (41)$$

Com estes valores, a função de transferência do motor CC é dada por:

$$G(s) = \frac{5,5}{s(0,13s+1)} \quad (42)$$

Na Figura 44 é apresentado o diagrama de blocos do servossistema do motor CC com realimentação negativa e degrau aplicado a entrada. Este sistema foi implementado no *Simulink* e utilizado para avaliação.




Figura 44 – Diagrama do sistema de controle para servossistema do motor CC.

Para este estudo foram obtidos dois controladores através de técnicas mono objetivo e multiobjetivo:

- Controlador PID sintonizado por AG mono objetivo (minimização do RMSE);
- Controlador PID sintonizado por AG multiobjetivo com Agregador Fuzzy (três objetivos: minimização do *overshoot*, do tempo de subida e do tempo de acomodação);

Os ganhos obtidos após a evolução para os dois controladores PID são mostrados na Tabela 22.

Tabela 22 – Comparação dos ganhos PID para planta do motor CC.

	<i>Controlador PID – AG Mono objetivo</i>	<i>Controlador PID – Agregador Fuzzy com três objetivos</i>
<i>Kp</i>	18,7994	19,9213
<i>Ki</i>	0	0,0097
<i>Kd</i>	0,6250	0,9747

Para os controladores obtidos foram calculados os valores do *overshoot*, tempo de subida e tempo de acomodação. Estes valores são mostrados na Tabela 23.

Tabela 23 – Comparação entre os controladores PID para planta do motor CC.

	<i>Controlador PID - AG Mono objetivo</i>	<i>Controlador PID - Agregador Fuzzy com três objetivos</i>
<i>Overshoot</i>	8,79%	0,50%
<i>Tempo de subida</i>	0,066s	0,091s
<i>Tempo de acomodação</i>	0,209s	0,144s

A Figura 45 apresenta a resposta ao degrau dos controladores desenvolvidos para o motor CC durante uma simulação de 10 segundos.

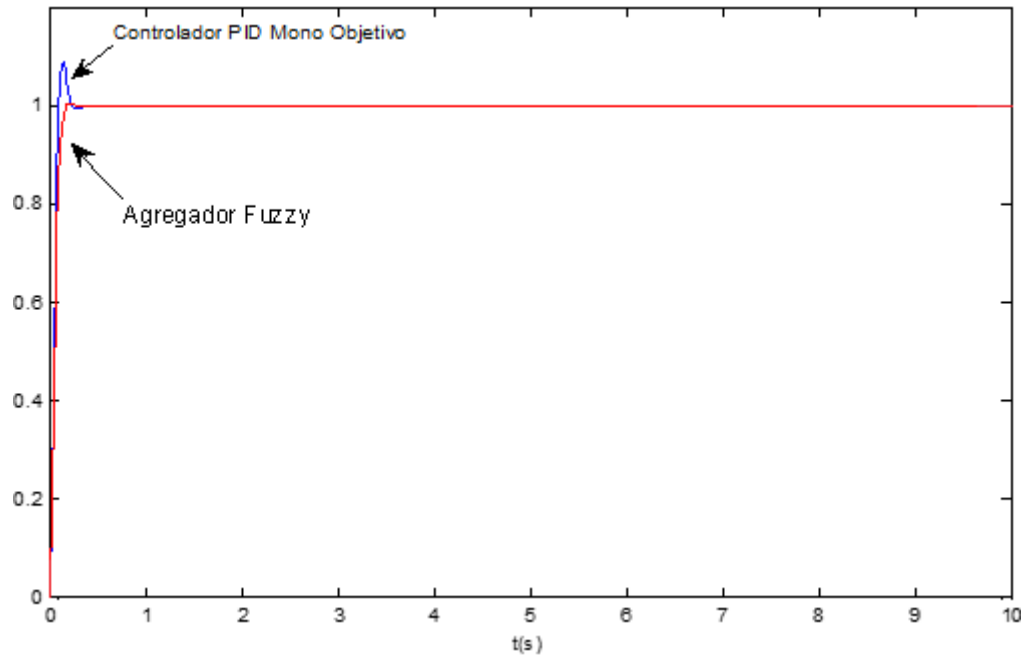


Figura 45 – Resposta ao degrau unitário obtida pelos controladores.

