

UNIVERSIDADE NOVE DE JULHO - UNINOVE
PROGRAMA DE MESTRADO EM ENGENHARIA DE PRODUÇÃO

**UM ESTUDO COMPARATIVO DAS TÉCNICAS METAHEURÍSTICAS ALGORITMO
GENÉTICO E *SIMULATED ANNEALING* APLICADAS A SISTEMAS DE APOIO À
DECISÃO PARA OTIMIZAÇÃO DE PARÂMETROS EM PROCESSOS DE USINAGEM**

APARECIDA DE FÁTIMA CASTELLO ROSA

SÃO PAULO

2011

APARECIDA DE FÁTIMA CASTELLO ROSA

**UM ESTUDO COMPARATIVO DAS TÉCNICAS METAHEURÍSTICAS ALGORITMO
GENÉTICO E *SIMULATED ANNEALING* APLICADAS A SISTEMAS DE APOIO À
DECISÃO PARA OTIMIZAÇÃO DE PARÂMETROS EM PROCESSOS DE USINAGEM**

Dissertação apresentada ao Programa de Mestrado em Engenharia de Produção da Universidade Nove de Julho - Uninove, como requisito parcial para a obtenção do grau de Mestre em Engenharia de Produção.

Prof. André Felipe Henriques Librantz, Dr – Orientador, Uninove

SÃO PAULO

2011

Rosa, Aparecida de Fátima Castello.

Um estudo comparativo das técnicas metaheurísticas algoritmo genético e simulated annealing aplicadas a sistemas de apoio à decisão para otimização de parâmetros em processos de usinagem./ Aparecida de Fátima Castello Rosa.

177 f.

Dissertação (mestrado) – Universidade Nove de Julho - UNINOVE, São Paulo, 2011.

Orientador (a): Prof. Dr. André Felipe Henriques Librantz.

1. Otimização de parâmetros em processos de usinagem. 2. Sistemas de Apoio à Decisão. 3. Algoritmo Genético. 4. Simulated Annealing.

I. Librantz, André Felipe Henriques.

CDU 621

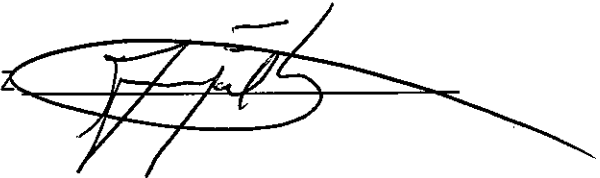
São Paulo, 02 de março de 2011.

TERMO DE APROVAÇÃO

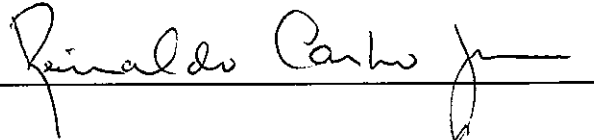
Aluno: APARECIDA DE FÁTIMA CASTELLO ROSA

Título da Dissertação: UM ESTUDO COMPARATIVO DAS TECNICAS METAHEURÍSTICAS
ALGORITMO GENÉTICO E SIMULATED ANNEALING APLICADAS A SISTEMAS DE APOIO À
DECISÃO PARA OTIMIZAÇÃO DE PARÂMETROS EM PROCESSOS DE USINAGEM

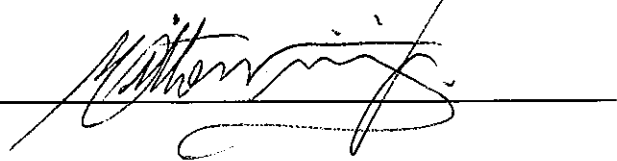
Presidente: PROF. DR. ANDRE FELIPE HENRIQUES LIBRANTZ



Membro: PROF. DR. REINALDO CASTRO SOUZA



Membro: PROF. DR. MILTON VIEIRA JUNIOR



À

Toda minha família, especialmente ao meu esposo Luiz, minha filha Talita, minha mãe Esmeralda, aos meus irmãos Gabriel e Márcia.

Sem eles nunca teria chegado até aqui.

AGRADECIMENTOS

A Deus por não me deixar fraquejar diante dos vários obstáculos encontrados e porque sem Ele nada acontece.

Ao professor André Felipe Henrique Librantz pela amizade, orientação, dedicação, compreensão e incentivo.

Ao professor Nivaldo Lemos Coppini pela amizade, coorientação, compreensão e incentivo.

Ao professor Sidnei Alves de Araújo pela amizade, colaboração e incentivo inclusive para o meu crescimento profissional.

Ao professor Elesandro Antonio Baptista pela colaboração e sugestões ao longo do desenvolvimento deste trabalho.

Ao professor Wagner Lucato pelos comentários e sugestões enriquecedoras.

Ao meu esposo Luiz e minha filha Talita pelo apoio incondicional, compreensão e incentivo em todos os momentos.

As minhas amigas Marilda Fátima de Souza da Silva e Maria Aparecida Pereira, pela amizade, companheirismo e apoio principalmente nas horas mais difíceis.

A todos os professores da graduação e do mestrado que contribuíram para a minha formação.

A Universidade Nove de Julho – Uninove, pela concessão da bolsa de estudos.

“Para cultivar a sabedoria, é preciso força interior.
Sem crescimento interno, é difícil conquistar a
autoconfiança e a coragem necessárias. Sem elas,
nossa vida se complica. O impossível torna-se
possível com a força de vontade.” Dalai Lama

ROSA, Aparecida de Fátima Castello. ***UM ESTUDO COMPARATIVO DAS TÉCNICAS METAHEURÍSTICAS ALGORITMO GENÉTICO E SIMULATED ANNEALING APLICADAS A SISTEMAS DE APOIO À DECISÃO PARA OTIMIZAÇÃO DE PARÂMETROS EM PROCESSOS DE USINAGEM***. 2011. 177 f. Dissertação (Mestre em Engenharia de Produção) - UNIVERSIDADE NOVE DE JULHO – UNINOVE, São Paulo.

RESUMO

As técnicas metaheurísticas têm sido aplicadas na resolução de problemas complexos de otimização o que é uma preocupação constante na indústria de manufatura. Neste trabalho comparam-se as técnicas Algoritmo Genético e *Simulated Annealing* aplicadas a Sistemas de Apoio à Decisão para otimização de parâmetros de usinagem, com vistas à minimização dos custos de produção, maximização da margem de contribuição dos produtos fabricados, utilização de forma racional das disponibilidades da capacidade dos equipamentos e formação de preços com base na margem de contribuição. Para tanto foram desenvolvidas três ferramentas de apoio à decisão: Ferramenta GAPE – Algoritmo Genético para Estimação de Parâmetros de Corte, Ferramenta OPMP – Otimização de Parâmetros em Processo de Usinagem e IAS – Sistema de Análise de Ociosidade. Os resultados apresentados indicam a robustez e consistência das técnicas aplicadas, e sinalizam que tais técnicas podem ser utilizadas no desenvolvimento de sistemas de suporte à decisão em processos de usinagem.

PALAVRAS-CHAVE: Otimização de parâmetros em processos de usinagem, Sistemas de Apoio à Decisão, Técnicas metaheurísticas, Algoritmo Genético, *Simulated Annealing*.

ROSA, Aparecida de Fátima Castello. *UM ESTUDO COMPARATIVO DAS TÉCNICAS METAHEURÍSTICAS ALGORITMO GENÉTICO E SIMULATED ANNEALING APLICADAS A SISTEMAS DE APOIO À DECISÃO PARA OTIMIZAÇÃO DE PARÂMETROS EM PROCESSOS DE USINAGEM*. 2011. 190 f. Dissertação (Mestre em Engenharia de Produção) - UNIVERSIDADE NOVE DE JULHO – UNINOVE, São Paulo.

A COMPARATIVE STUDY OF METAHEURISTIC TECHNIQUES GENETIC ALGORITHM AND SIMULATED ANNEALING APPLIED IN DECISION SUPPORT SYSTEMS FOR OPTIMIZING PARAMETERS IN MACHINING PROCESSES.

ABSTRACT

Metaheuristic techniques have been applied in solving complex optimization problems that is a constant concern in the manufacturing industry. This paper compares the Genetic Algorithm and Simulated Annealing techniques applied to Decision Support Systems for the optimization of machining parameters, in order to reduce costs, maximizing the contribution margin of products manufactured, rationally use of available capacity of equipment and pricing based on contribution margin. For this purpose, it were developed three decision support tools: GAPE Tool - Genetic Algorithm for Cutting Parameters Estimation, OPMP Tool - Optimization Parameters in Machining Process and IAS - Idleness Analysis System. Partial results indicate the robustness and consistency of the applied techniques, pointing that such techniques can be used in developing decision support systems in machining processes.

KEYWORDS: Parameters optimization in machining processes, Decision Support Systems, Metaheuristic techniques, Genetic Algorithm, Simulated Annealing.

SUMÁRIO

RESUMO	vi
ABSTRACT	vii
LISTA DE FIGURAS	xi
LISTA DE TABELAS	xiii
LISTA DE ABREVIATURAS E SIGLAS	xiv
1. INTRODUÇÃO	1
1.1. REVISÃO DA LITERATURA	4
1.2. JUSTIFICATIVA.....	7
1.3. OBJETIVOS	8
1.3.1. Objetivos Específicos	8
1.4. DESCRIÇÃO DOS PROBLEMAS ABORDADOS	9
1.4.1. Otimização dos Parâmetros de Corte em Processo de Usinagem e Formação do Preço de Venda de uma Peça	9
1.4.2. Problema de Minimização da Ociosidade	12
1.5. MÉTODO DE PESQUISA.....	15
1.6. TRABALHOS PUBLICADOS RESULTANTES DA DISSERTAÇÃO.....	16
1.7. RELEVÂNCIA DO TRABALHO.....	17
1.8. ESTRUTURA DO TRABALHO.....	17
2. FUNDAMENTAÇÃO TEÓRICA DOS PROBLEMAS ABORDADOS	19
2.1. SISTEMAS DE CUSTEIO.....	19
2.2. MARGEM DE CONTRIBUIÇÃO (MC).....	21
2.3.FORMAÇÃO DE PREÇOS DE VENDA COM BASE NO CONCEITO MARGEM DE CONTRIBUIÇÃO	22
2.4. ANÁLISE DAS CONDIÇÕES ECONÔMICAS DE USINAGEM.....	24
2.4.1. Tempo de Fabricação por Peça	24
2.4.2. Cálculo do custo de produção	26
2.4.3. Intervalo de Máxima Eficiência (IME)	29
3.FUNDAMENTAÇÃO TEÓRICA SOBRE AS TÉCNICAS COMPUTACIONAIS APLICADAS	32
3.1. MÉTODOS E TÉCNICAS COMPUTACIONAIS DE BUSCA E OTIMIZAÇÃO	32
3.1.1. Busca Exaustiva (BE).....	38
3.1.2. Técnicas Heurísticas.....	39
3.1.3. Técnicas Metaheurísticas.....	39
3.2. ALGORITMO GENÉTICO (AG)	40
3.2.1. Algoritmo Genético Simples	44
3.2.2. Representação das Soluções	46
3.2.2.1. Codificação e Decodificação	47
3.2.3. População Inicial.....	49
3.2.4. Função de Aptidão	49
3.2.5. Operadores do Algoritmo Genético	49
3.2.5.1. Operador de Seleção.....	50
3.2.5.2. Elitismo.....	51
3.2.5.3. Operador de Cruzamento.....	51
3.2.5.4. Operador de Mutação	52
3.3. <i>SIMULATED ANNEALING</i> (SA) - RECOZIMENTO SIMULADO	53
3.3.1. Processo de Recozimento (<i>Annealing</i>).....	54
3.3.2. Algoritmo <i>Simulated Annealing</i> (SA)	57
3.3.3. Esquema de Decaimento da Temperatura (EDT)	60

3.3.3.1. Esquema de Decaimento Geométrico (EDG)	61
3.3.3.2. Esquema de Decaimento Linear (EDL).....	61
3.3.4. Número de Iterações na Temperatura	62
3.3.5. Critério de parada do algoritmo	62
3.4. SISTEMAS DE APOIO À DECISÃO (SAD).....	62
4. MATERIAIS E METODOLOGIA	66
4.1. METODOLOGIA DE DESENVOLVIMENTO DOS SADs	66
4.1.1. FERRAMENTA GAPE.....	67
4.1.2. FERRAMENTA OPMP	68
4.1.3. FERRAMENTA IAS	69
4.2. MÉTODOS APLICADOS AO PFP.....	72
4.2.1. Formulação Matemática do PFP	72
4.2.2. Parâmetros do Processo de Usinagem do PFP.....	72
4.2.3. Parâmetros do AG aplicados ao PFP.....	73
4.2.4. Parâmetros do SA aplicados ao PFP	74
4.3. METODOLOGIA APLICADA AO PMO	75
4.3.1. Cálculo da Ociosidade	75
4.3.2. Formulação Matemática do PMO	76
4.3.3. Parâmetros do PMO	78
4.3.4. Parâmetros do AG aplicados ao PMO.....	79
4.3.5. Aplicação do SA no PMO	80
5. RESULTADOS E DISCUSSÃO	82
5.1. AJUSTE DOS PARÂMETROS DAS TÉCNICAS METAHEURÍSTICAS AG E SA	82
5.1.1. Ajuste dos parâmetros do AG para o PFP	82
5.1.2. Ajuste dos parâmetros do SA para o PFP.....	86
5.1.2.1. Comparativo entre o EDG e o EDL do SA para o PFP	92
5.1.3. BE Aplicada ao PFP.....	92
5.1.3.1. Desempenho da BE para o PFP	93
5.1.4. Comparativo entre o AG, SA e BE para o PFP	94
5.1.5. Ajuste dos parâmetros do AG para o PMO	95
5.1.6. Ajuste dos parâmetros do SA para o PMO.....	101
5.1.6.1. Comparativo entre EDG e EDL do SA para o PMO.....	108
5.1.7. BE Aplicada ao PMO	109
5.1.7.1. Desempenho da BE para o PMO.....	109
5.1.8. Comparativo entre o AG, SA e BE para o PMO	110
5.2. APLICAÇÃO DAS TÉCNICAS AG E SA AO PFP.....	110
5.3. APLICAÇÃO DAS TÉCNICAS AG E SA AO PMO.....	115
5.4. EXEMPLO DE APLICAÇÃO PARA O PFP	115
5.5. EXEMPLO DE APLICAÇÃO PARA O PMO	120
6. CONCLUSÕES	124
6.1. SUGESTÕES PARA TRABALHOS FUTUROS	125
REFERÊNCIAS BIBLIOGRÁFICAS	126
APÊNDICE A - ETAPAS DA MODELAGEM E SIMULAÇÃO DE SISTEMAS	135
ANEXO A - GENETIC ALGORITHM APPLIED TO INVESTIGATE CUTTING PROCESS PARAMETERS INFLUENCE ON WORKPIECE PRICE FORMATION	138
ANEXO B - SIMULATED ANNEALING APPLIED TO MINIMIZE THE IDLENESS AND MAXIMIZE THE CONTRIBUTION MARGIN FOR GENERIC FLEXIBLES MACHINING CELLS	Erro! Indicador não definido.

**ANEXO C - SIMULATED ANNEALING TECHNIQUE APPLIED FOR
PARAMETERS OPTIMIZATION IN MACHINING PROCESSES**Erro! Indicador não defini
**ANEXO D - THE IDLENESS ANALYSIS DURING MACHINING: SEARCHING
FOR BEST ORGANIZATIONAL RESULTS.....** Erro! Indicador não definido.

LISTA DE FIGURAS

Figura 1 - Intervalo de Máxima Eficiência (IME).....	29
Figura 2 – Ótimo local e global de uma função de duas variáveis	34
Figura 3 – Regiões do Espaço de Busca.	36
Figura 4 – Classificação de algoritmos de otimização global de acordo com o método de operação	37
Figura 5 - Pseudocódigo BE.....	38
Figura 6 – Estrutura de um cromossomo.	43
Figura 7 - Pseudocódigo AG.	45
Figura 8 – Estrutura de um cromossomo binário.....	46
Figura 9 - Cromossomo gerado aleatoriamente com tamanho de 33 <i>bits</i>	48
Figura 10 - Par de cromossomos pais com ponto de corte na nona posição para gerar dois novos cromossomos filhos por meio do operador cruzamento.....	52
Figura 11 – Configuração desordenada das partículas nas técnicas <i>annealing</i> e <i>quenching</i>	55
Figura 12 – Pseudocódigo do <i>Simulated Annealing</i>	58
Figura 13 – Estrutura da tomada de decisão.....	64
Figura 14 – Fluxograma do desenvolvimento das ferramentas SADs.	67
Figura 15 - Fluxograma do desenvolvimento da ferramenta GAPE.	68
Figura 16 - Fluxograma do desenvolvimento da ferramenta OPMP.	69
Figura 17 - Fluxograma do desenvolvimento da ferramenta IAS.	71
Figura 18 – Divisão do cromossomo para representação das seis variáveis do PFP.....	73
Figura 19 - Divisão do cromossomo para representação das seis variáveis do PMO.	79
Figura 20 - Desempenho do AG considerando-se diferentes números de gerações para o PFP.....	83
Figura 21 – Desempenho do AG considerando-se diferentes tamanhos de população para o PFP.	84
Figura 22 – Desempenho do AG considerando-se diferentes taxas de mutação para o PFP.....	85
Figura 23 – Desempenho do AG para diferentes esquemas de cruzamento para o PFP.	85
Figura 24 - Valor de K_p para o EDG com L iterações para cada <i>Temp</i>	86
Figura 25 - Custo computacional do EDG com L iterações para cada <i>Temp</i> aplicado ao PFP.....	87
Figura 26 - Valor de K_p para o EDL com L iterações para cada <i>Temp</i>	88
Figura 27 - Custo computacional para o EDL com L iterações para cada <i>Temp</i> aplicado ao PFP.	88
Figura 28 - Comparativo dos valores de K_p para o EDG e o EDL, com L iterações para cada temperatura.....	89
Figura 29 - Comparativo do custo computacional para o EDG e EDL, com L iterações para cada temperatura.	90
Figura 30 – Gráfico comparativo do EDG e do EDL com uma iteração para cada temperatura.....	91
Figura 31 – Comparativo do custo computacional para o EDG e EDL com uma iteração para cada temperatura.	91
Figura 32 - Custo Computacional da BE aplicado ao PFP com linha de tendência.	94
Figura 33 - Desempenho do AG considerando-se diferentes números de gerações para a MCT (PMO).	96
Figura 34 - Desempenho do AG considerando-se diferentes números de gerações para a MCTPE (PMO).....	96

Figura 35 - Desempenho do AG considerando-se diferentes tamanhos de população para a MCT (PMO).	97
Figura 36 - Desempenho do AG considerando-se diferentes tamanhos de população para a MCTPE (PMO).	98
Figura 37 - Desempenho do AG considerando-se diferentes taxas de mutação para a MCT (PMO).	98
Figura 38 - Desempenho do AG considerando-se diferentes taxas de mutação para a MCTPE (PMO).	99
Figura 39 - Desempenho do AG para diferentes esquemas de cruzamento para a MCT (PMO).	100
Figura 40 - Desempenho do AG para diferentes esquemas de cruzamento para a MCTPE (PMO).	100
Figura 41 - EDG para MCT com L iterações para cada $Temp$ aplicados ao PMO.	102
Figura 42 - Esquema EDG para MCTPE com L iterações para cada $Temp$ aplicados ao PMO.	103
Figura 43 - Custo Computacional do EDG com L iterações para cada $Temp$ aplicado ao PMO.	104
Figura 44 - Esquema EDL para MCT com L iterações para cada $Temp$ aplicados ao PMO.	105
Figura 45 - Esquema EDL para MCTPE com L iterações para cada $Temp$ aplicado ao PMO.	105
Figura 46 - Custo Computacional do EDG com L iterações para cada $Temp$ aplicado ao PMO.	106
Figura 47 - Esquema EDG e EDL para MCT e MCTPE com uma iteração para cada $Temp$ aplicados ao PMO.	107
Figura 48 - Custo Computacional do EDG e EDL com uma iteração para cada $Temp$ aplicado ao PMO.	107
Figura 49 - Comparativo do SA e AG, na influência no valor de K_p quando os parâmetros são considerados individualmente e todos juntos, com variação de $\pm 10\%$	113
Figura 50 - Tela inicial do SAD GAPE após o processamento, apresentando os resultados finais.	117
Figura 51 - Tela principal do SAD OPMP após o processamento, apresentando os resultados finais.	119
Figura 52 - Interface para Determinação de Gargalo e Ociosidade da IAS.	121
Figura 53 - Interface para Determinação da Margem de Contribuição e Prazo de Entrega da IAS.	122

LISTA DE TABELAS

Tabela 1 – Formação de Preço de Venda.....	23
Tabela 2 - Terminologia referente a analogia entre a Biologia e o AG.....	44
Tabela 3 - Analogia entre o reconhecimento físico e problema de otimização combinatória.	56
Tabela 4 – Tempo de produção disponível, em minutos, de cada máquina para um dia de trabalho.....	78
Tabela 5 – Quantidade de peças e tempo de produção por máquina que cada produto necessita para ser produzido.....	78
Tabela 6 - Quantidade de peças e tempo de produção por máquina que cada produto extra necessita para ser produzido.	79
Tabela 7 – Custo Computacional do AG para o problema da formação de preços.....	83
Tabela 8 – Qualidade do ajuste das curvas exponenciais para o EDL com L iterações para cada $Temp$ aplicado ao PFP.	89
Tabela 9 – Comparativo dos melhores resultados obtido pelo EDG e EDL com uma ou mais iterações para cada $Temp$, considerando-se os valores de K_p e o custo computacional.....	92
Tabela 10 - Domínio das variáveis do problema de preço para a BE.....	93
Tabela 11 - Custo Computacional da Busca Exaustiva aplicado ao PFP.	93
Tabela 12 – Comparativo entre AG, SA e BE para o PFP.....	94
Tabela 13 – Resultados dos valores obtidos para determinação dos parâmetros de controle do AG para o PMO.....	101
Tabela 14 - Qualidade do ajuste das curvas exponenciais para o EDG com L iterações para cada $Temp$ aplicado ao PMO.	104
Tabela 15 - Qualidade do ajuste das curvas exponenciais para o EDL com L iterações para cada $Temp$ aplicado ao PMO.	106
Tabela 16 – Comparativo dos melhores resultados obtido para a MCT e a MCTPE utilizando os esquemas EDG e EDL com uma ou mais iterações a cada $Temp$, considerando-se o custo computacional.	109
Tabela 17 – Comparativo entre AG, SA e BE para o PMO.....	110
Tabela 18 - Comparação ente AG e SA na influência do K_p quando todos os parâmetros são otimizados ao mesmo tempo, com variação de $\pm 10\%$	111
Tabela 19 - Influência no K_p quando os parâmetros são considerados individualmente e todos juntos, com variação de $\pm 10\%$, utilizando o AG.....	111
Tabela 20 - Influência no K_p quando os parâmetros são considerados individualmente e todos juntos, com variação de $\pm 10\%$, utilizando o SA.	112
Tabela 21 - Comparativo do AG e SA, na influência de K_p quando os parâmetros são considerados individualmente e todos juntos, com variação de $\pm 10\%$	112
Tabela 22 - Grupo dos parâmetros de acordo com sua influência no custo variável por peça utilizando AG e SA.....	114
Tabela 23 - Grau de dificuldade para adotar o valor final estimado dos parâmetros após a aplicação das técnicas AG e SA.....	114
Tabela 24 – Comparativo entre o AG e SA aplicados ao PMO.	115

LISTA DE ABREVIATURAS E SIGLAS

$\%Impostos$	Percentual de impostos diretos que incidem sobre as vendas brutas;
$\%MC$	Percentual da margem de contribuição desejada pela empresa;
ΔE	Delta E;
AE	Algoritmos Evolucionários;
AG	Algoritmo Genético;
a_{ip}	Unidades da ociosidade do recurso i ;
a_p	Profundidade ou largura de usinagem;
BE	Busca Exaustiva;
C1	Custo independente da velocidade de corte;
C2	Custo de operação;
C3	Custo relativo à ferramenta;
C_m	Custo do material [R\$];
CO_i	Capacidade de ociosidade disponível do recurso de índice i ;
C_{iu}	Custo do tempo improdutivo [R\$];
<i>CustosVariáveis</i>	Custo do material, do salário homem, do salário máquina e do ferramental [R\$];
CV	Custo Variável;
d	Diâmetro da peça [mm];
d_p	Quantidade de demanda (lote) do produto p ;
EDG	Esquema de Decaimento Geométrico;
EDL	Esquema de Decaimento Linear;
EDT	Esquema de Decaimento da Temperatura;
E_m	Espaço ocupado pela máquina [m ²];
f	Avanço;
FP_p	Fator de penalização do produto p
FO	Função Objetivo
GAPE	GAPE Tool - <i>Genetic Algorithm for cutting Parameters Estimation</i> ;
g_i	Gene i do cromossomo;
H	Número de horas de trabalho por ano;
i	i -ésima posição;
IAS	IAS – Sistema de Análise de Ociosidade;
IME	Intervalo de Máxima Eficiência;
j	Taxa de juros [ano];
K	Constante da equação de vida de Taylor;
K_c	Custo do m ² ocupado pela máquina [R\$/m ² .ano];
K_{ft}	Custo da aresta de corte [R\$/aresta];
K_{mc}	Custo anual de manutenção da máquina [R\$/ano];
K_p	Custo total de usinagem por peça [R\$];
L	Número de iterações para cada temperatura;
l_f	Percurso de avanço [mm/rotação];
m	Idade da máquina [em anos];
M	Vida prevista para a máquina [em anos];
<i>Max_Gen</i>	Número máximo de geração;
MC	Margem de Contribuição;
<i>MCT</i>	Margem de Contribuição total;
<i>MCTPE</i>	Margem de Contribuição Total com prazo de entrega;
n	n -ésima posição;
OPMP	OPMP Tool - <i>Optimization Parameters in Machining Process</i> ;

p	Produto;
pe	Número de dias de prazo de entrega;
PFP	Problema de Formação de Preço;
p_{MC}	Margem de contribuição do produto p ;
PMEs	Pequenas e Médias Empresas
PMO	Problema de Minimização da Ociosidade;
PSR	Problemas de Satisfação de Restrições
pv_i	Variação porcentagem do valor da variável representada no gene i no cromossomo;
qtm_i	Variação da quantidade do produto referente da variável representada no gene i no cromossomo;
SA	<i>Simulated Annealing</i> ;
SAD	Sistema de Apoio à Decisão
S_L	Salário homem incluindo benefícios [R\$/hora];
S_M	Salário máquina [R\$/hora];
T	Vida da ferramenta [min];
t_1	Tempo improdutivo;
t_2	Tempo relacionado com a troca de ferramenta;
t_a	Tempo de aproximação e afastamento;
t_c	Tempo de corte [min];
t_c	Tempo de corte;
Temp	Parâmetro de controle Temperatura;
t_{ft}	Tempo de troca da aresta de corte e ajuste do posicionamento da ferramenta [min];
TOC	Teoria das Restrições, do inglês, <i>Theory of Constraints</i> ;
T_p	Preço inicial de vendas a ser ofertado a uma proposta do cliente [R\$];
t_p	Tempo de preparo de máquina;
t_s	Tempo secundário;
t_t	Tempo total de usinagem de uma peça [min];
VB 6.0	Microsoft Visual Basic® 6.0
V_c	Velocidade de corte [m/min];
V_{cmc}	Velocidade de corte de mínimo custo [m/min];
V_{cmcLim}	Velocidade de corte de mínimo custo limite [m/min];
V_{cmxp}	Velocidade de corte de máxima produção [m/min];
V_{mi}	Valor inicial de aquisição da máquina [R\$];
VV	Valor de Venda;
x	Expoente da Equação de vida de Taylor;
X_{max}	Limite superior da variável;
X_{min}	Limite inferior da variável;
Z	Número de peças pertencente a um lote;

1. INTRODUÇÃO

Uma das preocupações nas últimas décadas é a otimização de processos nas mais diversas áreas do conhecimento humano, o que tem levado pesquisadores a explorar novas técnicas ou métodos de otimização, ou ainda, aprimorar os já existentes (MUNDIM e DELAVY, 2008).

Na indústria manufatureira essa preocupação é constante devido às exigências para que as organizações consigam vencer os desafios competitivos, satisfazer a demanda do mercado e garantir a qualidade do produto com custo mínimo. Além disso, no cenário econômico atual, muitas vezes os preços são definidos pelo mercado, o que leva as empresas a aceitarem os preços impostos por seus clientes. Por esses motivos, elas têm que considerar com cuidado seus custos, e buscar alternativas para maximizar seus lucros (BAPTISTA, LIBRANTZ e COPPINI, 2008; MOREIRA et al., 2009).

Esse cenário tem levado as empresas a rever e efetuar mudanças radicais nas suas estratégias de produção (YILDIZ, 2009). Os processos de produção são, em geral, muito complexos e envolvem uma grande variedade de materiais, operações e recursos. Um dos segmentos importantes dos processos de produção na indústria manufatureira é a usinagem de materiais dentre os quais os metálicos são mais relevantes.

Nesse contexto, devido à complexidade dos processos de produção, torna-se importante a utilização de Sistemas de Apoio à Decisão (SAD). Tais sistemas podem dar suporte e melhorar a qualidade de decisão em determinados cenários.

Problemas de otimização em usinagem, geralmente, são do tipo não-linear e nem sempre podem ser resolvidos por meio de métodos de otimização convencional, que convergem para soluções ótimas locais (SANKAR et al., 2007).

Muitos problemas de otimização têm sido apresentados como NP – Difícil (*NP-hard - nondeterministic polynomial-time hard*), o que significa que o tempo de execução para que o

algoritmo garanta a melhor solução cresce exponencialmente com o tamanho do problema, como exemplo, pode-se citar o Problema do Caixeiro Viajante (PCV) (*Traveling Salesman Problem* - TSP). Esse problema consiste em, dada uma lista de cidades, um caixeiro partindo de uma cidade inicial pretende visitar todas as cidades uma única vez, e regressar à cidade de origem de modo que a distância percorrida seja mínima (EGLESE, 1990).

Uma alternativa para resolução de problemas de otimização complexos e de difícil solução tem sido a utilização de técnicas metaheurísticas.

Elas são constituídas por algoritmos de busca os quais percorrem o espaço de soluções e possuem mecanismos para escapar de ótimos locais, encontrando soluções de qualidade que podem ser “ótimas” ou “próximas de ótima”, com custo computacional viável (BLUM e ROLLI, 2003, 2008; EGGLESE 1990).

As técnicas metaheurísticas mais conhecidas são os Algoritmos Genéticos (AG) (HOLLAND, 1975), *Simulated Annealing* (SA) (KIRKPATRICK, GELATTI e VECCHI, 1983), Sistema Colônia de Formigas (*Ant Colony System* - ACO) (DORIGO, MANIEZZO e COLORNI, 1996), Otimização por Enxame de Partículas (*Particle Swarm Optimization* – PSO) (KENNEDY e EBERHART, 1995), *Greedy Randomized Adaptive Search Procedure* (GRASP) (FEO e RESENDE, 1995) e Busca Tabu (BT) (GLOVER e LAGUNA, 1997).

Dentre as técnicas supracitadas, AG e SA têm sido amplamente empregadas na resolução de problemas de otimização (GEN e CHENG, 2000; HWANG e HE, 2006; OYSU e BINGUL, 2009).

O AG, como apresentado no capítulo 3 (seção 3.2), é um método estocástico, de busca e otimização com base nos princípios da genética natural e no processo de seleção natural que simula a evolução das espécies (GOLDBERG, 1989; HAUPT e HAUPT, 2004).

O SA, apresentado no capítulo 3 (seção 3.3), é um método de busca de otimização que foi proposto originalmente por Kirkpatrick et al. (1983), o qual faz uma analogia entre o

processo de recozimento físico de metais e vidros e problemas de otimização. Ele é conhecido como uma técnica compacta e robusta que proporciona excelentes soluções para problemas de otimização com custo computacional viável (BALRAM, 2004).

Em virtude das técnicas metaheurísticas possibilitarem a determinação de soluções factíveis, ótimas ou próximas de ótimas com custo computacional viável e, devido à complexidade das operações envolvidas nos processos de fabricação da indústria de manufatura, elas têm sido aplicadas com sucesso nos mais diversos segmentos: Oysu e Bingul (2009) realizaram uma análise comparativa de três abordagens: AG, SA e AGSA híbrido, aplicados ao problema de otimização da trajetória da ferramenta de corte para minimização dos tempos não produtivos (movimentação de ferramenta de corte de usinagem); Rao e Pawar (2010) utilizaram os algoritmos *Artificial Bee Colony* (ABC), *Particle Swarm Optimization* (PSO) e SA para otimização dos parâmetros em operações de fresamento multipasse; Manjeshwar, Damodaran e Srihari (2009) o SA para minimizar o *makespan* (tempo total da tarefa no processo) em chão de fábrica com duas máquinas de processamento em lotes; Sardiñas, Santana e Brindis (2009) aplicaram AG para otimização dos parâmetros de corte em processos de torneamento; Yang et al. (2009) aplicaram SA para otimização de parâmetros em usinagem por descargas elétricas.

Embora se perceba a atualidade do tema, são poucos os relatos de pesquisas que realizaram um estudo comparativo entre as técnicas AG e SA aplicadas à otimização de parâmetros em processos de usinagem.

Dentro desse contexto, a proposta deste trabalho é a investigação e desenvolvimento de SADs utilizando as técnicas metaheurísticas AG e SA.

1.1. REVISÃO DA LITERATURA

Os trabalhos aqui elencados estão classificados em ordem cronológica crescente.

Cus e Balic (2003) propõem em seu trabalho uma nova técnica de otimização baseada em AG para a determinação dos melhores parâmetros de corte em processos de usinagem que minimizem o custo unitário de produção sem violação das restrições de corte impostas no processo. Eles apresentam uma nova metodologia para melhoria contínua nas condições de corte.

Em 2006 Sardiñas, Santa e Brindis (2006) propuseram um método de otimização multiobjetivo com base em técnicas *a posteriori* utilizando o AG para obtenção dos melhores parâmetros de corte, avanço, profundidade e velocidade de corte em processos de torneamento. Neste problema eles consideram dois objetivos conflitantes que é a otimização simultânea da vida da ferramenta e o tempo de operação.

Durán, Barrientos e Cosalter (2007) aplicaram AG e equação expandida de Taylor para obter o Intervalo de Máxima Eficiência (IME) na otimização dos parâmetros de usinagem (velocidade e profundidade de corte) as quais garantem as condições de mínimo custo e máxima produção em uma operação de torneamento.

Coppini e Baptista (2007) apresentaram um sistema baseado na WEB denominado MOS – *Machining Optimizer System*, que foi desenvolvido visando auxiliar a tarefa de otimização do processo de usinagem a partir de dados coletados em chão de fábrica.

Para minimizar os custos da produção Kim et al. (2008) utilizaram o AG com representação em números reais para encontrar a combinação dos melhores parâmetros das condições de usinagem com restrições. Eles também consideram cinco modelos matemáticos para otimização das condições de usinagem.

Uma abordagem híbrida do método Taguchi e o método de Superfície de Resposta foram utilizados por Dubey e Yadava (2008) para a otimização do processo de corte com

feixe de laser para várias características de qualidade como taxa de remoção de material e largura do sulco.

Uma abordagem para otimização do processo de usinagem, com base no custo unitário da produção foi desenvolvida por Manna e Salodkar (2008). Os autores utilizaram investigação experimental para determinar os valores ótimos de várias condições de usinagem. As técnicas Taguchi e ANOVA (Análise de Variância) foram empregadas para investigar a influência da profundidade de corte, taxa de avanço e velocidade de corte na rugosidade superficial durante operação de torneamento.

Zeng et al. (2008) propuseram um sistema baseado na WEB para seleção dos parâmetros de usinagem. A característica principal do sistema é que as máquinas-ferramentas, cortadores e parâmetros de corte podem ser selecionados para o processo de usinagem. Durante as análises de usinagem alguns dos indicadores de desempenho podem ser verificados, como força de giro, consumo de energia, estado de vibração, distorção da peça e qualidade das peças usinadas.

No sequenciamento ou agendamento da produção Andresen et al. (2008) compararam duas técnicas metaheurísticas, SA e AG, para minimizar a soma dos tempos de conclusão ou o tempo médio do fluxo do processo.

Uma metodologia de otimização para a seleção dos melhores parâmetros em usinagem por descargas elétricas foi proposta por Yang et al. (2009). Os autores utilizam um sistema integrado de Rede Neural Artificial *Counter-Propagation* construído com base em dados experimentais. Neste trabalho, o SA foi utilizado para resolver a função multiobjetivo para maximizar a taxa de remoção de material e minimizar o valor da rugosidade da superfície.

Oysu e Bingul (2009) analisaram e compararam três abordagens: AG, SA e AGSA híbrido, aplicados ao problema de otimização da trajetória da ferramenta de corte para minimização dos tempos não produtivos (movimentação de ferramenta de corte de usinagem).

Lucato, Baptista e Coppini (2009) apresentam em seu trabalho um procedimento, o qual se aplica às Pequenas e Médias Empresas (PMEs) prestadoras de serviços de usinagem, para a formação de preços de peças usinadas com base no conceito de Margem de Contribuição (MC), bem como na análise econômica do processo de corte. O procedimento proposto permite determinar o preço de uma peça utilizando-se somente os custos variáveis, eliminando completamente a necessidade dos custos fixos alocados ao produto. Além disso, é considerado o ajuste das variáveis de usinagem, como forma de avaliar o impacto das diferentes condições de usinagem sobre os preços dos produtos e prazos de entrega. Com base no procedimento proposto pelos autores, as PMEs terão base para negociar a proposta junto ao cliente, analisando a relação entre custo e preço, buscando possibilidades de fechar um contrato, aceitar ou não um serviço de usinagem em perspectiva. Os autores também ilustram os procedimentos com uma simulação numérica para um melhor entendimento.

Manjeshwar, Damodaran e Srihari (2009) aplicaram SA para minimizar o *makespan* de duas máquinas de processamento em lote.

Gu et al. (2010) propuseram um novo Algoritmo Genético Quantum Coevolucionário para o *Job Shop Scheduling Problem* com o objetivo de minimizar o valor esperado do *makespan*. Três novas estratégias denominadas *competitive hunter*, *cooperative surviving and the big fish eating small fish*, foram desenvolvidas no processo de crescimento da população. Com base na ideia da melhoria da coevolução de várias populações e os conceitos da teoria quântica. De acordo com os autores, esse algoritmo poderá não somente ajustar o tamanho da população de forma dinâmica para aumentar a diversidade de genes e evitar a convergência prematura, mas também acelerar a velocidade de convergência.

1.2. JUSTIFICATIVA

O uso de técnicas metaheurísticas para a solução de problemas de otimização pode tornar-se uma alternativa àquelas já aplicadas em alguns problemas de engenharia que, apesar de efetivas, podem ainda ter suas soluções otimizadas. Dentre as mencionadas anteriormente, optou-se por utilizar as técnicas AG e SA.

O AG é uma poderosa técnica de busca estocástica e de otimização que vem sendo frequentemente utilizada nos últimos anos em problemas de otimização na engenharia de produção (YILDIZ, 2009). Ademais, com frequência, ela tem sido preferida na solução de problemas de otimização de parâmetros em processos de usinagem (MUKHERJEE e TAY, 2006).

O SA também é uma técnica de otimização a qual se fundamenta em uma relação entre conceitos termodinâmicos e processos de otimização, onde a técnica de resfriamento gradual garante a obtenção do mínimo global (MUNDIN e DELAVY, 2008).

Da mesma forma que o AG, o SA pode ser utilizado para solucionar problemas de otimização de parâmetros em processos de usinagem (CHANDRASEKARAN et al., 2010; MUKHERJEE e RAY, 2006).

Tanto a técnica AG quanto a técnica SA são indicadas para a resolução de Problemas de Satisfação de Restrições (PSR), como é o caso dos dois problemas abordados neste trabalho (BRAILSFORD, POTTS e SMITH, 1999; RUSSEL e NORVIG, 2004). Ambas têm facilidade de integração com outros métodos de otimização e simplicidade para modelar problemas complexos.

A proposta de desenvolvimento de SADs, no contexto deste trabalho, mostra-se pertinente devido às características dos problemas abordados, ao grande número de variáveis e parâmetros envolvidos, assim como a flexibilidade necessária durante o procedimento de análise, negociação e tomadas de decisões.

No cenário apresentado, os SADs propostos podem tornar-se ferramentas auxiliares importantes, para que as empresas possam utilizar de forma racional as capacidades disponíveis (ociosidade) em seus equipamentos, buscar por maior qualidade e redução dos custos nos processos de produção.

No que se refere à busca por maior qualidade e redução de custos nos processos de produção, as técnicas metaheurísticas de otimização podem ser aplicadas na busca de valores ideais para os fatores controláveis que interferem no processo, visando, principalmente: 1) uma redução da variação do processo e melhor concordância entre os valores nominais obtidos e os valores pretendidos; 2) redução do tempo do processo; 3) redução do custo operacional; 4) melhoria no rendimento do processo.

1.3. OBJETIVOS

O principal objetivo deste trabalho é investigar a aplicabilidade, eficiência e robustez das técnicas metaheurísticas Algoritmo Genético (AG) e *Simulated Annealing* (SA) no desenvolvimento de SADs, no que diz respeito à otimização de parâmetros em processos de usinagem, redução dos custos de usinagem e utilização das capacidades disponíveis em equipamentos.

1.3.1. Objetivos Específicos

- Avaliar as vantagens e desvantagens oferecidas pelas técnicas metaheurísticas AG e SA na implementação de SADs aplicados a dois problemas característicos das empresas de usinagem, os quais seguem:
 - a) Problema de Formação de Preço (PFP) com base no conceito de MC, com vistas à otimização dos parâmetros de corte em processos de usinagem,

minimização dos custos de produção e consequentemente a maximização da MC;

- b) Problema de Minimização da Ociosidade (PMO), no qual, considera-se a capacidade disponível (ociosidade) dos equipamentos proveniente da produção normal, para produção de um *mix* de produtos extras a serem fabricados nesses equipamentos, tendo como parâmetro a maximização da MC.

1.4. DESCRIÇÃO DOS PROBLEMAS ABORDADOS

As subseções a seguir apresentam os problemas característicos das empresas de usinagem abordados neste trabalho.

1.4.1. Otimização dos Parâmetros de Corte em Processo de Usinagem e Formação do Preço de Venda de uma Peça

O ambiente econômico contemporâneo revela que na maioria das indústrias os preços dos bens e serviços são impostos pelo mercado. Mesmo assim, a determinação dos custos deve ser considerada com muita atenção, para permitir que o preço de venda possa ser sempre considerado, envolvendo uma negociação na sua formação, para que não haja prejuízos drásticos para nenhuma das partes. Este é o caso das empresas prestadoras de serviço em processos de usinagem. Geralmente a empresa que presta esse tipo de serviço recebe um desenho com as especificações técnicas da peça para cotação de preço. Na maioria dos casos, os preços não são informados pelo cliente. Baseando-se nas informações do desenho técnico, a empresa deverá cotar o preço inicial de venda, considerando seus conhecimentos técnicos, bem como o sistema de custeio (LIBRANTZ et al. 2011; LUCATO, 2005).

As metodologias tradicionais para cálculo de custo de usinagem publicadas na literatura consideram os custos de produção calculados, em geral, por meio de complexos critérios de rateio. Poucas são as empresas que consideram os resultados econômicos apresentados pelo Demonstrativo de Resultados e Contabilidade de Custos como ferramentas de apoio à decisão (BAPTISTA, LIBRANTZ e COPPINI, 2008).

Isso ocorre devido à dificuldade de gerenciamento e definição dos custos envolvidos no processo, levando-as assim a seguirem os preços de mercado, sem se preocupar com sua rentabilidade (LUCATO, COPPINI e BAPTISTA, 2009). Essa limitação dificulta o cálculo dos custos de fabricação reais e, conseqüentemente, a determinação do preço de venda de seus produtos ou serviços (SOUZA et al., 2006).

Para Baptista, Librantz e Coppini (2008) a utilização do conceito de Margem de Contribuição (MC) poderá ajudar as empresas a definirem seus preços, devido a essa abordagem considerar somente os custos variáveis, ou seja, os custos que estão diretamente envolvidos no processo de produção (custos de material, de ferramentas, de salários e máquinas).

Sendo a operação de usinagem um dos principais custos na fabricação de um produto, a sua minimização deverá ser um dos principais objetivos da produção. A minimização dos custos de usinagem poderá ser obtida por meio da otimização do processo, configurando-se adequadamente as condições e os parâmetros envolvidos no processo (MANNA e SALODKAR, 2008).

Segundo Singh et al. (2006), na maioria das vezes, ao se executar operações de usinagem, três objetivos são levados em consideração: (a) taxa máxima de produção ou tempo de ciclo mínimo; (b) mínimo custo; e (c) lucro máximo. Encontrar a combinação ideal para alcançar esses objetivos é uma tarefa difícil, principalmente devido ao número de variáveis e restrições envolvidas no processo.

Geralmente as abordagens relacionadas à otimização dos parâmetros de corte em usinagem, referem-se à escolha correta dos parâmetros avanço, profundidade de usinagem e velocidade de corte que, com frequência, são adotados baseando-se nas informações dos catálogos dos fornecedores de ferramentas e/ou na experiência do usuário (COPPINI e BAPTISTA, 2007). Porém, as informações sobre os parâmetros contidas nos catálogos dos fabricantes, raramente condizem com a realidade das empresas, pois os mesmos são obtidos em testes laboratoriais muitas vezes distantes dos cenários de fabricação dos usuários.

Quando os dados são obtidos em ambiente fabril, de acordo com Coppini e Baptista (1998) “[...] haverá maior confiança na seleção da velocidade de corte, pois a otimização estará sendo realizada em tempo real com a ocorrência do processo, com dados retirados do próprio sistema máquina, ferramenta e peça” sem que haja extrapolações.

Outra abordagem, ainda segundo Coppini e Baptista (1998), diz respeito à otimização da velocidade de corte, tendo em vista que o avanço e a profundidade de usinagem (a_p) devem ser otimizados considerando-se a geometria ferramenta-peça envolvida e, no caso do avanço, o tipo de operação que está sendo alvo da otimização. A utilização adequada da velocidade de corte de acordo com o cenário produtivo poderá minimizar os custos e maximizar a produção de forma mais precisa.

Um método referencial, já consagrado pela literatura especializada para otimização da velocidade de corte em processos de usinagem em ambiente fabril é o Intervalo de Máxima Eficiência (IME) (DINIZ, MARCONDES e COPPINI, 2008; FERRARESI, 1997).

O IME é definido pelas velocidades de corte de mínimo custo V_{cmc} e pela velocidade de corte de máxima produção V_{cmxp} . Ainda, dentro do IME pode-se encontrar a velocidade de corte de mínimo custo limite V_{cmcLim} . O IME possibilita a identificação da condição mais econômica entre as duas velocidades de corte do intervalo, considerando-se os diversos cenários produtivos em função das suas características e/ou restrições (BAPTISTA, 2004).

O IME se utiliza de dois parâmetros fundamentais: os custos e os tempos de fabricação envolvidos no processo. De acordo com Souza et al. (2006), não existem controvérsias quanto aos cálculos dos tempos de fabricação, no entanto, para os cálculos dos custos, não se pode dizer o mesmo.

Desta forma, otimizar os parâmetros de corte de usinagem e analisar a sua influência na determinação do preço de vendas, utilizando o conceito de MC, e possivelmente identificar os fatores estratégicos para minimizar o custo de produção por peça, permitirá aos fornecedores decidirem a aceitação ou não do preço imposto por seu cliente em uma negociação, com base em argumentos reais.

Doravante este problema é referido no texto como Problema de Formação de Preço (PFP).

1.4.2. Problema de Minimização da Ociosidade

Ambientes industriais são altamente competitivos. Fatores como agilidade, flexibilidade, prestação de serviço, qualidade e preços são vantagens competitivas procuradas pelas organizações. Neste cenário, propostas de otimizações de tais fatores são de especial interesse às empresas.

Um dos maiores desafios das empresas prestadoras de serviços em processos de usinagem, em termos de tomada de decisão, é o gerenciamento das atividades operacionais do dia-a-dia.

Esses desafios devem considerar a utilização dos equipamentos produtivos, no que diz respeito à maximização da capacidade produtiva por meio da identificação dos equipamentos gargalos e/ou ociosos presentes no ambiente fabril, com vistas à maximização dos resultados.

A Teoria das Restrições (*Theory of Constraints – TOC*), criada por Eliyahu M. Goldratt que na década de 1980 desenvolveu uma metodologia para a administração dos

processos de produção industriais, visando à maximização dos resultados. Ela é uma metodologia para identificação dos gargalos, ou seja, a identificação de qualquer elemento ou fator que impede que um sistema alcance um nível melhor de desempenho no que diz respeito a sua meta (GOLDRATT e COX, 1986).

De acordo com Rahman (1998):

- a) todo sistema deve ter no mínimo uma restrição. Se isso não for verdade, então o sistema real deveria ter lucro ilimitado. Por essa razão, a restrição é alguma coisa que limita o sistema de alcançar alto desempenho versus a meta;
- b) a existência das restrições representa oportunidades de melhoria. Originalmente pensando, a TOC apresenta as restrições como algo positivo, não negativo. As restrições determinam o desempenho do sistema. Uma gradual elevação na restrição do sistema vai melhorar o seu desempenho.

Como em todo processo há a existência de recurso restritivo, ou seja, o gargalo, a capacidade fabril tende a seguir a capacidade do recurso restritivo.

Se por um lado, a restrição é algo que limita a capacidade fabril, por outro, o volume da capacidade ociosa pode definir a quantidade de oportunidades de desenvolvimento fabril e também a quantidade de incremento financeiro direto na lucratividade do negócio.

Monks (1987) e Slack (1997) abordam o tema ociosidade industrial a fim de quantificar o espaço de tempo “perdido” e ressaltam a importância desse tempo ser minimizado a fim de garantir a eficiência industrial.

A variação de *mix* de produtos pode afetar a capacidade produtiva com incremento ou eliminação de horas produtivas por estações ou processos fabris de acordo com as características técnicas dos produtos a serem fabricados (SLACK, 1997).

Para Padoveze (2006) e Martins (2006), métodos de contabilidade e sistemas de custeio consideram a ociosidade como um recurso pago e rateado inserido nos custos industriais.

Desta forma, a identificação e exploração da capacidade disponível dos equipamentos, a correta utilização da velocidade de corte em processos de usinagem (principalmente nos equipamentos identificados como gargalo), a otimização dos parâmetros de usinagem e a variação do *mix* de produtos poderão gerar eficiência fabril com aumento de capacidade industrial além de reduzir os custos operacionais de usinagem.

Nesta abordagem, dado um *mix* de produtos extras a serem usinados, em operação de torneamento, deseja-se determinar “quais” produtos e “quantos” fabricar de cada um deles, utilizando-se da capacidade disponível (ociosidade) dos equipamentos, proveniente da produção normal, de modo a maximizar a Margem de Contribuição Total (MCT), priorizando-se a MC ou a data de entrega do produto, dependendo do fator mais restritivo.

As restrições dos equipamentos ou da demanda deverão ser respeitadas. Para tanto se faz necessário identificar no processo fabril onde se localizam os recursos restritivos e não-restritivos e suas capacidades.

É importante ressaltar que a TOC foi utilizada neste trabalho com a única e exclusiva finalidade de caracterizar o que seja gargalo e que explica a presença da ociosidade. Neste sentido, a ociosidade será tratada pela programação de peças que não utilizam o equipamento gargalo visando explorar o que diz Padoveze (2006).

Doravante este problema é mencionado ao longo do texto como Problema de Minimização da Ociosidade (PMO).

1.5. MÉTODO DE PESQUISA

A pesquisa bibliográfica foi realizada, principalmente, por meio de sistemas de busca disponíveis no portal periódicos da CAPES. O Web of Science, Science Direct On-Line, EBSCOhost Web e Scielo, foram os sistemas mais consultados. Também foram obtidos alguns artigos em anais de congressos, nacionais e internacionais. A estratégia de busca consistiu no uso dos seguintes termos: técnicas metaheurísticas, algoritmo genético, *simulated annealing*, métodos de otimização computacionais, otimização, usinagem, intervalo de máxima eficiência, torneamento, margem de contribuição, formação de preço. Todos os termos foram utilizados em língua portuguesa e inglesa, de acordo com o sistema utilizado, sendo procurados no título, nas palavras-chave e no resumo. O levantamento bibliográfico foi iniciado no ano de 2009, sempre pesquisando os últimos 5 anos e, repetido até a conclusão do trabalho.

Este trabalho está contextualizado de acordo com Bertrand e Fransoo (2002) em Gestão de Operações (*Operations Management* – OM) por tratar de processos que envolvem operações em indústrias ou prestadoras de serviços de usinagem, e Pesquisa Operacional (*Operations Research* – OR) no que diz respeito à aplicação de técnicas de otimização. Segundo Chwif e Medina (2007), contextualiza-se também em Simulação e Otimização, visto que um dos objetivos é a otimização dos parâmetros nos processos de usinagem utilizando técnicas de simulação e metaheurísticas.

Trata-se de uma pesquisa quantitativa axiomática que faz uso de simulação computacional para gerar soluções no domínio do modelo, fornecendo uma visão sobre a estrutura dos problemas abordados; é descritiva, pois deriva diretamente dos modelos idealizados; produz conhecimento das variáveis do modelo com vistas a encontrar “soluções próximas de ótima” para os problemas abordados (BERTRAND e FRANSOO, 2002).

Este trabalho classifica-se quanto ao tipo como pesquisa Empírica Normativa (EN). O mesmo aborda os aspectos da elaboração conceitual, a construção, a solução e a implementação do modelo (BERTRAND e FRANSOO, 2002).

1.6. TRABALHOS PUBLICADOS RESULTANTES DA DISSERTAÇÃO

Os seguintes trabalhos são resultados da dissertação.

LIBRANTZ, A. F. H.; COPPINI, N. L.; BAPTISTA, E. A.; ARAUJO, S. A.; ROSA, A. F. C. Genetic Algorithm Applied to Investigate Cutting Process Parameters Influence on Workpiece Price Formation. *Materials and Manufacturing Processes*. v.26, n.3, p. 550-557, 2011.

COPPINI, N. L., LIBRANTZ, A. F. H., ROSA, A. F. C., CARVALHO, A. A. M. Simulated Annealing Applied to Minimize the Idleness and Maximize the Contribution Margin for Generics Flexibles Machining Cells **In:** 2nd International Conference On Engineering Optimization, 2010, Lisboa. Proceedings of the 2nd International Conference on Engineering Optimization., 2010. v.1. p.1 – 8.

ROSA, A. F. C.; LIBRANTZ, A. F. H.; COPPINI, N. L.; BAPTISTA, E. A.; ARAUJO, S. A. Simulated Annealing Technique Applied for Parameters Optimization in Machining Processes. **In:** 30º Iberian-Latin-American Congress on Computacional Methods in Engineering - CILAMCE, 2009, Armação de Búzios. Proceedings of 30º Iberian-Latin-American Congress on Computational Methods in Engineering, 2009. v. 1. p. 1-10.

COPPINI, N. L.; LIBRANTZ, A. F. H.; CARVALHO, A. A. M.; RODRIGO, R. ; ROSA, A. F. C. The Idleness Analysis During Machining: Searching for Best Organizational Results. **In:** 30º Iberian-Latin-American Congress on Computacional Methods in Engineering - CILAMCE, 2009, Armação de Búzios. Proceedings of 30º Iberian-Latin-American Congress on Computational Methods in Engineering, 2009. v. 1. p. 1-10.

1.7. RELEVÂNCIA DO TRABALHO

A otimização e gerenciamento de processos em operações bem como decisões em negociações de preços são partes fundamentais para que as empresas possam manter-se no mercado, cada vez mais competitivo.

Devido ao volume de informações envolvidas nos processos de tomadas de decisões, ferramentas que auxiliem os gestores tornam-se instrumentos fundamentais de apoio à decisão.

As técnicas computacionais utilizadas para o desenvolvimento de tais SADs devem garantir que as informações obtidas sejam rápidas e confiáveis.

Ademais, as abordagens dos temas deste trabalho são relevantes no que dizem respeito à otimização dos parâmetros de corte e redução dos custos em processos de usinagem, formação de preços de uma determinada peça e, ao uso racional dos recursos físicos disponíveis com vistas à otimização de suas capacidades ociosas, quando estas existirem.

Desta forma, a relevância deste trabalho está no estudo comparativo das técnicas metaheurísticas AG e SA e na aplicação das mesmas para o desenvolvimento de Sistemas de Apoio à Decisão (SAD) com vistas à maximização de lucros.

1.8. ESTRUTURA DO TRABALHO

Este trabalho foi estruturado em 6 capítulos, sendo:

- capítulo 1 – Introdução, objetivos, descrição dos problemas abordados, justificativa, revisão da literatura, método de pesquisa, trabalhos publicados e estrutura do trabalho;
- capítulo 2 – Primeiramente tem-se a fundamentação teórica dos conceitos básicos sobre sistema de custeio, margem de contribuição, formação de preços com base no

conceito de margem de contribuição. Em seguida, apresenta os conceitos básicos sobre usinagem destacando-se o a análise das condições econômicas de usinagem.

- capítulo 3 – Neste capítulo é apresentada a fundamentação teórica no que diz respeito às técnicas computacionais. Primeiramente apresenta os conceitos básicos de técnicas de busca e otimização e em seguida os fundamentos teóricos das técnicas metaheurísticas Algoritmo Genético e *Simulated Annealing*. Finalmente apresenta-se a fundamentação sobre SAD.
- capítulo 4 – São apresentados neste capítulo os Materiais e Metodologia aplicados neste trabalho.
- capítulo 5 – Apresentação e discussão dos resultados parciais obtidos com as técnicas metaheurística AG e SA.
- capítulo 6 – Apresenta as conclusões e sugestões para trabalhos futuros.

Além dos capítulos relacionados, fazem parte deste trabalho: as referências bibliográficas; Apêndice A o qual aborda as etapas da modelagem e simulação de sistemas; e os Anexos A, B, C e D nos quais os trabalhos publicados são apresentados.

2. FUNDAMENTAÇÃO TEÓRICA DOS PROBLEMAS ABORDADOS

O principal objetivo deste capítulo é abordar os tópicos relevantes ao PFP e ao PMO. Para tanto, se faz necessário conceituar a análise de custos, MC e formação de preços de venda. Aborda também, os itens referentes à análise das condições econômicas de usinagem, ou seja, os custos envolvidos em um processo de produção e o conceito do IME.

2.1. SISTEMAS DE CUSTEIO

Os custos de produção são aqueles que estão diretamente relacionados com o processo de obtenção de bens e serviços destinados à venda, e somente a eles. As despesas financeiras, administrativas e de vendas não estão incluídas nesse grupo. É difícil, em algumas situações, a apuração dos custos de produção e, para tanto, as empresas podem adotar a abordagem tradicional da Contabilidade de Custos (MARTINS, 2006).

Ainda de acordo com Martins (2006), os custos podem ser classificados em Custos Diretos e Indiretos, e Custos Fixos e Variáveis.

Os Custos Diretos estão relacionados aos produtos. Havendo uma medida de consumo, como por exemplo, quilograma de materiais consumidos, embalagens utilizadas, horas de mão-de-obra, quantidade de força consumida, estes podem ser apropriados diretamente aos produtos. Por outro lado, existem custos que não oferecem condição de medida e sua alocação tem que ser feita de maneira estimada e muitas vezes arbitrária, podendo ser classificados como Custos Indiretos com relação aos produtos. Esta classificação está relacionada aos produtos feitos ou serviços prestados, e não à produção no sentido geral ou aos departamentos da empresa (MARTINS, 2006, P. 48-49).

Para os Custos Fixos e Variáveis, é considerada a relação entre o valor total de um custo e o volume de atividade em uma unidade de tempo. Para Martins (2006, p. 48), esta classificação é mais importante do que todas as demais.

Os Custos Fixos são independentes da quantidade de produtos produzidos, ou seja, são aqueles que não estão ligados de forma direta a uma venda. Dentro de um determinado período seu valor não varia, é independente do aumento ou diminuição do volume de produção. Neste caso pode-se citar como exemplo, o valor do aluguel do prédio da empresa, telefone, etc. (MARTINS, 2006).

Os Custos Variáveis são dependentes diretamente do volume de produção; são os valores pagos que estão associados diretamente a uma determinada venda. Por exemplo, o valor total de consumo dos materiais diretos utilizados para a fabricação do produto, em um determinado período (mês, por exemplo) varia de acordo com o volume de produção. Quanto maior a quantidade produzida, maior o valor dos custos variáveis (MARTINS, 2006).

A abordagem tradicional da Contabilidade de Custos pressupõe três sistemas básicos de custeio: custeio por absorção, custeio baseado em atividades e o custeio variável (ATKINSON et al. 1998; JONES, 1991; KHOURY e ANCELEVICZ, 1999).

No custeio por absorção, o custo de produção de um determinado produto é formado pelos custos que incidem diretamente na fabricação do mesmo, ou seja, custos com materiais e mão de obra direta, com base no consumo real desses recursos. Todos os gastos que estão relacionados ao processo de produção são distribuídos para todos os produtos ou serviços feitos por meio de critérios de rateio. Além disso, uma significativa parcela correspondente aos custos indiretos de fabricação também é atribuída ao produto (BAPTISTA, LIBRANTZ e COPPINI, 2008; LUCATO, COPPINI e BAPTISTA, 2009).

O sistema de custeio baseado em atividades, conhecido como ABC (*Activity-Based-Costing*) considera que os recursos são consumidos por atividades, e as atividades são

consumidas pelo custo do produto. Nesse sistema são considerados os custos diretos, os custos indiretos e as despesas, sendo que nos dois últimos, é considerado o quanto custam as atividades necessárias para produzir os produtos (BAPTISTA, LIBRANTZ e COPPINI, 2008; LUCATO, COPPINI e BAPTISTA, 2009; TRENTIN, ADAMCZUCK e LIMA, 2009).

No custeio variável são considerados somente os custos essencialmente variáveis, o que geralmente correspondem aos custos que estão ligados diretamente na fabricação do produto (custos de materiais e mão-de-obra direta). Neste caso não são agregados aos produtos os custos fixos ou despesas. Com esta abordagem, simplifica-se o processo de precificação e também o torna independente do volume agregado de produção (BAPTISTA, LIBRANTZ e COPPINI, 2008; LUCATO, COPPINI e BAPTISTA, 2009; MARTINS, 2006).

A abordagem de custo variável, do ponto de vista de facilidade de uso, favorece as empresas de manufatura a estabelecerem os custos diretos envolvidos na produção de uma determinada peça, principalmente porque essa abordagem elimina completamente a alocação dos custos fixos (BAPTISTA, LIBRANTZ e COPPINI, 2008; LUCATO, COPPINI e BAPTISTA, 2009).

2.2. MARGEM DE CONTRIBUIÇÃO (MC)

De acordo com Martins (2006, p. 179) “O conceito de margem de contribuição por unidade é a diferença entre o preço de venda e o Custo Variável de cada produto; é o valor que cada unidade efetivamente traz à empresa de sobra entre sua receita e o custo que de fato provocou e que lhe pode ser imputado sem erro.”

É possível utilizar a MC somente no custeio variável, pois nele os custos fixos não são apropriados ao produto e sim são computados integralmente no resultado. A MC pode ser expressa matematicamente conforme equação (1) (CARVALHO, 2007):

$$MC = VV - CV \quad (1)$$

na qual: MC = margem de contribuição; VV = valor da venda; CV = custo variável.

A MC tanto pode ser unitária (determinada para uma unidade de um produto específico), como total (calculada para o total da produção agregada). A MCT pode ser calculada multiplicando-se a MC unitária pela quantidade do produto vendido e somada a dos demais produtos.

De acordo com Carvalho (2007), entender a influência da MC para formação de preço é entender como a empresa deve se posicionar para alcançar seus objetivos de maximizar seus resultados financeiros e definir comportamento estratégico sem prejudicar sua saúde financeira.

2.3. FORMAÇÃO DE PREÇOS DE VENDA COM BASE NO CONCEITO MARGEM DE CONTRIBUIÇÃO

Como mencionado anteriormente, atualmente no Brasil, para a maioria das empresas, em especial as indústrias prestadoras de serviços em usinagem, os preços de produtos e serviços são definidos pelos clientes ou mercado.

Para que a empresa possa aceitar o preço do produto e/ou do serviço proposto pelo cliente, se faz necessário o cálculo da formação do preço inicial de venda e, através de uma análise, ela se posicionará perante seu cliente na negociação do preço.

Com base nos conceitos acima e considerando-se as limitações das empresas, a utilização da abordagem dos custos variáveis, facilita estabelecer os custos diretamente envolvidos no processo. O preço inicial pode ser calculado de acordo com a equação (2) (LUCATO, COPPINI e BAPTISTA, 2009).

$$T_p = \frac{Custos\ Variáveis}{\left[\left(1 - \frac{\%MC}{100}\right) \cdot \left(1 - \frac{\%Impostos}{100}\right)\right]} \quad (2)$$

na qual: T_p = preço inicial de venda [R\$]; $Custos\ Variáveis$ = custos variáveis do processo de usinagem [R\$]; $\%MC$ = percentual da margem de contribuição desejada pela empresa; $\%Impostos$ = percentual de impostos diretos que incidem sobre as vendas brutas.

Baseando-se na equação do cálculo de preço inicial de vendas, T_p , o preço de venda líquido (sem impostos) poderá ser obtido dividindo-se os custos variáveis por $(1 - \%MC/100)$ e, ao se dividir o preço de venda líquido por $(1 - \%Impostos/100)$ o preço de venda (com impostos) será obtido (LUCATO, COPPINI e BAPTISTA, 2009).

Conforme se observa na tabela 1, ao se dividir R\$ 2,00 por $(1 - (50\% + 5\% + 3\%))$ obtém-se o preço de venda líquido de R\$ 4,77 e, dividindo-se R\$ 4,77 por $(1 - 21,65\%)$ tem-se o preço de venda da peça por R\$ 6,09.

Tabela 1 – Formação de Preço de Venda.

Formação de Preço de Venda		
		R\$ / Peça
a) Custo da Matéria Prima	C_1	1,78
b) Custo da Operação	C_2	0,17
c) Custo da Ferramenta	C_3	0,05
d) Custo Total (a+b+c)		2,00
e) Margem de Contribuição (h*%e)	50,0%	2,39
f) Comissão do Vendedor (h*%f)	5,0%	0,24
g) Outros (h*%g)	3,0%	0,14
h) PREÇO DE VENDA LÍQUIDO (d/(1-(e+f+g)))		4,77
i) ICMS / PIS / COFINS (j-h)	21,65%	1,32
j) PREÇO DA PEÇA (h/(1-%i))		6,09
k) IPI (j*%k)	5,0%	0,30
l) PREÇO DE VENDA (j+k)		6,39

Os itens C_1 , C_2 e C_3 relacionados na tabela 1 referem-se aos custos diretos envolvidos no processo de produção, ou seja, custo independente da velocidade de corte, custo de operação e custo relativo à ferramenta, respectivamente e são detalhados na subseção 2.4.2.

2.4. ANÁLISE DAS CONDIÇÕES ECONÔMICAS DE USINAGEM

Nesta seção são abordados os tópicos relativos às variáveis e equacionamento dos custos de produção, bem como as condições e cenários para a utilização do intervalo de máxima eficiência, com vistas à otimização do processo de usinagem e melhor aproveitamento da velocidade de corte a ser adotada conforme cenário fabril.

2.4.1. Tempo de Fabricação por Peça

O tempo de fabricação de uma determinada peça está inversamente relacionado com a velocidade de corte utilizada no processo. Se a velocidade de corte utilizada for baixa, o tempo de corte será alto e como consequência tem-se produção horária baixa e aumento dos custos com utilização de máquina e operador. Por outro lado, se a velocidade de corte empregada for alta, o tempo de corte será baixo e a utilização da máquina e do operador também será menor, reduzindo-se assim os custos. As fases do ciclo de usinagem de uma peça, pertencente a um lote de Z peças são (DINIZ, MARCONDE e COPPINI, 2008):

Fase direta

- 1- Colocação e fixação da peça;
- 2- Aproximação e posicionamento da ferramenta;
- 3- Corte;
- 4- Afastamento da ferramenta;
- 5- Inspeção e retirada da peça.

Fase indireta

- 6- Preparo da máquina;
- 7- Remoção para troca de ferramenta;
- 8- Ajuste e colocação da nova ferramenta;

O tempo de fabricação de uma determinada peça é dado de acordo com a equação (3):

$$t_t = \frac{l_f \cdot \pi \cdot d}{1000 \cdot f \cdot V_c} + \left(t_s + t_a + \frac{t_p}{Z} - \frac{1}{Z} \cdot t_{ft} \right) + \frac{l_f \cdot \pi \cdot d}{1000 \cdot f \cdot V_c \cdot T} \cdot t_{ft} \quad (3)$$

na qual: t_t = tempo total de usinagem de uma peça; l_f = percurso de avanço [mm/rotação]; d = diâmetro da peça [mm]; f = avanço; V_c = velocidade de corte [m/min]; t_s = tempo secundário (fases 1 e 5); t_a = tempo de aproximação e afastamento (fase 2 e 4); t_p = tempo de preparo de máquina (fase 6); Z = número de peças usinadas durante a vida T de uma ferramenta; t_{ft} = tempo de troca da aresta de corte e ajuste do posicionamento da ferramenta [min].

Na equação (3), considerando o tempo total de fabricação em função da velocidade de corte, apresenta um ponto mínimo onde a primeira derivada é igual a zero. De tal modo, é possível determinar a velocidade de corte que minimiza o tempo de usinagem ou maximiza a produção. Essa velocidade de corte é chamada de Velocidade de Corte de Máxima Produção (V_{cmax}).

O tempo de fabricação de uma determinada peça (equação 3) também pode ser expresso em três parcelas conforme equação (4):

$$t_t = t_c + t_1 + t_2 \quad (4)$$

na qual: t_c = tempo de corte, que diminui com o aumento da velocidade de corte; t_1 = tempo improdutivo, referente à colocação, inspeção e retirada da peça, aproximação e afastamento da ferramenta, substituição da ferramenta e preparo da máquina para usinagem de um lote que é independente da velocidade de corte; t_2 = tempo relacionado com a troca de ferramenta. Quanto maior a velocidade de corte, menor a vida da ferramenta e maior é o número de paradas da máquina para substituição da mesma.

O tempo de corte (t_c) representa a totalidade dos tempos ativos por peça, ou seja, o tempo em que os movimentos de corte e ou de avanço estão ocorrendo (DINIZ, MARCONDES e COPPINI, 2008). Seu cálculo é dado pela equação (5):

$$t_c = \frac{l_f \cdot \pi \cdot d}{1000 \cdot f \cdot V_c} \quad (5)$$

na qual: l_f = percurso de avanço [mm/rotação]; d = diâmetro da peça [mm]; f = avanço; V_c = velocidade de corte [m/min].

A equação (5) é válida somente quando todos os parâmetros envolvidos são mantidos constantes durante a usinagem. Por exemplo, quando uma peça cilíndrica é usinada com avanço e velocidade de cortes constantes. Quando os parâmetros envolvidos variam, é necessário um equacionamento adequado para cálculo do tempo de corte. Geralmente, o tempo de corte é medido diretamente na máquina.

2.4.2. Cálculo do custo de produção

Diversos são os custos envolvidos na produção de uma determinada peça por usinagem. Existem os custos decorrentes do processo, como custos de ferramentas e de ocupação de máquinas e dos operadores e os custos que não estão envolvidos diretamente com o processo, como custo de controle de qualidade, da matéria-prima, da mão-de-obra indireta, etc. Na literatura existem muitos meios para se calcular os custos de usinagem. A maioria deles é similar e basicamente consideram o custo total de produção por peça.

Diniz, Marcondes e Coppini (2008) abordam os custos da produção com vistas a se obter a velocidade econômica de corte que depende somente dos custos decorrentes do processo, ou seja, os custos diretamente envolvidos com a produção de uma peça por usinagem.

O custo total de produção por peça (K_p), assumindo-se apenas os custos diretos, consiste em três termos: C_1 , C_2 e C_3 , os quais estão representados na equação (6) (DINIZ; MARCONDES e COPPINI, 2008). Os demais desdobramentos para o cálculo do custo total

de produção são detalhados a seguir, de acordo com as equações propostas pelos autores citados.

$$K_p = C_1 + C_2 + C_3 \quad (6)$$

O primeiro termo, C_1 , representa o custo independente da velocidade de corte, ou seja, o custo do material mais os custos do salário homem e salário máquina durante os tempos improdutivos, equação (7).

$$C_1 = C_{tu} + C_m \quad (7)$$

O segundo termo, C_2 , representa o custo de operação, isto é, incluem os custos do salário homem e salário máquina relacionados ao tempo de utilização desses recursos no processo, equação (8).

$$C_2 = \frac{t_c}{60} \cdot (S_H + S_M) \quad (8)$$

E finalmente o terceiro termo, C_3 , representa o custo relativo à ferramenta, que é formado pelo custo da ferramenta propriamente dito mais o custo ocorrido na troca e ajuste da aresta de corte, equação (9).

$$C_3 = \left(\frac{t_c}{T} \right) \cdot \left(K_{ft} + \frac{t_{ft}}{60} \cdot (S_H + S_M) \right) \quad (9)$$

Ou, pode-se ainda expressar o custo por peça em função dos parâmetros do processo de corte apresentado na equação (10), na qual cada termo da equação está relacionado respectivamente com C_1 , C_2 e C_3 da equação (6):

$$K_p = (C_{tu} + C_m) + \left(\frac{t_c}{60} \cdot (S_H + S_M) \right) + \left(\left(\frac{t_c}{T} \right) \cdot \left(K_{ft} + \frac{t_{ft}}{60} \cdot (S_H + S_M) \right) \right) \quad (10)$$

na qual: K_p = custo total de usinagem por peça [R\$]; C_{tu} = custo do tempo improdutivo [R\$]; C_m = custo do material [R\$]; K_{ft} = custo da aresta de corte [R\$/aresta]; t_c = tempo de corte

[min]; t_{ft} = tempo de troca da aresta de corte e ajuste do posicionamento da ferramenta [min]; S_H = custo do salário homem incluindo benefícios [R\$/hora]; S_M = custo do salário máquina [R\$/hora]; T = vida da ferramenta [min].

Considerando a equação (10) e expressando o custo total de usinagem em função da velocidade de corte, é possível determinar um ponto no qual a velocidade de corte minimiza o custo total de usinagem. Essa velocidade de corte é chamada de Velocidade de Corte de Mínimo Custo (V_{cmc}).

A vida da ferramenta (T) é o tempo em que a mesma trabalha até perder sua capacidade de corte conforme critérios previamente estabelecidos. Conforme equação de Taylor, a vida da ferramenta (T) é dada pela equação (11) (DINIZ, MARCONDES e COPPINI, 2008):

$$T = K \cdot V_c^{-x} \quad (11)$$

na qual: T = vida da ferramenta; K e x = constantes do material para determinadas condições de usinagem; V_c = velocidade de corte.

De acordo com Diniz, Marcondes e Coppini (2008), o custo da máquina (salário máquina S_M) por hora pode ser calculado por meio da equação (12):

$$S_M = \frac{1}{H} \left[\left(V_{mi} \cdot V_{mi} \cdot \frac{m}{M} \cdot j \right) + \frac{V_{mi}}{M} + K_{mc} + E_m \cdot K_c \cdot j \right] \quad (12)$$

na qual: H = número de horas de trabalho por ano; V_{mi} = valor inicial de aquisição da máquina [R\$]; m = idade da máquina (em anos); M = vida prevista para a máquina (em anos); j = taxa de juros (ano); K_{mc} = custo anual de manutenção da máquina (R\$/ano); E_m = espaço ocupado pela máquina (m^2); K_c = custo do m^2 ocupado pela máquina (R\$/ m^2 .ano).

2.4.3. Intervalo de Máxima Eficiência (IME)

O Intervalo de Máxima Eficiência (IME), apresentado na figura 1, é formado pela velocidade de mínimo custo V_{cmc} (equação 13) e pela velocidade de máxima produção V_{cmxp} (equação 14). O cálculo destas velocidades é apresentado a seguir. Este intervalo é assim chamado porque qualquer velocidade dentro dele terá a característica de aliar ao menor custo uma máxima produção possível. Por este motivo é comum que esta velocidade seja chamada de velocidade econômica de usinagem.

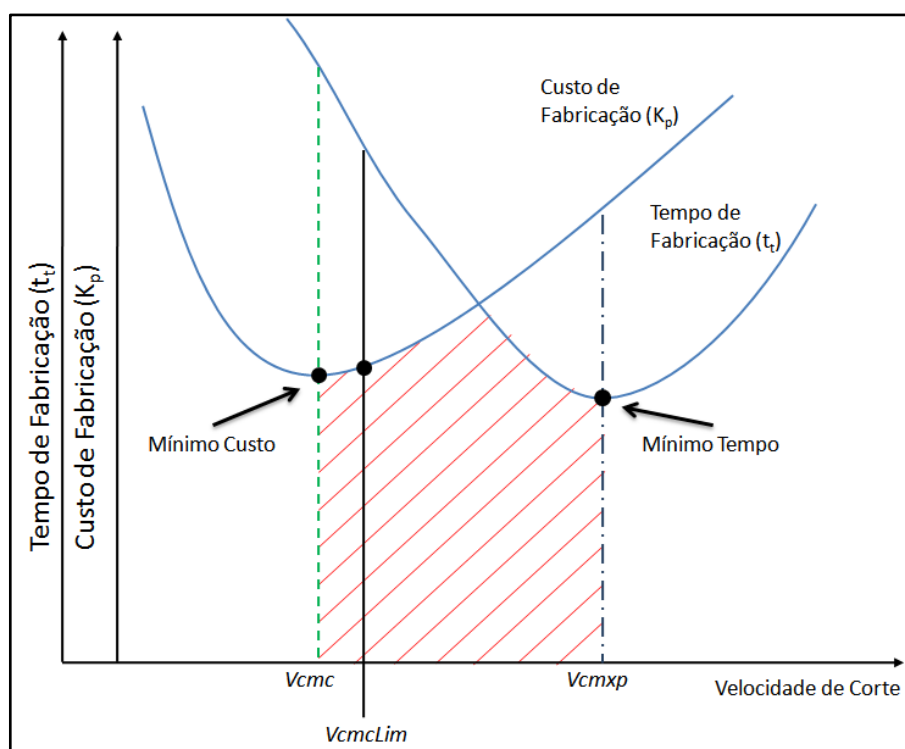


Figura 1 - Intervalo de Máxima Eficiência (IME). Fonte: Adaptado de Lucato, Coppini e Baptista (2009).

Quando o tempo de troca da ferramenta for muito pequeno, o custo para realizar sua troca (equação 13) pode ser considerado desprezível diante do custo da ferramenta K_{ft} , e então, a velocidade de corte de mínimo custo limite V_{cmcLim} se apresentará de acordo com a equação (15) (COPPINI e MALAQUIAS, 1998; DINIZ, MARCONDES e COPPINI, 2008; FERRARESI, 1997).

Para cada velocidade de corte, existe um cenário, que de acordo com suas características e restrições, indicará qual velocidade de corte deverá ser adotada como referência na otimização do processo (COPPINI e BAPTISTA, 1998; DURÁN, BARRIENTOS e COSALTER, 2007).

Para o cenário produtivo no qual se deseja o menor custo possível para o sistema máquina-ferramenta-peça, adota-se a V_{cmc} a qual pode ser calculada conforme equação (13), porém o tempo de corte e produção horária serão maiores quando comparado com a V_{cmp} .

$$V_{cmc} = \left\{ \frac{K \cdot (S_H + S_M)}{60 \cdot (x - 1) \cdot \left[K_{ft} + \left(\frac{S_H + S_M}{60} \right) \cdot t_{ft} \right]} \right\}^{\frac{1}{x}} \quad (13)$$

Na qual: K é a constante e x é o coeficientes da equação de Taylor referente a vida da ferramenta; t_{ft} é o tempo de troca da ferramenta [min]; K_{ft} é o custo do ferramental [R\$/aresta de corte].

Em um cenário restritivo, com máquina gargalo, ou em cenário no qual se deseja maior volume de produção e não há preocupação com custos, adota-se a V_{cmp} , pois permite a obtenção do menor tempo de corte para o processo, porém os custos serão mais altos devido ao maior consumo de ferramenta. A V_{cmp} pode ser calculada conforme equação (14).

$$V_{cmp} = \sqrt[x]{\frac{K}{(x - 1) \cdot t_{ft}}} \quad (14)$$

Quando o tempo de troca da ferramenta for muito pequeno, a velocidade de corte de máxima produção poderá ser maior que a velocidade máxima da máquina. Neste caso, depois de confirmada a validade dos coeficientes de Taylor, em lugar da velocidade de máxima produção, poderá ser usada esta última.

A V_{cmcLim} , representada pela equação (15), deve ser aplicada em cenários para sistemas de fabricação altamente flexíveis, onde o tempo de troca da aresta de corte tende a valores muito pequenos, podendo até ser igual a zero (BAPTISTA e COPPINI, 2007).

$$V_{cmcLim} = \left\{ \frac{K \cdot (S_H + S_M)}{60 \cdot (x - 1) \cdot K_{ft}} \right\}^{\frac{1}{x}} \quad (15)$$

Para a V_{cmc} e V_{cmcLim} , também deve-se considerar o sistema de custeio, pois o mesmo tem influência direta na definição das velocidades devido à utilização dos valores do salário homem e salário máquina. O sistema de custeio deverá determinar com precisão esses valores para que os resultados não sejam afetados (COPPINI e BAPTISTA, 1998).

A otimização dos parâmetros de corte de usinagem, a formação de preços, bem como a maximização da MC foi aplicada aos SADs desenvolvidos para o PFP utilizando-se as equações e suas derivações apresentadas na fundamentação teórica, quais sejam: T_p (equação 2) para formação do preço inicial de uma determinada peça usinada; K_p (equação 6) para o cálculo do custo total de produção por peça, considerando-se apenas os custos variáveis; V_{cmc} (equação 13), V_{cmxp} (equação 14) e V_{cmcLim} (equação 15) as quais calculam, respectivamente, Velocidade de Corte de Mínimo Custo, Velocidade de Corte de Máxima Produção e Velocidade de Corte de Mínimo Custo Limite; e MC (equação 1) para o cálculo da Margem de Contribuição utilizada tanto para o PFP quanto para o PMO.

3. FUNDAMENTAÇÃO TEÓRICA SOBRE AS TÉCNICAS COMPUTACIONAIS APLICADAS

Neste capítulo são abordados os tópicos relevantes às técnicas computacionais Busca Exaustiva, Algoritmo Genético e *Simulated Annealing*, bem como a fundamentação teórica sobre Sistemas de Apoio à Decisão.

3.1. MÉTODOS E TÉCNICAS COMPUTACIONAIS DE BUSCA E OTIMIZAÇÃO

No contexto matemático, a otimização consiste no processo pelo qual se determina o valor ótimo de uma função em relação a suas variáveis, isto é, encontrar os valores das variáveis de modo a se obter os valores extremos da função, que podem ser os pontos de máximo ou de mínimo da função (MUNDIM e DELAVY, 2008).

Uma função pode apresentar apenas um ponto de mínimo ou de máximo, função unimodal, ou conter vários pontos de extremos que minimizam ou maximizam a função, função multimodal. A função multimodal apresenta valores ótimos locais e valores ótimos globais (MUNDIM e DELAVY, 2008).

Muitos problemas, sejam eles de importância prática ou teórica, consistem na escolha da melhor configuração ou conjunto de parâmetros para alcançar um determinado objetivo (PAPADIMITRIOU e STEIGLITZ, 1982).

Os problemas de otimização normalmente envolvem a minimização ou maximização de uma Função Objetivo (FO) com uma ou mais variáveis, sobre um determinado domínio, sujeita a um conjunto de restrições.

De acordo com Blum e Roli (2008), um problema de otimização, P , pode ser descrito como uma tripla (\mathcal{S}, Ω, f) , na qual:

- a) S é o espaço de busca definido sobre um conjunto finito das variáveis de decisão X_i , $i = 1, \dots, n$. Caso essas variáveis tenham domínios discretos, P é chamado de problema de otimização discreta (ou problema de otimização combinatória), e em casos no qual as variáveis tenham domínios contínuos, P é chamado de problema de otimização contínua. Problemas com variáveis mistas também existem. Ω é um conjunto de restrições entre as variáveis.
- b) $f : S \rightarrow \mathbb{R}^+$ é a função objetivo que indica um valor positivo do custo para cada elemento (ou solução) de S .

O objetivo é encontrar a uma solução $s \in S$ de tal forma que $f(s) \leq f(s'), \forall s' \in S$, isto é, a solução encontrada é menor do que a solução atual, para quando se deseja minimizar a função objetivo, ou $s \in S$ tal que $f(s) \geq f(s'), \forall s' \in S$, ou seja, a solução encontrada é maior que a solução atual, para quando se deseja maximizar a função objetivo. Em problemas reais, o objetivo é frequentemente otimizar várias funções objetivo ao mesmo tempo. Essa forma de otimização é definida como otimização multiobjetivo (BLUM e ROLI, 2008).

A figura 2 ilustra um problema de maximização com uma função objetivo f definida sobre um espaço bidimensional (duas variáveis) $X = (X_1, X_2)$ contendo pontos de ótimo local e ótimo global.




Figura 2 – Ótimo local e global de uma função de duas variáveis. Fonte: Adaptado de Weise (2009, p.26).

Um ótimo local $x_i^* \in \mathbb{X}$ de um função objetivo $f : \mathbb{X} \rightarrow \mathbb{R}$ ou é um mínimo local ou um máximo local. É a melhor solução somente em um subespaço de busca (WEISE, 2009).

Um ótimo global $x^* \in \mathbb{X}$ de um função objetivo $f : \mathbb{X} \rightarrow \mathbb{R}$ ou é um mínimo global ou um máximo global. É a melhor solução em um subespaço de busca. É a melhor solução em todo espaço de busca (WEISE, 2009).

Uma das dificuldades em otimização é determinar se o valor encontrado é um ponto ótimo local ou ótimo global (WEISE, 2009).

Estruturas de otimização, geralmente, apresentam (WEISE, 2009):

- a) Espaço do problema – o espaço do problema \mathbb{X} de um problema de otimização é constituído pelo conjunto que contém todos os elementos x que pode ser a sua solução;
- b) Solução candidata – uma solução candidata x é um elemento do espaço do problema \mathbb{X} de um determinado problema de otimização;
- c) Espaço de solução – é a união de todas as soluções de um problema de otimização no seu espaço de solução \mathbb{S} ; $\mathbb{X}^* \subseteq \mathbb{S} \subseteq \mathbb{X}$. Esse espaço de solução contém (e pode ser igual) o conjunto \mathbb{X}^* ótimo global. Podem existir soluções

válidas $x \in \mathbb{S}$, que não são elementos do X^* , principalmente no contexto de otimização com restrição;

- d) Espaço de busca – o espaço de busca \mathbb{G} de um problema de otimização é o conjunto de todos os elementos g que podem ser processados por uma operação de busca; é formado pelo conjunto de todas as soluções viáveis de um determinado problema; cada ponto no espaço de busca representa uma solução possível (SIVANANDAM e DEEPA, 2008);
- e) Função objetivo - também chamada de função custo ou para os AGs, função de aptidão – é a função matemática utilizada para avaliar as soluções produzidas, associando a cada uma delas uma nota;
- f) Restrições - de forma geral, os problemas de otimização apresentam algum tipo de restrição pertinente ao contexto real do problema a ser otimizado que podem estar relacionadas com otimalidade (estratégia utilizada na busca para encontrar a solução ótima), completeza (garantia de que o algoritmo encontrará uma solução quando ela existir). Pode-se também considerar uma restrição o tempo de processamento computacional, ou seja, o custo computacional.

O espaço de busca se divide em região factível e não factível conforme ilustrado na figura 3. As soluções da região factível são aquelas que satisfazem a todas as restrições do problema, já as soluções da região não factível são as que violam uma ou mais restrições do problema.




Figura 3 – Regiões do Espaço de Busca.

Weise (2009) apresenta uma classificação geral dos métodos de otimização global de acordo com o seu método de operação, conforme ilustrado na figura 4. Geralmente, os algoritmos de otimização são divididos em duas classes básicas: os algoritmos determinísticos e os algoritmos probabilísticos (não determinísticos).

Os métodos determinísticos geralmente utilizam a derivada da função objetivo para explorar o espaço de busca, enquanto que os métodos probabilísticos, sucessivamente, melhoraram uma ou várias soluções do modelo subjacente para obter uma aproximação da solução ótima global.

Os métodos probabilísticos são geralmente aplicados quando a utilização de outros métodos se torna inviável devido ao custo computacional. Isto acontece em problemas de otimização multidimensional, onde o número de soluções possíveis cresce exponencialmente com o número de variáveis (ARAÚJO, LIBRANTZ e ALVES, 2009). Além disso, os métodos determinísticos não têm um bom desempenho para lidar com funções multimodais, ou seja, funções que têm muitos valores ótimos locais. Assim, muitos métodos probabilísticos têm sido propostos na literatura para resolver problemas em ciência e engenharia (GOLDBERG, 1989; PHAM e PHAM, 1999).

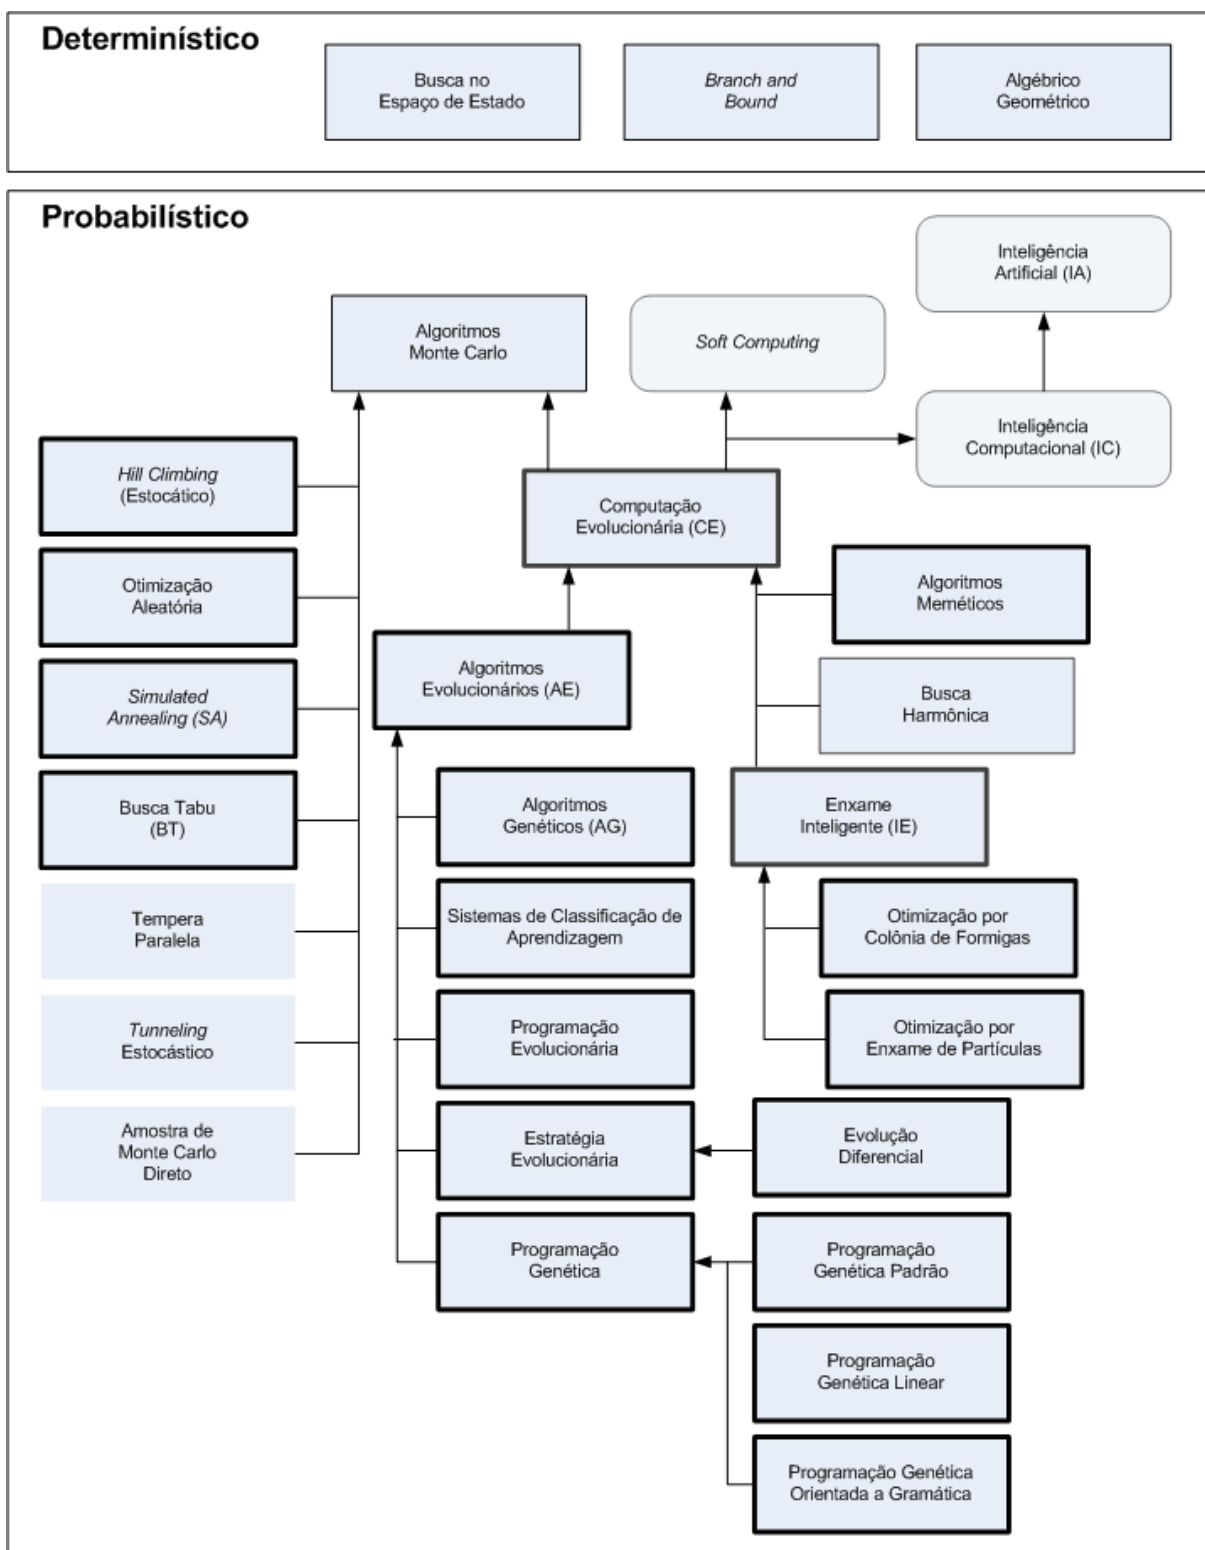


Figura 4 – Classificação de algoritmos de otimização global de acordo com o método de operação. Fonte: Adaptado de Weise (2009, p.23).