Com os resultados obtidos é possível observar que os controladores apresentaram desempenho satisfatório e que o controlador com agregador fuzzy multiobjetivo obteve um valor de overshoot bem inferior ao proporcionado pelo AG mono. Os tempos de subida foram similares e ambos os controladores alcançaram erro praticamente nulo em regime permanente. O circuito é apresentado na Figura 46.




Figura 46 – Circuito do controlador PID Analógico para o controle do motor CC

6 CONSIDERAÇÕES FINAIS

6.1 Conclusões

Neste trabalho foi utilizado um modelo evolucionário para o desenvolvimento de circuitos eletrônicos analógicos, o qual usa um método para avaliação que considera mais de um objetivo e utiliza, para isso, um processo de agregação de objetivos através de um sistema fuzzy. Tal método foi denominado agregador fuzzy e diversos circuitos foram evoluídos com sucesso.

O agregador fuzzy foi aplicado no processo de avaliação de algoritmos genéticos, modificando o método tradicional destes algoritmos e incluindo, dessa forma, a característica de avaliação multiobjetivo a tais algoritmos evolutivos.

Foram realizados estudos de casos de evolução de circuitos para analisar a eficácia do método. Optou-se por uma implementação baseada puramente em simulação de modelos de circuitos, possibilitando um ambiente flexível para estudo de casos e viabilizando futuras aplicações. Evoluções de circuitos eletrônicos analógicos em áreas de aplicações distintas são avaliadas através de simulações computacionais. Dentre os estudos de casos são incluídos projetos de:

- Circuito simples de divisor de tensão
- Circuitos de funções de pertinência para sistemas fuzzy
- Controlador PID analógico.

Especificamente sobre o controlador PID analógico, o estudo envolveu a comparação com outros controladores para três plantas. Os parâmetros dos controladores PID foram evoluídos através do algoritmo genético, utilizando um agregador fuzzy para avaliar a minimização de três objetivos: o *overshoot*, o tempo de subida e o tempo de acomodação. Foram apresentadas tabelas e gráficos comparando os controladores com avaliação multiobjetivo com aqueles com avaliação de apenas um objetivo.

O trabalho desenvolvido para evolução, avaliação e implementação apresentou bom desempenho nos estudos de casos analisados, podendo ser utilizado como base para novas aplicações e implementações de outros circuitos.

Em comparação aos outros métodos estudados, o método avaliado obteve resultados consistentes, com as vantagens de inserir preferências e especificações do projetista de uma forma simples e interpretável no início do projeto, além de não necessitar de interferência do projetista, nem durante e nem após o processo de evolução.

Dessa forma, o trabalho desenvolvido para a evolução de circuitos eletrônicos analógicos com avaliação multiobjetivo por meio de um sistema fuzzy constitui uma contribuição aos estudos de projeto e implementação de sistemas eletrônicos que pode ser utilizada em diversas aplicações.

6.2 Trabalhos futuros

Para trabalhos futuros podem ser sugeridos estudos em diferentes linhas de atuação.

Seria importante implementar a avaliação de circuitos num simulador de circuitos do tipo *Spice*, facilitando assim a experimentação e projeto de novos circuitos com modelos mais próximos do real.

A utilização da técnica de GPGPU merece ser investigada pois certamente vai contribuir para avaliações mais rápidas nos simuladores e, conseqüentemente, o circuito evoluído será obtido em menor tempo.

Após a implementação de uma plataforma evolucionária com simulador do tipo *Spice* e que utiliza GPGPU, vale investigar representações cromossomiais para viabilizar a busca de topologias de circuitos e não apenas dos valores dos componentes.