Como apresentado na figura 4, tanto o AG quanto o SA são técnicas de otimização probabilísticas as quais pertencem à família de algoritmos com base na abordagem do método de Monte Carlo.

3.1.1. Busca Exaustiva (BE)

A Busca Exaustiva (BE) também chamada de “Força Bruta” é um método para gerar, de forma sistemática, todas as possíveis soluções do espaço de busca do problema para então determinar a solução ótima (HAUPT e HAUPT, 2004).

Ela é uma das mais simples de se implementar, porém, se torna computacionalmente inviável quando o espaço de solução a ser percorrido é muito grande. Seu custo computacional é proporcional ao número de soluções e o tempo de processamento também cresce exponencialmente conforme o aumento do número de soluções (ARAÚJO, LIBRANTZ e ALVES, 2009). A figura 5 apresenta seu pseudocódigo.

Procedimento Busca Exaustiva

Início

Seja s_0 a solução inicial, s a solução representada pelo estado corrente, s' a solução representada pelo sucessor do estado corrente, s^* a melhor solução obtida até então

$s \leftarrow s_0$

$s^* \leftarrow s_0$

enquanto (não esgotar todo o espaço de busca) faça

 Gera sucessor s' {sistematicamente}

$s \leftarrow s'$

se $s > s^*$ então

$s^* \leftarrow s$

fim-se

fim-enquanto

Retorne s^*

Fim

Figura 5 - Pseudocódigo BE.

No *looping* interno do algoritmo da BE, todos os valores das variáveis que formam a função objetivo, são testados e comparados, guardando-se sempre o maior valor (no caso representado no procedimento, é um problema de maximização) até que o algoritmo tenha percorrido todo o espaço de busca.

3.1.2. Técnicas Heurísticas

Em otimização, heurística é uma parte de um algoritmo de otimização que se utiliza da informação atual obtida pelo algoritmo, para encontrar soluções de boa qualidade em um tempo computacional razoável, para problemas de otimização complexos, porém, não garantem que a solução encontrada seja a solução ótima ou o quão próxima uma determinada solução está da solução ótima (WEISE, 2009).

As buscas com base em heurísticas podem ser úteis nos casos onde as técnicas de otimização convencionais (Algoritmos com base em Programação Linear, em Programação Dinâmica, em Programação Não-Linear) não são adequadas para resolução de problemas com espaço de busca grande com muitos ótimos locais (MUKHERJEE e RAY, 2006).

A grande desvantagem das heurísticas está na dificuldade de escaparem de ótimos locais. A partir dessa dificuldade, surgiram as técnicas de busca metaheurísticas.

3.1.3. Técnicas Metaheurísticas

As metaheurísticas são métodos que combinam métodos heurísticos básicos com estratégias de alto nível para explorar o espaço de busca (BLUM e ROLI, 2003). Elas possuem mecanismos que possibilitam escapar dos ótimos locais.

As técnicas metaheurísticas são ferramentas poderosas para resolução de problemas de otimização complexos, cujo espaço de busca das soluções ótimas seja muito grande para que se possa determiná-las com precisão por meio de um método determinístico com tempo de processamento aceitável. Estas técnicas utilizam informação e intuição a respeito do problema para produzirem soluções rápidas e de boa qualidade.

Elas são algoritmos de otimização que para escapar de ótimos locais, utilizam-se de alguma heurística básica a qual pode ser uma heurística construtiva que parte de uma solução

nula e adiciona elementos para construir uma solução completa, ou uma heurística de busca local que, a partir de uma solução inicial tenta melhorar essa solução por meio de operações de troca, remoção ou inserção, até que não seja mais possível a melhoria dessa solução ou algum outro critério de parada seja satisfeito (HAMMOUCHE, DIAF e SIARRY, 2010).

Dentre as propriedades fundamentais sumarizadas por Blum e Roli (2003) que caracterizam as técnicas metaheurísticas, pode-se destacar:

- são estratégias que "guiam" o processo de busca;
- o objetivo é explorar eficientemente o espaço de busca para encontrar soluções ótimas ou próximas do ótimo;
- as soluções são aproximadas e, geralmente, não-determinísticas;
- incorporam mecanismos para evitar ótimos locais do espaço de busca;

As metaheurísticas pertencem à classe dos algoritmos de otimização estocásticos, pois se utilizam de aleatoriedade para encontrar a solução ótima (ou próximas do ótimo) de um problema complexo. Dentre os algoritmos pertencentes a essa classe, pode-se citar: Otimização por Colônia de Formigas (*Ant Colony Optimization* – ACO), Computação Evolucionária (CE) incluindo os Algoritmos Genéticos (AG), Busca Local Iterativa (*Iterated Local Search* - ILS), *Simulated Annealing* (SA), Otimização por Enxame de Partículas (*Particle Swarm Optimization* – PSO) e Busca Tabu (Tabu Search- TS).

Nas seções a seguir são abordadas as técnicas AG e SA as quais são os objetos de pesquisa deste trabalho.

3.2. ALGORITMO GENÉTICO (AG)

Computação Evolucionária é o nome genérico dado a métodos computacionais inspirados na teoria da evolução das espécies. Os algoritmos utilizados em computação evolucionária são conhecidos como Algoritmos Evolucionários (AE).

Nos anos de 1950 e 1960, muitos cientistas da computação estudaram independentemente os sistemas evolucionários com a ideia de que a evolução pode ser utilizada como uma ferramenta de otimização para problemas de engenharia.

Os AE mais conhecidos são: Algoritmos Genéticos (AGs), Programação Evolucionária (PE) e Estratégias Evolucionárias (EE).

A ideia nesses sistemas foi evoluir uma população de soluções candidatas de um determinado problema, utilizando operadores inspirados na variação da genética natural e seleção natural.

Os AE compartilham de uma base conceitual comum, que consiste na simulação da evolução de estruturas individuais, por meio de processos de seleção e os operadores de busca, referidos como Operadores Genéticos tais como *crossover* (cruzamento ou recombinação) e mutação, os quais poderão ser vistos detalhadamente na subseção 3.2.5. O processo depende do *fitness* (nota de aptidão dada a um indivíduo, detalhada na subseção 3.2.4) alcançado pelas estruturas individuais, frente a um ambiente. A seleção é focada nos indivíduos da população com um alto grau de aptidão, explorando então, a informação da aptidão disponível. O cruzamento e a mutação modificam esses indivíduos da população, fornecendo heurística geral para a exploração (AZEVEDO, BRASIL e OLIVEIRA, 2000).

O AG foi criado por John H. Holland, na década de 1960 e desenvolvido por ele, por seus estudantes e colegas na Universidade de Michigan nas décadas de 1960 e 1970, e finalmente popularizado por um de seus alunos, David Goldberg que resolveu um problema difícil envolvendo o controle de transmissão de gasoduto em sua dissertação (GOLDBERG, 1989).

Em 1975, em seu livro “*Adaptation in Natural and Artificial Systems*”, Holland apresentou o AG como uma abstração da evolução biológica e deu uma estrutura teórica para a adaptação no domínio do AG. Ele se inspirou no mecanismo da evolução das espécies da

teoria de Charles Darwin e nos trabalhos de Mendel sobre genética natural (AZEVEDO, BRASIL e OLIVEIRA, 2000; MITCHELL, M., 1999).

Vale lembrar, o AG é um método estocástico, de busca e otimização fundamentado nos princípios da genética natural e no processo de seleção natural, que simula a evolução das espécies (GOLDBERG, 1989; HAUPT e HAUPT, 2004; RUSSEL e NORVIG, 2004).

Ele pode ser visto como um método de otimização que, em um grande espaço de busca, procura uma solução candidata que obtenha o melhor resultado, o qual é definido como aquele que otimiza uma medida numérica pré-definida para o problema, denominada de função de aptidão (detalhada na subseção 3.2.4) ou função *fitness*. Apesar de não ser garantido encontrar uma solução candidata “ótima”, frequentemente o AG encontra soluções candidatas de alta aptidão com tempo computacional relativamente rápido. Ele tem sido aplicado a problemas de otimização tais como problemas de *layout* de circuito, agendamento de tarefas (*Job-shop Scheduling Problem*), otimização de processos e parâmetros, dentre outros (MITCHELL, T. M., 1997).

O AG opera de forma iterativa atualizando o conjunto de indivíduos, chamados de população. A cada iteração, o AG gera os membros da população (também chamados de indivíduos ou cromossomo, apresentado na figura 6) para evoluírem em busca da solução de um dado problema de otimização. Eles são avaliados de acordo com uma função de aptidão. Uma nova população é gerada probabilisticamente, selecionando os indivíduos mais aptos da população atual. Alguns destes indivíduos selecionados são transportados para a próxima geração da população sem modificação. Outros são utilizados como base para a criação de novos indivíduos descendentes através da aplicação de operações genéticas como cruzamento e mutação. Dessa forma, a cada nova geração deve haver um indivíduo mais próximo de uma solução ótima para o problema (HAUPT e HAUPT, 2004; MITCHELL, T. M., 1997).

Os elementos básicos de um AG são: (a) cromossomo: conjunto de bits; (b) gene: subconjunto de bits do cromossomo e (c) alelo: cada bit de um gene. A estrutura básica de um AG contempla quatro operações principais: o cálculo de aptidão, o processo de seleção, o cruzamento e a mutação dos indivíduos (HAUPT e HAUPT, 2004; MICHALEWICZ, 1996).

Devido o AG ser inspirado na genética natural e na teoria da evolução das espécies, ele utiliza palavras emprestadas da genética natural existindo assim uma analogia entre os termos da biologia e os utilizados no AG.

Na natureza um ou mais cromossomos se combinam para formar as características genéticas básicas de um indivíduo. No contexto do AG os termos cromossomo e indivíduo têm o mesmo significado; eles são uma estrutura de dados que representam uma das possíveis soluções do problema no espaço de busca (PACHECO, 1999).

Os cromossomos, conforme ilustrado na figura 6, são formados por genes organizados em uma sequência linear, que podem ter um determinado valor entre vários possíveis, chamados de alelos. Cada gene controla a herança genética das características dos indivíduos e possui um local fixo no cromossomo denominado *locus*. Outros termos importantes a serem considerados são genoma, genótipo e fenótipo (MICHALEWICZ, 1996).




Figura 6 – Estrutura de um cromossomo.

O genótipo representa a estrutura do cromossomo codificado, e pode ser identificado no AG com o termo estrutura; cada genótipo representa uma potencial solução para um determinado problema. Fenótipo corresponde à interação do conteúdo genético com o ambiente, ou seja, o cromossomo decodificado; no AG essa interação se dá por meio do

conjunto de parâmetros do algoritmo. A tabela 2 apresenta a analogia da terminologia utilizada na biologia e no AG (LINDEN, 2008).

Tabela 2 - Terminologia referente a analogia entre a Biologia e o AG.

Biologia	Algoritmos Genéticos
Cromossomo	Indivíduo ou cromossomo
Gene	Característica
Alelo	Valor
<i>Locus</i>	Posição de cada gene
Genótipo	Estrutura do cromossomo
Fenótipo	Conjunto de parâmetros
Geração	Ciclo

3.2.1. Algoritmo Genético Simples

A estrutura de um AG simples é descrita da seguinte forma: durante a iteração t , um AG mantém uma população de soluções potenciais (cromossomos, vetores), $P(t) = \{x_1^t, \dots, x_n^t\}$. Cada solução x_i^t é avaliada e produz uma medida de sua aptidão (*fitness*). Uma nova população (iteração $t + 1$) é então formada selecionando-se os indivíduos mais aptos. Alguns membros dessa nova população sofrem alterações por meio de cruzamento (*crossover*) e mutação (*mutation*) para formar novas soluções. Cada iteração desse processo é chamada de geração. O processo é repetido até que o número máximo de gerações seja atingido ou até algum outro critério de parada pré-estabelecido (MICHALEWICZ, 1996). A figura 7 apresenta o pseudocódigo do AG.

Algoritmo Genético

Início

Seja s' a melhor solução da geração corrente, s^* a melhor solução obtida até então, Ger o contador do número de gerações e Max_Ger o número máximo de gerações permitidas.

$Ger \leftarrow 1$

Gera população inicial {aleatoriamente}

Avalia população {cálculo da aptidão dos indivíduos}

Enquanto $Ger \leq Max_Ger$ ou algum outro critério de parada não for atingido

 Faz seleção dos melhores indivíduos

 Efetua o cruzamento entre os melhores indivíduos para recompor a população

 Faz mutação de um percentual dos indivíduos da população

 Avalia população {cálculo da aptidão dos indivíduos}

se $s' > s^*$ então

$s^* \leftarrow s'$

fim se

$Ger \leftarrow Ger + 1$

fim enquanto

Retorne s^*

Fim

Figura 7 - Pseudocódigo AG.

No pseudocódigo (figura 7) do AG pode-se ver que ele começa com uma população inicial de indivíduos gerados aleatoriamente, os indivíduos são avaliados de acordo com sua aptidão, os melhores indivíduos são selecionados para reprodução e mutação formando uma nova população e a cada geração se guarda o melhor indivíduo. Esse processo se repete até a condição de parada do algoritmo.

De uma forma geral, os AGs têm cinco componentes (MICHALEWICZ, 1996):

- a) uma representação das possíveis soluções do problema;
- b) uma forma de gerar uma população inicial das soluções;
- c) uma função de avaliação para classificar as soluções em termos de sua aptidão;
- d) operadores genéticos que alterem a composição genética dos filhos durante a reprodução;
- e) valores dos parâmetros que o AG utiliza tais como: tamanho da população, número de gerações, taxa de mutação, método de seleção, entre outros.

3.2.2. Representação das Soluções

A representação das soluções candidatas do espaço de busca de um problema de otimização define a estrutura do cromossomo a ser manipulado pelo algoritmo, que depende do tipo de problema e do que, essencialmente, se deseja manipular geneticamente. Nos AGs as operações não são realizadas diretamente sobre as soluções candidatas, mas sobre uma codificação das mesmas. Um cromossomo, normalmente um vetor, pode representar números binários, números reais, números inteiros, permutação de símbolos, símbolos repetidos, dentre outras (PACHECO, 1999).

A representação binária, um vetor de bits composto pelo alfabeto “0” e “1”, foi adotada inicialmente por Holland (1975). Ela é simples, fácil de manipular os cromossomos por meio dos operadores genéticos e fácil de ser transformada em inteiro ou real (PACHECO, 1999).

Na implementação do AG, inicia-se definindo um cromossomo ou um vetor dos valores das variáveis a serem otimizadas. Se o cromossomo tem N_{var} variáveis (um problema de otimização de N_{var} dimensão) dado por $p_1, p_2, \dots, p_{N_{var}}$, então o cromossomo é definido como um vetor de N_{var} elementos (HAUPT e HAUPT, 2004).

$$cromossomo = [p_1, p_2, \dots, p_{N_{var}}] \quad (16)$$

A figura 8 ilustra a estrutura de um cromossomo binário, com três genes para um problema de otimização de três dimensões. Cada gene é uma parte indissociável e representa uma variável do problema.




Figura 8 – Estrutura de um cromossomo binário.

Embora, a representação binária possa ser utilizada em problemas com parâmetros contínuos, a representação de números reais apresenta maior precisão e capacidade de representação de domínios do problema (MICHALEWICZ, 1996).

A codificação do problema e a função de avaliação são dois componentes dos AGs que são dependentes do problema (WHITLEY, 1994).

3.2.2.1. Codificação e Decodificação

Uma vez que os valores das variáveis são representados por cromossomos binários, deve existir uma forma para converter os valores contínuos em binário e vice-versa (HAUPT e HAUPT, 2004).

Segundo Linden (2008) para representar números reais como números binários faz-se necessário saber: a) a faixa de operação de cada uma das variáveis, ou seja, o domínio da variável representado por seus limites mínimo e máximo; b) a precisão de casas decimais desejada. Esses parâmetros em conjunto definem a quantidade de bits necessária para a codificação e decodificação da variável.

Deste modo, para se obter a quantidade de bits k necessária para um número binário representar um número real X_R , pertencente a um domínio $[X_{max}, X_{min}]$ com p casas decimais, pode ser feita conforme equação (17) (PACHECO, 1999).

$$2^K \geq (X_{max} - X_{min}) \cdot 10^p \quad (17)$$

Na qual: X_{max} é o limite superior da variável; X_{min} é o limite inferior da variável; p é o número de casas decimais desejadas e K o número de bits necessários.

Tomando-se como exemplo o problema para maximizar a seguinte equação (18) com precisão de quatro casas decimais para cada variável (MICHALEWICZ, 1996, p. 36).

$$f(x_1, x_2) = 21,5 + x_1 \cdot \sin(4\pi x_1) + x_2 \cdot \sin(20\pi x_2) \quad (18)$$

Na qual o domínio das variáveis é: $-3,0 \leq x_1 \leq 12,1$ e $4,1 \leq x_2 \leq 5,8$. Neste caso, para a variável x_1 o domínio é de 15,1 [12,1 – (-3,0)]; para precisão de quatro casas decimais tem-se: $15,1 \cdot 10^4$, isto é, 151000, portanto $2^{17} < 151000 < 2^{18}$, logo, serão necessários 18 *bits* para representar a primeira parte do cromossomo. Para representar x_2 tem-se: domínio igual a 1,7 [5,8-(4,1)]; $1,7 \cdot 10^4$ para precisão de quatro casas decimais, ou seja, 17000, portanto $2^{14} < 17000 < 2^{15}$, logo, serão necessários 15 *bits* para representar a segunda parte do cromossomo.

O tamanho total do cromossomo será de 33 *bits* [18+15]; os primeiros 18 *bits* para representar a variável x_1 e os 15 *bits* [33-18] restantes para representar x_2 . A figura 9 apresenta um exemplo de um cromossomo de 33 *bits* gerado aleatoriamente.

010001001011010000111110010100010

Figura 9 - Cromossomo gerado aleatoriamente com tamanho de 33 *bits*.

A decodificação do número binário dentro do cromossomo para o número real correspondente ao domínio da variável se dá por meio da equação (19) (LINDEN, 2008).

$$real = X_{min} + \frac{X_{max} - X_{min}}{2^K - 1} \cdot r_i \quad (19)$$

Na qual: *real* é o número real convertido e $real \in [X_{max}, X_{min}]$; r_i é o número inteiro correspondente ao número binário; K é o número de bits que representa a variável.

Retornando ao exemplo acima, os primeiros 18 *bits*, **010001001011010000**, representam $x_1 = -3,0 + \frac{12,1 - (-3,0)}{2^{18} - 1} \cdot 70352 = 1,052426$; e os 15 *bits* restantes **111110010100010** representam $x_2 = 4,1 + \frac{5,8 - 4,1}{2^{15} - 1} \cdot 31906 = 5,755330$.

De acordo com Linden (2008) geralmente o tamanho dos genes que representam as variáveis têm o mesmo número de *bits*, no entanto, os genes podem ter números de *bits* diferentes o que depende do domínio da variável ou da precisão decimal desejada. Vale

ressaltar que quanto maior for o número de *bits* em cada gene, maior será a precisão numérica para representar números decimais, porém, também será exigido mais processamento o que eleva o custo computacional.

3.2.3. População Inicial

Uma população é uma coleção de indivíduos. (SIVANANDAM e DEEPA, 2008). O primeiro passo na implementação do AG é a geração de uma população inicial, que na maioria das vezes se dá por meio da geração de números aleatórios distribuídos uniformemente (LINDEN, 2008).

3.2.4. Função de Aptidão

A aptidão de um indivíduo no contexto do AG é o valor da função objetivo para o seu fenótipo (conjunto de parâmetros) (SIVANANDAM e DEEPA, 2008).

A função de aptidão, também conhecida como função *fitness* no AG, associa um valor de aptidão para cada indivíduo da população para determinar a sua qualidade como solução para o problema. Essa medida de aptidão é utilizada para determinar o número de vezes que o indivíduo será selecionado para reprodução (DRÉO et al., 2006).

3.2.5. Operadores do Algoritmo Genético

A cada geração, os indivíduos reproduzem, sobrevivem ou desaparecem de uma população por meio dos operadores genéticos.

No AG, a geração de sucessores é determinada por um conjunto de operadores que recombina e transformam os indivíduos da população atual (MITCHELL, T. M., 1997).

A forma mais simples do AG envolve três tipos de operadores: seleção, cruzamento (único ponto) e mutação (MITCHELL, M., 1999).

3.2.5.1. Operador de Seleção

Este operador seleciona os cromossomos da população para reprodução; ele determina quantas vezes um indivíduo será reproduzido na geração (MITCHELL, M., 1999).

Análogo ao processo de seleção natural, a cada geração o AG seleciona os melhores indivíduos (cromossomos pais) da população para gerar novos filhos (cromossomos filhos) por meio dos operadores de cruzamento e mutação.

Geralmente, a capacidade de um indivíduo ser selecionado para reprodução depende de sua aptidão. Indivíduos com melhor aptidão são reproduzidos com mais frequência do que os outros, porém não se podem descartar os outros indivíduos, pois eles podem conter características genéticas que favoreçam a geração de um indivíduo que pode ser a melhor solução do problema. Caso se utilize somente os melhores indivíduos para se reproduzirem, a população tenderá a ter indivíduos cada vez mais semelhantes causando falta de diversidade na população. Esse efeito é denominado de convergência genética (LINDEN, 2008).

Existem diferentes tipos de seleção. Os mais comuns são:

- seleção por roleta (*roulette wheel*): este método faz analogia a roleta de cassinos. A ideia básica é determinar a probabilidade de seleção para cada indivíduo proporcionalmente a sua aptidão. A probabilidade de cada indivíduo é calculada dividindo-se a aptidão do indivíduo pelo somatório das aptidões dos indivíduos da atual população. Os indivíduos são selecionados a partir de um sorteio aleatório.
- seleção por torneio (*tournament selection*): neste método uma série de indivíduos da população são selecionados e competem entre si para determinar a escolha do pai, utilizando a aptidão como forma de avaliação. De acordo com um parâmetro,

denominado de tamanho do torneio, é definido quantos indivíduos são selecionados na população para competirem. Aquele que possuir a melhor aptidão é selecionado.

3.2.5.2. Elitismo

A estratégia do elitismo consiste em preservar os n melhores indivíduos da população para a próxima geração. Esses indivíduos não devem desaparecer durante as gerações, mas sim passarem para a próxima geração.

Se os melhores indivíduos não forem preservados para se reproduzirem nas próximas gerações, eles podem não ser selecionados ou destruídos pelos operadores de cruzamento ou mutação. O elitismo melhora significativamente o desempenho do AG (MITCHELL, M., 1999).

3.2.5.3. Operador de Cruzamento

A forma mais comum de cruzamento é a seleção de dois “cromossomos pai” para gerar dois “cromossomos filho”. O método mais simples escolhe um ponto de corte nos cromossomos, isto é, o ponto de separação entre cada um dos genes que compõem o material genético de cada pai. O ponto de cruzamento é selecionado aleatoriamente entre o primeiro e o último *bit* dos cromossomos pais para a codificação binária. (LINDEN, 2008).

A figura 10 ilustra o cruzamento de um par de cromossomos pais com ponto de corte na posição 9. Esses cromossomos são separados após o nono *bit* e substituídos para gerar um novo par de cromossomos filhos.

Pai 1 =	100011000	101101
Pai 2 =	111011101	101110
Filho 1 =	100011000	101110
Filho 2 =	111011101	101101

Figura 10 - Par de cromossomos pais com ponto de corte na nona posição para gerar dois novos cromossomos filhos por meio do operador cruzamento.

De acordo com Michalewicz (1996) a troca de informações entre as diferentes soluções potenciais se dá por meio do operador de cruzamento.

O cruzamento de dois pontos de corte é similar ao de um ponto, neste caso são selecionados dois pontos aleatoriamente. O primeiro filho é formado pelas partes do primeiro pai que estão fora dos pontos de corte e pela parte do segundo pai que está entre os dois pontos de corte. O segundo filho tem sua formação semelhante ao primeiro filho, porém invertendo-se os pais.

3.2.5.4. Operador de Mutação

A mutação é um importante método para preservação da diversidade genética da população onde pequenas trocas aleatórias são efetuadas nos cromossomos selecionados (LINDEN, 2008).

A operação mutação modifica aleatoriamente os genes de um indivíduo de acordo com uma baixa probabilidade conhecida como taxa de mutação. No cromossomo binário, se o valor do *bit* é “0” ele passa a ser “1” e vice-versa (DÉO et al., 2006). Por exemplo, o cromossomo 00000100 tem o seu *bit* da segunda posição alterado, e o novo cromossomo será 01000100.

3.3. *SIMULATED ANNEALING* (SA) - RECOZIMENTO SIMULADO

O *Simulated Annealing* (SA) se baseia em uma relação entre conceitos termodinâmicos e processos de otimização combinatória. O termo *Annealing*, vem do inglês e significa recozimento que é utilizado na metalurgia e pelos vidreiros para modelar um material ou vidro usando o processo de resfriamento controlado (MUNDIM e DELAVY, 2008).

O SA é um método de otimização combinatória que foi proposto originalmente por Kirkpatrick et al. (1983). Os autores apresentaram em seu trabalho a relação entre mecânica estatística (o comportamento de sistemas com muitos graus de liberdade em equilíbrio térmico com uma temperatura finita) e otimização combinatória (encontrar o mínimo de uma determinada função de acordo com vários parâmetros) inspirados no algoritmo de Metropolis et al. (1953, apud Kirkpatrick et al., 1983, p. 672). Um trabalho similar foi desenvolvido independentemente e ao mesmo tempo por Černý (1985) que utilizou uma abordagem similar no problema do caixeiro viajante.

Desde a sua descoberta, o método SA provou a sua eficácia em vários domínios, como por exemplo, em projetos de circuitos integrados (VLSI - *Very-large-scale integration*) (KIRKPATRICK, GELATTI e VECCHI, 1983), processamento de imagens (HAMMOUCHE, DIAF e SIARRY, 2010), problemas de agendamento/programação (*scheduling problem*) (NADERI, FATEMI GHOMI e AMINNAYERI, 2010) e no clássico problema do caixeiro viajante (*Traveling Salesman Problem*) (KIRKPATRICK, GELATTI e VECCHI, 1983).

O SA é conhecido como uma técnica compacta e robusta que proporciona excelentes soluções para problemas de otimização com custo computacional viável (BALRAM, 2004).

3.3.1. Processo de Recozimento (*Annealing*)

Recozimento físico refere-se ao processo de tratamento térmico para modificar as propriedades de um determinado material, como por exemplo, um metal ou vidro, onde inicialmente o mesmo é aquecido sob condições controladas de temperatura alta e, em seguida, resfriado lentamente até a temperatura aproximar-se do ponto de solidificação do material, encontrando uma configuração de baixa energia.

No estado líquido do material, os átomos são organizados aleatoriamente atingindo uma configuração de alta energia. O resfriamento deve ser lento para que os átomos atinjam o seu estado fundamental, o qual corresponde a configuração de mínima energia, resultando assim em uma estrutura sólida cristalina sem defeitos como um cristal. Se o resfriamento não for feito lenta e cuidadosamente, o sólido resultante não alcançará o seu estado fundamental, porém será solidificado em um estado meta-estável, uma estrutura ótima local, como por exemplo, um cristal com defeitos em sua estrutura ou um vidro. No processo de têmpera, ou resfriamento muito rápido (*quenching*), os átomos não têm o tempo necessário para se organizar na configuração de mínima energia, resultando em uma estrutura amorfa (sem uma forma definida como o vidro ou como um cristal com muitos defeitos em sua estrutura), conferindo assim, ao sólido resultante, propriedades diferentes às alcançadas com o processo de recozimento (EGLESE, 1990; MUNDIM e DELAVY, 2008).

A figura 11 apresenta a configuração desordenada das partículas quando um sólido é submetido ao banho térmico e a ordenação dos átomos nos processos de *annealing* (recozimento) e *quenching* (têmpera).

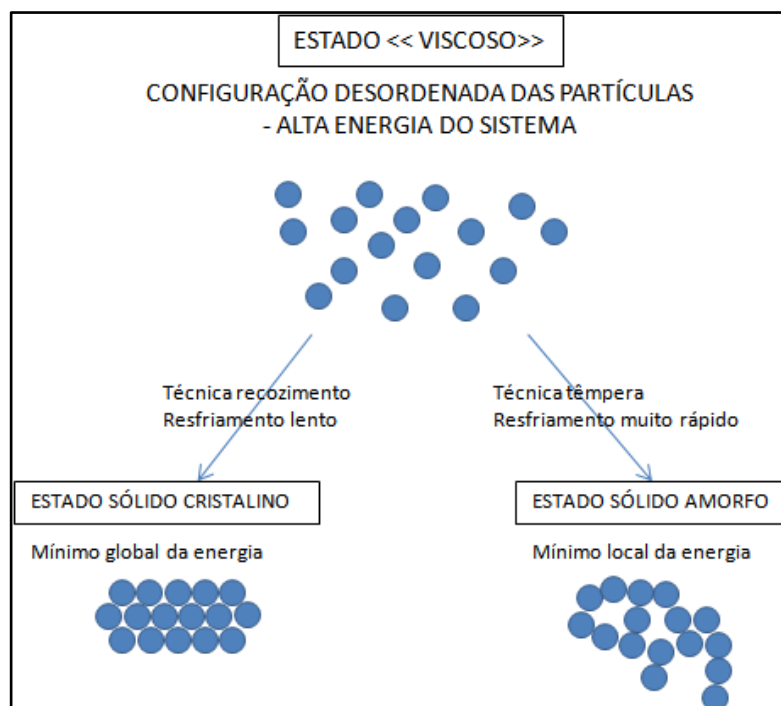


Figura 11 – Configuração desordenada das partículas nas técnicas *annealing* e *quenching*. Fonte: Adaptado de DRÉO et al. (2006, p. 6).

Na década de 1950, Metropolis et al. (1953) propuseram um algoritmo para a simulação de um conjunto de átomos em equilíbrio a uma determinada temperatura.

A cada iteração do algoritmo de Metropolis, um átomo é dado a um pequeno deslocamento aleatório e a variação na energia (ΔE) do sistema, (nova energia – energia corrente) é calculada. Se $\Delta E \leq 0$, o deslocamento é aceito e a nova configuração é utilizada como ponto de partida para o próximo passo. Entretanto se $\Delta E > 0$, o caso é tratado probabilisticamente: a probabilidade para que a configuração seja aceita é dada pela equação (20).

$$P(\Delta E) = e^{(-\Delta E / K_B T)} \quad (20)$$

Na qual T é a temperatura e K_B é uma constante física chamada de constante de Boltzmann. Uma maneira de implementação da parte aleatória para uma simulação computacional é a utilização de números aleatórios distribuídos uniformemente entre $[0,1]$. O número selecionado é comparado com a probabilidade de aceitação $P(\Delta E)$, dado pela equação (20). Se $P(\Delta E)$ for maior que o número aleatório, a nova configuração é aceita, caso contrário,

a configuração atual é utilizada para o próximo passo. Se em cada temperatura são realizadas várias iterações, o sistema encontra o equilíbrio térmico para cada temperatura (EGLESE, 1990; KIRKPATRICK, GELATTI e VECCHI, 1983; METROPOLIS et al., 1953; MUNDIM e DELAVY, 2008).

Na analogia entre o processo físico e o SA, os diferentes estados da substância correspondem às diferentes soluções factíveis para o problema de otimização combinatória e, a energia do sistema corresponde à função objetivo a ser minimizada (EGLESE, 1990). A tabela 3 apresenta a analogia entre recozimento físico e problema de otimização combinatória.

Tabela 3 - Analogia entre o recozimento físico e problema de otimização combinatória.

Recozimento físico de um sólido	Problema de otimização combinatória
Estado físico	Solução
Energia do estado	Valor da função objetivo (função custo)
Temperatura	Parâmetro de controle que faz o papel da temperatura
Deslocamento aleatório do átomo	Soluções vizinhas
Cronograma de resfriamento (<i>cooling schedule</i>)	Regras para inicialização e decréscimo do parâmetro de controle
Estado fundamental do sólido	Ótimo global

No SA, para garantir que o mínimo global foi atingido é necessário controlar a redução da “temperatura”. O nome “temperatura” utilizado no SA não expressa a temperatura física. Ela é apenas um valor artificial que age como uma fonte estocástica que possibilita eventuais escapes de bacias atratoras. Quando essa “temperatura” diminuir o suficiente, o SA ficará confinado em uma pequena região em torno do que foi identificado como menor valor (MUNDIM e DELAVY, 2008).

3.3.2. Algoritmo *Simulated Annealing* (SA)

O algoritmo SA, como mencionado anteriormente, foi inspirado no algoritmo de Metropolis, o qual simula o processo de um grupo de átomos a uma dada temperatura a procura do equilíbrio térmico para a resolução de problemas de otimização. A ideia principal do algoritmo é permitir movimentos que resultem em soluções piores que a solução atual para tentar evitar a convergência prematura para um mínimo local em problemas de minimização, ou um máximo local, em problemas de maximização.

Os passos básicos do algoritmo SA (para um problema de minimização) são apresentados no seu pseudocódigo (figura 12):

Procedimento Simulated Annealing

Início

Seja s_0 solução inicial (gerada aleatoriamente), s solução representada pelo estado corrente, s' solução representada pelo sucessor do estado corrente, s^* melhor solução obtida até então, $Iter$ contador do número de iterações, L número máximo de iterações na temperatura atual, ΔE variação entre a solução atual e a solução representada pelo estado sucessor, P probabilidade de aceitar soluções piores que a atual, $Temp$ temperatura que controla a probabilidade P , α taxa de resfriamento.

Temperatura inicial $Temp_0 > 0$

$L > 0$

α

Gerar solução inicial s_0 {aleatoriamente}

$s \leftarrow s_0$

$s^* \leftarrow s_0$

se ($Temp = 0$) então

Retorne s^*

fim-se

enquanto ($Temp > 0$) faça {critério de parada para o parâmetro T }

enquanto ($Iter < L$) faça

$Iter \leftarrow Iter + 1$

Gera sucessor s' {aleatoriamente}

$\Delta E \leftarrow (s' - s)$

se ($\Delta E \leq 0$) então

$s \leftarrow s'$

senão

$P \leftarrow e^{(-\Delta E / Temp)}$ {função de probabilidade de aceitação}

$x \leftarrow$ Gera número aleatório [entre 0 e 1]

se ($x \leq P$) então

$s \leftarrow s'$

fim-se

fim-se

se ($s < s^*$) então

$s^* \leftarrow s$

fim-se

fim-enquanto

$Temp \leftarrow \alpha * Temp$ {varia de acordo com esquema de resfriamento adotado}

$Iter \leftarrow 0$

fim-enquanto

Retorne s^*

Fim

Figura 12 – Pseudocódigo do *Simulated Annealing*.

O SA inicia gerando aleatoriamente uma solução candidata inicial s_0 e iguala a solução candidata atual s e a melhor solução candidata s^* por ser a primeira solução encontrada até então.

A cada iteração do algoritmo é gerado aleatoriamente uma solução candidata sucessora s' da solução candidata atual s , e o custo da função objetivo, ΔE , é calculado, ou seja, solução candidata sucessora menos solução candidata corrente ($s' - s$).

Se $\Delta E \leq 0$, ou seja, se houve redução na função objetivo, a solução candidata sucessora é aceita e passa a ser a solução candidata corrente.

Se $\Delta E > 0$, ou seja, se houve um aumento na função objetivo, a solução candidata sucessora poderá ser aceita, mas com uma determinada probabilidade (P). A probabilidade de aceitar um aumento na função objetivo (movimento de subida) é conhecida como função de aceitação e é dada pela equação (21).

$$P = e^{(-\Delta E / Temp)} \quad (21)$$

Na qual $Temp$ é um parâmetro de controle o qual corresponde a temperatura na analogia com o processo de recozimento físico. A aceitação ou rejeição do movimento de subida é geralmente determinada por um número aleatório, x , distribuído uniformemente entre $[0,1]$ e comparada com a probabilidade P . Se $x \leq P$, então a solução candidata sucessora, ainda que aumente o valor da função objetivo, é aceita e passa a ser a solução candidata corrente.

A constante de Boltzman, K_B , da equação (20), foi eliminada do SA (equação 21) por não ter analogia com problemas de otimização e pelo fato de $Temp$ (temperatura artificial) ser um parâmetro de controle, ou seja, $Temp$ não é mais a temperatura termodinâmica (EGLESE, 1990).

O parâmetro de controle temperatura, $Temp$, é de fundamental importância no SA. No início do SA, o valor de $Temp$ deve ser alto o suficiente para que a maioria dos movimentos

de subida seja aceito, possibilitando uma busca aleatória no espaço de soluções do problema evitando sua convergência prematura para um ótimo local. Quando o valor de $Temp$ é alto, a função de aceitação P , equação (21), tem seu valor próximo a um (1). À medida que o valor de $Temp$ diminui a função de aceitação P , tem seu valor próximo de zero (0) e, portanto, a maioria dos movimentos de subida serão rejeitados. O valor de $Temp$ é mantido constante por um número determinado de iterações (L) e depois ele é decrescido gradualmente de acordo algum procedimento definido. Esse processo é repetido enquanto $Temp > 0$. O pseudocódigo mostrado na figura 12 ilustra o Esquema de Decaimento Geométrico - EDG, o qual é abordado na seção 3.3.3.1 deste capítulo.

A determinação da temperatura inicial ($Temp_0$), a taxa de redução da temperatura, o número de iterações a cada temperatura e o critério de parada do algoritmo é conhecido como cronograma de recozimento (*annealing schedule*) ou cronograma de resfriamento (*cooling schedule*) (EGLESE, 1990).

3.3.3. Esquema de Decaimento da Temperatura (EDT)

O Esquema de Decaimento da Temperatura (EDT) é muito importante para o SA. O EDT define como a temperatura é decrescida e o número de iterações realizadas para cada temperatura. A convergência do SA, assim como o tempo de processamento e a probabilidade de aceitação estão diretamente ligados ao EDT adotado. Uma das dificuldades para se determiná-lo, é que cada problema requer um tipo de EDT (OYSU e BINFUL, 2009). Diversos autores têm pesquisado varias abordagens para diferentes EDT que foram classificados no trabalho dos autores Collins, Eglese e Golden (1988).

Para o EDT é necessário definir:

- valor inicial da temperatura ($Temp_0$);
- função de decaimento da temperatura ($Temp$);

- número de iterações a cada temperatura (L);
- critério de parada do algoritmo.

O valor da temperatura inicial ($Temp_0$) deve ser relativamente alto para que todas as soluções candidatas tenham maior probabilidade de serem aceitas.

Vários EDTs têm sido estudados para melhoria do SA. Neste trabalho, é abordado o Esquema de Decaimento Geométrico - EDG e o Esquema de Decaimento Linear - EDL.

3.3.3.1. Esquema de Decaimento Geométrico (EDG)

O EDG é utilizado com maior frequência devido a sua simplicidade (TRIKI, COLLETE e SIARRY, 2005). A temperatura é reduzida utilizando a seguinte regra geométrica (equação 22):

$$Temp(i + 1) = \alpha \cdot Temp(i) \quad (22)$$

na qual: $Temp$ é o parâmetro de controle temperatura e α é uma constante. Geralmente os valores de α utilizados na prática estão entre [0,8 e 0,99]. Quanto maior for o valor de α , mais lenta será a redução da temperatura, o que implica em maior custo computacional devido ao aumento no número de iterações processadas pelo algoritmo (AARTS, KORST e van LAARHOVEN, 1997).

3.3.3.2. Esquema de Decaimento Linear (EDL)

O EDL, ou também chamado de Esquema de Decaimento Aritmético, reduz a temperatura da seguinte forma (equação 23):

$$Temp(i + 1) = Temp(i) - 1 \quad (23)$$

na qual $Temp$ é o parâmetro de controle temperatura.

3.3.4. Número de Iterações na Temperatura

O número de iterações (L) para cada temperatura deve ser determinado de acordo que este tenha um número suficiente de movimentos para que o sistema alcance o equilíbrio térmico a cada temperatura. A cada iteração, L , guarda-se o melhor valor da solução encontrado para que esta informação não seja perdida na geração da próxima solução.

3.3.5. Critério de parada do algoritmo

O critério de parada do algoritmo pode ser definido quando o valor da temperatura se aproxima de zero ou quando a solução obtida em um determinado número de iterações da temperatura não sofra mais alteração.

3.4. SISTEMAS DE APOIO À DECISÃO (SAD)

As operações em chão de fábrica representam uma parte fundamental das empresas de manufatura, na qual, a cada etapa são agregados valores ao processo, transformando matéria prima em produtos (SRINIVAS e HARDING, 2008).

O controle em chão de fábrica gerencia as operações responsáveis pela transformação das ordens de serviço planejadas em um conjunto de saídas por meio de atividades dentre as quais se podem destacar o agendamento de tarefas, liberação de pedidos, alocação de recursos, planejamento de processos, coleta de dados e monitoramento

As atividades de controle em chão de fábrica desempenham papel importante na coordenação das operações necessárias para processar as ordens de serviços por meio dos recursos de manufatura disponíveis (SRINIVAS e HARDING, 2008).

Não somente o controle das operações em chão de fábrica é importante para as empresas assim como as atividades responsáveis por negociações e vendas dos seus produtos, objetivando a obtenção de lucro.

Dentro desse contexto e devido à competitividade das organizações no mercado, se faz necessário obter informações rápidas para auxílio no processo de tomada de decisão. A implementação de sistemas computacionais em ambientes industriais que apóiam as estratégias para tomadas de decisão poderá ser tornar um diferencial.

A abordagem de Sistemas de Apoio à Decisão (SAD) neste trabalho se dá em nível de desenvolvimento de ferramentas que forneçam informações para auxílio à decisão.

Para a criação de um SAD, dentre os fatores importantes, pode-se citar a quantidade de informações disponíveis, o poder de cálculo e de armazenamento destas informações, os sistemas computacionais de fácil utilização e a possibilidade de integração entre departamentos com um baixo custo.

De acordo com Turban, Mclean e Wetherbe (2004), não há um consenso sobre o que constitui exatamente um SAD e suas características e capacidades, entretanto, o autor elenca o que pode ser considerado um conjunto ideal. Dentre os atributos citados pelos autores, destaca-se neste trabalho:

- a) o SAD dá apoio aos tomadores de decisão em todos os níveis gerenciais, seja individualmente ou em grupo;
- b) o SAD é fácil de construir e utilizar em muitos casos;
- c) com o tempo o SAD é adaptado pelo usuário para poder lidar com mudanças de condições.

Os SADs são desenvolvidos para dar apoio à tomada de decisão a qual consiste na escolha de uma opção entre diversas alternativas. O modelo de decisão apresentado na figura 13 descreve as etapas do processo de tomada de decisão:

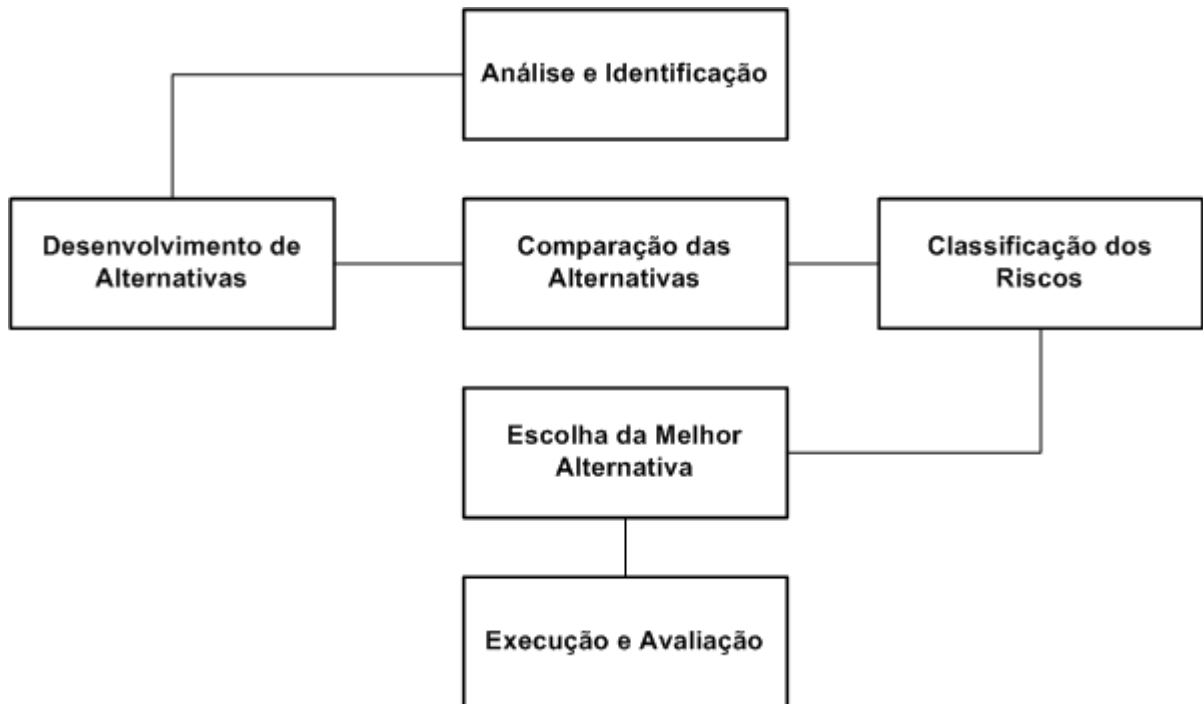


Figura 13 – Estrutura da tomada de decisão. Fonte: Binder (1994).

- a) análise e identificação da situação – a situação do ambiente onde o problema está inserido deve ser claramente identificado, através de um cuidadoso levantamento das informações disponíveis, para que a decisão possa ser tomada de maneira segura e precisa;
- b) desenvolvimento de alternativas - com base nos dados coletados anteriormente e na experiência pessoal, o executivo poderá identificar possíveis alternativas para a resolução do problema proposto;
- c) comparação entre as alternativas - devem ser relacionadas as vantagens e desvantagens de cada alternativa, bem como os custos necessários para a sua implantação;
- d) classificação dos riscos de cada alternativa - deve-se mensurar o grau de incerteza das alternativas, analisando-se os possíveis riscos de cada uma;
- e) escolher a melhor alternativa - uma vez identificadas vantagens, desvantagens e riscos, o executivo deve ser capaz de identificar a opção que melhor

solucione o problema em questão. Após a escolha da melhor alternativa, deve ser feita uma previsão dos resultados esperados para uma futura avaliação;

- f) execução e avaliação - a alternativa escolhida deve ser implantada com energia e domínio da situação. Após algum tempo, fornecerá certos resultados que deverão ser comparados com as previsões anteriores. Neste ponto, deve-se escolher entre continuar com a solução atual, ou partir para um novo ciclo de tomada de decisão (BINDER, 1994).

4. MATERIAIS E METODOLOGIA

Para melhor organização deste capítulo, primeiramente é apresentada a metodologia para o desenvolvimento das ferramentas dos SADs. Em seguida apresenta-se a formulação matemática, os parâmetros dos problemas abordados, a configuração dos parâmetros do AG e do SA, bem como as funções objetivo dos problemas PFP e PMO.

Neste trabalho foram utilizadas as linguagens de programação Microsoft Visual Basic® 6.0 (VB 6.0) e ANSI C para o desenvolvimento das ferramentas dos SADs aplicadas aos problemas PFP e PMO utilizando-se as técnicas metaheurísticas AG e SA.

Para a calibração dos parâmetros tanto do AG quanto do SA, bem como para a comparação dos resultados obtidos por cada uma das técnicas aplicadas ao PFP e PMO foi realizada uma série de dez execuções de cada técnica (AG e SA) e os resultados apresentados são as médias aritméticas dos valores obtidos a cada simulação.

As simulações foram realizadas em um computador com processador Duo Core 1,83 GHz, 4 GB de memória RAM, com exceção da BE para o PFP que foi realizada em um computador com processador Pentium-3, 700MHz, 1 GB de memória RAM, em virtude do tempo de processamento.

4.1. METODOLOGIA DE DESENVOLVIMENTO DOS SADs

A metodologia de desenvolvimento das ferramentas propostas neste trabalho, de forma geral, se dá por meio da entrada de dados, a minimização ou maximização da FO, análise dos resultados, tomada de decisão. Tais ferramentas foram denominadas de *GAPE Tool - Genetic Algorithm for cutting Parameters Estimation*, *OPMP Tool - Optimization Parameters in Machining Process* e IAS – Sistema de Análise de Ociosidade. A figura 14 apresenta o fluxograma do desenvolvimento das ferramentas SADs.

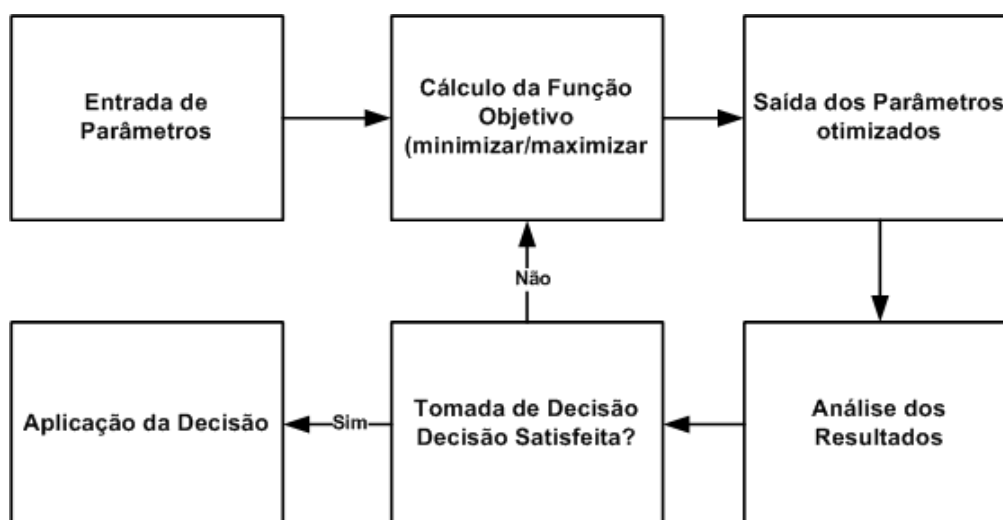


Figura 14 – Fluxograma do desenvolvimento das ferramentas SADs.

A metodologia para o desenvolvimento de cada ferramenta de SAD é apresentada nas seções a seguir.

4.1.1. FERRAMENTA GAPE

A ferramenta denominada *GAPE Tool - Genetic Algorithm for Cutting Parameters Estimation*, como o próprio nome sugere, foi desenvolvida utilizando-se a abordagem da técnica metaheurística AG para o PFP.

No desenvolvimento dessa ferramenta utilizou-se a linguagem de programação VB 6.0 para a interface gráfica e a linguagem de programação ANSI C para o desenvolvimento do AG.

Os dados de entrada para o sistema que dizem respeito às especificações da peça a qual será usinada são: x e K que são coeficientes da equação de vida de Taylor (equação 11), diâmetro da peça (d), percurso de avanço (lf) e avanço (f). A Margem de Contribuição (MC) e Taxas (Impostos) referem-se aos dados de contabilidade.

Os parâmetros de entrada referentes ao custo total da produção de uma determinada peça são: salário homem (S_H), custo do material (C_m), custo de cada aresta de corte (K_f),

tempo de troca da ferramenta (t_{ft}), custos de tempos passivos (C_{tu}) e salário máquina (S_M). Esses parâmetros elencados aqui serão processados e otimizados gerando então a saída de dados, os quais seguem: o custo variável por peça (K_p), o preço inicial de venda (T_p) e a velocidade de corte de mínimo custo (V_{cmc}).

A entrada de dados é realizada por meio da interface gráfica desenvolvida no VB 6.0, faz-se a chamada para o programa desenvolvido na linguagem de programação ANSI C para a otimização da FO, ou seja, a minimização de K_p , e este último retorna então os valores estimados para o VB 6.0. Os procedimentos descritos para o desenvolvimento da GAPE estão representados na figura 15.

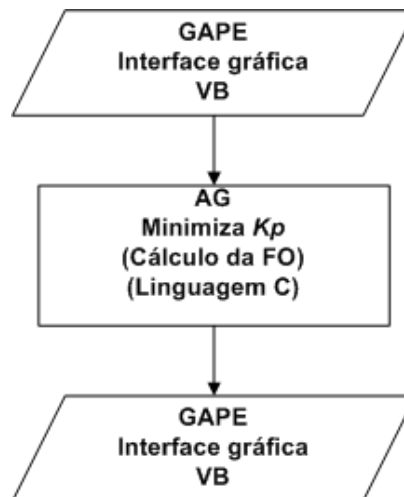


Figura 15 - Fluxograma do desenvolvimento da ferramenta GAPE.

A troca de dados entre os dois programas desenvolvidos se dá por meio de leitura e gravação em arquivos.

4.1.2. FERRAMENTA OPMP

A ferramenta denominada *OPMP Tool - Optimization Parameters in Machining Process*, foi desenvolvida utilizando-se a abordagem da técnica metaheurística SA para o PFP.

A OPMP foi implementada na íntegra em linguagem de programação VB 6.0, ou seja, tanto a interface gráfica quanto os procedimentos do SA foram desenvolvidos no próprio VB 6.0.

Os procedimentos para a otimização de K_p são apresentados na figura 16. Os dados gerados para leitura e gravação são armazenados em arquivos.

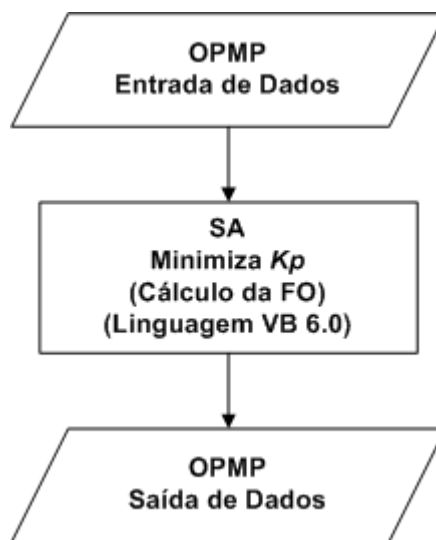


Figura 16 - Fluxograma do desenvolvimento da ferramenta OPMP.

Da mesma forma como elencado para ferramenta GAPE, uma vez que ambas foram desenvolvidas para o mesmo problema, os parâmetros de entrada e saída são os mesmos, porém, a ferramenta OPMP apresenta como saída de dados adicional, os valores das velocidades de corte mínimo custo limite (V_{cmcLim}) e da máxima produção (V_{cmxp}).

4.1.3. FERRAMENTA IAS

A ferramenta denominada IAS – Sistema de Análise de Ociosidade, foi desenvolvida para o PMO e aborda as técnicas metaheurísticas AG e SA.

Para esta ferramenta, a mesma interface gráfica é utilizada tanto para o AG quanto para o SA, mudando-se apenas a codificação de acordo com a técnica abordada.

A IAS possui duas etapas diferentes. A primeira etapa diz respeito ao cálculo da capacidade de utilização dos equipamentos, de acordo com a programação das tarefas que estão sendo executadas ou serão executadas em um determinado período. Para essa etapa, foi desenvolvida a interface denominada de Interface para Determinação de Gargalo e Ociosidade. Caso a necessidade do usuário seja apenas o cálculo da ociosidade/gargalo, ele pode utilizar somente esta primeira etapa da IAS.

Para a primeira etapa tem-se como entrada de dados o tempo total de produção disponível (t_{pt}), a quantidade de produtos (Z) e seu tempo de corte por peça em cada máquina que o produto utiliza.

Tem-se como saída de dados resultante após o processamento, o tempo total de ocupação para cada máquina e o tempo de produção total disponível (t_{pt}).

A segunda etapa diz respeito ao cálculo da maximização das funções objetivo MCT e MCTPE. Para tanto, é utilizada a segunda interface da IAS denominada Interface para Determinação da Margem de Contribuição e Prazo de Entrega.

Nesta segunda etapa tem-se como entrada de dados o tempo total de produção disponível por máquina oriundo da primeira etapa que é transportado automaticamente para a Interface de Determinação de Gargalo e Ociosidade com Margem de Contribuição e Prazo de Entrega. Além dessas informações também tem-se a quantidade de cada produto extra (Z_{ex}), o tempo de corte por peça em cada máquina que o produto utiliza, a margem de contribuição e o prazo de entrega dos seus respectivos produtos.

A saída para este conjunto de dados é a quantidade de peças de cada produto extra que poderá ser fabricado e o valor total da MC tendo-se em conta o fator restritivo que se deseja, ou seja, quando se considera somente a MC ou quando a prioridade é o prazo de entrega.

Para a abordagem do AG a IAS realiza uma chamada ao programa desenvolvido na linguagem ANSI C, o qual faz todo o processamento.

Para a abordagem do SA a IAS foi implementada na íntegra em linguagem de programação VB 6.0, ou seja, tanto a interface gráfica quanto os procedimentos do SA foram desenvolvidos no próprio VB 6.0.

A entrada de dados é realizada por meio da interface gráfica, faz-se então a otimização das funções objetivo, ou seja, a MCT e a MCTPE, e têm-se então os valores estimados. A figura 17 apresenta o fluxograma do desenvolvimento da IAS.

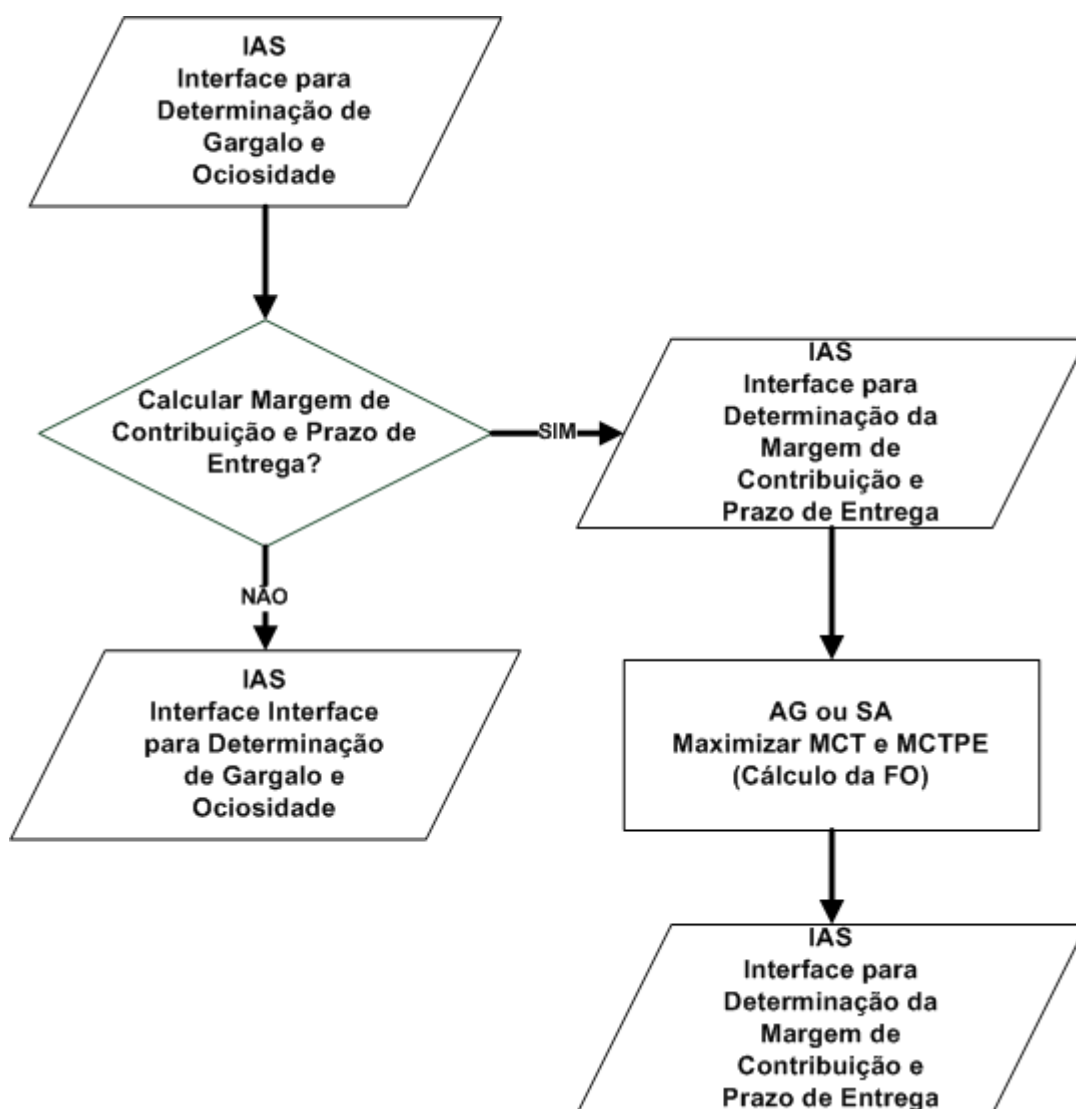


Figura 17 - Fluxograma do desenvolvimento da ferramenta IAS.

A troca de dados entre os dois programas desenvolvidos se dá por meio de leitura e gravação em arquivos.

4.2. MÉTODOS APLICADOS AO PFP

Nesta seção é apresentada a função objetivo para minimização de K_p , as configurações dos parâmetros do próprio PFP bem como as configurações dos parâmetros do AG e do SA utilizados.

4.2.1. Formulação Matemática do PFP

A formulação matemática do PFP está fundamentada no capítulo 2, seção 2.4.2.

A função objetivo para minimizar K_p , já apresentada no capítulo mencionado (equação (10)), é mostrada a seguir:

$$K_p = (C_{tu} + C_m) + \left(\frac{t_c}{60} \cdot (S_H + S_M) \right) + \left(\left(\frac{t_c}{T} \right) \cdot \left(K_{ft} + \frac{t_{ft}}{60} \cdot (S_H + S_M) \right) \right)$$

Vale ressaltar que K_p representa o custo total de produção por peça, assumindo-se apenas os custos diretos envolvidos no processo da produção da peça.

4.2.2. Parâmetros do Processo de Usinagem do PFP

Os valores de referência utilizados neste trabalho para o PFP são: $x = 4,1557$ e $K = 5,02 \times 10^{10}$ (coeficientes da equação de vida de Taylor, equação 11); diâmetro da peça (d) = 37,8mm; percurso de avanço (lf) = 552,46mm; avanço (f) = 0,25mm; Margem de Contribuição (MC) = 50%; Taxas = 34,65%; S_H = R\$ 15,00; C_m = R\$ 4,34; K_{ft} = R\$ 3,28; t_{ft} = 0,58 min.; C_m = R\$ 2,05; S_M = R\$ 40,00. A partir desse conjunto de valores é possível calcular o custo variável por peça (K_p), o preço inicial de venda (T_p) e as velocidades de corte (V_{cmc} , V_{cmLim} , V_{cmxp}) de acordo com o cenário. Os valores foram obtidos da literatura (BAPTISTA, 2004; BAPTISTA, LIBRANTZ e COPPINI, 2008).

Apesar de informar que os valores foram retirados da literatura, é importante ressaltar que trata-se de uma situação específica e podem mudar conforme o caso, principalmente no que diz respeito aos valores de x e K .

O domínio das variáveis considerado é definido pelo usuário de acordo com o intervalo estabelecido por ele, sendo que o limite inferior é dado pela % mínima permitida e para o limite superior é dados pela % máxima permitida.

Vale ressaltar que a OPMP apresenta como adicional, em relação à GAPE, as velocidade de corte V_{cmcLim} , V_{cmxp} .

4.2.3. Parâmetros do AG aplicados ao PFP

Após o ajuste dos parâmetros do AG conforme demonstrado no capítulo 5 na seção 5.1.1, o AG foi desenvolvido como segue.

Estrutura dos cromossomos: sequência binária com 66 *bits*, divididos em seis genes de 11 *bits*, cada um representando uma variável a ser estimada (figura 18).




Figura 18 – Divisão do cromossomo para representação das seis variáveis do PFP.

Na qual: g_1 : valor do salário homem de acordo com a variação da porcentagem (pv_1); g_2 : valor do custo do material de acordo com a variação da porcentagem (pv_2); g_3 : valor do custo da aresta da ferramenta de acordo com a variação da porcentagem (pv_3); g_4 : valor do custo do tempo de troca da ferramenta de acordo com a variação da porcentagem (pv_4); g_5 : valor do custo dos tempos improdutivos de acordo com a variação da porcentagem (pv_5); g_6 : valor do salário máquina de acordo com a variação da porcentagem (pv_6). O valor para cada variável (pv_i) é obtido de acordo com a equação (24).

$$pv_i = \%_min_permitida + (\%_max_permitida - \%_min_permitida) \cdot \frac{g_{i10}}{2^l - 1} \quad (24)$$

Na qual: g_{i10} representa a substring binária g_i convertida para o valor na base dez e l é o tamanho da substring binária g_i . O domínio de solução para cada parâmetro pode variar de $\%_min_permitida$ para $\%_max_permitida$.

Outros parâmetros de configuração do AG são: número máximo de geração (Max_Gen): 200; tamanho da população: 200 indivíduos; taxa de mutação *bit a bit*: 2%; pontos de cruzamento: 2 (definidos aleatoriamente). Esses quatro parâmetros foram calibrados experimentalmente conforme apresentado no capítulo 5.

O método de seleção elitismo foi utilizado na seleção dos indivíduos para recombinação. Foi definido que $\frac{1}{4}$ da população, incluindo os melhores indivíduos, poderiam ser selecionados a cada geração e entre eles, 10% são preservados intactos para a próxima geração.

A função de aptidão é a própria função objetivo do problema, isto é, K_p (equação 6). O domínio de cada parâmetro é estimado de acordo com o intervalo estabelecido pelo usuário ($\%_permitida \pm$). Por exemplo, para o parâmetro Salário Homem (S_H), o intervalo considerado é $S_{Hmin} \leq S_H \leq S_{Hmax}$, no qual $S_{Hmin} = -10\%$ do valor de referência de (S_H) e $S_{Hmax} = +10\%$ do mesmo valor de referência.

4.2.4. Parâmetros do SA aplicados ao PFP

Os parâmetros do SA aplicados ao PFP foram configurados da seguinte maneira após terem sido ajustados conforme apresentado no capítulo 5 na subseção 5.1.2: o EDT adotado é o EDG com $Temp = 500$, $L = 30$ e 0,99% de taxa de redução da temperatura.

4.3. METODOLOGIA APLICADA AO PMO

Nesta seção são apresentadas as configurações dos parâmetros do PMO bem como as configurações dos parâmetros do AG e do SA utilizados.

4.3.1. Cálculo da Ociosidade

A capacidade de produção consiste na utilização de parâmetros do planejamento industrial do processo de corte de usinagem e setores de planejamento da produção. Esses parâmetros são:

- tempo total de produção disponível para cada máquina envolvida no processo [min];
- tempo total de corte de produção/peça - obter a partir do planejamento [min];
- gargalo ou tempo ocioso de cada máquina-ferramenta [min];
- lotes de peças programados para ser cortado durante um dia de trabalho ou em qualquer outro período a ser considerado na análise;
- tempo total de corte de produção de todas as peças de cada lote [min].

Esses parâmetros podem ser correlacionados de acordo com a equação (25):

$$t_{bi} = t_{pt} - (t_t).Z \quad (25)$$

na qual: t_{pt} = tempo de produção total disponível [min]; t_t = tempo total de corte de produção [min]; t_{bi} = tempo de gargalo/ociosidade [min]; Z = número de peças por lote programado.

4.3.2. Formulação Matemática do PMO

O planejamento e programação da produção de um *mix* de produtos, ou seja, fabricação de diversos produtos envolve decisões como “quais” produtos e “quanto” fabricar de cada um deles em um ou mais períodos, considerando-se as restrições impostas no ambiente (gargalo de uma ou mais máquinas, recursos humanos e financeiros) (ARENALES et al., 2007; LINHARES, 2009).

Seja x_p a quantidade do produto p ($p = 1, 2, \dots, n$) a ser produzida. Seja CO_i a capacidade de ociosidade disponível do recurso i ($i = 1, 2, \dots, m$). Para produzir uma unidade de peça p , são consumidas a_{ip} unidades da ociosidade do recurso i . A quantidade de demanda (lote) do produto p é dada por d_p . Cada unidade do produto p tem sua margem de contribuição p_{MC} . Deste modo, o PMO pode ser formulado matematicamente como segue.

A equação (26) é a representação matemática da Margem de Contribuição Total (MCT) a ser maximizada quando somente se considera a Margem de Contribuição (MC).

$$\text{Maximizar } MCT \ f(x_1, \dots, x_n) = \sum_{p=1}^n MC_p x_p \quad (26)$$

A equação (27) representa a Margem de Contribuição Total com Prazo de Entrega ($MCTPE$) quando se prioriza o prazo de entrega.

$$\text{Maximizar } MCTPE \ f(x_1, \dots, x_n) = \sum_{p=1}^n MC_p x_p FP_p \quad (27)$$

O fator de penalização (FP_p) é dado conforme equação (28), no qual pe é o número de dias de prazo de entrega.

$$FP_p = \frac{1}{pe} \quad p = 1, \dots, n; pe = 1, \dots, d \quad (28)$$

A restrição (29) do problema limita de fabricação dos produtos devido às disponibilidades das capacidades dos equipamentos.

$$\sum_{p=1}^n a_{ip} x_p \leq CO_i \quad i = 1, \dots, m \quad (29)$$

A restrição apresentada na equação (30) impõem que a quantidade de cada produto não pode ser maior que a quantidade do lote.

$$0 \leq x_p \leq d_p \quad p = 1, \dots, n \quad (30)$$

A função objetivo para maximizar a MCT é o desdobramento da função (26), isto é, o somatório da multiplicação da MC pela quantidade de peças de cada produto a qual é dada conforme equação (31).

$$MCT = \sum_{p=A}^F MC_p x_p \quad (31)$$

na qual: MCT = Margem de Contribuição Total; MC_p = Margem de Contribuição do produto extra; x_p = quantidade do produto extra. Para este trabalho foram considerados produtos extras nomeados de A até F.

Da mesma forma, o somatório da multiplicação da MC pela quantidade de peças e pelo fator de penalização de cada produto, representa a função objetivo para maximizar a MCTPE quando se considera o prazo de entrega como fator restritivo (equação 32):

$$MCTPE = \sum_{p=A}^F MC_p x_p PF_p \quad (32)$$

na qual: $MCTPE$ = Margem de Contribuição Total com Prazo de Entrega; MC_p = Margem de Contribuição do produto extra; x_p = quantidade do produto extra; PF_p = fator de penalidade do produto extra.

Os possíveis valores das funções objetivo são calculados de acordo com a igualdade definida nas equações 31 e 32. Neste trabalho a alteração na função objetivo representa a maximização da MCT.

4.3.3. Parâmetros do PMO

Os valores referentes ao tempo de produção em minutos, disponível para cada máquina considerando-se um dia de trabalho são apresentados na tabela 4.

Tabela 4 – Tempo de produção disponível, em minutos, de cada máquina para um dia de trabalho.

Máquina	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Tempo Prod. Disponível	480	480	480	480	480	480	480	480	480	480

A quantidade de peças de cada produto em um dia de jornada e o tempo de produção das peças por máquina que cada um dos produtos consome estão descritos na tabela 5.

Tabela 5 – Quantidade de peças e tempo de produção por máquina que cada produto necessita para ser produzido.

Máquinas		M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Produto	Qtde.										
1	8	10,6			0,7	1	0,6				
2	23	0,3	4,1	1,5	1,5	1,8	11,6			0,8	1,9
3	20	11	5,2	1,5		2,9		2,6	2,2		0,9
4	15	7,7	4,1	0,7	2,6	1,9	11,6	22,3	1	1,8	0,7
5	8	0,4						0,7	1	0,3	
6	4										107
7	1			26,2					2,8	0,8	

A tabela 6 apresenta os dados referentes ao *mix* de produtos extras que poderão ser produzidos utilizando-se as ociosidades provenientes de uma jornada de trabalho. Nesta tabela encontram-se a quantidade (Qtde.), o tempo de fabricação, dado em minutos, por peça em cada máquina (M), a margem de contribuição (MC) e o prazo de entrega (PE) por produto.

Tabela 6 - Quantidade de peças e tempo de produção por máquina que cada produto extra necessita para ser produzido.

Máquinas		M1	M2	M3	M4	M5	M6	M7	M8	M9	M10		
Prod. Ex.	Qtde.											MC (\$)	PE
A	45		5,3	2,8		9,7						8,50	10
B	8				3,8	1,5		6,8				12,00	80
C	34			7,1	9,3				10,6	11,3		10,38	10
D	45	5,3	2,8		9,7							7,25	5
E	88				3,8	1,5		6,8				6,30	3
F	6		7,1	9,3				10,6	11,3			5,00	2

Os valores de referência apresentados nas tabelas 4, 5 e 6 foram obtidos da literatura e dizem respeito a uma situação específica, sendo que estes podem variar de acordo com o cenário no qual se deseja aplicar a metodologia apresentada (COPPINI et al., 2009; COPPINI et al., 2010).

4.3.4. Parâmetros do AG aplicados ao PMO

Na resolução do PMO os parâmetros do AG foram ajustados conforme apresentado no capítulo 5 seção 5.1.5. Ele foi desenvolvido como segue.

Estrutura dos cromossomos: sequência binária com 66 *bits*, divididos em seis genes de 11 *bits*, cada um representando uma variável a ser estimada figura 19.




Figura 19 - Divisão do cromossomo para representação das seis variáveis do PMO.

Na qual: g_1 : quantidade do produto extra A de acordo com a quantidade máxima permitida (qtm_1); g_2 : quantidade do produto extra B de acordo com a quantidade máxima permitida (qtm_2); g_3 : quantidade do produto extra C de acordo com a quantidade máxima permitida (qtm_3); g_4 : quantidade do produto extra D de acordo com a quantidade máxima

permitida (qtm_4); g_5 : quantidade do produto extra E de acordo com a quantidade máxima permitida (qtm_5); g_6 : quantidade do produto extra F de acordo com a quantidade máxima permitida (qtm_6). O valor para cada variável (qtm_i) é obtido de acordo com a equação (33).

$$qtm_i = qtde_min_permitida + (qtde_max_permitida - qtde_min_permitida) \cdot \frac{g_{i10}}{2^l - 1} \quad (33)$$

Na qual: g_{i10} representa a substring binária g_i convertida para o valor na base dez e l é o tamanho da substring binária g_i . O domínio de solução para cada parâmetro pode variar de $qtde_min_permitida$ para $qtde_max_permitida$. Neste caso, a quantidade máxima permitida depende ou da demanda ou da capacidade máxima que a máquina poderá produzir, porém, sem torná-la um gargalo.

Outros parâmetros de configuração do AG são: número máximo de geração (Max_Gen): 200; tamanho da população: 200 indivíduos; taxa de mutação *bit a bit*: 10%; pontos de cruzamento: 2 (definidos aleatoriamente). Esses quatro parâmetros foram calibrados experimentalmente conforme abordado no capítulo 5.

O método de seleção elitismo foi utilizado na seleção dos indivíduos para recombinação. Foi definido que $\frac{1}{4}$ da população, incluindo os melhores indivíduos, poderiam ser selecionados a cada geração e entre eles, 10% são preservados intactos para a próxima geração.

A função de aptidão é a própria função objetivo do problema, isto é, MCT e MCTPE (equações 31 e 32) respectivamente.

4.3.5. Aplicação do SA no PMO

A partir dos resultados obtidos e demonstrados no capítulo 5 na subseção 5.1.6, os parâmetros de configuração do SA adotados para PMO são: $Temp = 500$; $L = 10$ e o esquema

EDG. Como mencionado anteriormente, optou-se por adotar o custo computacional para definir os parâmetros do SA e o EDT.

5. RESULTADOS E DISCUSSÃO

Os resultados obtidos nas simulações assim como os comentários e análises estão divididos para melhor entendimento.

Com vistas a obter o melhor desempenho das técnicas metaheurísticas AG e SA aplicadas aos problemas propostos, ajustaram-se os principais parâmetros das técnicas. No caso do AG os parâmetros são: número máximo de geração (*Max_Gen*), tamanho da população, taxa de mutação e pontos de cruzamento. Para o SA, os parâmetros são: o valor do parâmetro de controle *Temp*, número de iterações (*L*) a cada *Temp* e o EDT. Essa calibração dos parâmetros teve como referencia os resultados obtidos por meio da técnica BE.

Esses parâmetros ajustados foram então aplicados ao AG e SA nos SADs para os problemas PFP e PMO.

Por fim, são apresentados cenários de exemplos utilizando-se os SADs desenvolvidos.

5.1. AJUSTE DOS PARÂMETROS DAS TÉCNICAS METAHEURÍSTICAS AG E SA

Com vistas a calibrar os parâmetros das técnicas metaheurísticas AG e SA para os dois problemas abordados, foram realizados experimentos computacionais descritos nas próximas subseções.

5.1.1. Ajuste dos parâmetros do AG para o PFP

Para ajustar os valores dos parâmetros de controle do AG mais adequados ao PFP foi realizada uma série de dez simulações, com variação de apenas um desses parâmetros, mantendo-se todos os outros fixos. Os valores apresentados representam a média aritmética dos valores obtidos nas simulações.

A figura 20 apresenta a convergência do AG após 30, 50, 100 e 200 gerações. Como pode ser visto o AG converge após aproximadamente 150 gerações. Optou-se, utilizar 200 como número máximo de gerações (*Max_Gen*), uma vez que pode-se atingir um resultado melhor sem aumento significativo do custo computacional. A utilização de um valor ainda maior para o número máximo de gerações não se justifica, uma vez que dada a aplicação do critério Elitismo no AG não serão encontradas soluções melhores.

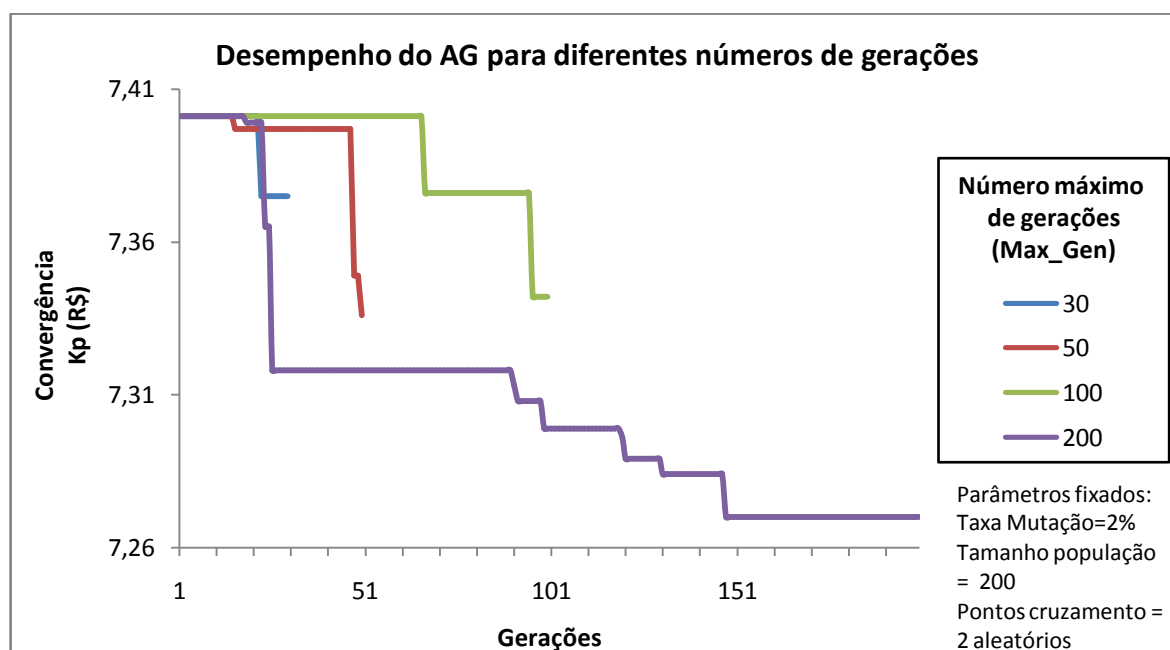


Figura 20 - Desempenho do AG considerando-se diferentes números de gerações para o PFP.

A tabela 7 apresenta o custo computacional em segundos para cada geração do AG em um computador com processador Duo Core 1,83 GHz, 4 GB de memória RAM.

Tabela 7 – Custo Computacional do AG para o problema da formação de preços.

	Número de Gerações				
	30	50	100	150	200
Custo Computacional (s)	0,1058	0,162	0,3949	0,6623	0,9165

Para o parâmetro tamanho da população, foram considerados os valores 200, 300, 400 e 500. A comparação do desempenho do AG é apresentada na figura 21. Como esperado, o desempenho do AG é proporcional ao aumento no valor do parâmetro. No entanto, é possível

ver que, para todos os tamanhos da população estudados o desempenho é muito parecido.

Assim sendo, foi adotado como valor para o parâmetro a população de menor tamanho.




Figura 21 – Desempenho do AG considerando-se diferentes tamanhos de população para o PFP.

O desempenho do AG considerando quatro diferentes taxas de mutação é apresentado na figura 22. Observa-se que o melhor desempenho é alcançado quando a taxa de mutação é igual a 2%. Nessa situação, a utilização de uma taxa de mutação alta aumenta o risco de perderem-se soluções potenciais, mesmo com a utilização do critério elitismo.

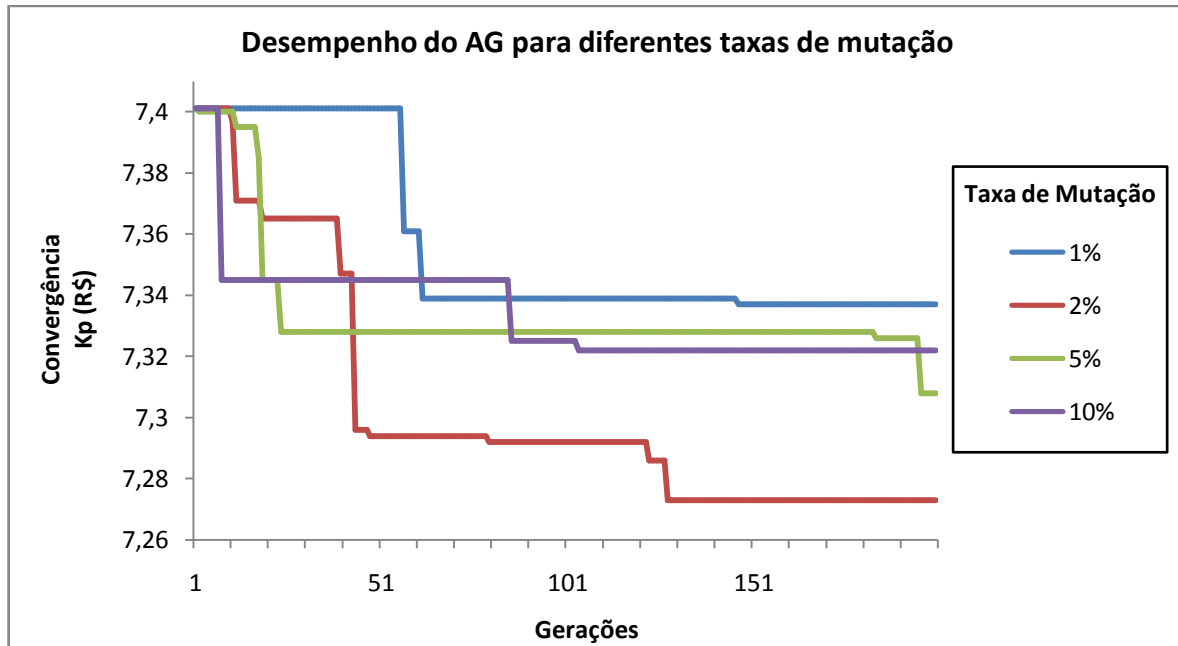


Figura 22 – Desempenho do AG considerando-se diferentes taxas de mutação para o PFP.

A figura 23 mostra o desempenho do AG considerando dois esquemas de cruzamento: com 2 pontos fixos: um no *bit* 17 e o outro no *bit* 50, e 2 pontos definidos aleatoriamente. Observa-se que, o desempenho do AG é melhor quando dois pontos de cruzamento são definidos aleatoriamente.




Figura 23 – Desempenho do AG para diferentes esquemas de cruzamento para o PFP.

5.1.2. Ajuste dos parâmetros do SA para o PFP

Para ajustar os valores dos parâmetros $Temp$ e L nos dois esquemas de decaimento (EDG e EDL) do SA que mais se adequam ao PFP foi realizada uma série de dez experimentos, com variação de apenas um desses parâmetros, mantendo-se o outro fixo. A taxa de redução de $Temp$ foi mantida fixa: para o EDG em 0,99% e para o EDL o decréscimo é de uma unidade.

Para o EDG e EDL foram utilizados os seguintes valores dos parâmetros: $L = 10, 20, 30, 50, 100$ e $Temp = 10, 20, 30, 50, 100, 200, 500, 700, 1000$.

Pode-se observar na figura 24 que o melhor K_p , isto é, os menores valores são alcançados com $L = 100$ e os valores medianos são obtidos com $L = 30$, para todos os valores de $Temp$.

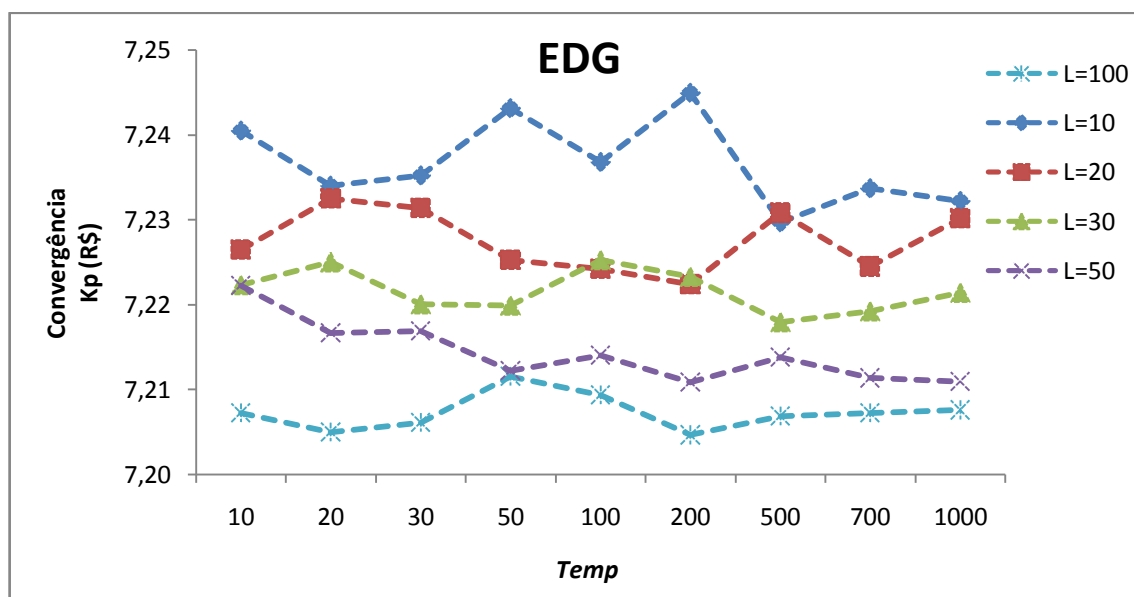


Figura 24 - Valor de K_p para o EDG com L iterações para cada $Temp$.

A figura 25 apresenta o custo computacional para o EDG. O maior custo computacional é encontrado quando se executam mais iterações, $L = 100$, enquanto que com $L = 30$ o custo computacional é mediano, para todos os valores de $Temp$.

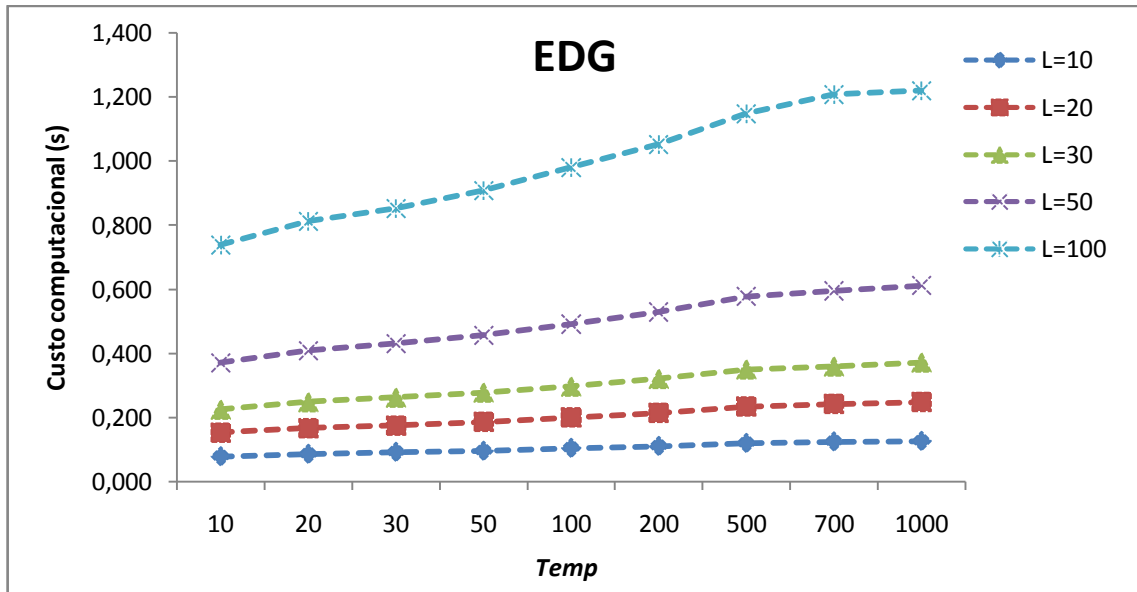


Figura 25 - Custo computacional do EDG com L iterações para cada $Temp$ aplicado ao PFP.