REFERÊNCIAS

ALTINOZ, O. T.; DEB, K. Late Parallelization and Feedback Approaches for Distributed Computation of Evolutionary Multiobjective Optimization Algorithms, Second International Conference on Soft Computing and Machine Intelligence, 2015.

AMARAL, J. F. Síntese de Sistemas Fuzzy por Computação Evolucionária. Tese de Doutorado, Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, 2003.

AMARAL, J. L. M.; AMARAL, J. F. M.; MORIN, D.; TANSCHKEIT, R.; “An immune fault detection system with automatic detector generation by genetic algorithms”. Seventh International Conference on Intelligent Systems Design and Application (ISDA), 2007, p. 283 – 288.

ANDERSSON, J. A survey of multiobjective optimization in engineering design. Tech. Rep. LiTH-IKP-R-1097, Department of Mechanical Engineering, Linköping University, 2000.

ARROYO, J. E. C. Heurísticas e metaheurísticas para otimização combinatória multiobjetivo. Tese de doutorado, Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação, 2002.

COELHO, P. H. G.; AMARAL, J. F. M.; ALMEIDA, N. N.; FONSECA, A. C. X. S.; GUIMARÃES, K. P. Application of Fuzzy Inference Systems in the Transmission of Wireless Sensor Networks. 19^o ICEIS – International Conference on Enterprise Information Systems, 2017.

COELLO COELLO, C. A. Multi-objective evolutionary algorithms in real-world applications: some recent results and current challenges. Advances in Evolutionary and Deterministic Methods for Design, Optimization and Control in Engineering and Sciences, Vol. 36 of the series Computational Methods in Applied Sciences pp 3-18, 2013.

COELLO COELLO, C. A. A comprehensive survey of evolutionary-based multiobjective optimization techniques. Knowledge and Information Systems, Volume 1, Issue 3, p. 269–308, 1999.

DAVIS, L. D. Handbook of genetic algorithms, VNR Comp. Library, 1990.

DEB, K.; PRATAP, A.; MEYARIVAN, T. Constrained Test Problems for Multi-objective Evolutionary Optimization. In: Zitzler E., Thiele L., Deb K., Coello Coello C.A., Corne D. (eds) Evolutionary Multi-Criterion Optimization. EMO 2001.

EREMIA, M.; LIU, CHEN-CHING; EDRIS, ABDEL-ATY. Artificial Intelligence and Computational Intelligence: A Challenge for Power System Engineers, 1072p, Wiley-IEEE Press, 2016.

FIGUEIREDO, K. T.; VELLASCO, M. M. B. R.; PACHECO, M. A. C. ; SOUZA, F. J. DE . Hierarchical Neuro-Fuzzy Models Based on Reinforcement Learning for Autonomous Agents. *International Journal of Innovative Computing, Information & Control*, v. 10, p. 1471-1494, 2014.

FOGEL, L. J.; OWENS, A. J.; WALSH, M. J.; “Artificial Intelligence Through Simulated Evolution”. John Wiley, New York, 1966.

FONSECA, A. C. X. S., Modelo Evolucionário baseado em Agregador Fuzzy para Avaliação de Múltiplos Objetivos, Dissertação de Mestrado, UERJ, 2017.

FONSECA, C. M.; FLEMING, P. J. Multiobjective Genetic Algorithms Made Easy: Selection, Sharing and Mating Restriction, *First International Conference on Genetic Algorithms in Engineering Systems: Innovations and Applications*, (Conf. Publ. No. 414), 1995.

GACTO, M. J.; ALCALÁ, R.; HERRERA, F. Interpretability of linguistic fuzzy rule-based systems: An overview of interpretability measures, *Information Sciences, Special Issue on Interpretable Fuzzy Systems*, Vol. 181, Issue 20, p.4340–4360, 2011.

GOLDBERG, D. E. *Genetic algorithms in search, optimization, and machine learning*. Reading, Addison-Wesley Professional, 1989.