Analisando as figuras 24 e 25 do EDG, pode-se inferir que, para o PFP, a utilização de $Temp = 500$ com $L = 30$ apresenta um resultado satisfatório para K_p considerando-se também o custo computacional.

Considerando-se o EDL, este também obtém os melhores K_p , quando $L = 100$ para todos os valores de $Temp$. Entretanto, observa-se que a evolução para alcançar o mínimo global de K_p se dá de forma mais homogênea, com menor dispersão, e os valores de K_p convergem para o mínimo global conforme o valor de $Temp$ aumenta, concentrando-se ainda mais quando $Temp = 1000$ (figura 26).

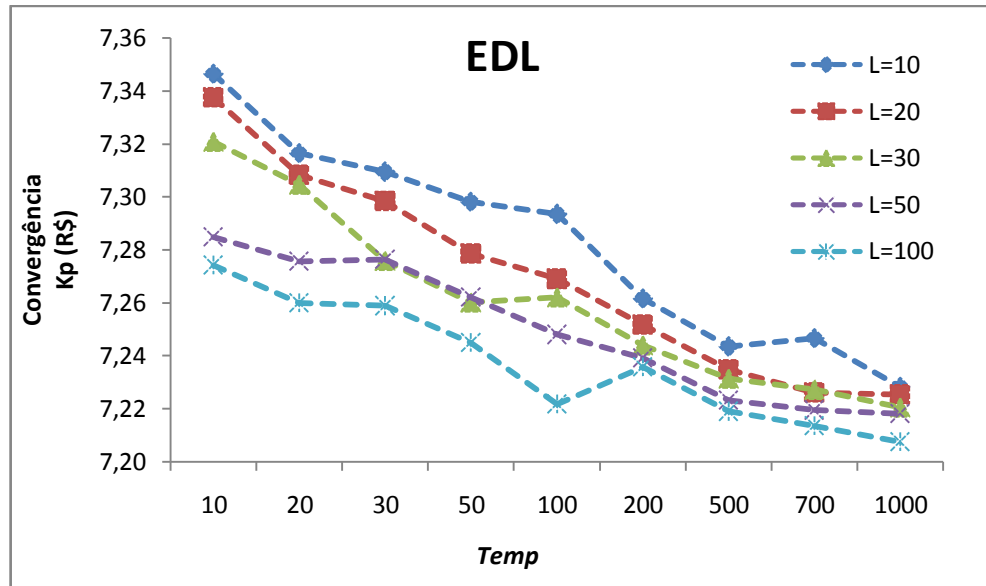


Figura 26 - Valor de K_p para o EDL com L iterações para cada $Temp$.

Quando se analisa o custo computacional do EDL com L iterações observa-se que o mesmo aumenta exponencialmente com o número de iterações. Para verificar se o custo computacional cresce exponencialmente foi adicionada a linha de tendência exponencial no gráfico (figura 27). Vale ressaltar que, no gráfico acrescentou-se somente uma linha de tendência para melhor visualização do mesmo. Os resultados de todas as curvas são apresentados na tabela 8.

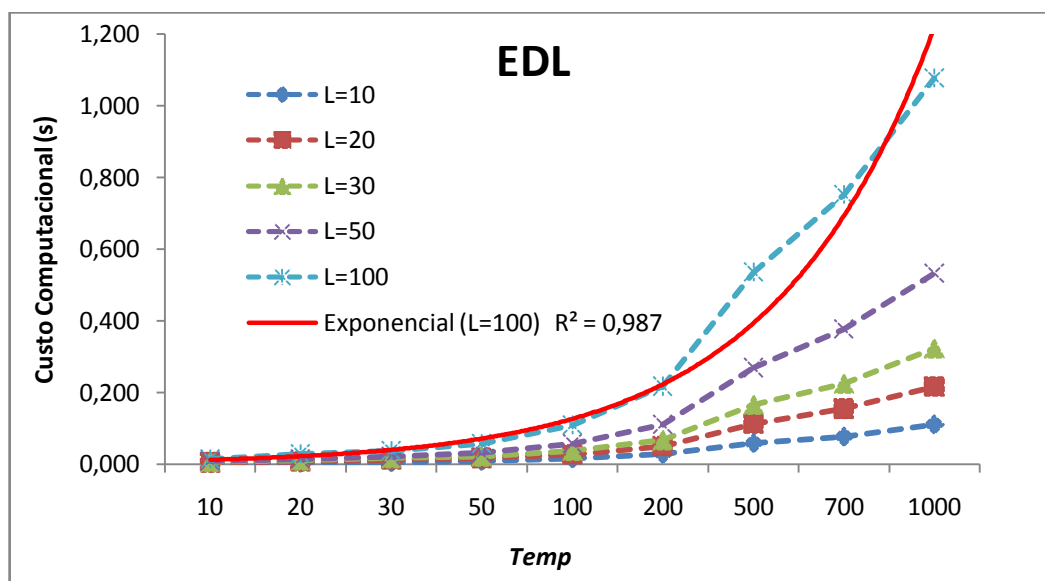


Figura 27 - Custo computacional para o EDL com L iterações para cada $Temp$ aplicado ao PFP.

Como pode ser observado na figura 27, a taxa de crescimento exponencial de $L=100$ é maior quando se compara com os outros valores de L .

A qualidade do ajuste (R^2) das curvas exponenciais para o número de iterações (L) para cada $Temp$ é apresentado na tabela 8.

Tabela 8 – Qualidade do ajuste das curvas exponenciais para o EDL com L iterações para cada $Temp$ aplicado ao PFP.

R^2	Número de Iterações				
	$L=10$	$L=20$	$L=30$	$L=50$	$L=100$
	0,983	0,990	0,987	0,987	0,987

A partir dos valores de ajustes (tabela 8) verifica-se que todas as combinações de $Temp$ com L iterações tendem a um crescimento exponencial.

A figura 28 apresenta o comparativo entre o EDG e o EDL com L iterações, para K_p . O EDG apresenta, de forma geral, valores melhores do que o EDL.

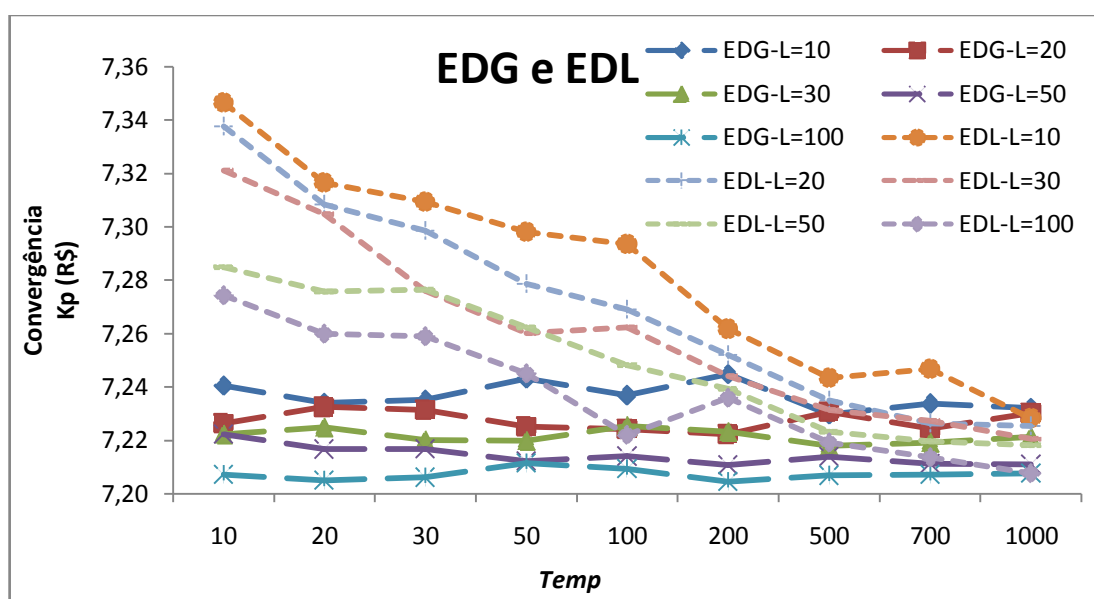


Figura 28 - Comparativo dos valores de K_p para o EDG e o EDL, com L iterações para cada temperatura.

No entanto, para o EDG, o custo computacional é maior do que no EDL (figura 29), devido à regra de decaimento de $Temp$. Para o EDG o valor final de $Temp$ é quando este se aproxima de zero ($Temp = 0,01$), enquanto que para o EDL, o valor final de $Temp$ é quando este alcança o valor um ($Temp = 1$).

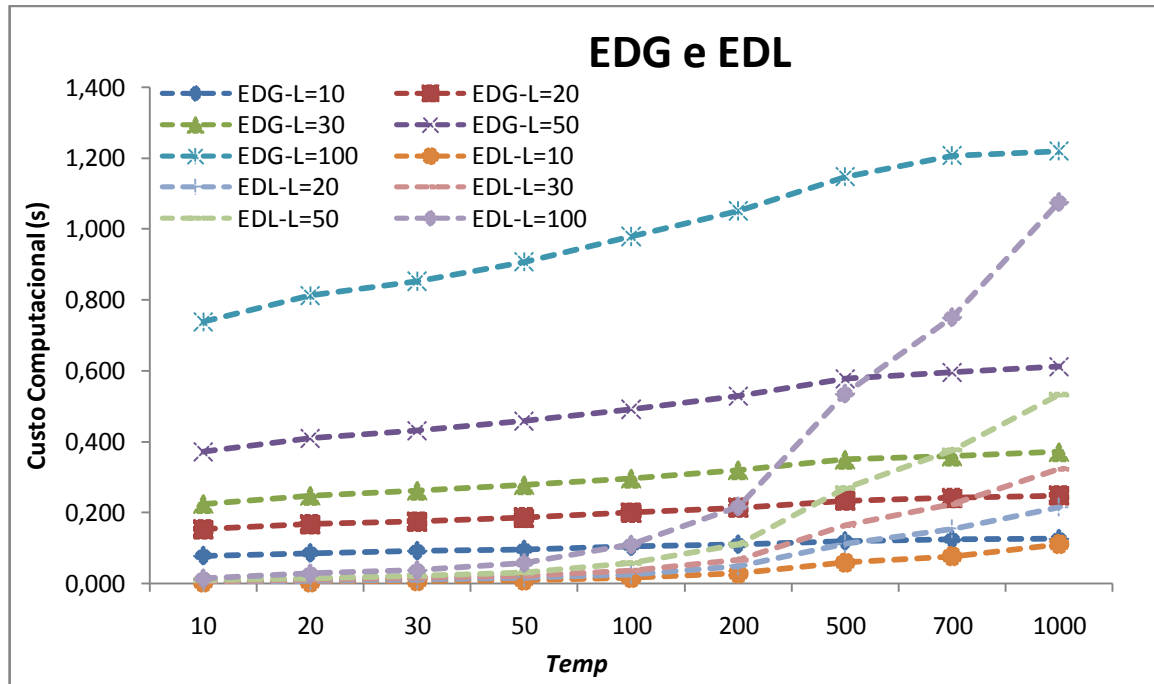


Figura 29 - Comparativo do custo computacional para o EDG e EDL, com L iterações para cada temperatura.

Tanto o EDG quanto o EDL com uma iteração ($L = 1$) foram abordados com os seguintes valores: $Temp = 100, 200, 300, 500, 700, 1000, 3000, 5000, 7000, 10000, 20000, 30000, 50000, 70000$ e 100000 . Os dois esquemas necessitam que $Temp$ tenha valores mais altos quando comparados com os esquemas que utilizam mais de uma iteração para cada $Temp$. Esse acréscimo em $Temp$ é necessário para que o sistema alcance o seu estado de equilíbrio, ou seja, encontre o mínimo global para K_p . Eles alcançam melhores resultados com $Temp = 100000$, porém, a um custo computacional elevado.

A figura 30 representa os resultados obtidos para o EDG e o EDL com $L = 1$.




Figura 30 – Gráfico comparativo do EDG e do EDL com uma iteração para cada temperatura.

Para o EDL o custo computacional é superior quando se compara ao EDG. O comparativo do custo computacional para o EDG e do EDL considerando-se $L = 1$ é apresentado na figura 31.




Figura 31 – Comparativo do custo computacional para o EDG e EDL com uma iteração para cada temperatura.

Um resumo comparativo entre os métodos EDG e EDL do SA aplicado ao PFP é apresentado a seguir.

5.1.2.1. Comparativo entre o EDG e o EDL do SA para o PFP

Um resumo dos esquemas abordados anteriormente para o SA aplicado ao PFP é apresentado na tabela 9. Os valores foram compostos considerando-se o melhor K_p , (menor valor) e o custo computacional. O EDG com $T = 500$ e $L = 30$ é o que melhor se destaca. Mediante essa análise esses parâmetros de configuração do SA foram adotados para serem utilizados na ferramenta OPMP.

Tabela 9 – Comparativo dos melhores resultados obtido pelo EDG e EDL com uma ou mais iterações para cada $Temp$, considerando-se os valores de K_p e o custo computacional.

Esquema	$Temp$	L	K_p (R\$)	Custo computacional (s)
EDL	10000	1	7,20	1,1485
EDG	10000	1	7,26	0,0250
EDL	1000	30	7,22	0,3234
EDG	500	30	7,21	0,3502

O custo computacional para todas as simulações é proporcional ao aumento de $Temp$ e de L , isto ocorre devido ao aumento na quantidade iterações que o algoritmo deverá processar. É importante ressaltar que, em virtude da utilização de valores gerados aleatoriamente, os resultados poderão variar, porém mantendo valores aproximados.

5.1.3. BE Aplicada ao PFP

A BE foi aplicada ao PFP com a finalidade de se obter parâmetros para comparação, tanto para o custo computacional quanto para os resultados obtidos nas funções objetivo. Esses parâmetros são importantes para verificar a eficiência e robustez das técnicas metaheurísticas AG e SA.

5.1.3.1. Desempenho da BE para o PFP

A tabela 10 apresenta o domínio das variáveis para o problema do preço, considerando-se a variação dos parâmetros em +10% para os limites superiores das variáveis, denotado pelo índice “max”, e de -10% para os limites inferiores das variáveis denotado pelo índice “min”.

Tabela 10 - Domínio das variáveis do problema de preço para a BE.

Parâmetro	Valor Inicial	Valor Mínimo	Valor Máximo
S_H	15,00	S_H min	S_H max
C_m	4,34	C_m min	C_m max
K_{ft}	3,28	K_{ft} min	K_{ft} max
t_{ft}	0,58	t_{ft} min	t_{ft} max
C_{tu}	2,05	C_{tu} min	C_{tu} max
S_M	40,00	S_M min	S_M max

Os resultados obtidos pela BE são apresentados na tabela 11. Nota-se que conforme o decréscimo no valor da variável, o tempo de processamento aumenta exponencialmente. Isto ocorre devido ao aumento no espaço de busca, ou seja, o espaço de soluções aumenta conforme aumenta o domínio da variável.

Tabela 11 - Custo Computacional da Busca Exaustiva aplicado ao PFP.

Incremento (R\$)	K_p (R\$)	Tempo Processamento
		Formato hh:mm:ss
0,10	7,23	00:00:01
0,05	7,17	00:00:37
0,04	7,19	00:01:44
0,03	7,19	00:08:51
0,02	7,16	01:41:18
0,01	-	Processo interrompido após 5 dias
	7,14	Cálculo determinístico

Verifica-se também que conforme o domínio das variáveis aumenta, o K_p diminui o que já era esperado em virtude do tipo de problema. A última linha da tabela 11 apresenta o valor através do cálculo determinístico, isto é, o K_p é obtido manualmente utilizando os

valores das variáveis em seus limites inferiores. A realização do cálculo manual se dá em virtude do algoritmo BE ser abortado após cindo dias de execução. O custo computacional é apresentado na figura 32. Foi adicionada a linha de tendência exponencial para se certificar que o tempo de execução cresce exponencialmente.




Figura 32 - Custo Computacional da BE aplicado ao PFP com linha de tendência.

5.1.4. Comparativo entre o AG, SA e BE para o PFP

Nesta seção apresenta-se o comparativo final entre as técnicas de otimização e a BE aplicadas ao PFP para a calibração dos parâmetros das técnicas metaheurísticas AG e SA.

A tabela 12 apresenta os melhores resultados obtidos pelo AG, SA e BE e analisados anteriormente. Na linha referente à BE, para ter-se um valor para o custo computacional, foi utilizado o resultado obtido quando o incremento das variáveis é de R\$ 0,02, conforme apresentado na tabela 11.

Tabela 12 – Comparativo entre AG, SA e BE para o PFP.

Técnica	K_p (R\$)	Custo Computacional (s)
AG	7,27	0,9165
SA	7,21	0,3502
BE	7,16	6078,000

A BE apresenta o melhor K_p em virtude da sua própria natureza, uma vez que ela percorre todo o espaço de busca, no entanto, o seu custo computacional torna-se inviável.

Quando se compara o custo computacional entre o AG e o SA, nota-se que no caso do AG esse valor é praticamente três vezes maior em relação ao SA.

Comparando-se os valores de K_p , o SA também apresenta melhor qualidade no resultado, sendo este ligeiramente menor (0,08%) do que o valor encontrado pelo AG.

5.1.5. Ajuste dos parâmetros do AG para o PMO

A calibração dos parâmetros de controle do AG para o PMO segue os mesmos critérios utilizados no problema PFP, ou seja, realizou-se uma série de dez simulações, com variação de apenas um desses parâmetros, mantendo-se todos os outros fixos. Os valores apresentados representam a média dos valores obtidos nas simulações.

Os parâmetros mantidos fixos são: número máximo de gerações = 200; taxa de mutação = 2%; tamanho de população = 200; pontos de cruzamento = 2 aleatórios.

As simulações geram os valores de MCT e MCTPE conjuntamente, mas eles são distintos entre si, isto é, a cada iteração (geração) se guarda o conjunto dos valores para cada caso separadamente. Os dados diferem para cada opção, devido a MCTPE ter uma restrição a mais do que MCT, ou seja, o prazo de entrega, porém o custo computacional corresponde a totalidade da execução do programa. Cabe ressaltar que o IAS não dispõe de mecanismo para optar qual das duas situações o usuário deseja priorizar. Portanto, a análise dos resultados foi realizada distintamente.

A figura 33 apresenta a convergência do AG após 30, 50, 100 e 200 gerações. Para a MCT observa-se que a convergência do AG se dá após aproximadamente 160 gerações.




Figura 33 - Desempenho do AG considerando-se diferentes números de gerações para a MCT (PMO).

O desempenho do AG considerando-se diferentes números de gerações para a MCTPE é apresentado na figura 34. Neste caso, pode se observar que o AG converge aproximadamente com 200 gerações.




Figura 34 - Desempenho do AG considerando-se diferentes números de gerações para a MCTPE (PMO).

Considerando-se que os resultados são gerados conjuntamente para MCT e MCTPE e, para este último, o AG converge aproximadamente com 200 gerações, esse valor é adotado para o parâmetro (*Max_Gen*) do AG.

A figura 35 apresenta o desempenho do AG considerando-se os valores de 200, 300, 400 e 500 para os tamanhos de população. Para a MCT, os valores encontrados estão próximos. Do tamanho de população 200 para o tamanho de população 500, a diferença é de aproximadamente 1% a mais, porém, o custo computacional é aproximadamente o dobro, como pode ser observado mais adiante na tabela 13.




Figura 35 - Desempenho do AG considerando-se diferentes tamanhos de população para a MCT (PMO).

As considerações para o desempenho do AG para os tamanhos de população para a MCTPE não diferem das observações apresentadas para a MCT. O AG apresenta melhor resultado com tamanho de população igual a 500, como pode ser observado na figura 36. A diferença do valor encontrado para o tamanho de população 200 para tamanho de população 500, neste caso, também é de aproximadamente 1% a mais, no entanto, como mencionado anteriormente, o custo computacional é mais elevado (tabela 13).




Figura 36 - Desempenho do AG considerando-se diferentes tamanhos de população para a MCTPE (PMO).

Para determinação do parâmetro taxa de mutação do AG foram considerados os valores de 1%, 2%, 5% e 10%. A figura 37 apresenta o desempenho do AG para a MCT. Observa-se o AG apresenta melhor desempenho quando a taxa de mutação é igual a 10%. Vale ressaltar que a utilização de uma taxa de mutação alta aumenta o risco de se perder soluções potenciais, mesmo com a utilização do critério elitismo.




Figura 37 - Desempenho do AG considerando-se diferentes taxas de mutação para a MCT (PMO).

O desempenho do AG considerando-se a taxa de mutação para a MCTPE é apresentado na figura 38. Neste caso, também o AG apresenta melhor desempenho quando a taxa de mutação é igual a 10% e as observações feitas para a MCT também valem para a MCTPE.




Figura 38 - Desempenho do AG considerando-se diferentes taxas de mutação para a MCTPE (PMO).

A figura 39 apresenta o desempenho do AG quando se considera dois esquemas de cruzamento: com 2 pontos fixos: um no *bit* 17 e o outro no *bit* 50, e 2 pontos definidos aleatoriamente. Observa-se que quando se utiliza dois pontos definidos aleatoriamente o desempenho do AG é melhor do que a utilização de dois pontos fixos.




Figura 39 - Desempenho do AG para diferentes esquemas de cruzamento para a MCT (PMO).

Para o caso da MCTPE, a figura 40 mostra o desempenho para o esquema de cruzamento do AG. Nota-se que praticamente o AG não apresenta diferença entre os dois esquemas, o que pode ser observado na tabela 13 com detalhes.




Figura 40 - Desempenho do AG para diferentes esquemas de cruzamento para a MCTPE (PMO).

A tabela 13 apresenta o resultado dos valores obtidos pelo AG para a determinação de seus parâmetros quando aplicado ao PMO bem como o custo computacional para cada parâmetro do AG investigado.

Observa-se na referida tabela que a qualidade dos resultados melhora conforme aumenta-se o tamanho da população, porém o custo computacional também aumenta. Nota-se ainda que, quando são utilizadas taxa de mutação igual a 10% e tamanho da população igual a 200, os resultados estão próximos àqueles encontrados quando o tamanho da população é igual a 500 com um custo computacional reduzido praticamente pela metade. Os resultados tendem a melhorar conforme aumenta-se a taxa de mutação devido à diversificação da população, porém há de se ter cuidado para não aumentar o risco de perder soluções potenciais.

Tabela 13 – Resultados dos valores obtidos para determinação dos parâmetros de controle do AG para o PMO.

Qtde. de Gerações	MCT (R\$)	MCTPE (R\$)	Custo Computacional (s)
30	749,75	86,74	0,1758
50	755,40	86,83	0,2930
100	759,90	87,85	0,6624
200	774,69	89,09	1,4151
Taxa de Mutação	MCT (R\$)	MCTPE (R\$)	Custo Computacional (s)
1%	760,32	87,33	1,4043
2%	774,69	89,09	1,4135
5%	779,35	89,96	1,4450
10%	780,65	90,00	1,4779
Tamanho População	MCT (R\$)	MCTPE (R\$)	Custo Computacional (s)
200	774,69	89,09	1,4151
300	774,78	89,72	2,0091
400	779,19	89,54	2,5900
500	782,51	90,26	3,1981
Ponto de Corte	MCT (R\$)	MCTPE (R\$)	Custo Computacional (s)
2 Pontos fixos	771,44	89,31	1,4212
2 Pontos aleatórios	774,69	89,09	1,4151

Os dados reportados na tabela 13 foram obtidos após processamento em um computador com processador Duo Core 1,83 GHz, 4 GB de memória RAM.

5.1.6. Ajuste dos parâmetros do SA para o PMO

O procedimento dos experimentos para o ajuste dos parâmetros do SA na utilização do PMO segue os mesmos critérios descritos anteriormente, ou seja, a média de dez simulações

para cada experimento. Para o EDG e EDL, foram considerados os valores: $L = 10, 20, 30$ e 50 e $Temp = 10, 20, 30, 50, 100, 200, 500, 700$ e 1000 .

Vale ressaltar que, a exemplo das simulações realizadas para o AG (item 5.1.3), também para a calibração dos parâmetros do SA, os valores de MCT e MCTPE são gerados conjuntamente, porém, eles são distintos entre si, isto é, a cada iteração se guarda o conjunto dos melhores valores para cada caso separadamente e, portanto, a análise dos resultados foi realizada distintamente.

Quando se aplica o EDG para obter os melhores valores da MCT, nota-se que estes são alcançados com $L=50$ para todos os valores de $Temp$ (figura 41).




Figura 41 - EDG para MCT com L iterações para cada $Temp$ aplicados ao PMO.

Para a MCTPE com o EDG os resultados obtidos também são alcançados com $L = 50$, o que já é esperado, pois conforme o aumento de $Temp$ concomitantemente com o aumento de L , o SA tende a convergir para o ótimo global (figura 42).




Figura 42 - Esquema EDG para MCTPE com L iterações para cada $Temp$ aplicados ao PMO.

Como observado anteriormente, conforme aumenta o número de iterações (L) e/ou o valor de $Temp$, o SA tende a convergir para o ótimo global, no entanto o custo computacional cresce exponencialmente com aumento dos valores desses parâmetros (figura 43). A linha de tendência exponencial foi adicionada ao gráfico para verificar se o custo computacional tende a um crescimento exponencial.




Figura 43 – Custo Computacional do EDG com L iterações para cada $Temp$ aplicado ao PMO.

Vale ressaltar que, no gráfico foi acrescentada somente uma linha de tendência para a simplificação do mesmo. A tabela 14 apresenta os valores da qualidade do ajuste (R^2) das curvas exponenciais para o EDG com L iterações para cada $Temp$.

Tabela 14 - Qualidade do ajuste das curvas exponenciais para o EDG com L iterações para cada $Temp$ aplicado ao PMO.

	Número de Iterações			
	$L=10$	$L=20$	$L=30$	$L=50$
R^2	0,992	0,990	0,990	0,995

A partir desses valores de ajuste (R^2 – tabela 14) das curvas apresentados, verifica-se que para todas as combinações de $Temp$ com L iterações existe uma tendência de crescimento exponencial para o custo computacional.

A figura 44 apresenta os resultados obtidos para a MCT com EDL. Nesta abordagem, observa-se que o SA tende a convergir conforme o aumento de $Temp$ e L , o que é compatível com o comportamento do SA.




Figura 44 - Esquema EDL para MCT com L iterações para cada $Temp$ aplicados ao PMO.

Semelhante ao MCTPE com o EDG, os resultados obtidos com o EDL são alcançados com $L = 50$ para todos os valores de $Temp$ (figura 45).




Figura 45 - Esquema EDL para MCTPE com L iterações para cada $Temp$ aplicado ao PMO.

O custo computacional para o EDL é apresentado na figura 46. Neste caso, também se percebe que o custo computacional cresce exponencialmente. A linha de tendência foi adicionada a série de dados referente à $L=50$ (figura 46), para verificar a qualidade do ajuste da curva.




Figura 46 - Custo Computacional do EDG com L iterações para cada $Temp$ aplicado ao PMO.

Da mesma forma, no gráfico foi acrescentado somente uma linha de tendência para a simplificação do mesmo.

A qualidade do ajuste (R^2) das curvas exponenciais para o EDL com L iterações para cada $Temp$ é apresentada na tabela 15.

Tabela 15 - Qualidade do ajuste das curvas exponenciais para o EDL com L iterações para cada $Temp$ aplicado ao PMO.

	Número de Iterações			
	$L=10$	$L=20$	$L=30$	$L=50$
R^2	0,989	0,990	0,990	0,990

A partir dos valores de ajuste das curvas (tabela 15), para todas as combinações de $Temp$ com L iterações observa-se que também existe uma tendência de crescimento exponencial.

A figura 47 apresenta os resultados obtidos para os esquemas EDG e EDL com uma iteração ($L=1$) para cada $Temp$. Nesta abordagem foram considerados os seguintes valores para $Temp$: 100, 200, 300, 500, 700, 1000, 3000, 5000, 7000, 10000, 20000, 30000, 50000, 70000 e 100000. Os melhores resultados obtidos tanto para a MCT quanto para a MCTPE são alcançados com o EDL com $Temp = 100000$, mas com um custo computacional elevado.




Figura 47 - Esquema EDG e EDL para MCT e MCTPE com uma iteração para cada *Temp* aplicados ao PMO.

O custo computacional tanto para o EDG quanto para o EDL com uma iteração ($L=1$) para cada *Temp* é apresentado na figura 48.




Figura 48 – Custo Computacional do EDG e EDL com uma iteração para cada *Temp* aplicado ao PMO.

As linhas de tendência exponencial e a qualidade do ajuste (R^2) das curvas foram adicionadas ao gráfico (figura 48) com vistas à verificação do crescimento exponencial do custo computacional.

A partir dos valores de ajustes das curvas nota-se que o custo computacional tende exponencialmente. Também é possível observar que a taxa de crescimento do EDL é mais elevada do que a taxa de crescimento do EDG.

O próximo item apresenta um resumo comparativo entre os métodos EDG e EDL do SA aplicados ao PMO.

5.1.6.1. Comparativo entre EDG e EDL do SA para o PMO

Para a calibração dos parâmetros do SA, *Temp*, *L* e o tipo de EDT, foi considerado o custo computacional como fator determinante para a escolha dos valores dos parâmetros, uma vez que os valores para a MCT e a MCTPE são gerados conjuntamente como foi descrito no item 5.1.3.

O custo computacional foi considerado entre 2,5s e 3,0s em virtude de que, os resultados obtidos com o custo computacional abaixo de 2,5s serem de qualidade inferior, o que significa que o SA realizou menos iterações e pode convergir para um ótimo local. No entanto, conforme os valores dos parâmetros do SA aumentam, o algoritmo realiza mais iterações e o custo computacional tende a um crescimento exponencial, embora os resultados obtidos com o custo computacional acima de 3,0s apresentem, de forma geral, uma tendência para alcançar o ótimo global.

A tabela 16 apresenta os melhores resultados obtidos para a MCT e a MCTPE no SA, com a utilização dos esquemas EDG e EDL com uma ou mais iterações (*L*) a cada *Temp*, considerando o intervalo do custo computacional mencionado anteriormente.

Tabela 16 – Comparativo dos melhores resultados obtido para a MCT e a MCTPE utilizando os esquemas EDG e EDL com uma ou mais iterações a cada *Temp*, considerando-se o custo computacional.

Esquema	<i>Temp</i>	<i>L</i>	MCT (R\$)	MCTPE (R\$)	Custo Computacional (s)
EDG	500	10	787,44	91,06	2,9859
EDL	200	50	784,02	91,85	2,7921
EDL	500	20	787,03	90,87	2,7859
EDL	1000	10	780,43	91,29	2,7765
EDL	10000	1	782,09	91,67	2,7750
EDG	200	10	781,94	91,68	2,7390
EDG	100	10	782,02	91,67	2,5562
EDL	200	30	780,23	91,03	1,6828
EDG	100000	1	771,68	89,12	0,4484

A partir dos resultados obtidos (tabela 16) os parâmetros de configuração do SA adotados para PMO são: *Temp* = 500; *L* = 10 e o esquema EDG. Como mencionado anteriormente, optou-se por adotar o custo computacional para definir os parâmetros do SA e o EDT.

5.1.7. BE Aplicada ao PMO

A BE também foi aplicada ao PMO com a finalidade de se obter parâmetros para comparação, tanto para o custo computacional quanto para os resultados obtidos nas funções objetivo. Como mencionado anteriormente, esses parâmetros são importantes para verificar a eficiência e robustez das técnicas metaheurísticas AG e SA.

5.1.7.1. Desempenho da BE para o PMO

Para o PMO, de acordo com os dados utilizados nas simulações, o custo computacional é de aproximadamente 2452 segundos (00:40:52). Os valores obtidos para as funções objetivo são R\$ 810,29 para a MCT e R\$ 96,06 para a MCTPE.

5.1.8. Comparativo entre o AG, SA e BE para o PMO

Nesta seção apresenta-se o comparativo final entre as técnicas de otimização e a BE aplicadas ao PMO para a calibração dos parâmetros das técnicas metaheurísticas AG e SA.

Nesta abordagem, considera-se o custo computacional como parâmetro comparativo. A tabela 17 apresenta os melhores resultados analisados anteriormente.

Tabela 17 – Comparativo entre AG, SA e BE para o PMO.

Técnica	MCT (R\$)	MCTPE (\$)	Custo Computacional (s)
AG	780,65	90,00	1,4779
SA	787,44	91,06	2,9859
BE	810,29	96,06	2452,000

A BE apresenta o melhor valor tanto para MCT quanto para MCTPE em virtude da sua própria natureza, visto que ela percorre todo o espaço de busca, no entanto, o seu custo computacional torna-se inviável.

Analisando-se o custo computacional do AG e SA em relação ao obtido com a BE, percebe-se que o valor é aproximadamente mil vezes maior quando comparado com o SA e duas mil vezes maior que o do AG.

Quando se compara o custo computacional entre o AG e o SA, nota-se que este último é aproximadamente o dobro em relação ao AG.

5.2. APLICAÇÃO DAS TÉCNICAS AG E SA AO PFP

Esta seção aborda a comparação entre as técnicas metaheurísticas AG e SA aplicadas ao PFP e a otimização dos parâmetros de usinagem.

A tabela 18 apresenta a comparação dos resultados obtidos entre AG e SA na influência do valor de K_p quando todos os parâmetros são otimizados ao mesmo tempo com

variação de $\pm 10\%$. Observa-se que o resultado apresentado pelo SA, R\$ 7,19, é melhor em comparação com o obtido pelo AG, R\$ 7,23.

Tabela 18 - Comparação entre AG e SA na influência do K_p quando todos os parâmetros são otimizados ao mesmo tempo, com variação de $\pm 10\%$.

Parâmetros	AG			SA	
	Valor Inicial (R\$)	Valor estimado (R\$)	Percentual de variação (%)	Valor estimado (R\$)	Percentual de variação (%)
S_H	15,00	13,65	-8,98	13,95	-6,96
C_m	4,34	3,94	-9,08	3,91	-9,69
K_{ft}	3,28	2,98	-8,86	2,99	-8,75
t_{ft}	0,58	0,53	-8,51	0,56	-2,21
C_{tu}	2,05	1,86	-9,08	1,84	-9,89
S_M	40,00	36,36	-9,08	36,08	-9,79
K_p	7,96	7,23	-9,12	7,19	-9,61
T_p	24,36	22,12		22,00	-9,61
V_{cmc}	202,26	202,75		202,28	0,01
V_{cmxp}	324,92			326,66	0,54
V_{cmcLim}	209,71			209,56	-0,07

Na aplicação do AG, para avaliar qual a influência de cada parâmetro no K_p , foi utilizada a variação de $\pm 10\%$ para cada parâmetro individualmente e para todos os parâmetros ao mesmo tempo. Os resultados obtidos pelo AG são apresentados na tabela 19.

Tabela 19 - Influência no K_p quando os parâmetros são considerados individualmente e todos juntos, com variação de $\pm 10\%$, utilizando o AG.

Parâmetros	Valor estimado do parâmetro (R\$)	Variação (%)	K_p (R\$)	K_p (%)
S_H	13,63	-9,08	7,92	-0,38
C_m	3,94	-9,08	7,56	-4,95
K_{ft}	2,98	-9,08	7,92	-0,38
t_{ft}	0,52	-9,08	7,95	-0,06
C_{tu}	1,86	-9,08	7,77	-2,34
S_M	36,36	-9,08	7,87	-1,03
Todos			7,23	-9,12

Da mesma forma para o SA, utilizou-se a variação de $\pm 10\%$ para cada parâmetro individualmente e para todos os parâmetros ao mesmo tempo (tabela 20).

Tabela 20 - Influência no K_p quando os parâmetros são considerados individualmente e todos juntos, com variação de $\pm 10\%$, utilizando o SA.

Parâmetros	Valor estimado do parâmetro (R\$)	Variação (%)	K_p (R\$)	K_p (%)
S_H	13,50	-10,00	7,92	-0,43
C_m	3,90	-10,00	7,52	-5,45
K_{ft}	2,95	-10,00	7,92	-0,42
t_{ft}	0,52	-9,98	7,95	-0,07
C_{tu}	1,84	-10,00	7,75	-2,58
S_M	36,00	-10,00	7,86	-1,14
Todos			7,19	-9,61

Os resultados obtidos pelo AG e SA (tabelas 19 e 20) são comparados na tabela 21. É possível observar que o melhor resultado para K_p é obtido quando todos os parâmetros são otimizados ao mesmo tempo com a variação de $\pm 10\%$ tanto no AG quanto no SA. No entanto, o resultado apresentado pelo AG é aproximadamente 0,55% maior do que o apresentado pelo SA.

Tabela 21 - Comparativo do AG e SA, na influência de K_p quando os parâmetros são considerados individualmente e todos juntos, com variação de $\pm 10\%$.

Parâmetros	AG		SA	
	K_p (R\$)	Variação (%)	K_p (R\$)	Variação (%)
S_H	7,92	-0,38	7,92	-0,43
C_m	7,56	-4,95	7,52	-5,45
K_{ft}	7,92	-0,38	7,92	-0,42
t_{ft}	7,95	-0,06	7,95	-0,07
C_{tu}	7,77	-2,34	7,75	-2,58
S_M	7,87	-1,03	7,86	-1,14
Todos	7,23	-9,12	7,19	-9,61

A figura 49 apresenta os resultados comparativos entre o AG e o SA reportados na tabela 21.




Figura 49 - Comparativo do SA e AG, na influência no valor de K_p quando os parâmetros são considerados individualmente e todos juntos, com variação de $\pm 10\%$.

A partir dos resultados obtidos pode-se separar os parâmetros em dois grupos: o Grupo 1 que é composto pelos parâmetros que exercem uma influência menor no valor de K_p (S_H , K_{ft} , t_{ft} , S_M) e, o Grupo 2 que é formado pelos parâmetros que influenciam mais significativamente no valor de K_p (C_m e C_{tu}). A tabela 22 apresenta os grupos e seus respectivos parâmetros e valores. Esses resultados estão de acordo com a literatura.

Tabela 22 - Grupo dos parâmetros de acordo com sua influência no custo variável por peça utilizando AG e SA.

Parâmetros	AG		SA	
	Valor (R\$)	Variação (%)	Valor (R\$)	Variação (%)
Grupo 1: S_H , K_{ft} , t_{ft} , S_M				
S_H	13,64	-9,02	13,55	-9,63
K_{ft}	2,98	-9,04	2,97	-9,41
t_{ft}	0,53	-8,45	0,53	-8,53
S_M	36,36	-9,08	36,01	-9,97
K_p	7,81	-1,83	7,79	-1,98
Grupo 2: C_{tu} , C_m				
C_{tu}	3,94	-9,08	3,90	-10,00
C_m	1,86	-9,08	1,84	-9,92
K_p	7,37	-7,29	7,31	-8,01

Assim, além de ter sido observado que alguns parâmetros influenciam mais do que outros no custo por peça, é possível observar que alguns parâmetros podem ser modificados com maior liberdade do que outros para otimizar o processo. Na tabela 23, esses aspectos são sugeridos, com a análise do grau de facilidade ou dificuldade para adotar o valor final sugerido pelas ferramentas GAPE e OPMP.

Tabela 23 - Grau de dificuldade para adotar o valor final estimado dos parâmetros após a aplicação das técnicas AG e SA.

Parâmetros	Valor Inicial (R\$)	Valor Final (R\$)		Grau de dificuldade
		AG	SA	
S_H	15,00	13,65	13,95	Inviável
C_m	4,34	3,94	3,91	Negociável
K_{ft}	3,28	2,98	2,99	Negociável
t_{ft}	0,58	0,53	0,56	Tecnicamente possível
C_{tu}	2,05	1,86	1,84	Tecnicamente possível
S_M	40,00	36,36	36,08	Difícil

É importante considerar que, apesar da redução de custo, esse valor se refere ao custo por peça e, portanto, pode ser representativo dependendo do número de peças a serem produzidas.

5.3. APLICAÇÃO DAS TÉCNICAS AG E SA AO PMO

Esta seção aborda a comparação entre as técnicas metaheurísticas AG e SA aplicada ao PMO para a otimização da MC.

A comparação dos resultados obtidos entre AG e SA para a MCT e MCTPE é apresentada na tabela 24. Pode-se observar que para a MCT os valores alcançados pelo SA são melhores do que os obtidos pelo AG, porém, para a MCTPE ocorre o inverso.

Tabela 24 – Comparativo entre o AG e SA aplicados ao PMO.

Técnica	Qtde. Prod. Ex. A	Qtde. Prod. Ex. B	Qtde. Prod. Ex. C	Qtde. Prod. Ex. D	Qtde. Prod. Ex. E	Qtde. Prod. Ex. F	TOTAL (R\$)
MCT							
AG	34	7	32	5	4	2	776,61
SA	33	8	34	5	1	2	781,99
MCTPE							
AG	32	4	32	8	5	3	756,66
SA	28	3	31	9	4	6	716,23

Vale ressaltar que os valores de MCT e MCTPE são obtidos em conjunto e que o custo computacional foi considerado como parâmetro comparativo (seção 5.1.8). O custo computacional do SA é praticamente o dobro em relação ao custo computacional do AG.

Nas próximas seções são apresentados exemplos da aplicação dos SADs desenvolvidos de acordo com o cenário em que cada problema está inserido.

5.4. EXEMPLO DE APLICAÇÃO PARA O PFP

Supondo-se o cenário para uma negociação de preço no qual o mesmo é imposto pelo cliente e apresenta os seguintes parâmetros: $d = 37,8$; $lf = 552,46$; $f = 0,25$; $x = 4,1557$; $K = 5,02 \times 10^{10}$; $S_H = \text{R\$ } 15,00$; $C_m = \text{R\$ } 4,34$; $K_{ft} = \text{R\$ } 3,28$; $t_{ft} = 0,58 \text{ min.}$; $C_{tu} = \text{R\$ } 2,05$;

$S_M = \text{R\$ } 40,00$, taxas = 34,65 %; MC = 50 %; variação $\pm 5\%$ para o parâmetro C_m e variação de $\pm 3\%$ para o parâmetro K_{ft} .

Para este exemplo, só é possível a variação de $\pm 5\%$ para o custo do material (C_m) e de $\pm 3\%$ para o custo de cada aresta (K_{ft}), visto que, como mencionado na tabela 23, para a negociação dos outros parâmetros é praticamente inviável

A utilização da GAPE, devido a sua flexibilidade, permitirá ao usuário efetuar os devidos cálculos para obter o preço inicial de vendas da peça bem como a estimação dos parâmetros a serem otimizados e a velocidade de corte que poderá ser adotada.

Na tela inicial da GAPE, no quadro Valores Iniciais, o usuário deverá preencher os dados técnicos da peça e os dados referentes aos custos e a variação permitida para esses custos. Os dados podem ser digitados na interface ou restaurados de arquivos previamente existentes. A figura 50 apresenta a tela preenchida com os dados conforme o exemplo citado.

GAPE Tool - Genetic Algorithm Parameters Estimation

Valores Iniciais

Diâmetro da Peças (d) [mm]	37.8
Percurso de Avanço (lf) [mm]	552.46
Avanço [mm/rev]	0.25
Constante do Material (k)	50200000000
Coefficiente de Taylor (x)	4.1557

% permitido (+/-)

Salário homem (Sh)	15.00	0
Custo do material (Cm)	4.34	5
Custo de cada aresta (Kft)	3.28	3
Tempo troca ferram. (Tft)	0.58	0
Custo tempo improdutivo (Ctu)	2.05	0
Salário máquina (Sm)	40.00	0

Margem Contribuição [%] 50

Taxas [%] 34.65

Final results

Velocidade corte mínimo custo (Vcmc)	203.41	variação(%) 1.1658
Custo variável por peça (Kp)	7.74	-2.6958
Preço inicial de vendas (Tp)	23.69	

SIMULAÇÃO

Restaura valores iniciais

Limpar

Resultados Finais

valor est.	variação(%)
15.00	0.0000
4.13	-4.7361
3.19	-2.7067
0.58	0.0000
2.05	0.0000
40.00	0.0000

Salvar dados da simulação

Sair

Figura 50 – Tela inicial do SAD GAPE após o processamento, apresentando os resultados finais.

Após o preenchimento de todos os dados necessários para os cálculos, e clicar no botão **SIMULAÇÃO**, os resultados são apresentados conforme mostra a figura 50.

Desta forma, os valores dos parâmetros otimizados são apresentados, bem como sua variação. Apresentam-se também o custo variável por peça (K_p), o preço inicial de venda (T_p) e a velocidades de corte V_{cmc} .

Como pode-se observar (figura 50), o custo do material (C_m) tem variação de -4,7361% e, para o custo de cada aresta (K_f), a variação é de -2,7067%. A variação dos dois

parâmetros significa uma redução de -2,26958% no valor do custo variável por peça (K_p), sendo este último estimado em R\$ 7,74 e o preço inicial de vendas (T_p) é de R\$ 23,69.

Com os dados obtidos e apresentados na tela da GAPE, o tomador de decisão terá subsídios para uma possível negociação com seu cliente. Ademais, a flexibilidade da GAPE permitirá ao usuário, alterar os parâmetros e realizar novas simulações de acordo com sua necessidade.

Os resultados obtidos por meio da GAPE podem ser armazenados em arquivos para futuras consultas ou alterações.

Da mesma forma que a GAPE, a OPMP foi desenvolvida para os mesmos propósitos, sendo que esta última apresenta os valores iniciais de K_p , T_p e V_{cmc} , isto é, os valores sem otimização, e como adicional, mostra os valores das velocidades de corte V_{cmcLim} e V_{cmxp} . A tela principal da OPMP é apresentada na figura 51, a qual já se encontra devidamente preenchida com os dados de entrada e o resultado final.

Os dados podem ser inseridos diretamente na interface gráfica principal da OPMP (figura 51) ou restaurados de arquivos previamente existentes. Após a inserção dos dados, o usuário deverá clicar no botão Calcular para que a OPMP efetue os cálculos necessários para otimização dos parâmetros.

OPMP Tool - Optimization Parameters in Machining Process

Entrada de dados

		%permitida (+/-)	
Diâmetro da peça (d)	37,8	Salário homem (Sh)	15,00 0
Percorso de avanço (lf)	552,46	Custo material (Cm)	4,34 5
Avanço (f)	0,25	Custo de cada aresta (Kft)	3,28 3
Constante do material (k)	50200000000	Tempo de troca ferram. (Tft)	0,58 0
Coefficiente de Taylor (x)	4,1557	Custos tempos passivos (Ctu)	2,05 0
Margem de contribuição [%]	50	Salário máquina (Sm)	40,00 0
Taxas [%]	34,65		

Valores estimados

		Variação %
Salário homem (Sh)	15,00	0
Custo material (Cm)	4,12	-5,07
Custo de cada aresta (Kft)	3,18	-3,05
Tempo de troca ferram. (Tft)	0,58	0
Custos tempos passivos (Ctu)	2,05	0
Salário máquina (Sm)	40,00	0

Restaura valores iniciais

Calcular

Salvar valores

Limpar

Fechar

Resultados

	Valores Iniciais	Valores Otimizados	Variação %
Custo variável por peça (kp)	7,96	7,73	-2,89
Preço inicial de venda (tp)	24,35	23,66	-2,83
Veloc. de corte de mínimo custo (Vcmc)	202,2638	203,525	0,62
Veloc. corte máxima produção (Vcmxp)	324,9183	324,9183	0
Veloc. corte mínimo custo limite (VcmcLim)	209,7092	211,2327	0,73

Figura 51 - Tela principal do SAD OPMP após o processamento, apresentando os resultados finais.

Utilizando-se o mesmo exemplo para a GAPE, pode-se observar que o custo do material (C_m) tem variação de -5,07% e para o custo de cada aresta (K_{ft}), a variação foi de -2,05%. A variação nos dois parâmetros significa uma redução de -2,89% no valor do custo variável por peça (K_p), sendo este último estimado em R\$ 7,73 e o preço inicial de vendas (T_p) é de R\$ 23,66.

Os valores apresentados na tela na cor vermelha representam a variação do parâmetro em questão. No quadro Resultados, obtêm-se então os valores iniciais e valores otimizados dos parâmetros, bem como as velocidades de corte que poderão ser adotadas de acordo com o

cenário apresentado. Esses resultados podem ser armazenados em arquivos para futuras consultas ou alterações.

Cabe ressaltar que a GAPE apresenta para K_p o valor de R\$ 7,74 e a OPMP apresenta para K_p o valor de R\$ 7,73. Como foi demonstrado anteriormente (tabela 21), o SA apresenta, de forma geral, resultado relativamente melhor do que o AG.

5.5. EXEMPLO DE APLICAÇÃO PARA O PMO

Para o cenário do PMO, a IAS foi desenvolvida com as mesmas interfaces gráficas tanto para o AG quanto para o SA. Na exemplificação são apresentadas as telas com a abordagem do SA e, os dados utilizados no exemplo são os que foram apresentados no capítulo 4, seção 4.3.3.

A IAS possui duas interfaces diferentes. A primeira interface, denominada de Interface para Determinação de Gargalo e Ociosidade, diz respeito ao cálculo da capacidade de utilização dos equipamentos, de acordo com a programação das tarefas que estão sendo executadas para um determinado período. A figura 52 apresenta a primeira tela da IAS devidamente preenchida e os cálculos efetuados.

IAS - Sistema de Análise de Ociosidade - Interface para Determinação de Gargalo e Ociosidade

Entrada de Dados - Máquinas

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Tempo Total Prod. Disponível [tpt]	480	480	480	480	480	480	480	480	480	480
Tempo Ocupação [min.]	430,40	259,80	101,20	79,10	135,90	445,60	392,10	69,80	48,60	500,20
Ociosidade/Gargalo [min.]	49,60	220,20	378,80	400,90	344,10	34,40	87,90	410,20	431,40	-20,20

Tempo de Ocupação das Máquinas por Produto - [minutos]

z	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Produto 1	8	10,6		0,7	1	0,6				
Produto 2	23	0,3	4,1	1,5	1,8	11,6			0,8	1,9
Produto 3	20	11	5,2	1,5	2,9		2,6	2,2		0,9
Produto 4	15	7,7	4,1	0,7	2,6	1,9	11,6	22,3	1	1,8
Produto 5	8	0,4					0,7	1	0,3	
Produto 6	4									107
Produto 7	1		26,2					2,8	0,8	

Restaura Valores Iniciais

Calcular

Mix de Produtos

Gravar Dados

Limpar Formulário

Fechar

Figura 52 - Interface para Determinação de Gargalo e Ociosidade da IAS.

Os dados de entrada podem ser digitados na interface (figura 52) ou serem lidos em arquivos existentes. São efetuados então os cálculos necessários para a determinação da capacidade disponível nos equipamentos e o resultado é apresentado na tela.

Nesta tela, a linha Ociosidade/Gargalo, do quadro Entrada de Dados – Máquinas, a linha colorida de amarelo indica o Tempo Total de Produção Disponível de cada Máquina. A linha em branco indica o Tempo de Ocupação para cada Máquina, ou seja, o tempo necessário para todos os produtos que se utilizam da Máquina. A linha Ociosidade?Gargalo, quando colorida de verde indica o tempo, em minutos, da capacidade disponível para a máquina correspondente; quando colorida de vermelho, representa uma máquina gargalo, e o tempo em minutos que a mesma está extrapolada (sobrecarregada). Essa última linha é o resultado dessa primeira etapa.

Os dados resultantes podem ser gravados em arquivo. Caso a necessidade do usuário seja apenas o cálculo da ociosidade/gargalo, ele pode utilizar somente essa primeira etapa do IAS.

Para calcular a MCT e a MCTPE bem como as quantidades de peças do *mix* dos produtos extras, o usuário deverá pressionar o botão Mix de Produtos para iniciar a segunda etapa.

A segunda etapa então, diz respeito ao cálculo da maximização das funções objetivo MCT e MCTPE. Para tanto, é utilizada a segunda interface da IAS denominada Interface para Determinação da Margem de Contribuição e Prazo de Entrega, a qual é preenchida automaticamente com os dados oriundos da etapa anterior, sendo que estes não podem ser alterados. A Interface para Determinação da Margem de Contribuição e Prazo de Entrega é apresentada na figura 53.

IAS - Sistema de Análise de Ociosidade - Interface para Determinação de Gargalo e Ociosidade com Margem de Contribuição e Pra...

Status da Máquinas Atualizado para Gargalo e Ociosidade

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	
Tempo Total Prod. Disponível [tpt]	480	480	480	480	480	480	480	480	480	480	
Tempo Ocupação [min.]	430,40	259,80	101,20	79,10	135,90	445,60	392,10	69,80	48,60	500,20	
Ociosidade [min.]	49,60	220,20	378,80	400,90	344,10	34,40	87,90	410,20	431,40	-20,20	

Margem Contribuição sobre Custo Cada Produto [R\$]

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M. Contrib. [R\$]	Prazo Entrega
Prod.Ex. A	45	5,3	2,8		9,7						8,50	10
Prod.Ex. B	8			3,8	1,5		6,8				12,00	80
Prod.Ex. C	34		7,1	9,3				10,6	11,3		10,38	10
Prod.Ex. D	45	5,3	2,8		9,7						7,25	5
Prod.Ex. E	88		3,8	1,5		6,8					6,30	3
Prod.Ex. F	6		7,1	9,3			10,6	11,3			5,00	2

Tempo da Ociosidade utilizado na Maximização da Margem de Contribuição

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	
Tempo Total Prod. Disponível [tpt]	49,60	220,20	378,80	400,90	344,10	34,40	87,90	410,20	431,40	-20,20	
Tempo Ocupação [min.]	26,50	203,10	356,20	396,60	332,10	6,80	75,60	383,00	384,20	0,00	
Ociosidade Restante [min.]	23,10	17,10	22,60	4,30	12,00	27,60	12,30	27,20	47,20	-20,20	

Tempo da Ociosidade utilizado na Maximização da Margem de Contribuição e Prazo de Entrega

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	
Tempo Total Prod. Disponível [tpt]	49,60	220,20	378,80	400,90	344,10	34,40	87,90	410,20	431,40	-20,20	
Tempo Ocupação [min.]	47,70	216,20	369,50	393,00	276,10	27,20	84,00	396,40	350,30	0,00	
Ociosidade Restante [min.]	1,90	4,00	9,30	7,90	68,00	7,20	3,90	13,80	81,10	-20,20	

Prod.Ex. A 33 **Prod.Ex. B** 8 **Prod.Ex. C** 34 **Prod.Ex. D** 5 **Prod.Ex. E** 1 **Prod.Ex. F** 2 **Total M. Contrib. [R\$]** 781,97

Prod.Ex. A 28 **Prod.Ex. B** 3 **Prod.Ex. C** 31 **Prod.Ex. D** 9 **Prod.Ex. E** 4 **Prod.Ex. F** 6 **Total M. Contrib. [R\$]** 716,23

Restaura Valores Mix Produtos

Calcular

Gravar Dados Mix Produtos

Limpar Formulário

Fechar

Figura 53 - Interface para Determinação da Margem de Contribuição e Prazo de Entrega da IAS.

Para os dados de cada produto extra, a quantidade de peças e seu respectivo tempo de corte em cada máquina, como também a margem de contribuição e o prazo de entrega devem ser inseridos no sistema. Da mesma forma como etapa anterior, o usuário poderá preencher os dados referentes aos produtos extras diretamente na interface ou obtê-los por meio da leitura de arquivos. Para a identificação de cada produto extra (Prod. Ex.) foram atribuídas letras de A a F.

O quadro “Tempo de Ociosidade Utilizado na Maximização da Margem de Contribuição” (figura 53), mostra o valor acumulado da margem de contribuição e o número total de peças, Z_{ex} , de cada produto a ser usinado, considerando-se todas as restrições mencionadas anteriormente, ou seja, apresenta-se a maximização da MCT.

Para a mesma tela, no quadro “Tempo de Ociosidade Utilizado na Maximização da Margem de Contribuição e Prazo de Entrega”, tem-se os resultados do valor acumulado da margem de contribuição priorizando-se o prazo de entrega, ou seja, a MCTPE, e o número total de peças, Z_{ex} , de cada produto a ser usinado.

Nos resultados demonstrados (figura 53) para a quantidade de cada produto extra, percebe-se que de fato, priorizou-se o prazo de entrega.

6. CONCLUSÕES

De acordo com o apresentado em capítulos anteriores que se refere à aplicação das técnicas metaheurísticas AG e SA aplicadas a dois problemas (PFP e PMO) característicos da empresas de usinagem, em especial a operação de torneamento, pode concluir-se que:

- as técnicas metaheurísticas AG e SA são viáveis de serem implementadas nos problemas apresentados com vistas à otimização dos parâmetros em processos de usinagem;
- os resultados obtidos para o PFP, conforme apresentados na tabela 22, são consistentes e estão de acordo com aqueles já publicados na literatura, confirmando-se assim a aplicabilidade, eficiência e robustez do AG e SA, na pesquisa operacional aplicada à otimização dos processos de corte;
- tanto o AG quanto o SA apresentaram resultados semelhantes para o PFP assim como também o custo computacional, sendo que qualquer uma das duas técnicas podem ser utilizadas para este tipo de problema;
- para o PMO, apesar dos resultados obtidos pelo AG e SA serem próximos, conforme mostrado na tabela 24, o custo computacional favorece a aplicação do AG;
- uma dificuldade apresentada na utilização das técnicas AG e SA é a calibração dos seus parâmetros os quais são estimados empiricamente, porém, essa dificuldade é característica das próprias técnicas.
- os SADs desenvolvidos, *GAPE Tool - Genetic Algorithm for Cutting Parameters Estimation*, *OPMP Tool - Optimization Parameters in Machining Process* e *IAS – Sistema de Análise de Ociosidade*, são flexíveis e intuitivos permitindo assim a total interatividade com o usuário. Eles podem ser aplicados como SADs.

6.1. SUGESTÕES PARA TRABALHOS FUTUROS

Como trabalhos futuros sugerem-se:

- Desenvolver os SADs em uma abordagem híbrida com AG e SA, *Genetic Simulated Annealing* (GSA) e comparar com os resultados obtidos neste trabalho;
- Aplicar a técnica metaheurística Otimização por Enxame de Partículas (*Particle Swarm Optimization* – PSO) nos problemas PFP e PMO e comparar seus resultados com os obtidos neste trabalho;
- Implementar separadamente, para o PMO, as opções da MCT e MCTPE, na qual o usuário do IAS poderá escolher qual das situações ele deseja otimizar;
- Desenvolver os SADs com acesso a banco de dados, no qual poderá se guardar todas as informações da respectiva peça bem como dos fornecedores e clientes

REFERÊNCIAS BIBLIOGRÁFICAS

AARTS, E. H.; KORST, J. H.; van LAARHOVEN, P. J. *Simulated Annealing*. In: AARTS, E.; LENSTRA, J. K. (Eds.), *Local Search in Combinatorial Optimization*. U.S.A.: John Wiley & Sons Ltd., 1997, Cap. 4, p. 536.

ANDRESEN, M.; BRÄSEL, H.; MÖRIG, M.; TUSCH, J.; WERNER, F.; WILLENIUS, P. *Simulated Annealing and Genetic Algorithms for minimizing mean flow time in an open shop. Mathematical and Computer Modelling*. v.48, n. 7-8, p. 1279–1293, Oct. 2008.

ARAÚJO, S. A.; LIBRANTZ, A. F. H.; ALVES, W. A. Algoritmos Genéticos na estimação de parâmetros em gestão de estoque. **Exacta**, São Paulo, v.7, n.1, p.21-29, 2009.

ARAÚJO, S. A.; LIBRANTZ, A. F. H.; ALVES, W. A. Técnicas metaheurísticas aplicadas na otimização de parâmetros em um modelo probabilístico de gestão de estoques. **In: XVI SIMPEP - Simpósio de Engenharia de Produção**. Bauru, 2009.

ARENALES, M.; ARMENTANO, V.; MORABITO, R.; YANASSE, H. **Pesquisa Operacional**. Rio de Janeiro: Elsevier, 2007.

ATKINSON, A. A.; BANKER, R. D.; KAPLAN, R. S.; YOUNG, S. M. *Management Accounting*. 3rd ed. Upper Saddle River, NJ: Prentice Hall. 1998.

AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R. C. **Redes Neurais com Aplicações em Controle e em Sistemas Especialistas**. São Paulo: Visual Books Editora, 2000.

BALRAM, S. *Study of Simulated Annealing based algorithms for multiobjective optimization of a constrained problem. Computers and Chemical Engineering*. v.28, p. 1849–1871, 2004.

BAPTISTA, E. A. **Desenvolvimento de um Sistema Especialista para a Otimização do Processo de Usinagem Baseado na WEB**. FEAU, UNIMEP, 2004. 196p. Tese (Doutorado em Engenharia de Produção) – Faculdade de Engenharia, Arquitetura e Urbanismo, Universidade Metodista de Piracicaba, Santa Bárbara d'Oeste, 2004.

BAPTISTA, E. A.; COPPINI, N. L.. Otimização de processos de usinagem: Uma abordagem para sistemas de fabricação flexível que foi implementada em um sistema baseado na Web.

In: IV COBEF - Congresso Brasileiro de Engenharia de Fabricação. Estância de São Pedro: ABCM, 2007, v.1, p. 1-10

BAPTISTA, E. A.; LIBRANTZ, A. F. H.; COPPINI, N. L. *Analyses of the parameters influence on the price determination based on the contribution margin concept for cutting process*. In: *International Conference on Advanced Manufacturing System and Technology*, 2008, Udine, Italy: Springer. **Anais...** Udine, Italy, 2008, v.1, p. 27-34.

BERTRAND, J. W.; FRANSOO, J. C. *Modeling and Simulation: Operations management research methodologies using quantitative modeling*. **International Journal of Operations & Production Management**, v.22, p. 241-264, 2002.

BINDER, F. V. **Sistemas de Apoio a Decisão**. São Paulo: Editora Érica. 1994.

BLUM, C.; ROLI, A. *Hybrid metaheuristics: an introduction*. In: BLUM, C.; AGUILERA, M. J.; ROLI, A.; SAMPLES, M. **Hybrid Metaheuristics: An Emerging Approach to Optimization (Studies in Computational Intelligence)**. Berlin Heidelberg: Springer. Cap. 1, p. 1-30, 2008.

BLUM, C.; ROLI, A. *Metaheuristics in Combinatorial Optimization: Overview and Conceptual Comparison*. **ACM Computing Surveys**. v.35, n.3, p. 268–308, Sep. 2003.

BRAILSFORD, S. C.; POTTS, C. N.; SMITH, B. M. *Constraint satisfaction problems: Algorithms and applications*. **European Journal of Operational Research**. v.119, n.3, p. 557-581, 1999.

CARVALHO, A. A. **Modelo de formação de preço para peças usinadas baseado no conceito de margem de contribuição**. 2007. 142p. Dissertação (Mestre em Engenharia de Produção) – Faculdade de Engenharia, Arquitetura e Urbanismo, Universidade Metodista de Piracicaba, Santa Bárbara d'Oeste, 2007.

ČERNÝ, V. *Thermodynamical approach to the Traveling Salesman Problem: An efficient simulation algorithm*. **Journal of Optimization Theory and Applications**. v.45 n.1, p. 41-51, Jan. 1985.

CHANDRASEKARAN, M.; MURALIDHAR, M.; KRISHNA, C. M.; DIXIT, U. S. *Application of soft computing techniques in machining performance prediction and*

optimization: a literature review. The International Journal of Advanced Manufacturing Technology. v. 46, n.5-8, p. 445–464, Jan. 2010.

CHWIF, L.; MEDINA, A. C. **Modelagem e Simulação de Eventos Discretos: Teoria e Aplicações.** São Paulo: Ed. dos Autores, 2007.

COLLINS, N. E.; EGGLESE, R. W.; GOLDEN, B. L. *Simulated Annealing - An annotated bibliography. American Journal of Mathematical and Management Sciences.* v.8, n.3-4, p. 209-307, 1988.

COPPINI, N. L.; BAPTISTA, E. A. Alternativas de otimização dos parâmetros de corte para cenários de fabricação em usinagem. **In:** Encontro Nacional de Engenharia de Produção, ENEGEP. Niterói, RJ, 1998.

COPPINI, N. L.; BAPTISTA, E. A. Sistema Especialista em Usinagem: MOS - *Machining Optimizer System.* **Revista Ciências Exatas,** v.13 n.1, p. 49-58, 2007.

COPPINI, N. L.; MALAQUIAS, J. C. Gerenciamento em Usinagem - Proposta para Cenário de Fabricação Flexível. **In:** ENEGEP'98 - 18º Encontro Nacional de Engenharia de Produção. Niterói, 1998.

COPPINI, N. L.; LIBRANTZ, A. F. H.; CARVALHO, A. A.; RODRIGO, R.; ROSA, A. F. *The idleness analysis during machining: searching for best organizational results.* **In:** 30º Congresso Ibero-Latino-Americano de métodos computacionais em engenharia- CILAMCE. Búzios – RJ, 2009, p. 1-10.

COPPINI, N. L.; LIBRANTZ, A. F. H.; ROSA, A. F. C.; CARVALHO, A. A. *Simulated Annealing Applied to Minimize the Idleness and Maximize the Contribution.* **In:** 2nd International Conference on Engineering Optimization. Lisboa - Portugal. **Anais...** Lisboa – Portugal, 2010, p.1-10.

CUS, F.; BALIC, J. *Optimization of cutting process by GA approach. Robotics and Computer Integrated Manufacturing.* v.19, p.113–121, 2003.

DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L.. **Tecnologia da usinagem dos materiais.** 6 ed. São Paulo: Artliber. 2008.

- DORIGO, M.; MANIEZZO, V.; COLORNI, A. *The Ant System: optimization by a colony of cooperating agents. IEEE Transactions on Systems, Man, and Cybernetics*. Part B: *Cybernetics*, v.26, n.1, p. 29-41, 1996.
- DRÉO, J.; PÉTROWSKI, A.; SIARRY, P.; TAILLARD, E. *Metaheuristics for Hard Optimization - Methods and Case Studies*. Springer, 2006.
- DUBEY, A. K.; YADAVA, V. *Multi-objective optimisation of laser beam cutting process. Optics & Laser Technology*. v. 40, n.3, p. 562–570, Apr. 2008.
- DURÁN, O.; BARRIENTOS, R.; COSALTER, L. A. *Aplicación de algoritmos genéticos y ecuación expandida de Taylor en la obtención del intervalo de máxima eficiencia*. In: IV Congresso Brasileiro de Engenharia de Fabricação, 2007, Estância São Pedro. **Anais... IV COBEF**. Rio de Janeiro. RJ.: ABCM, 2007, v. 1, p. 1-10.
- EGLESE, R. W. *Simulated Annealing: A tool for Operational Research. European Journal of Operational Research*, v.46, p.271-281, 1990.
- FEO, T. A.; RESENDE, M. G. *Greedy Randomized Adaptive Search Procedures. Journal of Global Optimization*. v.6, p. 109–133, 1995.
- FERRARESI, D. **Fundamentos da Usinagem dos Metais**. São Paulo: Edgard Blucher, 1997.
- GEN, M.; CHENG, R. *Genetic Algorithms and Engineering Optimization*. New York: John Wiley & Sons, Inc, 2000.
- GLOVER, F.; LAGUNA, M. *Tabu Search*. Kluwer Academic Publishers, 1997.
- GOLDBERG, D. E. *Genetic Algorithms in search, optimization, and machine learning*. Massachusetts: Addison-Wesley Pub. Inc, 1989.
- GOLDRATT, E.; COX, J. **A meta: um processo de aprimoramento contínuo**. São Paulo: IMAM, 1986.
- GU, J.; GU, M.; CAO, C.; GU, X. *A novel competitive co-evolutionary Quantum Genetic Algorithm for stochastic job shop scheduling problem. Computers & Operations Research*. v.37, n.5, p. 927-937, 2010.

HAMMOUCHE, K.; DIAF, M.; SIARRY, P. *A comparative study of various meta-heuristic techniques applied to the multilevel thresholding problem. Engineering Applications of Artificial Intelligence.* v.23, n.5, p. 676-688, Aug. 2010.

HAUPT, R. L.; HAUPT, S. E. *The Binary Genetic Algorithm. In: HAUPT, R. L.; HAUPT, S. L. Practical Genetic Algorithms.* 2 ed. Hoboken, New Jersey: John Wiley & Sons, Inc., 2004.

HOLLAND, J. H. *Adaptation in Natural and Artificial Systems.* Massachusetts: MIT Press, 1975.

HWANG, S. F., & HE, R. S. *Engineering optimization using a real-parameter Genetic-Algorithm-based hybrid method. Engineering Optimization.* v.38, n.7, p. 833–852, 2006.

JONES, L. F. *Product Costing at Caterpillar. Management Accounting.* v.72, n.8, p. 20-77, Aug. 1991.

KENNEDY, J.; EBERHART, R. C. *Particle swarm optimization. Proceedings - IEEE International Conference on Neural Networks,* v.4, p. 1942–1948, 1995.

KHOURY, C.; ANCELEVICZ, J. A utilização do sistema de custeio ABC no Brasil. **Revista de Administração de Empresas,** v.39, n.1, p. 55-63, jan/mar.1999.

KIM., S. S.; KIM, I.-H.; MANI, V.; KIM, H. J. *Real-Coded Genetic Algorithm for Machining Condition Optimization. The International Journal of Advanced Manufacturing Technology,* v.38, n. 9-10, p.884-895, 2008.

KIRKPATRICK, S.; GELATTI, C. D.; VECCHI, M. P. *Optimization by Simulated Annealing. Science, New Series,* v.220, n.4598, p. 671-680, May. 1983.

LIBRANTZ, A. F. H.; COPPINI, N. L.; BAPTISTA, E. A.; ARAÚJO, S. A.; ROSA, A. F. C. *Genetic Algorithm Applied to Investigate Cutting Process Parameters Influence on Workpiece Price Formation. Materials and Manufacturing Processes.* v.26, n.3, p. 550-557, 2011.

LINDEN, R. **Algoritmos Genéticos.** 2ª ed. Rio de Janeiro: Brasport, 2008.

LINHARES, A. *Theory of constraints and the combinatorial complexity of the product-mix decision. International Journal of Production Economics,* v.121, n.1, p. 121-129, Sep. 2009.

LUCATO, W. C. **Gestão de pequenas e médias empresas – como resolver questões financeiras sem traumas**. 2ª ed. São Paulo: Fênix, 2005.

LUCATO, W. C.; COPPINI, N. L.; BAPTISTA, E. A. *Machined Part Sales Price Build-up Based on the Contribution Margin Concept*. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**. v.31, n.03, p. 181-185, 2009.

MANJESHWAR, P. K.; DAMODARAN, P.; SRIHARI, K. *Minimizing makespan in a flow shop with two batch-processing machines using Simulated Annealing*. **Robotics and Computer-Integrated Manufacturing**. v.25, p. 667–679, 2009.

MANNA, A.; SALODKAR, S. *Optimization of machining conditions for effective turning of E0300 alloy steel*. **Journal of Materials Processing Technology**. v.203, p.147-153, 2008.

MARTINS, E. **Contabilidade de Custos**. 9ª ed. São Paulo - SP: Editora Atlas S. A., 2006.

METROPOLIS, N.; ROSENBLUTH, A.; ROSENBLUTH, M.; TELLER, A.; TELLER, E. *Equation of state calculations by fast computing machines*. **Journal of Chemical Physics**. v.21, p.1087-1092, 1953.

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. 3ª ed. New York: Springer-Verlag Berlin Heidelberg, 1996.

MITCHELL, M. **An Introduction to Genetic Algorithms**. Cambridge, Massachusetts, London, England: MIT Press, 1999.

MITCHELL, T. M. **Machine Learning**. WCB/McGraw-Hill, 1997.

MONKS, J. **Administração da Produção**. São Paulo: McGraw-Hill, 1987.

MOREIRA, A. A.; OLIVEIRA, N. R.; RAMOS, N. L.; TABOSA, C. M.; RODRIGUES, M. V. Utilização de ponto de equilíbrio para análise de margem de lucro operacional através de simulações de custos fixos e variáveis em uma indústria metalgráfica Cearense. **In: ENEGEP - XXIX Encontro Nacional De Engenharia De Produção**. Salvador, BA, 2009.

MUKHERJEE, I.; RAY, P. K. *A review of optimization techniques in metal cutting process*. **Computers & Industrial Engineering**. v.50. n.1-2, p. 15-34, 2006.

MUNDIM, K. C.; DELAVY, V. C. Otimização Global de Processos Usando o Método *Generalized Simulated Annealing*. **Revista Processos Químicos**. n.4, p. 9-23. Jul/Dez. 2008.

NADERI, B.; FATEMI GHOMI, S. M.; AMINNAYERI, M. *A high performing metaheuristic for job shop scheduling with sequence-dependent setup times*. **Applied Soft Computing**. v.10, n.3, p. 703-710, Jun. 2010.

OYSU, C.; BINGUL, Z. *Application of heuristic and hybrid-GASA algorithms to tool-path optimization problem for minimizing airtime during machining*. **Engineering Applications of Artificial Intelligence**. v.22, n.3, p. 389-396, Apr. 2009.

PACHECO, M. A. Algoritmos Genéticos: Princípios e Aplicações. **In: Proceedings of V Congresso Internacional de Ingeniería Electrónica, Eléctrica y Sistemas**. Lima, 1999, p.11-16.

PADOVEZE, C. L. **Curso básico gerencial de custos**. São Paulo: Atlas, 2006.

PAPADIMITRIOU, C. H.; STEIGLITZ, K. **Combinatorial Optimization: Algorithms and Complexity**. New York: Dover Publications, Inc., 1982.

PHAM, D. T.; PHAM, P. T. *Artificial intelligence in engineering*. **International Journal of Machine Tools and Manufacture**. v.39, n.6, p. 937-949, 1999.

PRESSMAN, R. S. **Engenharia de Software**. McGraw-Hill, 2006.

RAHMAN, S. *Theory of Constraints: A review of philosophy and its applications*. **International Journal of Operations & Production Management**, v.18, n.4, p. 336-355, 1998.

RAO, R. V.; PAWAR, P. J. *Parameter optimization of a multi-pass milling process using non-traditional*. **Applied Soft Computing**. v.10, n.2, p.445-456, Mar. 2010.

RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. Rio de Janeiro: Editora Campus. 2004.

SANKAR, R. S.; ASOKAN, P.; SARAVANAN, R.; KUMANAN, S.; PRABHAHARAN, G. *Selection of machining parameters for constrained machining problem using evolutionary computation*. **International Journal of Advanced Manufacturing Technology**, v.32, n. 9-10, p. 892–901, Apr. 2007.

SARDIÑAS, R. Q.; SANTANA, M. R.; BRINDIS, E. A. *Genetic Algorithm-based multi-objective optimization of cutting parameters in turning processes. **Engineering Applications of Artificial Intelligence***, v.19, n.2, p.127-133, Mar. 2006.

SINGH, G.; CHOUDHARY, A. K.; KARUNAKARAN, K. P.; TIWARI, M. K. *An evolutionary approach for multi-pass turning operations. **Proceedings of the Institution of Mechanical Engineers, Part B: Journal Engineering Manufacture***. v.220, n.2, p. 145-162, 2006.

SIVANANDAM, S. N.; DEEPA, S. N. *Introduction to Genetic Algorithms*. New York: Springer, 2008.

SLACK, N. **Administração da produção**. Vários tradutores. São Paulo: Atlas, 1997.

SOUZA, F. B.; BAPTISTA, E. A.; GRIVOL, R. F.; FRANCHI, R. H.; COPPINI, N. L. Otimização de Processos de Usinagem: Uma Abordagem Baseada na Teoria das Restrições. **In: ABEPRO**. Fortaleza, 2006, p. 1-10.

SRINIVAS; HARDING, J. A. *A data mining integrated architecture for shop floor control. **Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture***. v.222, n.5, p. 605-624, 2008.

TRENTIN, M. G.; ADAMCZUK, G.; LIMA, J. D. Análise de custos no setor moveleiro: um estudo de caso em uma empresa produtora de componentes para móveis. **In: XXIX ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO A Engenharia de Produção e o Desenvolvimento Sustentável: Integrando Tecnologia e Gestão**. Salvador, BA, Brasil. 2009, p. 1-14.

TRIKI, E.; COLLETTE, Y.; SIARRY, P. *A theoretical study on the behavior Of Simulated Annealing leading to a new cooling schedule. **European Journal of Operational Research***. v.166, p. 77–92, 2005.

TURBAN, E.; MCLEAN, E.; WETHERBE, J. C. Apoio à gestão e à tomada de decisão. **In: Tecnologia Da Informação Para Gestão - Transformando Os Negócios Na Economia Digital**. 3ª ed. São Paulo: Bookman Companhia, 2004. p.361-393.

WEISE, T. *Global Optimization Algorithms - Theory and Application*. 2^a ed., 2009, disponível em: <http://www.it-weise.de/projects/book.pdf>, acesso em 22/09/2009.

WHITLEY, D. A *Genetic Algorithm Tutorial*. *Statistics and Computing*. v.4, n.2, p. 65-85, 1994.

YANG, S.; SRINIVAS, J.; MOHAN, S.; LEE, D.; BALAJI, S. *Optimization of electric discharge machining using Simulated Annealing*. *Journal of Materials Processing Technology*. v.209, p. 4471–4475, 2009.

YILDIZ, A. R. *An effective hybrid immune-hill climbing optimization approach for solving design and manufacturing optimization problems in industry*. *Journal of Materials Processing Technology*. v.209, n.6, p. 2773-2780, Mar. 2009.

ZHENG, L.; YANG, X. M.; ZHANG, Z. H.; LIU, T. I. *A web-based machining parameter selection system for life cycle cost reduction and product quality enhancement*. *Computers in Industry*. v.59, p.254-261, 2008.

APÊNDICE A - ETAPAS DA MODELAGEM E SIMULAÇÃO DE SISTEMAS

As etapas descritas a seguir foram adaptadas de Arenales et al. (2007), Chwif e Medina (2007) e Pressman (2006):
Formulação do problema: Inicia-se definindo claramente os objetivos relacionados ao problema a ser resolvido (modelado). Será realizado estudo do problema para se obter informações relevantes a fim de definir os seus objetivos, restrições e complexidade.

Formulação do modelo: Esta etapa compreende no desenvolvimento do modelo conceitual que tem como objetivo a abstração do problema quanto ao seu entendimento e objetivos; será efetuado o levantamento dos requisitos, definição do escopo e restrições do sistema, coleta dos dados de entrada, definição dos parâmetros e variáveis do modelo/sistema e, modelagem das funções objetivo.

Implementação: O modelo conceitual é convertido no modelo computacional; serão desenvolvidas as interfaces gráficas e a codificação do modelo em linguagem de programação aplicando as técnicas AG e SA individualmente.

Verificação e Validação do modelo: Neste ponto, será verificado se o modelo desenvolvido corresponde ao modelo idealizado. Serão realizadas simulações, variando-se os valores de entrada (utilizando-se inclusive as fronteiras dos intervalos de valores) no sistema e verificar se os resultados obtidos são coerentes com os esperados. Dentro deste contexto, a validação do modelo de simulação significa assegurar-se de que o modelo computacional representa o sistema real, ou seja, se os resultados obtidos computacionalmente estão próximos aos oriundos do sistema real dentro de um nível de significância desejado para a validação do mesmo.

Planejamento dos experimentos: Nesta etapa, o programa desenvolvido será executado repetidas vezes, variando-se os valores dos parâmetros de entrada para cada técnica metaheurística de otimização definidas anteriormente e, os dados obtidos serão documentados para a próxima etapa.

Análise e interpretação dos dados: Os resultados obtidos na simulação e otimização através do sistema desenvolvido serão analisados estatisticamente para verificar a consistência dos mesmos e a robustez do modelo proposto, permitindo assim a utilização em cenários semelhantes.

**ANEXO A - GENETIC ALGORITHM APPLIED TO INVESTIGATE CUTTING
PROCESS PARAMETERS INFLUENCE ON WORKPIECE PRICE FORMATION**

Genetic Algorithm Applied to Investigate Cutting Process Parameters Influence on Workpiece Price Formation

ANDRÉ FELIPE HENRIQUES LIBRANTZ¹, NIVALDO LEMOS COPPINI¹, ELESANDRO ANTÔNIO BAPTISTA¹,
SIDNEI ALVES DE ARAÚJO², AND APARECIDA DE FÁTIMA CASTELLO ROSA¹

¹*Industrial Engineering Post Graduation Program, Nove de Julho University, São Paulo, SP, Brazil*

²*Department of Informatics, Nove de Julho University, São Paulo, SP, Brazil*

In this work, genetic algorithm (GA) technique was applied to investigate cutting process parameters influence on workpiece price formation using the concepts of contribution margin. The cutting process is one of the most important processes among many others available in manufacturing scenarios. Nevertheless, it is common to find some manufactured item, or at least one part of it, that was made, by cutting process. Because of its importance, many studies related to its optimization were performed, and in the last years, cutting process optimization task has been explored in different approaches from several knowledge areas, such as deterministic methods, operational research and artificial intelligence, and design of experiments. The obtained results from GA application presented in this work are in good agreement with others already reported and could be properly used in cutting process optimization parameters.

Keywords Artificial intelligence; Contribution margin; Cutting process; Genetic algorithm; Parameters optimization.

INTRODUCTION

In the last years the cutting process optimization task has explored in different approaches from several knowledge areas, as deterministic methods, operational research, and artificial intelligence (AI) and design of experiments [1, 2].

Recently, several survey studies were conducted regarding GA applications in materials science and related fields, mainly due to the fact that evolutionary algorithms are highly robust and efficient for most engineering optimization problems [3–6]. In addition, Mukherjee and Ray [2] made a survey study regarding the most important approaches used in cutting process optimization. As a result, they proposed an organized and structured classification, which was divided in two main groups: the first one, composed by input-output modeling techniques and the second one involving optimization techniques. According to this study, the genetic algorithm (GA) is classified as a metaheuristic search, which allows to obtain the near optimal solutions, as others non-deterministic techniques, but the final result usually is very satisfactory and can be applied in real situations with success.

In the literature a lot of techniques were identified. In the following, it is presented a brief of some works that use GA as an optimization approach in different applications. In order to show that the presented purpose has a differential competitive approach, other cutting process optimization techniques already reported are also described.

Li et al. [7] developed and applied with success an GA approach, according to “prescribed criteria such as minimizing processing time,” to find the optimal process plan for both a single or a distributed manufacturing systems. A hybrid solution joining GA and Simulated Annealing techniques was developed by Oysu and Bingul [8] and applied to tool-path optimization problem for minimizing airtime during machining the airtime motion problems.

Mohanty et al. [9] used the GA technique to optimize hot rolled coil widths. They also evaluated the GA performance taken into account six different selection schemes and concluded that the elitism selection showed the better performance.

Mahanty et al. [10] presented two GA approaches for packing two-dimensional irregular-shaped polygonal elements. One of them applied a hybrid algorithm using a real-encoded genetic algorithm and a local optimization algorithm, which found the better results for problems of larger size.

Zheng et al. [11] have proposed a Web-based machining parameter selection system for an agile turning. The main system’s characteristic is that the machine tools, cutters, and cutting parameters can be selected for the turning process. During the machining analyses some of performance indicators can be verified, as a turning force, power consumption, vibration status, workpiece distortion, and quality of machined parts.

A GA approach for solving a cell formation problem in cellular manufacturing was developed by Mahdavi et al. [12]. In their work, the authors proposed a model to solve the real size problems, which involve nonlinear terms and integer variables. Agrawal et al. [13] have developed a GA to optimize the orientation of the primary or the master cutter path in machining of free form surfaces.

Received June 1, 2010; Accepted July 21, 2010

Address correspondence to André Felipe Henriques Librantz, Industrial Engineering Post Graduation Program, Nove de Julho University, Av. Francisco Matarazzo, 612, Água Branca, 05001-100 São Paulo, SP, Brazil; E-mail: librantz@uninove.br

An approach for machining process optimization, based on unit cost of production, was developed by Manna and Salodkar [14]. Authors used the experimental investigation to determine the optimal values of the various machining conditions. The Taguchi and ANOVA techniques was employed to investigate the depth of cut, feed rate, and cutting speed influences on the surface roughness during turning.

Salehi and Tavakkoli-Moghaddam [15] have developed a GA approach for process planning optimization in two stages: the first is the preliminary stage, where the feasible sequences of operations are generated based on the constraints analysis; and the second stage prunes the initial feasible sequences, optimizes operations sequence and optimizes the machine, cutting tool and tool access directions for each operation. Sardiñas et al. [16] have proposed an application to optimize the cutting parameters with a multiobjective optimization technique in turning processes. They applied a microgenetic algorithm to optimize tool-life and operation time-parameters.

A hybrid system called Genetically Optimized Neural Network System (GONNS) was developed by Tansel et al. [17]. They proposed that some empirical results could be used to optimize specific goals, one characteristic of specialized manufacturing applications. Jain et al. [18] have studied a water jet process and abrasive-water jet process optimization aided by GA. It was an example of an unconventional machining process.

Vidyakiran et al. [19] and Tiwari and Chakraborti [20] have presented evolutionary approaches for optimization of two and three-dimensional guillotine cutting problems.

Jamali et al. [21] deployed for multiobjective Pareto optimal design of group method of data handling (GMDH)-type neural networks which have been used for modelling an explosive cutting process using some input-output experimental data.

As can be seen, the GA technique has a lot of applications in cutting process optimization. Among the papers studied by the authors, just one takes care about the unit cost optimization, but using a different method from the proposed in this work, in which the GA technique is applied to investigate cutting process parameters influence on workpiece price formation using the concepts of contribution margin. The next topic presents a contribution margin, optimization methods, and GA concepts.

THEORETICAL BACKGROUND

Contribution Margin

The traditional cost accounting approach assumes three basic costing systems: absorption cost, activity-based cost and variable cost [22–24]. This work considers variable costing, which is divided into fixed (no variance with production volume) and variable costs. Product costs incorporate only the variable portion which in most cases corresponds to the direct costs [25]. Fixed rate cost is a practical rule to determine costs as a fixed percentage of the product selling price. This method is used only in very small businesses where simplistic production and simplistic management techniques are present. Usually, there is no relationship among rates used and the real costs incurred,

TABLE 1.—Typical six-month Income Statement for a manufacturing company using a variable cost approach [19].

	US\$	%NS
Income Statements		
a) Gross sales	9180.00	
b) Sales taxes	2502.00	
c) Net sales (a-b)	6678.00	100%
Variable costs		
d) Direct material	3265.20	
e) Direct labor	329.40	
f) Other variable costs	79.20	
g) Total (d+e+f)	3673.80	55.0%
h) Contribution margin (c-g)	3004.20	45.0%
i) Fixed costs	2190.60	
j) Operation incoming (EBIT) (h-i)	813.60	
k) Financial expenses	153.00	
l) Income tax	120.60	
m) Net income (j-k-l)	540.00	8.1%

because very frequently, in these small businesses, cost rates are simply passed on from generation to generation, no matter what product costs actually are related to them [26].

From the ease-of-use standpoint, the variable cost would be probably the best alternative for a small or medium-size company, mainly because this approach completely eliminates the allocation of fixed costs and overhead to product costs [27]. As a result, the procedure proposed in this article assumes that machined product cost will adopt the variable cost concept. Lucato et al. [28] suggest that, when using variable costing, the related Income Statement should be presented as illustrated in Table 1.

As can be seen in the Table 1, the contribution margin is the difference between net sales and total variable costs. Conceptually, the contribution margin is the amount of money that the company has available to cover all its fixed costs and to generate the desired profit.

Price Build-Up Using the Contribution Margin Concept. The contemporary economic environment reveals that in most industries the prices of goods and services are market driven. Even so, there are situations, in which the product cost should be used to determine an initial price level. That is the case of cutting process service companies. Machining firms usually receive an engineering drawing along with a request for quotation for that particular part. In most cases, no target prices are informed by the client. Based on the drawing information, the company should prepare an initial offer taking into account its technical background and cost system, as well.

Using the variable cost approach, it is fairly easy for the machining company to establish the direct costs involved (material, direct labor, machine, and tooling costs, related to independent cutting speed times). Based on this information, the initial price to be offered could be evaluated by the Eq. (1):

$$T_p = \frac{\text{Variable Costs}}{\left[\left(1 - \frac{\%CM}{100}\right) \times \left(1 - \frac{\%Taxes}{100}\right)\right]}, \quad (1)$$

where T_p = Target Price—Initial price to be offered to a client [\$], *Variable Costs* = Direct material, direct labor,

machining, and tooling costs [\$], $\%CM$ = percentage of current contribution margin to net sales, and $\%Taxes$ = percentage of sales taxes to gross sales.

Assuming that the Income Statement refers to a machining company, the rationale behind the aforesaid calculation is as follows: the average prices accepted by the market have enabled the company to generate a 45% contribution margin to sales. Considering the present level of production volume, this rate generates enough money to cover all the fixed costs, financial expenses, and income tax, and still produces 8% net income over sales. Assuming that the machining company is pleased with its current profitability level, it could, in principle, continue to price its goods using a 45% contribution margin rate. If so, when dividing the variable costs by the $(1 - \%CM)$ factor the net sales price will be obtained. Then, dividing net sales price by $(1 - \%Taxes)$ the gross sales price will be determined. The eventual need to improve profitability could be achieved through proper contribution margin rate adjustment [28, 29]. If for any reason the price obtained according to the described methodology is considered too high when compared to current market prices, a reverse analysis could be performed. Starting with the market price and deducting all taxes and direct costs required to manufacture the part, a new contribution margin could be determined. Management judgment will define if the market price and its related contribution margin could be reasonably accepted or if the total quoted amount should be decreased [28, 30]. In very small companies where the fixed rate cost system is used, selling prices could be determined by applying a fixed rate on the costs incurred. This is not the case of the method proposed herein. The contribution margin used is the percentage that the company is actually obtaining as a result of its actual financial performance in the marketplace. This is totally different when using fixed rates established by historical values, with no relationship with actual financial results obtained.

Cutting Process Cost Calculation. In the literature there are many ways to cutting costs calculation. Most of them are very similar and basically consider that the total machining cost per part, assuming only the direct costs, consists of three elements C_1 , C_2 , and C_3 , depicted in the Eq. (2) [31]. C_1 is the cost independent on cutting speed (i.e., part material cost plus labor and machine salary during the unproductive time), C_2 is the operation cost (i.e., including labor and machine salaries), and C_3 is the tooling cost (i.e., tool itself plus the cost incurred to change and adjust the tool edge). Total machining cost per part expressed in terms of the machining variables is the sum, shown in Eq. (3):

$$K_p = C_1 + C_2 + C_3 \quad (2)$$

Or, the cost per part as a function of cutting process parameters could be written as shown in Eq. (3), where each part is respectively related to C_1 , C_2 , and C_3 from Eq. (2):

$$K_p = (C_{tu} + C_m) + \left(\frac{t_c}{60} \times (S_L + S_M) \right) + \left(\left(\frac{t_c}{T} \right) \times \left(C_{tool} + \frac{t_{ct}}{60} \times (S_L + S_M) \right) \right), \quad (3)$$

where K_p = total machining cost per part [\$], C_{tu} = unproductive time cost [\$], C_m = Material cost [\$], C_{tool} = tool edge cost [\$/edge], t_c = cutting time [min.], t_{ct} = tool edge changing and positioning adjustment time, S_L = labor costs including benefits [\$/hour], S_M = machine cost [\$/hour] and T = tool life [min.].

Optimization Methods

Optimization problems normally involve the minimization or maximization of some function with one or more variables, regarding some domain, subject to a set of restrictions. Algorithms used to solve this kind of problem can be deterministic or nondeterministic. Deterministic methods generally use the derivative of objective function to explore the search space, whereas nondeterministic methods successively improve one or several solutions of the underlying model to obtain an approximation of the global optimum solution. Nondeterministic methods are usually applied when others methods are too costly. It happens in multidimensional optimization problems, where the total number of possible solutions grows exponentially with the number of variables [32]. Besides, the deterministic methods do not have a good performance to deal multi-modal functions, i.e., functions that have many local optimal values. So, many nondeterministic methods have been proposed in the literature to solve problems in science and engineering [33, 34].

Some nondeterministic optimization methods are inspired on biological principles and have been received an increasing interest in last decades mainly because their versatility in solving complex problems. Among these methods one can find the GA [33, 35] and the Ant System (AS) [36]. The GA is based on insights from the study of natural selection and evolution whereas the AS is inspired on behavior of ants, which use the pheromone density to mark the best paths to get to the food.