GREENWOOD, G. W.; TYRREL, A. M.; “Introduction to Evolvable Hardware: A Practical Guide for Designing Self-Adaptive Systems”. *IEEE Press Series on Computational Intelligence*. David B. Fogel Series Editor. 2007. ISBN: 978-0-471-71977-9.

HIGUCHI, T., IWATA, M., KEYMEULEN, D., SAKANASHI, H., MURAKAWA, M., KAJITANI, I., TAKANASHI, E., TODA, K., SALAMI, M., KAJIHARA, N., OTSU, N.; “Real-World Applications of Analog and Digital Evolvable Hardware”, *IEEE Transactions on Evolutionary Computation*, Vol. 3, no. 3, Setembro 1999.

HOLLAND, J. H.; “Adaptation in Natural and Artificial Systems”. University of Michigan Press, Ann arbor, USA, 1975.

HORROCKS, D.H.; KHALIFA, Y. M. A.; “Genetically derived filter circuits using preferred value components”. *IEE Colloquium on Analogue Signal Processing*, 1994, p. 4/1 – 4/5.

HOUCK, C.R.; JOINES, J.; KAY, M. A genetic algorithm for function optimization: A Matlab implementation, *ACM Transactions on Mathematical Software*, 1996.

ISHIBASHI, R. Extração de conhecimentos com interpretabilidade aumentada utilizando modelagem fuzzy e otimização multi-objetivo. Tese de Doutorado, Instituto Tecnológico da Aeronáutica, 2013.

ISHIBUCHI, H. Multiobjective genetic fuzzy systems: review and future research directions, Proceedings of the 2007 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2007), p.913-918, 2007.

JIANG, S.; YANG, S. Evolutionary Dynamic Multiobjective Optimization: Benchmarks and Algorithm Comparisons, IEEE Transactions on Cybernetics, Volume: PP, Issue: 99, pp. 1-14, 2016.

JONATHAN, M.; PACHECO, M. A. C. Técnicas de otimização de problemas com múltiplos objetivos - Um estudo sobre o método de minimização de energia e suas variantes. Departamento de Engenharia Elétrica da Pontifícia Universidade Católica do Rio de Janeiro, Revista Rica, 2010.

LABATI, R. D.; GENOVESE, A.; MUÑOZ, E.; PIURI, V.; SCOTTI, F.; SFORZA, G. Computational intelligence for industrial and environmental applications, IEEE 8th International Conference on Intelligent Systems (IS), 2016.

LACERDA, E. G. M.; CARVALHO, A. C. P. L. Introdução aos algoritmos genéticos. In: Galvão, C. O., Valença, M. J. S. (orgs.) Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais. Porto Alegre: Associação Brasileira de Recursos Hídricos. p. 99-150. 1999.

LARA, A.; SANCHEZ, G.; COELLO COELLO, C. A.; SCHUTZE, O. HCS: A New Local Search Strategy for Memetic Multi-Objective Evolutionary Algorithms. IEEE Transactions on Evolutionary Computation, 14(1):112–132, 2010.

LOHN, J. D.; COLOMBANO, S. P.; “A Circuit representation technique for automated circuit design”. IEEE Transactions on Evolutionary Computation, Vol. 3, No. 3, september 1999, p. 205 – 219.

LOPEZ, E. M. Un algoritmo evolutivo multiobjetivo basado en hipervolumen en GPUs, tese mestrado, Centro de Investigacion y de Estudios Avanzados del Instituto Politécnico Nacional, 2014.

LUCA, M.; LUCA, R.; BEJINARIU, SILVIU-IOAN; CIOBANU, A.; PADURARU, O.; ZBANCIOC, M.; BARBU, T. An Overview of Several Researches on Fuzzy Logic in Intelligent Systems. 2015 International Symposium on Signals, Circuits and Systems (ISSCS), 2015.

MAMDANI, E. H.; ASSILIAN, S. An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller. International Journal of Man-Machine Studies, 7(1): 1-13, 1975.