Genetic Algorithms Method (GA)

The GA is a nondeterministic optimization method inspired by natural evolution process [33–36]. This procedure generally uses binary strings called chromosome or individual to represent solutions of the problem. In fact, the chromosome can be encoded as a binary, integer, or real-valued string [5, 6]. By means of competition, the most able chromosomes of the population are selected and crossed each other, to generate new chromosomes better than those ones of the previous population. So, at each generation the probability of one or more individual to be a solution of the problem is increased. A GA can find the global optimum solution in a complex multimodal search space without requiring specific knowledge about the target problem, which was developed for solving. Besides, a GA operates over the population in parallel, yielding various solutions at each time. Hence, this method has found applications in engineering problems involving complex combinatorial optimization [34].

The GA procedure (Fig. 1) involves four main operations: fitness, selection, crossover, and mutation. At the beginning, a population of individuals is randomly generated. The size of population depends on the problem to be solved.

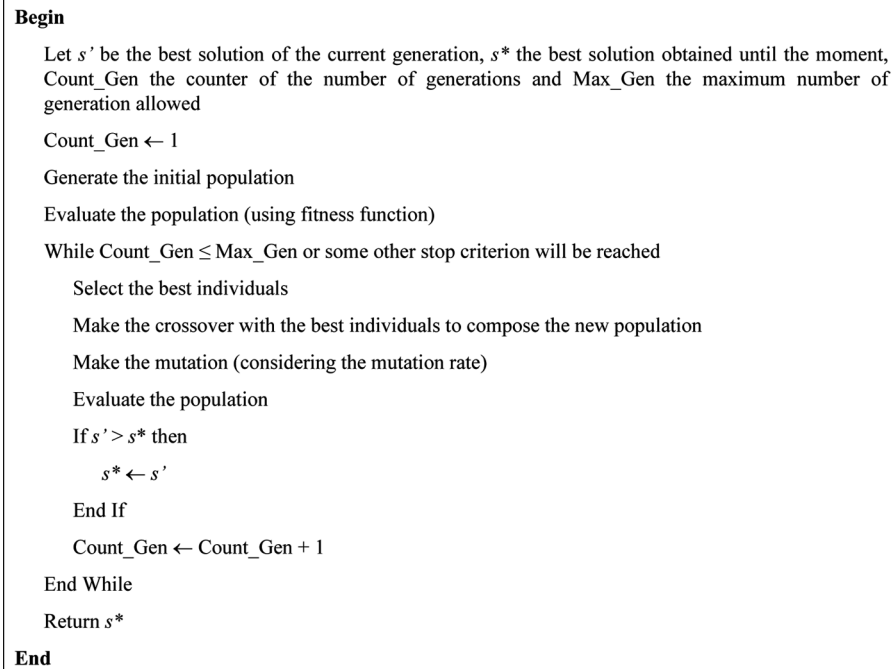


FIGURE 1.—Genetic algorithm procedure.

The fitness function is used to evaluate each individual of the population, providing information to the selection operation where the best candidates and the number of new individuals each one can generate, according to its aptitude, are defined. In the crossover operation, the genetic material of the best chromosomes is mixed to generate the individuals of the next population. Finally, a random change in a small number of bits, with some small probability, is applied as an alternative to prevent the population of chromosomes becoming too similar to each other or, in other words, to preserve the diversity of the population [5]. This operation is important to avoid the premature convergence, and it is known as bitwise mutation. Indeed, it is important to remember that the suitable convergence of the GA depends on some parameters such as: size of chromosome, number of generations, population size, crossover points, and mutation rate [32]. Unfortunately, the determination of these parameters is a task notoriously difficult and, in general, they are empirically defined [37]. In Subsection 4.1, it was described how the GA control parameters were obtained.

METHODOLOGY

In this work, the Microsoft Visual Basic® 6.0 and ANSI C programming languages were used in the development

of the proposed Genetic Algorithm for cutting Parameters Estimation (GAPE) Tool. A friendly graphical interface was implemented to allow the user to input the parameter values, such as taxes, contribution margin, and the initial values of parameters to be optimized, as well as the percentage of variation of each one of them. The GAPE Tool evaluates the variable workpiece cost (K_p), the initial sale price (T_p), the value of the minimum cost cutting speed (V_{cmc}), and another values of the cutting parameters, which could be used for decision making support. The choice of the parameters to be optimized was based on results already reported in Baptista et al. [38]. In that work, the authors studied the influence of each parameter involved in production cost, given by Eq. (3). As a result, it was possible to identify the more significant variables that have the major weight over the final production cost.

GA Technique Applied in Cutting Process Parameters Estimation

To solve the problem of parameters estimation in the cutting process as described in Section 2.1.2, the GA was built as follows. Chromosome structure: A binary string with 66 bits divided in 6 genes, each one representing one variable to be estimated (Fig. 2).




FIGURE 2.—Division of the chromosome to represent the six variables, where: g_1 : percentage variation in the labor costs value (pv1); g_2 : percentage variation in the material cost value (pv2); g_3 : percentage variation in the tool edge cost value (pv3); g_4 : percentage variation in the tool change time value (pv4); g_5 : percentage variation in the unproductive time cost value (pv5); g_6 : percentage variation in the machine cost value (pv6).

The value of each variable (pv_i) is obtained according to Eq. (4):

$$pv_i = \%_{\min_allowed} + (\%_{\max_allowed} - \%_{\min_allowed}) \times \frac{g_{i10}}{2^l - 1}, \quad (4)$$

where g_{i10} represents the binary substring g_i converted to base ten value and l is the size of binary substring g_i . The domain solution for each parameter can vary from $\%_{\min_allowed}$ to $\%_{\max_allowed}$ (as illustrated in the Fig. 7). Indeed, Eq. (4) provide a conversion of a binary number into a real number $r \in [r_{\min}, r_{\max}]$, with precision of p decimal points, given by the following inequality [39]:

$$2^k \geq (r_{\max} - r_{\min}) \cdot 10^p, \quad (5)$$

where k is the length of a binary string and p is the precision.

For example, let a binary string $b = 0101010101_2$, $r_{\min} = -10.0$, and $r_{\max} = 10.0$, then $b_2 = 682_{10}$ and, consequently, $r = [-10.0 + (10.0 - (-10.0)) * (682/2047)] = -3.34$. Naturally, the minimum and maximum values of b will generate, respectively, r_{\min} and r_{\max} .

Other parameters of GA configuration were maximum number of generation (Max_Gen): 200; population size: 200 individuals; bitwise mutation rate: 2%; crossover points: 2 (randomly defined). These four parameters were calibrated experimentally, as described in Subsection 4.1.

In order to select individuals for recombination, the elitism selection was used. We define that the 1/4 of the population, including the best individuals, could be selected at each generation and among them, 10% is preserved intact for the next generation.

The fitness function is the Objective Function (OF) itself, i.e., Minimize [Kp] [Eq. (3)]. The value of each optimization parameter is estimated according to interval established by the user ($\%$ allowed \pm), as demonstrated in the Fig. 7. For example, for the parameter Labor Cost (S_L), the considered interval is $S_{L\min} \leq S_L \leq S_{L\max}$, where $S_{L\min} = -10\%$ of the reference value (S_L) and $S_{L\max} = +10\%$ of the reference value (S_L).

RESULTS AND DISCUSSION

GA Configuration

In order to determine the GA control parameter values, a set of experiments was performed, in which we varied only one parameter, maintaining all others fixed. Figures 3–6 showed the obtained results of GA performance, i.e., the convergence to the minimum Objective Function value.

Figure 3 compares the convergence after 30, 50, 100, and 200 generations. As can be seen, the GA converges after ~ 150 generations. We adopted 200 as a maximum number of generations (Max_Gen) by precaution. However, even adopting more than a sufficient number of generations, the processing time is slightly increased. Each execution of GA, considering $Max_Gen = 200$, took approximately 1s in a Pentium 4–2.8GHz.

The comparison of the GA performance considering four different population sizes is illustrated in the Fig. 4. As




FIGURE 3.—Performance of GA considering different number of generations.




FIGURE 4.—Performance of GA considering different population sizes.

expected, the GA performance increases according to this parameter. However, it is possible to see that for all studied population sizes the performances are very similar. So, we adopted the smaller one.

The GA performance considering four different mutation rates is showed in Fig. 5. One can see that the better performance is attained when mutation rate is equal to 2%.




FIGURE 5.—Performance of GA considering different mutation rates.




FIGURE 6.—Performance of GA considering different crossover schemes.

In that situation, high mutation rates increases the risk of losing potential solutions, even using the elitist selection.

Figure 6 shows the GA performance considering two crossover schemes: fixed in the bits 17 and 50 and random points. As can be seen, the performance of GA is better when two crossover points are randomly chosen.

Cutting Parameters Optimization

In order to better investigate and analyze the influence of the cutting parameters, it was developed a computational tool, the GAPE Tool. This program allows changing the main parameters properly as showed in Fig. 7. The system found the nearest optimal combination of all parameters investigated in this work, as showed in the “Estimated Values” frame. The reference values used in this work are the following: $x = 4.1557$ and $K = 5.02 \times 10^{10}$ [Taylor’s

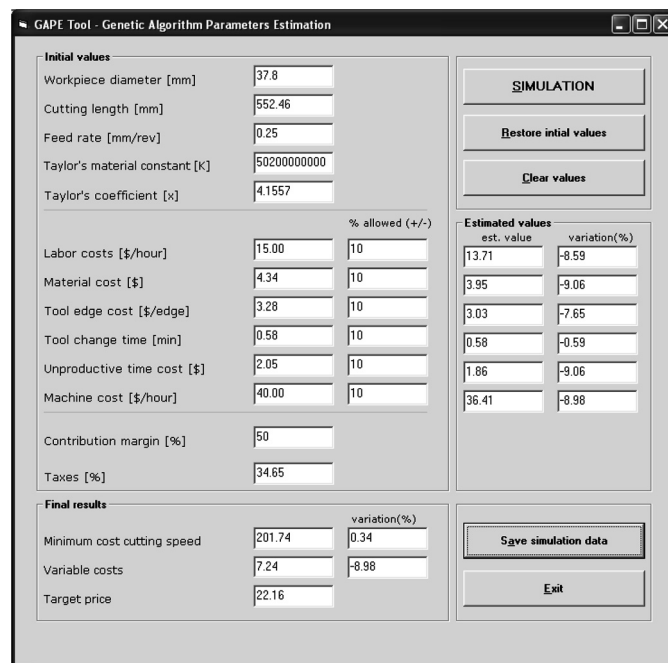


FIGURE 7.—The main window of GAPE tool.

equation coefficients, symbolized by T in Eq. (3)]; $S_L = \$15.00$; $C_m = \$4.34$; $C_{tool} = \$3.28$; $t_{ct} = 0.58$ min.; $C_{tu} = \$2.05$; and $S_M = \$40.00$. From this set of values it is possible to calculate the minimum cost cutting speed (V_{cmc}), the variable workpiece cost (K_p), and the initial sale price (T_p). These values were obtained from Baptista et al. [38].

It is possible to see that the unproductive time and material costs have the major influence on the machined price with -9.06% of reduction. They are followed closely by the machine costs, which has a reduction of -8.98% . In addition, labor cost has a reduction of -0.59% and the tool edge cost has a reduction of -7.65% . The tool change time has a minor influence (-0.59%), but with a great influence over the machine cost. So, there is an important indication about the goal value for each analyzed parameter and the process engineer can direct efforts to reach the final cost reduction.

When the minimum cost cutting speed is applied, the final target price is showed in the frame “Final Results” (see the Fig. 4). Obviously, a contribution margin of 50% was used and a budget based on the determination of machining costs can be presented to the customer. In the analyzed example, -8.98% of cost reduction was achieved, and the desired contribution margin was respected.

In order to investigate the efficiency of the computational system GAPE Tool, in terms of solution quality, its results were compared with those found by Baptista et al. [39], in which it was applied a deterministic method by using Microsoft Excel® spread sheet. Despite the good results, the main drawback of this approach is that only a few possibilities of solution were investigated, since that same percentage was applied to all variables at the same time. Moreover, GAPE Tool showed to be easier to use than the deterministic method.

Figure 8 shows the results reported in Table 2. It is possible to see that the best results for K_p were reached in the optimization when all of the parameters were considered together. Table 3 shows one of the simulation’s results obtained Q3 after applying the GAPE Tool resources, varying $\pm 10\%$ for each parameter independently, to determine the influence of each one in the variable cost for piece, both in the isolated and global ways.


Table 4 shows a case in which all parameters were optimized at the same time varying each parameter value in $\pm 10\%$, when best results of the variable cost per piece (K_p) are achieved. Initial and final parameters values are presented.

TABLE 2.—Influence of each parameter in the variable cost for piece (K_p) by using GAPE tool.

Parameters	Values	Variation (%)	K_p	
			K_p	Variation (%)
S_L	13.64	-9.06	7.93	-0.39
C_m	3.95	-8.98	7.57	-4.90
C_{tool}	2.98	-9.06	7.93	-0.38
t_{ct}	0.53	-9.06	7.95	-0.06
C_{tu}	1.87	-8.98	7.77	-2.31
S_M	36.38	-9.06	7.87	-1.04
All			7.24	-8.98

TABLE 3.—Results of the parameters influence on K_p when all parameters were optimized at the same time.

Parameters	Initial value	+ or – 10% variation	
		Final value	Final variation (%)
S_L	15.00	13.71	–8.59
C_m	4.34	3.95	–9.06
C_{tool}	3.28	3.03	–7.65
t_{ct}	0.58	0.58	–0.59
C_{tu}	2.05	1.86	–9.06
S_M	40.00	36.41	–8.98
K_p	7.96	7.24	–8.98

FIGURE 8.—Variation of the parameters considered individually and together, and its influence on the variable cost per piece (K_p).

Besides, in accordance with Baptista et al. [38], these parameters were separated in two groups: Group 1, constituted with the parameters that have smaller influence in the variable cost constitution per piece (S_L , C_{tool} , t_{ct} , and S_M), and Group 2, which is composed by the parameters that have a significant influence in the variable cost composition per piece (C_m , C_{tu}). Table 4 shows the groups and their respective parameters. In the results obtained in this study, which aims at the optimization of the parameters involved in the cutting process, specifically in a lathe operation and, consequently, at obtaining the smallest variable cost per piece and suggested initial price of sale, it is observed that, in spite of having a different approach, they are close to the values obtained by Baptista et al. [29]. These results allow observing that the procedure used by the authors was believed and, consequently, it confirms the adaptation of the GA in Operational Research applications for cutting processes optimization. Once the two methods showed consistent results, another application for this research could

TABLE 4.—Parameters group according to their influence on the variable cost per piece in GAPE tool.

Group 1: t_{ct} , C_{tool} , S_L , S_M			Group 2: C_{tu} , C_m		
Parameters	Values	Variation (%)	Parameters	Values	Variation (%)
S_L	13.65	–8.98	C_{tu}	3.95	–9.06
C_{tool}	2.99	–8.98	C_m	1.86	–9.06
t_{ct}	0.53	–7.88	–	–	–
S_M	36.41	–8.98	–	–	–
K_p	7.81	–1.82	K_p	7.38	–7.28

TABLE 5.—Degree of difficulty to adopt the final values after GAPE Tool application.

Parameters	Initial value	Final value	Degree
S_L	15.00	13.81	Not feasible
C_m	4.34	3.95	Negotiable
C_{tool}	3.28	3.13	Negotiable
t_{ct}	0.58	0.54	Technically possible
C_{tu}	2.05	1.86	Technically possible
S_M	40.00	36.82	Difficult

be the management of the machining process: thus, besides having been observed that some parameters influence more than others in the cost per piece, it is also observed that some of the parameters can be more easily modified than others, to optimize the process. In Table 5 these aspects are suggested, by analyzing the facility or difficulty degree to adopt the final values after the GAPE Tool application. It is important to consider that, despite the small cost reduction, this value refers to the cost per piece and, therefore, may be representative, depending on the number of pieces to be produced.

CONCLUSION

In this work, a tool named GAPE Tool, based on GA technique, is proposed in order to optimize cutting process parameters, aiming at variable cost reduction. The final minimum cost cutting speed determined by GAPE Tool application, could be considered as an important factor to reach cost reduction, as shown in the results. It is important to stand out that the percentage variation of the parameters should be chosen arbitrarily by the user, with good sense and in agreement with the situation involved in each productive cutting process. The final values determined by GAPE Tool application are not always easy to be adopted. Nevertheless, all the efforts must be done to make the adoption, considering that the cost reduction could be an interesting strategy to improve company competitiveness. The GAPE Tool showed to be adequate for cutting process optimization involving several influence factors simultaneously or not, once the obtained results are in good agreement to those obtained by means of deterministic technique. In addition, the GAPE Tool shows itself as a flexible application, with a friendly graphical interface that allows the user good interaction with the system, constituting, this way, an alternative tool in decision making support for the initial sale formation.

REFERENCES

1. Teti, R.; Kumara, S.R. Intelligent computing methods for manufacturing. *Annals of the CIRP* **1997**, *46*, 629–652.
2. Mukherjee, I.; Ray, P.K. A review of optimization techniques in metal cutting process. *Computers and Industrial Engineering* **2006**, *50*, 15–34.
3. Paszkowicz, W. Genetic algorithms, a nature-inspired tool: Survey of applications in materials science and related fields. *Materials and Manufacturing Processes* **2009**, *24*, 174–197.
4. Coello, C.A.C.; Becterra, R.L. Evolutionary multiobjective optimization in materials science and engineering. *Materials and Manufacturing Processes* **2009**, *24*, 119–129.

5. Oduguwa, V.; Tiwari, A.; Roy, R. Evolutionary computing in manufacturing industry: An overview of recent applications. *Appl. Soft Computing* **2005**, *5*, 281–299.
6. Chakraborti, N. Genetic algorithms in materials design and processing. *International Materials Reviews* **2004**, *49*, 246–260.
7. Li, L.; Fuh, J.Y.; Zhang, Y.F.; Nee, A.Y. Application of genetic algorithm to computer-aided process planning in distributed manufacturing environments. *Robotics and Computer-Integrated Manufacturing* **2005**, *21*, 568–578.
8. Oysu, C.; Bingul, Z. Application of heuristic and hybrid-GASA algorithms to tool-path optimization problem for minimizing airtime during machining. *Engineering Applications of Artificial Intelligence* **2009**, *22*, 389–396.
9. Mahanty, S.; Mahanty, B.; Mohapatra, P.K.J. Optimization of hot-rolled coil widths using a genetic algorithm. *Materials and Manufacturing Processes* **2003**, *18*, 447–462.
10. Mahanty, B.; Agrawal, R.K.; Shrin, S.; Chakravarty, S. Hybrid approach to optimal packing using genetic algorithm and coulomb potential algorithm. *Materials and Manufacturing Processes* **2007**, *22*, 668–677.
11. Zheng, L.; Yang, X.M.; Zhang, Z.H.; Liu, T.I. A web-based machining parameter selection system for life cycle cost reduction and product quality enhancement. *Computers in Industry* **2008**, *59*, 254–261.
12. Mahdavi, I.; Paydar, M.M.; Solimanpur, M.; Heidarzadeh, A. Genetic algorithm approach for solving a cell formation problem in cellular manufacturing. *Expert Systems with Applications* **2009**, *36*, 6598–6604.
13. Agrawal, R.K.; Pratihari, D.K.; RoyChoudhury, A. Optimization of CNC isoscallop free form surface machining using a genetic algorithm. *International Journal of Machine Tools and Manufacture* **2006**, *46* (7–8), 811–819.
14. Manna, A.; Salodkar, S. Optimization of machining conditions for effective turning of E0300 alloy steel. *Journal of Materials Processing Technology* **2008**, *203* (1–3), 147–153.
15. Salehi, M.; Tavakkoli-Moghaddam, R. Application of genetic algorithm to computer-aided process planning in preliminary and detailed planning. *Engineering Applications of Artificial Intelligence* **2009**, *22* (8), 1179–1187.
16. Sardiñas, R.Q.; Santana, M.R.; Brindis, E.A. Genetic algorithm-based multi-objective optimization of cutting parameters in turning processes. *Engineering Applications of Artificial Intelligence* **2006**, *19* (2), 127–133.
17. Tansel, I.N.; Ozcelik, B.; Bao, W.Y.; Chen, P.; Rincon, D.; Yang, S.Y.; Yenilmez, A. Selection of optimal cutting conditions by using GONNS. *International Journal of Machine Tools & Manufacture* **2006**, *46*, 26–35.
18. Jain, N.K.; Jain, V.K.; Deb, K. Optimization of process parameters of mechanical type advanced machining processes using genetic algorithms. *International Journal of Machine Tools & Manufacture* **2007**, *47*, 900–919.
19. Vidyakiran, Y.; Mahanty, B.; Chakraborti, N. A genetic-algorithms-based multiobjective approach for a three-dimensional guillotine cutting problem. *Materials and Manufacturing Processes* **2005**, *20* (4), 697–715.
20. Tiwari, S.; Chakraborti, N. Multi-objective optimization of a two-dimensional cutting problem using genetic algorithms. *Journal of Materials Processing Technology* **2006**, *173* (3), 384–393.
21. Jamali, A.; Nariman-zadeh, N.; Darvizeh, A.; Masoumi, A.; Hamrang, S. Multi-objective evolutionary optimization of polynomial neural networks for modelling and prediction of explosive cutting process. *Engineering Applications of Artificial Intelligence* **2009**, *22* (4–5), 676–687.
22. Atkinson, A.A.; Banker, R.D.; Kaplan, R.S.; Young S.M. *Management Accounting*, 3rd Ed.; Prentice Hall: Upper Saddle River, NJ, 1998; 816 pp.
23. Jones, L.F. Product costing at caterpillar. *Management Accounting* **1991**, *72* (8), 20–77.
24. Khoury, C.; Ancelevicz, J. A utilização do sistema de custeio ABC no Brasil. *Revista de Administração de Empresas* **1999**, *39* (1), 55–63.
25. Martins, E. *Contabilidade de Custos*, 9th Ed.; Atlas: São Paulo, Brazil, 2003; 370 pp.
26. Vaconcelos, A. *Principais questões conceituais e práticas da gestão estratégica de custos*. Anais do III Congresso Brasileiro de Gestão Estratégica de Custos, Curitiba, Brazil, 1996; 367–276.
27. Cooper, R.; Kaplan, R. How cost accounting distort product costs. *Management Accounting* **1999**, *80* (4), 20–27.
28. Lucato, W.C.; Coppini, N.L.; Baptista, E. A. Machined part sales price build-up based on the contribution margin concept. *Journal of the Brazilian society of Mechanical Sciences and Engineering* **2009**, *31* (03), 181–185.
29. Hirshleifer, J.; Hirshleifer, D. *Price Theory and Applications*, 6th Ed.; Prentice Hall: Upper Saddle River, NJ, 1997; 608 pp.
30. Monroe, K.B. *Pricing: Making Profitable Decisions*, 3th Ed.; McGraw-Hill: New York, 2002; 688 pp.
31. Dininz, A.E.; Marcondes, F.C.; Coppini, N.L. *Tecnologia da Usinagem Dos Materiais (Cutting Process Technology)*, 4th Ed.; Artliber: São Paulo, Brazil, 2001; 256 pp.
32. Araújo, S.A.; Librantz, A.F.; Alves, W.A. Algoritmos genéticos na estimação de parâmetros em gestão de estoque. *Exacta* **2009**, *7* (1), 21–29.
33. Goldberg, D.E. *Genetic Algorithms in Search, Optimization, and Machine Learning*; Addison-Wesley: Massachusetts, 1989; 432 pp.
34. Pham, D.T.; Pham, P.T. Artificial intelligence in engineering. *International Journal of Machine Tools & Manufacture* **1999**, *39* (6), 937–49.
35. Haupt, R.L.; Haupt, S.E. The binary genetic algorithm. In *Practical Genetic Algorithms*, 1st Ed.; Haupt, R.L.; Haupt, S.E. (Eds.); Wiley-Interscience: New York, 1998; 276 pp.
36. Dorigo, M.; Maniezzo, V.; Colomi, A. The ant system: optimization by a colony of cooperating agents. *IEEE Trans. on Systems, Man, and Cybernetics* **1996**, *26* (1), 29–41.
37. Myers, R. Empirical modelling of genetic algorithms. *Evolutionary Computation* **2001**, *9* (4), 461–493.
38. Baptista, E.A.; Librantz, A.F.; Coppini, N.L. Analyses of the parameters influence on the price determination based on the contribution margin concept for cutting process. *Proceedings of 8th International Conference on Advanced Manufacturing Systems and Technology*, Udine, Italy, 2008; 27–34.
39. Pacheco, M.A. Algoritmos genéticos: Princípios e aplicações. *Proceedings of V Congresso Internacional de Ingeniería Electrónica, Elétrica y Sistemas*, Lima, 1999; 11–16.

**ANEXO B - SIMULATED ANNEALING APPLIED TO MINIMIZE THE IDLENESS
AND MAXIMIZE THE CONTRIBUTION MARGIN FOR GENERICS FLEXIBLES
MACHINING CELLS**

Simulated Annealing Applied to Minimize the Idleness and Maximize the Contribution Margin for Generics Flexibles Machining Cells

Nivaldo Lemos Coppini¹, André Felipe Henriques Librantz¹, Aparecida de Fátima Castello Rosa¹, Alexandre Augusto Martins Carvalho²

¹Industrial Engineering Post Graduation Program – UNINOVE (Nove de Julho University), São Paulo, SP, Brazil, ncoppini@uninove.br, librantz@uninove.br, afc.rosa@uninove.edu.br

²Unicamp- Mechanical Engineering Faculty of State University of Campinas, Campinas, SP, Brazil, aa01mc@yahoo.com.br

Abstract

This paper aims to propose a methodology for optimization of industrial resources of a manufacturer of parts for machining. Not only the more rational use of activities that add value to the product and the use of machine idle time, but especially by the rationalization of the production mix towards greater contribution margin as possible. The methodology provides for the hypothesis that the production of parts is daily and that is repeated with the same minimum number to be produced every day. It was used concepts of Theory of Constraints (TOC), Costing Systems, Contribution Margin, Operational Research and Machining. The TOC was used to define the production bottlenecks and therefore, detect the idle machines. For the idle machines, it was made an extra planning process to cut specific pieces, with more flexible deadlines, fixed by sale department. So, the idleness can be used more rationally, and it was possible to introduce extra profit, considering that these idle machines shall have their fixed costs anyway paid. The concepts of costing systems were used to analyze and discuss what types of costs, direct or indirect, fixed or variable, focused on machining processes. The contribution margin was supposedly negotiated by the machining front of your customers and set for each product in the production mix. Optimization techniques were used in the methodology development by means production computational simulation in order to determine which products should be produced in a work day. The machining concepts were applied to make all the calculations about this matter properly. As a final consideration, it can be said that the software is functional and responds to the possibility of financial profit maximization due to a new proposed methodology.

Keywords: Theory of Constraints (TOC), Costing Systems, Contribution Margin, Operational Research and Machining.

1. Introduction

The market is a one of the main factor to incentive the industries to achieve differential competitiveness as technological innovation, quality, service and price in order to offer to their customers the conditions that could generate profit.

The price is set by the market, so competition sets parameters for pricing goods and services. It is the consumer that has the perception when is paying more for a product or service. Thus, the process management seeks to maximize activities that add value and eliminate activities that are not perceived by the consumer. But, to improve processes and maximize profit, it will necessary to manage costs and investments efficiently [1].

In this context, the understanding of concepts as price formation, contribution margin, idleness, industrial management and cost methodology is fundamental for an organization to gain a solid market position with a structural strengthening and a gain of agility in the search for competitive advantages.

Hamel & Prahalad [2], emphasizes that it is not enough a company to reduce its size and increase its efficiency and speed of production to beat deadlines. Utmost importance that tasks are, the company must also be able to reassess, regenerating its core strategies and reinvent their industry, and that a company must be able to be different.

With the exception of some large companies, most of them that produce non-durable goods and the smaller companies, have low levels of productivity, high costs of their products, slow response to changes when demanded, production of low flexibility and quality not ensured, they cannot have chance to compete properly in the market [3].

Currently it is possible to observe, by the analysis of economic Brazilians indices, a strong resumption of industrial growth, after a long period of low industrial investment, which highlights the discussion of industrial capacity. Is the Brazilian industrial capacity capable of supporting the demand? In this context, monitoring the degree of industrial efficiency and hence the degree of idle factory took a special interest of government regulators, that consistently held comments on this topic. This issue can occur with any country, although it was cited as an example the case of Brazil

The quest for change in direction that aims to transform and redirect fixed costs into variable, restructuring processes with decentralization and maximization of resource capacities, are competitive advantages that are part of the desired operational strategy for large companies. Companies that supply parts for machining are no exception in this scenario and must prepare to do his part.

The objective of this research is to develop a methodology that helps companies acquire tools that would allow a form of support to obtain a competitive advantage in its sector with the maximization of production capacity by minimizing idleness present in industrial production resources. For this, was developed a computational tool, with graphical interface, that makes use of the Simulated Annealing (SA) metaheuristic technique, which will support the decision-making. The main focus of this paper is to seek a mix of products to be machined using the idle coming from the normal production prioritizing the best contribution margin or delivery time dead line, depending on the more restrictive factor.

2. Theoretical Basis

Bibliographies whose approach relate to the study of idleness, especially in the management aspect is scarce. However, the importance of the theme is undeniable.

Kohler *apud* Guerreiro and Christians [4], seek to define idle capacity of production with the inverse definition of productive capacity, where it is considered the productive potential of unused or partially used. The measurement of this outcome may occur in units such as tones of potential production, or hours available for production.

Classical Literature and Monks [5], Slack [6] addressed the issue industrial idleness in order to quantify the amount of "lost" time and emphasize the importance of that time to be minimized to ensure industrial efficiency. Many efforts of industry and academic community have been conducted to find ways to achieve this goal.

Padoveze [7] and Martins [8] through methods of accounting and costing systems consider idleness as a resource paid and apportioned, to be integrated in industrial costs.

According to Corbett [9], "all action taken by any part of the company should be judged by impact on the overall purpose". That is, the overall goal of measures that had to be taken should be aligned in order to stratify, control and evaluate the obtained results.

Still according to Corbett [9] the TOC, data collected from observations made within the company should be analyzed in a systematic way. This methodology allows to conclude that the restrictions are always present and the company must arrange a product mix that prioritizes the product with the highest gain in constraint (bottleneck), generating, by this way, a higher overall result.

Manjeshwar et al [10], proposed a heuristic based on Johnson's algorithm and a SA algorithm for minimizing the makespan of two batch-processing machines in shop flow. They compared with SA results obtained from the proposed heuristic and a commercial solver. The SA outperformed both the heuristic and the commercial solver. On larger problem instances, the heuristic outperformed the commercial solver.

Rosa et al [11], proposed OPMP Tool - Optimization Parameters in Machining Process, a tool to aid in decision-making that applies the concepts of SA, metaheuristic optimization technique, contribution margin and a cutting process concept based on the Maximum Efficiency Interval (*MEI*). They found that was possible optimize the machining parameters involved in the cutting process in order to minimize the variable cost per unit and the initial selling price. OPMP Tool has a graphical user interface that allows good interaction with the system, providing possibility of establishing negotiation between cutting process services suppliers and their customers.

This work is based on operational research resources and applies three sets of knowledge: the concept of contribution margin, TOC and SA metaheuristic.

2.1. Contribution Margin

According to Campos et al [12], the function of inventories is to act as regulators of business flow, or balance the speed with which the materials are received by the speed with which they are used and delivered to customers.

Atkinson et al [13] state that "the difference between price and variable cost per unit is the contribution margin per unit".

Using the concept of contribution margin corporate billing can generate an index that allows establishing how much a customer, product or region represent revenue for the company and therefore their level of importance.

The contribution margin is used to cover the company's fixed costs and contribute to profit.

Depending on the value of the sale price and the value of the sum of the costs of industrialization with the price of a unit cost of product, the unit contribution margin can be: positive, negative or zero.

The positive contribution margin occurs when the value of the sale price is greater than the value of the sum of the costs of industrialization with the cost price per unit of product.

The negative contribution margin will occur when the value of the sale price is less than the sum of the value of the costs of industrialization with the cost price per unit of product.

The contribution margin void, will occur when the sale price is equal to the sum of the costs of industrialization with the cost price per unit of product.

2.2. Theory of Constraints (TOC)

Gerreiro [4] "the barriers of restrictions breaks the barriers of the production system and generalizes, for the company as a whole, the thought of optimization, admiring the set of global constraints (financial, marketing, production etc) that the company is submit. In the OPT (Optimized Production Technology), the keyword is 'bottleneck', and this name shows that the focus of its principles and procedures is fundamentally based on data from shop floor. In TOC, the keyword becomes "constraints", defined as anything that limits the scope of the company's objective".

The TOC has the basic premise that the management of production should be administered from the restrictions, and non-limiting resources are neglected. This theory considers five basic steps to troubleshoot the production process:

Step 1: Identify the system constraints;

Step 2: Explore the restrictions maximizing the limited resources;

Step 3: Subordinate the system the decisions of step 1 and 2;

Step 4: Elevate the system constraints;

Step 5: If the restrictions are not exploited, returns to the first step;

As Slack [6], product mix affects the productive capacity. Such a situation, the change in product mix can affect the productive capacity, by increasing or eliminating productive hours for stations or manufacturing processes in accordance with the technical characteristics of products being manufactured.

2.3. Simulated Annealing Method (SA)

The SA algorithm is a stochastic version of well known Hill Climbing technique and it was described by Kirkpatrick et al [15]. It is a local search method that accepts movements to worse states aiming to escape of local optimum. The SA pseudocode is presented in the figure (1).

According to Balram [14], "the SA method is known to be a compact and robust technique, providing excellent solutions to single objective optimization problems with a substantial reduction in computational cost".

SA is a metaheuristic method that imitates a thermodynamic process (physical annealing of solids) in which a metal is heated until its melting temperature and then is allowed to cool slowly so that its structure is frozen at the crystal configuration of lowest energy.

In the analogy with thermodynamic process, the different states of the substance correspond to the different feasible solutions to the combinatorial optimization problem, and the energy of the system corresponds to the function to be minimized.

The SA algorithm starts with an initial solution generated randomly. In the loop, a random movement (a new successor solution) is chosen at each temperature. If the new state is better than current state, it will be accepted. Otherwise, the new state will just be accepted with a certain probability smaller than 1 (one).

This probability is affected by the quality of movement, given by $e^{(-\Delta E/Temp)}$ where $Temp$ is a control parameter which corresponds to temperature in the analogy with physical annealing, and decreases according the temperature ($Temp$).

So, worse movements have major probability to be accepted at the beginning of algorithm, when the temperature is high. After that, it becomes more improbable because the value of $Temp$ is small. So in SA, the algorithm is started with a relatively high value of $Temp$, to avoid being prematurely trapped in a local optimum.

In general, the quality of solution found by the SA algorithm depends on the cooling schedule adopted. The stop criterion of the algorithm is given by the value of the variable $Temp$ [15-17].

In this work the parameter $Temp$ is started with a high value ($Temp = 10,000^{\circ}\text{C}$). To decrease the temperature, a function is used, i.e. $Temp(Temp + 1) = \alpha(Temp)$ where α is a constant.

According to Eglese [16], typical values of α are used in practice lie between 0.8 and 0.99. It was used 0.99 once the results showed to be better.

3. Methodology

In this work the Microsoft Visual Basic® 6.0 programming language was used in the development of the proposed IAS Idleness Analyze System. A friendly graphical interface was implemented to allow the user to input the parameter values, such as: total production time available (tpt), total production cutting time (tt), total production cutting time and quantity (Z_{ex}) demand of parts, contribution margin and deadline of products mix. The choice of the parameters to be optimized was based on results already reported in Coppini et al [18]. In that work, the authors proposed a computational tool for bottleneck and idleness determination.

Simulated Annealing Procedure

Begin

Let s_0 the initial solution (randomly generated), s the solution represented by the current state, s' the solution represented by successor of the current state, s^* the best solution obtained until the moment, $alfa$ is a constant that determine the rate at the temperature is reduced, ΔE the variation between s and s' , P the probability to accept solutions worse than the current solution and $Temp$ the temperature that control the probability P .

Set an initial temperature $Temp > 0$

Set $alfa$ { between 0.8 and 0.99 }

Generate initial solution s_0 { randomly }

$s \leftarrow s_0$

$s^* \leftarrow s_0$

While $Temp \geq 1$ Do

 If $Temp=1$ Then

 Return s^*

 End-If

 Generates s' { randomly }

$\Delta E \leftarrow s' - s$

 If $\Delta E > 0$ Then

$s \leftarrow s'$

 Else

$P \leftarrow e^{(-\Delta E/Temp)}$

 If $\text{random}(0,1) < P$

$s \leftarrow s'$ { with probability P }

 End-If

 End-If

 If $s > s^*$ Then

$s^* \leftarrow s$

 End-If

$Temp \leftarrow Temp * alfa$

End-While

Return s^*

End

Figure 1: Pseudocode of Simulated Annealing Algorithm (Source [11])

4. Problem Description and Mathematical Formulation

Let x_p is the quantity of the product p ($p = 1, 2, \dots, n$) being machined. Let also OC_i is the available idle capacity of resource i ($i = 1, 2, \dots, m$). To produce one unit of part p , are consumed a_{ip} units of idle resource i . The amount of demand (batch) product p is given by d_p . Each unit of the product p has its contribution margin p_{MC} . The problem can be expressed mathematically as follows:

$$\text{Maximize } CM(x_1, \dots, x_n) = \sum_{p=1}^n CM_p x_p \quad (1)$$

$$\text{Maximize } CMD(x_1, \dots, x_n) = \sum_{p=1}^n CM_p x_p PF_p \quad (2)$$

$$\sum_{p=1}^n a_{ip} x_p \leq OC_i \quad i = 1, 2, \dots, m \quad (3)$$

$$0 \leq x_p \leq d_p \quad p = 1, \dots, n \quad (4)$$

$$PF_p = \frac{1}{dl} \quad p = 1, \dots, n; dl = 1 \dots n \quad (5)$$

The Eq.(1) is the mathematical representation of the total contribution margin to be maximized only when considering the contribution margin (CM) for the optimization and the Eq.(2) has the same meaning for contribution margin with delivery deadline (CMD) given by the factor penalty (PF_p), where dl is the number of days of the deadline according to Eq.(5). Constraints (3) of the problem, limit the manufacture of products due to availability of idleness of resources and constraints (4) require that the quantity of each product cannot be larger than the amount of the batches.

The Eq.(6) is the objective function to maximize the contribution margin.

$$TCM = Qtd_{PA} * CM_{PA} + Qtd_{PB} * CM_{PB} + Qtd_{PC} * CM_{PC} + Qtd_{PD} * CM_{PD} + Qtd_{PE} * CM_{PE} + Qtd_{PF} * CM_{PF} \quad (6)$$

Where:

TCM = total contribution margin;

Qtd_{PA} = extra quantity product A;

CM_{PA} = contribution margin of extra product A;

Qtd_{PB} = extra quantity product B;

CM_{PB} = contribution margin of extra product B;

Qtd_{PC} = extra quantity product C;

CM_{PC} = contribution margin of extra product C;

Qtd_{PD} = extra quantity product D;

CM_{PD} = contribution margin of extra product D;

Qtd_{PE} = extra quantity product E;

CM_{PE} = contribution margin of extra product E;

Qtd_{PF} = extra quantity product F;

CM_{PF} = contribution margin of extra product F.

The objective function to maximize the contribution margin considering the penalty for delivery deadline, is given by the Eq.(7).

$$TCMDL = Qtd_{PA} * CM_{PA} * PF_{PA} + Qtd_{PB} * CM_{PB} * PF_{PB} + Qtd_{PC} * CM_{PC} * PF_{PC} + Qtd_{PD} * CM_{PD} * PF_{PD} + Qtd_{PE} * CM_{PE} * PF_{PE} + Qtd_{PF} * CM_{PF} * PF_{PF} \quad (7)$$

Where:

$TCMDL$ = total contribution margin with delivery deadline;

PF_{PA} = penalty factor of extra product A;

PF_{PB} = penalty factor of extra product B;

PF_{PC} = penalty factor of extra product C;

PF_{PD} = penalty factor of extra product D;

PF_{PE} = penalty factor of extra product E;

PF_{PF} = penalty factor of extra product F.

Possible solutions of the objective functions are calculated according to equality as Eq.(6) and Eq.(7). In this work, the changes in the objectives function represent the maximization of the total contribution margin.

5. Development and Use of the Proposed Procedure

The first window's IAS, showed in figure (2), comes from previous work mentioned above Coppini et al [18]. In this window the green line of the system interface (frame Data Input Machine), the results obtained in line Bottleneck/Idleness indicates the idleness in minutes. The red line identifies an operation that presents a bottleneck. These bottlenecks/Idleness are arising from the use of machines for normal production of parts to be machined within a schedule relating to a work shift.

To use the results of the first three lines showed in figure (2), just is enough to press the button "Product Mix Decision" and a new window will open (figure (3)) suitably prepared to enter the data for the mix of extra products to be machined using the remaining idleness.

So, the number of each Ex.Prod (extra products) demanded identified from A to F can be inserted and their respective cutting time in each machine, and also must be inserted their contribution margin and delivery deadline.

Machine Data Input [min]

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Total Production Time Available (tpt)	480	480	480	480	480	480	480	480	480	480
Total Production Cutting Time (tt)	430.40	259.80	101.20	79.10	135.90	445.60	392.10	69.80	48.60	500.20
Bottleneck/Idleness time (tbi)	49.60	220.20	378.80	400.90	344.10	34.40	87.90	410.20	431.40	-20.20

Total Production Cutting Time/Machine Inputs [min] and Number of Workpieces z

Z	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Product 1	8	10.6		0.7	1	0.6				
Product 2	23	0.3	4.1	1.5	1.5	1.8	11.6		0.8	1.9
Product 3	20	11	5.2	1.5		2.9		2.6	2.2	0.9
Product 4	15	7.7	4.1	0.7	2.6	1.9	11.6	22.3	1	1.8
Product 5	8	0.4					0.7	1	0.3	
Product 6	4									107
Product 7	1		26.2					2.8	0.8	

Control Panel:

- Restore Initial Values
- Calculate Idle
- Product Mix Decision
- Save Data
- Clear Form
- Exit

Figure 2: IAS- Idleness Analysis System

Both contribution margin and delivery deadline must be, at this moment, duly negotiated with clients. Products that, during the negotiations, showed no attractive contribution margins and delivery times impossible to be respected and unavailability of resources in terms of installed capacity machine, were previously discarded.

For the first set of results we have in the frame “Idleness time use for Contribution Margin Maximization”, the accumulated value of contribution margin and the total parts number Z_{ex} of each product to be machined, taking in account all the constraints mentioned before.

For the second set of results we have in the frame “Idleness time use for Contribution Margin Maximization and Delivery Time”.

In the last line of this frame are the number of parts to be machined, giving priority to products that have more urgent deadlines.

One can observe that there is a change in the number of parts only when the maximized contribution margin was considered. This is because, due to delivery time, parts and their numbers and their respective contribution margins should be a different combination.

In the simulated example in figure 3, the contribution margin that was maximized in the frame above, resulted lower. In another example this could result in greater value.

6. Final Considerations

In this work it was proposed a friendly computational tool named IAS, specifically developed to take decision about how to plan extra products mix, in terms of the improvement on the net profit. Although they have been used simulated data to validate the IAS, the program proved to be very consistent and appropriate to manage the proposed problem of maximizing the contribution margin and delivery deadline using the idleness found in a generic manufacturing plant.

The SA method was applied to maximize the values of objective functions that lead to the solution of identifying the best mix of extra products to be machined. The results show that the SA algorithm is a robust and efficient method for optimizations subjects.

The proposed procedure presents in this paper integrates traditional established methodologies as: TOC, SA metaheuristic and contribution margin.

The procedure allows providing real possibility of using idleness already paid and, as a consequence, minimizing costs with the advantage to make these costs in net income.

As a condition to implement the procedure, there is a requirement of knowledge of the manufacturing process, the concept of contribution margin and the TOC. Thus, it is possible to evaluate the idle capacity, measure its financial value which could be added to billing.

With the bottlenecks and idle capacity identification it may be proposed that must be taken the following guidelines:

- Assess among extra products those who have a higher contribution margin;
- Whereas the machines idleness are already paid for whether used or not, products that use these idleness to be machined, always they being larger than the raw material used, they will represent direct net profits for the company.

This work has a special contribution by allowing to the manager decides which is the best way to be taken, considering the performance of the market, as well as, his own. So, he can choose the best way to prioritize the contribution margin or prioritizing customer service. This can be an alternative on the following occasions:

- If demand is less than productive capacity, we can choose the solution that the system prioritizes the best contribution margin, since theoretically all requests are met within the stipulated time;
- If demand is greater than the capacity, you can choose the solution that the system prioritizes the delivery time imposed by the customer, since theoretically there will be applications at risk of delivery delays.

The procedure can detect and manage the resources not restrictive (idleness).

This procedure allows the organization to adopt a proper methodology aimed at policy optimization idleness, and contribute to the identification of critical fabrication processes allowing their visualization and allowing the manager to strategic business decisions such as: increase of manufacturing capacity by sale of identified idleness, specific marketing actions on products and markets.

Update Status of Machine Idleness and Bottleneck [min.]

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Total Production Time Available (tpt)	480	480	480	480	480	480	480	480	480	480
Total Production Cutting Time (tt)	430.40	259.80	101.20	79.10	135.90	445.60	392.10	69.80	48.60	500.20
Bottleneck/Idleness time (tbi)	49.60	220.20	378.80	400.90	344.10	34.40	87.90	410.20	431.40	20.20

Contribution Margin over each product cost (\$)

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Ex.Prod. A	45	5.3	2.8		9.7					
Ex.Prod. B	8			3.8	1.5		6.8			
Ex.Prod. C	34		7.1	9.3				10.6	11.3	
Ex.Prod. D	45	5.3	2.8	9.7						
Ex.Prod. E	88		3.8	1.5		6.8				
Ex.Prod. F	6	7.1	9.3				10.6	11.3		

Total Production Cutting Time/Machine Inputs [min] and Number of Workpieces Z_{ex}

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	Contr. Margin(\$)	Deadline
Ex.Prod. A	45	5.3	2.8		9.7						8.50	10
Ex.Prod. B	8			3.8	1.5		6.8				12.00	80
Ex.Prod. C	34		7.1	9.3				10.6	11.3		10.38	10
Ex.Prod. D	45	5.3	2.8	9.7							7.25	5
Ex.Prod. E	88		3.8	1.5		6.8					6.30	3
Ex.Prod. F	6	7.1	9.3				10.6	11.3			5.00	2

Idleness time use for Contribution Margin Maximization [min.]