MATLAB – The Language of Technical Computing – MathWorks. Disponível em: <<http://www.mathworks.com>>. Acesso em: 20 dez. 2016.

MESQUITA, A.; SALAZAR, F.A.; CANAZIO, P.P.; “Chromossome representation through Adjacency Matrix in Evolutionary Circuits Synthesis”. Proc. 2002 NASA/DoD Conference on Evolvable Hardware, IEEE Computer press., July 2002, p. 102-109.

NEOCLEOUS, A. C.; NICOLAIDES, K. H.; SCHIZAS, C. N. First Trimester Noninvasive Prenatal Diagnosis: A Computational Intelligence Approach, IEEE JOURNAL OF BIOMEDICAL AND HEALTH INFORMATICS, vol. 20, No. 5, 2016.

OGATA, K. Engenharia de Controle Moderno. 4ª ed., Prentice Hall do Brasil, 2003.

OGATA, K. Engenharia de Controle Moderno. 3ª ed. Prentice Hall do Brasil, 1997.

OLIVEIRA, L. S. Uma Contribuição ao Estudo dos Métodos de Otimização Multi-Objetivo. Dissertação de mestrado, Universidade Federal de Uberlândia, 2005.

OSYCZKA, A. Multicriteria optimization for engineering design. John S. Gero, editor, Design Optimization, p. 193-227. Academic Press, 1985.

RIBEIRO, F. S., Plataforma de desenvolvimento de circuitos eletrônicos adaptativos, Dissertação de Mestrado, UERJ, 2012.

SÁ, L. B.; “Síntese de Filtros com Baixa Sensibilidade utilizando Técnicas Evolutivas”. Rio de Janeiro, 2009, 121 p., Tese de Doutorado (COPPE – UFRJ).

SALAZAR, F. A.; MESQUITA, A.; “Synthesis of Analog Circuits Using Evolutionary Hardware”. Sixth Brazilian Symposium on Neural Networks, 2000, p. 101 – 106.

SANTOS, A. R. dos. Síntese de Árvores de Padrões Fuzzy através de Programação Genética Cartesiana, Dissertação de mestrado, Universidade do Estado do Rio de Janeiro, 2016.

SANTOS, F. M. DA C.; DA SILVA, I. N.; SUETAKE, M. Sobre a aplicação de sistemas inteligentes para diagnóstico de falhas em máquinas de indução - Uma visão geral, Sba Controle & Automação, v.23, n.5, p.553-569, 2012.

SINOHARA, H. T., “Reparos e Ajustes Automáticos de Circuitos Eletrônicos Através de Eletrônica Evolucionária”. Rio de Janeiro, 2001, 84 p. Dissertação de Mestrado (Departamento de Engenharia Elétrica - PUC-Rio).

SHUKLA, P. K.; TRIPATHI, S. P. A Review on the Interpretability-Accuracy Trade-Off in Evolutionary Multi-Objective Fuzzy Systems (EMOFS), Information, 3, p. 256-277, 2012.

TANSCHKEIT, R. Sistemas fuzzy, In: Inteligência computacional: aplicada à administração, economia e engenharia em Matlab, pp. 229–264, São Paulo, Thomson Learning, 2007.

ZADEH, L. A. Fuzzy sets. Information and Control, vol. 8, pp. 338-353, 1965.

ZEBULUM, R. S. Síntese de Circuitos Eletrônicos por Computação Evolutiva. Tese de Doutorado. Departamento de Engenharia Elétrica da Pontifícia Universidade Católica do Rio de Janeiro, 1999.

Zebulum, R.; Pacheco, M. A.; Vellasco, M.; "Evolutionary Electronics: Automatic Design of Electronic Circuits and Systems by Genetic Algorithms". Boca Raton, Florida: CRC PRes, 2001. ISBN 0-8493-0865-8.

ZIEGLER, J. G.; NICHOLS, N. B. Optimum settings for automatic controllers. Transactions of the A. S. M. E., pp. 759-768, 1942.