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Total Idleness Time Available (tpt)	49.60	220.20	378.80	400.90	344.10	34.40	87.90	410.20	431.40	20.20
Total Production Cutting Time (tt)	42.40	213.30	356.60	400.00	320.90	34.00	79.40	362.50	350.30	0.00
Bottleneck/Idleness time (tbi) Remaining	7.20	6.90	22.20	0.90	23.20	0.40	8.50	47.70	81.10	20.20

Idleness time use for Contribution Margin Maximization and Delivery Time [min.]

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Total Idleness Time Available (tpt)	49.60	220.20	378.80	400.90	344.10	34.40	87.90	410.20	431.40	20.20
Total Production Cutting Time (tt)	42.40	201.00	368.30	394.10	266.40	34.00	73.40	395.70	361.60	0.00
Bottleneck/Idleness time (tbi) Remaining	7.20	19.20	10.50	6.80	77.70	0.40	14.50	14.50	69.80	20.20

Buttons: Restore Initial Values, Calculate Idle, Save Data, Clear Form, Exit

Figure 3: IAS – Idleness Analyses System

Acknowledgements

The authors thank the support received from University Nove de Julho - UNINOVE and CNPq - National Research Council.

References

- [1] J.P. Martino, *Technological Forecasting for Decision Making*, New York : Mc Graw-Hill Inc., 3 ed., 1993.
- [2] G. Hamel and C.K. Prahalad, *Competindo pelo Futuro*, Campus, Rio de Janeiro, 19^a ed., 2005.
- [3] L.G. Coutinho and J.C. Ferraz, *Estudo da Competitividade da Indústria Brasileira*, Papirus, Campinas, Brazil, 4. ed., 2002.
- [4] R.N. Guerreiro and R.L.M. Christians, O Tratamento da Ociosidade – Análise das Implicações Contábeis e Fiscais, *XVI Congresso Brasileiro de Contabilidade*, Salvador-Bahia, Brazil, II, 1992.
- [5] J. Monks, *Administração da Produção*, McGraw-Hill, São Paulo, Brazil, 1987.
- [6] N. Slack, *Administração da Produção*, [trans.] Vários tradutores, Atlas, São Paulo, 1997.
- [7] C.L. Padoveze, *Curso Básico Gerencial de Custos*, Atlas, São Paulo, 2006.
- [8] E. Martins, *Contabilidade de Custos*, Atlas, São Paulo, 8^a ed., 2001.
- [9] T.N. Corbett, *Contabilidade de Ganhos*, Nobel, São Paulo, 1997.
- [10] P.K. Manjeshwar, P. Damodaran and K. Srihari, Minimizing Makespan in a Flow Shop with two Batch-Processing Machines Using Simulated Annealing, *Robotics and Computer-Integrated Manufacturing*, 25, 667–679, 2009.
- [11] A.F.C. Rosa, et al, Simulated Annealing Technique Applied for Parameters Optimization in Machining Processes, *30th Congresso Ibero-Latino-Americano de Métodos Computacionais em Engenharia – CILAMCE*, Búzios, Rio de Janeiro, Brazil, 1-10, 2009.
- [12] P.R.C. Alt and P.G. Martins, *Administração de Materiais e Recursos Patrimoniais*, Saraiva, São Paulo, 2000.
- [13] A.A. Atkinson, et al, *Contabilidade Gerencial*, Atlas, São Paulo, 2000.
- [14] S. Balram, Study of Simulated Annealing Based Algorithms for Multiobjective Optimization of a Constrained Problem. *Computers and Chemical Engineering*, 28, 1849–1871, 2004.
- [15] S. Kirkpatrick, C.D. Gelatti, and M.P. Vecchi, Optimization by Simulated Annealing, *Science*, New Series, 220 (4598), 671-680, 1983.
- [16] R.W. Eglese, Simulated Annealing: A Tool for Operational Research, *European Journal of Operational Research*, 46, 271-281, 1990.
- [17] S. Russel and P. Norving, *Inteligência Artificial*, Editora Campus, Rio de Janeiro, 2004.
- [18] N.L. Coppini, et al, The Idleness Analysis During Maching: Searching for Best Organizational Results, *30th Congresso Ibero-Latino-Americano de Métodos Computacionais em Engenharia – CILAMCE*, Búzios, Rio de Janeiro, Brazil, 1-10, 2009.

**ANEXO C - SIMULATED ANNEALING TECHNIQUE APPLIED FOR
PARAMETERS OPTIMIZATION IN MACHINING PROCESSES**

SIMULATED ANNEALING TECHNIQUE APPLIED FOR PARAMETERS OPTIMIZATION IN MACHINING PROCESSES

Aparecida F. C. Rosa

André F. H. Librantz

Nivaldo L. Coppini

Elesandro A. Baptista

afc.rosa@uninove.edu.br

librantz@uninove.br

ncoppini@uninove.br

elesandro@uninove.br

Mestrado Engenharia de Produção, Universidade Nove de Julho (UNINOVE), Av. Francisco Matarazzo, 612, Água Branca, 05001-100, São Paulo, SP, Brasil

Sidnei A. de Araújo

saraujo@uninove.br

Curso Ciência da Computação, Universidade Nove de Julho (UNINOVE), Rua Diamantina 302, Vila Maria Baixa, 02117-010, São Paulo, SP, Brasil

Abstract. *Parameters optimization in machining processes and a careful analysis of the costs involved in composition of the sales price can ensure a good outcome to the organization. In this context, this paper presents the OPMP Tool - Optimization Parameters in Machining Process, a tool to aid in decision making that applies Simulated Annealing, a metaheuristic optimization technique, contribution margin and the Maximum Efficiency Interval (MEI) concepts. By means of these techniques it is possible to optimize the machining parameters involved in the process for determining the minimum cost cutting speed (V_{cmc}), maximum production cutting speed (V_{cmxp}) and minimum cost limit cutting speed (V_{cmcLim}) in order to minimize the variable cost per unit and the initial selling price. OPMP Tool has a graphical interface that allows the user good interaction with the system, providing benefits for a possible negotiation of the sale price and / or adjustments in the process. Obtained results are in good agreement with other one already reported, indicating that the OPMP Tool can be properly used in optimization parameters in machining process and in similar scenarios, as well.*

Keywords: *Simulated annealing, Parameters optimization in machining processes, Metaheuristics techniques, Contribution margin, Maximum efficiency interval (MEI)*

1 INTRODUCTION

For one organization to survive currently in the market, each time more, needs to care with: costs reduction, delivery time, quality, flexibility, competitiveness and ability to manage the market requirements, particularly when machining processes industries are involved. A way to seek these conditions is the development and application of optimization techniques of machining processes, once these kinds of manufacturing process is very used and involves many parameters. In the great majority of the cases, the machining process optimization can be a complicated and an unfriendly task (BAPTISTA; COPPINI, 2001).

The contribution margin determination and its analysis for prices composition can serve as important indicative in this scenario, giving subsidies to the company for to guide its suppliers, resulting in a negotiation with competitive advantage.

The contribution margin and the machining process parameters involved also have influence on the prices composition of a certain piece. Their optimization can contribute to improve the profit.

There are several techniques and methods to solve optimization problems available in the literature. The optimum model is that one that finds the best possible solution for the objective function (OF) that is being optimized. Heuristic methods (or non-deterministic) are used to find a good solution (suboptimal solution) in complex problems, once the optimal solution determination in reasonable computation time can be very difficult or even impossible to explore the whole domain of possible solutions (BATALHA, 2008).

Other alternatives for solving complex problems of optimization that have been used in the last decades are the metaheuristic techniques, such as Genetic Algorithms (AGs), Simulated Annealing (SA), Tabu Search (TS), Greedy Randomized Adaptive Search Procedure (GRASP), Ant Colony Optimization Algorithm (ACO) and Variable Neighborhood Search.

The metaheuristic algorithms search the point that represents a solution using probabilistic rules and they have the advantage of not being arrested to minimum or maximum local (CHAVES et al., 2004).

There are several works, which were developed during the last years, in the literature, that the most several machining processes optimization approaches were used.

Baptista et al. (2008), has investigated the parameters influences in the workpiece price determination in the cutting process, using the concept of the contribution margin, trying to identify the most weight factors to minimize the cost for workpiece. The authors describe some influence factors, such as: workpiece material costs, maintenance costs, wage man and machine costs, tool change edge time, tool costs and the salesperson commissions.

Durán et al. (2007), has used Genetic Algorithms and the Expanded Taylor Tool Life Equation to accomplish the cutting parameters optimization (cutting speed and cutting depth), which guarantee the conditions of minimum cost and maximum production in a certain lathe operation. The adopted restrictions in the developed algorithms were the machine power available and the superficial roughness requirement of roughing and finishing operations. The implemented models generated significant results for different materials and situations of the cutting process analyzed. In addition, a study of detailed case using another approach to ratify the functioning and performance of the used model is presented.

Haber et al. (2009), has presented a strategy to compose a fuzzy controller in a net control system where a offline Simulated Annealing metaheuristic technique was applied, in order to obtain the best composition of the fuzzy controller, to regulate the drilling force in a cutting process, using a known maximum delay based on the ITAE (Integral Time Absolute Error) performance index, by means of adequate factors scale application, where the ITAE performance index is minimized. The control algorithm Simulated Annealing is linked to the

process through a fieldbus net that makes use of profibus net (communication system for that net type). Obtained results presented great convergence for the proposal strategy.

Yang et al. (2009), proposes an optimization methodology for parameters selection for electric discharges process. Experiments of regular cutting were performed in a recording head office machine under different process parameters conditions. The system model was created using Counter-Propagation Neural Network with experimental data. That system model was used simultaneously for maximizing the removal of the material rate as well as the roughness surface minimization using Simulated Annealing Scheme.

In this context, this paper presents the OPMP Tool - Optimization Parameters in Machining Process, a tool to aid in decision making that applies Simulated Annealing, a metaheuristic optimization technique, contribution margin and the Maximum Efficiency Interval (*MEI*) concepts. By means of these techniques it is possible to optimize the machining parameters involved in the process for determining the minimum cost cutting speed (V_{cmc}), maximum production cutting speed (V_{cmxp}) and minimum cost limit cutting speed (V_{cmcLim}) in order to minimize the variable cost per unit and the initial selling price. OPMP Tool has a graphical interface that allows the user good interaction with the system, providing benefits for a possible negotiation of the sale price and / or adjustments in the process.

2 THEORETICAL REVIEW

2.1 Cutting speed

The *MEI* (Maximum Efficiency Interval) already traditionally well-known for cutting process optimization (Rodrigues; Diniz; Coppini, 1987) is defined by the minimum cost cutting speed (V_{cmc}) and the maximum production cutting speed (V_{cmxp}). The minimum cost limit cutting speed (V_{cmcLim}) is strategic and it is always inside of *MEI*. It must be calculated when the tool edge change time tends to be very small and, consequently, the maximum production cutting speed tends to infinite, assuming a very big value, becoming larger than the maximum cutting speed that can be applied in machine. In this case, *MEI* can be adapted like *MEI_{mac}* (Maximum Efficiency Interval of the Machine) which is defined by the maximum cutting speed supported by the machine. For the adjusted cutting speed choice to the cutting parameters processes optimization, the shop floor scenario should be observed, once its restrictions or characteristics, could indicates what cutting speed should be used. Equations (1), (2) and (3) represent the cutting speeds V_{cmc} , V_{cmcLim} and V_{cmxp} (BAPTISTA; COPPINI, 2001; DURÁN; BARRIENTOS; COSALTER, 2007; SOUZA et al., 2006; COPPINI; BAPTISTA, 1998).

$$V_{cmc} = \left\{ \frac{K \cdot (S_h + S_m)}{60 \cdot (x-1) \cdot \left[K_{ft} + \left(\frac{S_h + S_m}{60} \right) \cdot T_{ft} \right]} \right\}^{\frac{1}{x}} \quad (1)$$

$$V_{cmcLim} = \left\{ \frac{K \cdot (S_h + S_m)}{60 \cdot (x-1) \cdot K_{ft}} \right\}^{\frac{1}{x}} \quad (2)$$

$$V_{cmax} = \sqrt[x]{\frac{K}{(x-1) \cdot T_{fi}}} \quad (3)$$

where:

K and x are the Taylor tool life equation coefficients; T_{fi} is the tool edge change time; S_h is the wages man; S_m is the machine cost and K_{fi} is the tool cost.

2.2 Contribution margin

Contribution margin per unit is the difference between the sale price and the variable cost of each unit produced; it is the value that each unit indeed brings to the company between its revenue and the cost that in fact provoked and that can be it imputed without mistake. It is possible to only use it in the variable costing, because in this situation the fixed costs are not appropriate to the product and they are computed integrally in the result (MARTINS, 2006).

According to Baptista et al. (2008), the fact of being used the approach of variable cost favors the manufacturing companies, particularly that one that use the cutting process, by establishing the direct costs involved in the workpiece production (material costs, tool and wage man and machine) and the initial sale price calculation (T_p), according to Eq. (4) described below.

$$T_p = \frac{VariableCosts}{[(1 - \%CM) * (1 - \%Taxes)]} \quad (4)$$

where:

T_p = initial sale price (\$);

Variable Costs = indirect material cost, wages, machine and tool costs (\$);

$\%CM$ = Percentage of desired Contribution Margin (net);

$\%Taxes$ = Percentage of sales rates (gross).

The calculation of the total machining cost per workpiece, assuming only the direct costs, is given through the Eq. (5), which is divided in three parts: C_1 , are the independent costs (cost of the man wage, material cost and machine wage during the unproductive time); C_2 , operation cost (including man wage and machine wage); and C_3 , tool cost (the cost of the tool properly more the tool change cost and the tool edge adjustment).

$$K_p = C_1 + C_2 + C_3 \quad (5)$$

Equation (6) describes the parameters in function of the cutting process where each term of the Equation represents C_1 , C_2 and C_3 in the Eq. (5).

$$K_p = (C_{tu} + C_m) + \left(\frac{t_c}{60} \cdot (S_h + S_m) \right) + \left[\left(\frac{t_c}{T} \right) \cdot C_{tool} + \frac{t_{ct}}{60} \cdot (S_h + S_m) \right] \quad (6)$$

where:

K_p = machining total cost per workpiece (\$);

C_{tu} = cost of unproductive time (\$);

C_m = material cost (\$);

C_{tool} = tool edge cost (\$/edge);

t_c = cutting time (min);

t_{ct} = tool edge change and tool adjustment time;
 S_h = man wage (\$/h);
 S_m = machine wage (\$/h);
 T = tool life (min).

Initial values of all parameters used in this work are described in the item 3.2.

3 METODOLOGY

3.1 Programming language

In this work the Microsoft Visual Basic® 6.0 programming language was used for OPMP Tool - Optimization Parameters in Machining Process development. A friendly graphical interface was implemented to allow the user to input the parameter values, such as taxes, contribution margin, parameters initial values to be optimized, and the percentage of variation of each one of them, as well.

The OPMP Tool presents the variable workpiece cost (K_p), the initial sale price (T_p), the value of the minimum cost cutting speed (V_{cmc}), of the maximum production cutting speed (V_{cmxp}), of the minimum cost limit cutting speed (V_{cmcLim}) and too much others values of the cutting parameters which will serve as decision making support.

3.2 Simulated Annealing

The Simulated Annealing (SA) algorithm is a stochastic version of well known Hill Climbing technique and it was described by Kirkpatrick et al. (1983). It is a local search method that accepts movements to worse states aiming to escape of local optimal values. Actually, SA is a metaheuristic method that imitates a thermodynamic process in which a metal is heated until its melting temperature and then is allowed to cool slowly so that its structure is frozen at the crystal configuration of lowest energy.

The pseudocode of SA is presented in the Fig. 1. In the main loop, a random movement is chosen for each iteration. If the new state is better than current state, it will be accepted. Otherwise, the new state will just be accepted with a certain probability smaller than 1. This probability is affected by the quality of movement, given by ΔE , and decreases according the temperature ($Temp$). So, worse movements have major probability to be accepted at the beginning of algorithm, when the temperature is high. After that, it becomes more improbable because the value of $Temp$ is small. In general, the quality of solution found by the SA algorithm depends on the cooling schedule adopted. The stop criterion of the algorithm is given by the value of the variable Max_Iter (RUSSEL; NORVING, 2004).

Simulated Annealing Procedure

Begin

Let s_0 the initial solution (randomly generated), s the solution represented by the current state, s' the solution represented by successor of the current state, s^* the best solution obtained until the moment, $Iter$ the counter of the number of iterations, Max_Iter the maximum number of iterations allowed, ΔE the variation between s and s' , P the probability to accept solutions worse than the current solution and $Temp$ the temperature that control the probability P .

$s \leftarrow s_0$

$s^* \leftarrow s_0$

$Iter \leftarrow 1$

$Max_Iter \leftarrow 10000$

```

While ( $Iter \leq Max\_Iter$ ) Do
   $Temp \leftarrow Max\_Iter - Iter$ 
  If  $Temp=0$  Then
    Return  $s^*$ 
  End-If
  Generates  $s'$  { randomly }
   $\Delta E \leftarrow s' - s$ 
  If  $\Delta E > 0$  Then
     $s \leftarrow s'$ 
  Else
     $P \leftarrow e^{\Delta E/Temp}$ 
     $s \leftarrow s'$  { with probability  $P$  }
  End-If
  If  $s > s^*$  Then
     $s^* \leftarrow s$ 
  End-If
   $Iter \leftarrow Iter + 1$ 
End-While
Return  $s^*$ 
End

```

Figure 1 – Pseudocode of *Simulated Annealing* Algorithm (Source authors)

The initial values of parameters used in this work are the following: $x = 4.1557$ and $K = 5.02 \times 10^{10}$ (Taylor's equation coefficients, symbolized by T in the Eq. 6); $S_h = \$ 15.00$; $C_m = \$ 4.3429$; $K_{fi} = \$ 3.28$; $T_{fi} = 0.58$ min.; $C_{lu} = \$ 2.05$; $S_m = \$ 40.00$. By means of these set of values is possible to calculate the minimum cost cutting speed (V_{cmc}), the minimum cost limit cutting speed (V_{cmcLim}), the maximum production cutting speed (V_{cmxp}), the variable workpiece cost (K_p) and the initial sale price (T_p) (BAPTISTA; LIBRANTZ; COPPINI, 2008).

For the optimization of the parameters in the machining process it was presented in this study, the objective function (OF) to be minimized is the variable workpiece cost (K_p), given by Eq. 5. The value of each optimization parameter is estimated according to interval established by the user (% allowed +/-), as demonstrated in the Fig. 2. For example, for the parameter labor cost (S_h), the considered interval is $S_{hmin} < S_h < S_{hmax}$, where $S_{hmin} = - 10\%$ of the reference value (S_h) and $S_{hmax} = + 10\%$ of the reference values (S_h).

The temperature $Temp$, one of the main parameters of *SA* algorithm, is started with a high value ($Temp=10,000^\circ\text{C}$), allowing movements to worse states with a probability P less than 1 and falling slowly at each iteration, until $Temp=1$. So, at each iteration, the algorithm tries to find a combination of optimization parameters that minimize the OF .

4 Results and discussion

Through OPMP Tool, for being a flexible tool, the variation of the percentage can be determined for each parameter, independently, aiding to find the best gain margin for the negotiation conditions of the sale price.

It is valid to stand out that, the percentage variation choice should respect the situation conditions in agreement with the scenario in which the productive process is involved.

Figure 2 shows the main screen of the OPMP Tool, in which the parameters values could be independently varied, showing the flexibility of the system.

OPMP Tool - Optimization Parameters in Machining Process

Input data

		% allowed(+/-)	
Workpiece diameter (d)	37,8	Labor costs (Sh)	15,00
Cutting length (lf)	552,46	Material costs (Cm)	4,3429
Feed rate (f)	0,25	Tool edge cost (Kft)	3,28
Material constant (k)	50200000000	Tool change time (Tft)	0,58
Taylor's coefficient (x)	4,1557	Unproductive time cost (Ctu)	2,05
Contribution margin	50	Machine costs (Sm)	40,00
Taxes	34,65		

Estimated values

		variation(%)
Labor costs (Sh)	15	0
Material costs (Cm)	3,909	-9,99
Tool edge cost (Kft)	3,0976	-5,56
Tool change time (Tft)	0,5755	-0,78
Unproductive time cost (Ctu)	1,9706	-3,87
Machine costs (Sm)	40	0

Buttons: Restore initial values, Calculate, Save data, Clear values, Exit

Final results

	Initial values	Optimized values	variation(%)
Variable costs (Kp)	7,9591	7,427	-6,69
Target price (Tp)	24,3584	22,7299	-6,69
Minimum cost cutting speed (Vcmc)	202,2638	204,7206	1,21
Maximum production cutting speed (Vcmxp)	324,9183	325,5279	0,19
Minimum cost limit cutting speed (VcmLim)	209,7092	212,6164	1,39

Figure 2 – OPMP Tool Main Window

Tables 1, 2 and 3 demonstrate the simulations results obtained after applying the OPMP Tool resources, varying $\pm 10\%$ each parameter independently, to determine the influence of each one of them in the variable cost for piece, both in the isolated and global ways.

Table 1 – Influence of each parameter in the variable cost for piece

Parameters	Values	Variation (%)	Value	K _p Variation (%)
S _h	13.5041	-9.97	7.9252	-0.43
C _m	3.9087	-10	7.5249	-5.46
K _{ft}	2.9524	-9.99	7.9256	-0.42
T _{ft}	0.5224	-9.93	7.9538	-0.07
C _{tu}	1.845	-10	7.7541	-2.58
S _m	36.0026	-9.99	7.8682	-1.14

In accordance with Baptista et al. (2008), these parameters were separated in two groups: the Group 1 constituted with the parameters that have smaller influence in the variable cost constitution per piece (S_h, K_{ft}, T_{ft} and S_m) and the Group 2, which is composed by the parameters that have a significant influence in the variable cost composition per piece (C_m, C_{tu}). Table 2 shows the groups and their respective parameters.

Table 2 – Parameters Group according to their influence on the variable cost per piece

Group 1: $S_h + K_{ft} + T_{ft} + S_m$			Group 2: $C_{tu} + C_m$		
Parameters	Values	Variation (%)	Parameters	Values	Variation (%)
S_h	13.514	-9.91	C_{tu}	3.9091	-9.99
K_{ft}	2.9771	-9.23	C_m	1.8455	-9.98
T_{ft}	0.5593	-3.57	K_p	7.3208	-8.02
S_m	36.1258	-9.69	-	-	-
K_p	7.8064	-1.92	-	-	-

Best results of the variable cost per piece minimization, when compared with the $\pm 10\%$ variation, were reached in the optimization of all the parameters considered together and they are presented in the Table 3, with the initials values of the respective parameters.

Table 3 – Results of the parameters influence

Parameters	Initial Value	+ or - 10%	
		Final Value	Variation (%)
S_h	15.00	13.528	-9.81
C_m	4.3429	3.9148	-9.86
K_{ft}	3.28	2.9725	-9.37
T_{ft}	0.58	0.5758	-0.72
C_{tu}	2.05	1.856	-9.46
S_m	40.00	36.4542	-8.86
K_p	7.9591	7.1929	-9.63
T_p	24.3584	22.0135	-9.63
V_{cmc}	202.2638	202.4294	0.08
V_{cmxp}	324.9183	325.487	0.18
V_{cmcLim}	209.7092	209.8492	0.07

Figure 3 shows the results reported in the Table 1 and the best result for K_p that was achieved when all parameters are optimized at the same time (Table 3).




Figure 3 - Variation of the parameters considered individually and together, and its influence on the variable cost per piece (K_p)

In the results obtained in this study, which seeks the optimization of the parameters involved in the cutting process, specifically in a lathe operation and, consequently to obtain the smallest variable cost per piece and suggested initial price of sale, it is observed that, in spite of having a different approach, they are close to the values obtained by Baptista et al. (2008). These results allow observing that the procedure used by Baptista et al. (2008), which is exhaustive with Microsoft Excel® spread sheets, was believed and, consequently, it confirms the adaptation of the Simulated Annealing in Operational Research applications for cutting processes optimization.

5 Conclusion

In this work the results obtained with the computational system, OPMP Tool, for cutting parameters optimization were presented, approaching of the contribution margin principles and the Simulated Annealing technique (SA), which shows good results in this kind of optimization problem resolution.

Values estimated for the cutting speeds could be used as reference for optimization of the cutting processes, because, in a shop floor atmosphere restrictions characteristic they can influence in the choice, as a neck machine, for example.

It is important to stand out that the percentage variation of the parameters should be chosen arbitrarily by the user, with good sense and in agreement with the situation involved in each productive cutting process.

In addition, the OPMP Tool - Optimization Parameters in Machining Process, shows itself as a flexible application, with a friendly graphical interface that allows the user good interaction with the system, constituting, this way, an alternative tool in decision making support for the initial sale formation.

Acknowledgements

The authors would like to thank the Universidade Nove de Julho – Uninove and Conselho Nacional de Pesquisa CNPq for financial support.

REFERENCES

- Baptista, E. A., Coppini, N. L., 2001. Maximizando o Lucro: Otimizando os processos de usinagem com o Auxílio de Sistema Especialista. In XXI Encontro Nacional de Engenharia de Produção - ENEGEPE e VI International Conference of Industrial Engineering and Operations Management – ICIEOM, 2001 : ABEPRO - Associação Brasileira de Engenharia de Produção, 2001. vol. 1, pp. 225-232.
- Baptista, E. A., Librantz, A. F. H., Coppini, N. L., 2008. Analyses of the parameters influence on the price determination based on the contribution margin concept for cutting process. In: International Conference on Advanced Manufacturing Systems and Technology, 2008 : SpringerWienNewYork, 2008. vol. 1. pp. 27-34.
- Batalha, M. O. (Org.), 2008. Introdução à Engenharia de Produção. Rio de Janeiro: Elsevier Editora.
- Chaves, A. A., Biajoli, F. L., Mine, O. M., Souza, M. J. F., 2004. Modelagens exata e heurística para resolução de uma generalização do problema do caixeiro viajante. In: XXXVI Simpósio Brasileiro de Pesquisa Operacional, 2004 : SOBRAPO, 2004. pp. 1367-1378.
- Coppini, N. L., Baptista, E. A., 1998. Alternativas de otimização dos parâmetros de corte para cenários de fabricação em usinagem. In: Encontro Nacional de Engenharia de Produção, 1998.

- Durán, O., Barrientos, R., & Cosalter, L. A., 2007. Aplicación de algoritmos genéticos y ecuación expandida de Taylor en la obtención del Intervalo de Máxima Eficiencia. In: IV Congresso Brasileiro de Engenharia de Fabricação - COBEF, 2007
- Haber, R. E., Haber, R. H., Jiménez, A., Galán, R., 2009. An optimal fuzzy control system in a network environment based on simulated annealing. An application to a drilling process. *Applied Soft Computing*, vol. 9, pp. 889-895, 2009.
- Kirkpatrick, S., Gelatti, C. D., Vecchi, M. P., 1983. Optimization by Simulated Annealing. *Science*, vol. 220, n. 4598, pp. 671-680, 1983.
- Martins, E., 2006. Contabilidade de Custos. São Paulo, SP. : Editora Atlas, 9ª ed.
- Rodrigues, A. C. S., Diniz, A. E., Coppini, N. L., 1987. Análise das condições operacionais visando a obtenção das condições de usinagem otimizadas. In: 7º SCNB - Seminário Comando Numérico Brasil, 1987.
- Russel, S., Norving, P., 2004. Inteligência Artificial. Rio de Janeiro: Editora Campus.
- Souza, F. B. de, Baptista, E. A., Grivol, R. F., Franchii, R. H. O. L., Coppini, N. L., 2006. Otimização de processos de usinagem: uma abordagem baseada na teoria das restrições. In: XXVI ENEGEP - Encontro Nacional de Engenharia de Produção, 2006.
- Yang, S, Srinivas, J., Mohan, S, Lee, D., Balaji, S., 2009. Optimization of electric discharge machining using simulated annealing. *Journal of Materials Processing Technology*, vol. 209, pp. 4471–4475, 2009.

**ANEXO D - THE IDLENESS ANALYSIS DURING MACHINING: SEARCHING FOR
BEST ORGANIZATIONAL RESULTS**

THE IDLENESS ANALYSIS DURING MACHINING: SEARCHING FOR BEST ORGANIZATIONAL RESULTS

Nivaldo Lemos Coppini

André Felipe Henriques Librantz

ncoppini@uninove.br

librantz@uninove.br

Uninove– Programa de Pós-Graduação em Engenharia de Produção da Universidade Nove de Julho, Avenida Francisco Matarazzo-612, 05001-100, São Paulo, SP, Brasil.

Alexandre Augusto Martins Carvalho

aa01mc@yahoo.com.br

Unicamp- Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas, Rua Mendeleiev- s/n, 13083-970, Campinas, SP, Brasil.

Rita Rodorigo

Aparecida de Fátima Castello Rosa

rita.r@terra.com.br

afc.rosa@uninove.edu.br

Uninove– Programa de Pós-Graduação em Engenharia de Produção da Universidade Nove de Julho, Avenida Francisco Matarazzo-612, 05001-100, São Paulo, SP, Brasil.

Abstract. *The correct parameterization of technical data, operational understanding and analysis of manufacturing process related to the installed capacity and consequently of their idleness, allow detecting better financial results and create the opportunity to establish competitive strategies in the market. With the help of management techniques such as TOC (Theory of Constraints), contribution margin, industrial costs, operational research, planning and scheduling, and cutting process technology, the present paper is to analyzes the idleness eventually but very often in any production process, particularly in the machining process industrial sector. The focus is to search the optimization of the fixed costs, by minimizing the idleness. The purpose of this work is to establish a friendly computerized procedure to identify and to store machine and operator idleness during cutting process operations in industries of this sector. After that and in continuing the present work, the authors will develop a procedure to rationalize the identified idleness, and how to manage its use to improve the production and/or the profit. As the respective costs of the identified idleness are fixed costs, their rationalization is a new strategy procedure to improve productivity and profit. Although the scenario of this work is the cutting process environment, its results can be extended to other productive sectors.*

Keywords: *Operational Research, Cutting Process, Industrial Costs, Contribution Margin, Theory of Constraints.*

1 INTRODUCTION

With the development of business policies and strategies, the apparent maturity of the market between buyers and sellers, the strategy to gain market price is higher and more common each day. The issue of product quality is no longer a strategy, but a basic requirement for the consumer acceptance. The manufacturing strategies, therefore, has turned the companies attention to gain of market, of sustainability of your product and of your brand. They are looking for the consolidation of their image inside and outside the sector of activity they belong.

Organizational skills of each company are specific. Each one uses different ways to identify their resources and transform them into competitive advantage. It should be emphasized that often the process of converting resources into organizational skills are not planned and designed, but occur in the competitive scenario and move dynamically.

In recent years the market becomes more and more active. This is due to an accelerated rate of technological updates, rapid changes of consumer preferences and changes related to demand and prices. Furthermore, globalization also contributes a lot with these factors in the market. Technological change is one of the responsibilities in developing products for easy manufacturing. The efficiency in the placement of new products to market is an important source of competitive advantage (Cherubini, 2000).

Besides, the contribution margin has equal meaning to the term gross profit on sales. This indicates how the sales, for the company, how to pay their fixed costs and generate profit. In whatever sector, industry, trade or services, it is perfectly possible to measure the value and percentage of their contribution margin.

Understanding the influence of the degree of contribution to price formation is to understand how the company should position itself to achieve its goal of maximizing financial performance and set strategic behavior without undermining its financial health. Thus, study and analyze the contribution margin in a negotiation is a competitive advantage that the company has in the formation of price and at the time of negotiation (MARTINS, 2006).

However, it is necessary to consider that result optimization does not depend solely on the margin of contribution. It depends also on optimization variables of material resources, human resources, structure and correct selection and parameterization of operational conditions. The maximum efficiency of a company is not possible to be reached based only in an isolated optimum part of it (Goldratt and Cox, 1986). Thus, the maximum degree of development of a company will have, as a limit, the maximum of optimization for one of its activities, in case it is not accomplished the global evaluation of whole chain of activities. The procedure is that a restrictive condition exists in all organizations and their understanding and control may be key factor when it is an aggressive strategy to target market.

The purpose of this work is to establish a friendly computational rized procedure to identify and to store machine tool and operator idleness during cutting process operations in industries of this sector. Also the authors develop a procedure to rationalize the identified idleness, and how to manage its use to improve the production and/or the profit.

2 THEORETICAL BASES

2.1. The concept of contribution margin

The marginal contribution or contribution margin may be calculated both considering the total amount of workpiece to be cutting or considering only one of them. Contribution

margin, as revealed by its name, is intended to show how much remains of the revenue from direct sales after deducting variable costs and expenditures.

According to Martins (2006), contribution margin may be calculated by equation (1):

$$CM = AS - VC - VE \quad (1)$$

where:

CM = Contribution Margin;

AS = Amount of Sale;

VC = Variable Cost;

VE = Variable Expenditure.

It is possible to understand, by following the equation (1) it is possible to understand that greater profits to the company come from those products that achieve higher contribution margins than others.

Martins (2006) believes that the method of margin contribution is important for decision making because:

- the direct cost clearly identifies the relationship cost-volume-profit, this essential information for planning of profitability;
- the profit of a period is not affected by fluctuations caused by higher or lower absorption of fixed costs to products. Under the direct costing, the results only respond by changes in sales;
- the statements of income and manufacturing costs generated by the direct cost system are more understandable and easier to be followed by thinking of administrators;
- the impact of fixed costs on profits is better made, because the value of the cost for the period, is already in the statement of income;
- the marginal contribution facilitates the analysis of the performance of products, territories, the types of customers and other segments of the company, but the results are obscured by common ownership of fixed costs;
- direct costing facilitates the immediate preparation of the instruments of control, such as standard costs, flexible budgets and the cost-volume-profit;
- the direct cost is closely related to the concepts of out costs and financial costs, that pass through box. This means that your results are more effective for the understanding of executives in decision-making.

With the information from a contribution margin of the product or mix (set) of products is possible:

- reduce the period of payment;
- offer products with higher margin contribution;
- increase the volume of purchasing by decreasing the effect of fixed costs;
- undertake the collection of charges for freight.

The use of contribution margin concept to analyze the revenue can generate a reference that can be point out how much one customer contributes to the company and consequently, how relevant it is.

Atkinson et.al. (2000:192-195) state that "the difference between price and variable cost per unit is called unit contribution margin." So, each workpiece produced means that a

financial improvement will be reflected on the revenue. Consequently, when some idleness is detected, it can be considered a loss. The use of such that idleness to produce a eventual number of extra workpieces will generate financial incomes possible to have this sale price predicted by unit contribution margin concept. In this case, it will be better to choose extra products based on their larger contribution margin.

2.2 Theory of constraints

Rahman(1998) states that whole system must have at least one restriction. If this is not true, then the system should have real profit limit. Therefore, the restriction is something that limits the system to achieve high performance versus the target. The existence of restrictions represents opportunities for improvement. As conceived originally thought, the theory of constraints (TOC) shows the restrictions as something positive, not negative. Restrictions determine system performance. A gradual increase in the restriction of the system will improve its performance.

Gupta (2002) provides a sequence of operations and continuous improvement for TOC. As follows:

- to identify the (s) Restriction (s) of the system;
- to decide how to exploit (s) Restriction (s) of the system;
- to subordinate everything else to the above decision;
- to raise (s) Restriction (s) of the system;
- to return to the first step, but not to let inertia become the constraint of the system.

According to Goldratt and Cox (1986), in order to analyse to examine the impact of a local action and profit (L) and return on investment (SRI), the TOC makes use of three measures of performance:

- gain(G): Index by which the system generates money through sales;
- investment (I): all the money the system invests in purchasing things that you want to sell;
- operating expenditure (THE): all the money the system spends in turning investment gain.

Corbett (2005) tackles, measured as gain by equation (2).

$$G_u = P - CVT \quad (2)$$

where:

G_u = Gain unit of product;
 P = Sales price of the product;
 CVT = Total Variable Cost.

To determine the total gain that can lead to a product company, one should you must multiply the gain per unit of product by the quantity sold of that product, as equation (3).

$$G_T = G_u \times q \quad (3)$$

where:

GT = Total Gain;

q = Quantity sold in a given period.

Guerreiro and Pacciez (2001) reported that “the concept of gain from the theory of constraints corresponds to the concept of contribution margin in cost accounting system that adopts the method of direct or variable cost”.

“When one takes a decision based on TOC, it is needed to measure the impact in the gain, in spending and investment of the company” (Corbett, 1997).

3 METHODOLOGY

It was employed exploratory method followed by an application example to verify the efficiency of the computational procedure specially developed to identify, store and manage the idleness time parameters of the machine tools and their operators.

4 DEVELOPMENT AND USE OF THE PROPOSED PROCEDURE

The statements bases to develop and use the proposed procedure come from the theory of constraints presented in the item 2 above.

The proposed procedure consists in use of parameters from the industrial cutting process planning and production planning sectors. These parameters are:

- total production time available for each machine involved in the process [min];
- total production cutting time/workpiece - take from the planning [min];
- bottleneck or idle time of each machine tool [min];
- workpieces batches scheduled to be cut during a work day or any other period to be considered under analysis;
- total production cutting time for all the workpieces of each batch; [min]

These parameters can be correlated in accordance with Eq (4).

$$t_{bi} = t_{pt} - (t_t) \times z \quad (4)$$

where:

t_{pt} = total production time available [min];

t_t = total production cutting time [min]

t_{bi} = bottleneck/idle time [min]

z = number of workpieces per batch scheduled.

Based on the Eq (4) it was created a routine to bottleneck and/or idleness calculation explained by theory of constraints. In this work the Microsoft Visual Basic[®] programming language was used for the development of this interface. The main screen is shown in figure (1).

Figure 1- Idle time calculation interface

Thorough of this interface, the user of that interface can freely input introduce all the data from the production planning and process planning to verify the presence of bottle neck and/or idleness for all the M machine tools and workpieces considered to be analyzed in your industry shop floor.

The first line in the top of the interface (highlighted in yellow) is prepared to receive the total production time available t_{pt} for each machine tool. t_{pt} is fixed by previously planning that consider the number of hours in a day work hours and non productive activities, as: predictive maintenance and others.

The second line in the top of the interface automatically calculates the $(t_i \times z)$ for each workpiece and machine tool involved and the third one gives automatically their bottleneck/Idleness time t_{bi} .

The first column in the bottom part of the interface (highlighted in yellow) is prepared to receive the number of workpieces z to be cut in each machine tool group. This will be inputted by the user based on the master production system. The seven blanks in white defined by lines and columns also in the bottom part of the interface, respectively reserved to products and machine tools respectively, are prepared to receive the total production cutting time t_i . After imputing this information time, the user is not more allowed to change them, because they come from the data base with these times previously determined by process planning. After that, the user will be free to make changes to identify the bottlenecks and how is the distribution of the idleness among the machine tools. Following Slack (2002), the mix of products affects the productivity time and consequently the idle time. So, the user can change the mix of production looking for satisfy the number of demanded workpiece to be produced. At this time all the idleness will be highlighted in green and the bottlenecks in red on the third line of the top part of the interface as showed in figure (2). From the number of workpieces that cause the bottlenecks it must be considered one less. For instance: in figure (2) for the machine one and product 3 it is found a bottleneck when the number of workpiece was 23. Indeed, as a matter of fact it will be possible to cut only 22 workpieces.

Machine Data Input [min]

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Total Production Time Available (tpt)	480	480	480	480	480	480	480	480	480	480
Total Production Cutting Time (tt)	486.50	287.70	107.80	86.90	150.30	480.40	466.80	79.40	54.00	505.00
Bottleneck/Idleness time (tb)	6.50	192.30	372.20	393.10	329.70	0.40	13.20	400.60	426.00	25.00

Total Production Cutting Time/Machine Inputs [min] and Number of Workpieces z

z	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Product 1	8	10.6		0.7	1	0.6				
Product 2	23	0.3	4.1	1.5	1.5	1.8	11.6		0.8	1.9
Product 3	23	11	5.2	1.5		2.9		2.6	2.2	0.9
Product 4	18	7.7	4.1	0.7	2.6	1.9	11.6	22.3	1	1.8
Product 5	8	0.4						0.7	1	0.3
Product 6	4									107
Product 7	1			26.2					2.8	0.8
Ex.Prod. 1										
Ex.Prod. 2										
Ex.Prod. 3										

Buttons: Restore Initial Values, Calculate, Save Data, Clear Form, Exit

Figures 2- Bottleneck and idleness after the input of number of pieces to be cut during one workday

The three lines in blue in the bottom of the interface are reserved to input extra workpieces to specifically rationalize the idleness identified before.

Finally, it can be seen in the right side of the interface in figure (1) or (2), five buttons to operate the routine and to have how to calculate all the parameters.

At this time it is very important to remember that all the idle time detected by the proposed procedure and showed in figure (2) is already paid and they will be losses in case they are not used. So, the idleness must be used to cut extra workpieces.

In the flow chart of figure (3) the procedure concept is illustrated and there, both the concepts of idleness and contribution margin are applied together. The flow chart of the figure (3) contains the following guidelines:

- firstly the user must select extra products to be cut using the idle resource available and choose a number of them to transform the idleness in bottleneck condition considering always those products with higher contribution margin. When one bottleneck resource is exhausted, those of lower margin contribution should be, if possible, discarded.
- among the non restrictive resources, considering that they are already "paid" and their capacity is not in use, it is suggested to use them for extra workpieces production, as mentioned before. The advantage is that any sell price of these workpieces, over the raw material, will be a financial income to the company.
- if the resource use is restricted due to seasonal factors in the market, while it last, the company's segment of machining must consider the possibility of working with the conditions of minimum cost in the manufacture of parts.

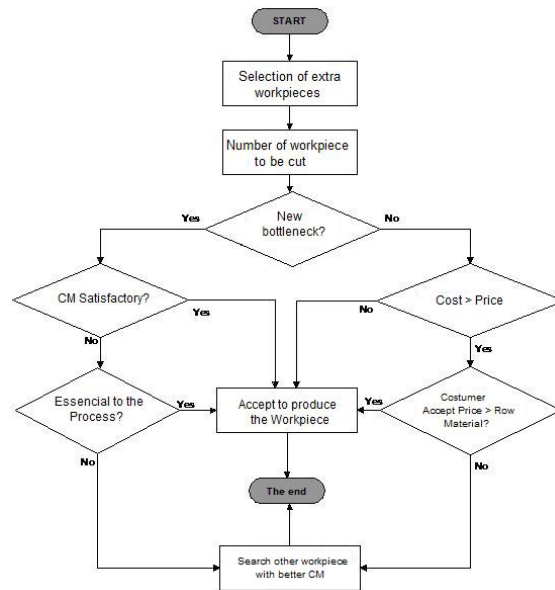


Figure 3- Flow chart showing the procedure concept

Following these guidelines is possible to reach the maximum use of idleness as showed in Figure (4). Even so, it can be seen that was not possible, at least for this simulation example, to take profit over all the idleness.

Figure (5) shows the ideal interface as a limit of the production optimization and use of the total idleness. As a matter of fact, this condition probably never is going to occur and it is only considered here as a reinforcement of the proposed procedure. Anyway, in the simulation example, only three lines were where predicted to extra workpieces. The interface must be constructed following the actual number of machine tools and products (including that considered here as extra products).

Interface for Bottleneck and idleness Determination

Machine Data Input [min]										
	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Total Production Time Available (tpt)	480	480	480	480	480	480	480	480	480	480
Total Production Cutting Time (tt)	486,50	483,80	481,20	481,70	291,70	480,40	487,20	204,80	259,20	505,00
Bottleneck/Idleness time (tbi)	6,50	3,00	1,20	1,70	188,30	0,40	7,20	275,20	220,80	25,00

Total Production Cutting Time/Machine Inputs [min] and Number of Workpieces z										
z	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Product 1	8	10,6		0,7	1	0,6				
Product 2	23	0,3	4,1	1,5	1,5	1,8	11,6		0,8	1,9
Product 3	23	11	5,2	1,5		2,9		2,6	2,2	0,9
Product 4	18	7,7	4,1	0,7	2,6	1,9	11,6	22,3	1	1,8
Product 5	8	0,4						0,7	1	0,3
Product 6	4									107
Product 7	1			26,2				2,8	0,8	
Ex.Prod. 1	37		5,3	2,8		3,7				
Ex.Prod. 2	3				13,8	1,5		6,8		
Ex.Prod. 3	38			7,1	9,3			3,3	5,4	

Buttons: Restore Initial Values, Calculate, Save Data, Clear Form, Exit

Figure 4- Inclusion of extra workpieces to take profit of all the idleness possible

Interface for Bottleneck and idleness Determination

Machine Data Input [min]										
	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Total Production Time Available (tpt)	480	480	480	480	480	480	480	480	480	480
Total Production Cutting Time (tt)	486,50	483,80	481,20	481,70	513,70	480,40	487,20	482,20	483,40	505,00
Bottleneck/Idleness time (tbi)	6,50	3,80	1,20	1,70	33,70	0,40	7,20	2,20	3,40	25,00

Total Production Cutting Time/Machine Inputs [min] and Number of Workpieces z										
z	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
Product 1	8	10,6		0,7	1	0,6				
Product 2	23	0,3	4,1	1,5	1,5	1,8	11,6		0,8	1,9
Product 3	23	11	5,2	1,5		2,9		2,6	2,2	0,9
Product 4	18	7,7	4,1	0,7	2,6	1,9	11,6	22,3	1	1,8
Product 5	8	0,4						0,7	1	0,3
Product 6	4									107
Product 7	1		26,2					2,8	0,8	
Ex.Prod. 1	37		5,3	2,8		9,7				
Ex.Prod. 2	3			13,8	1,5		6,8			
Ex.Prod. 3	38			7,1	9,3			10,6	11,3	

Buttons: Restore Initial Values, Calculate, Save Data, Clear Form, Exit

Figure 5- Use of the totality of the idleness - hypothetical ideal

5 FINAL CONSIDERATIONS

It was proposed a friendly computational procedure developed specifically to be applied in cutting process industries which aim to transform raw materials into finished products.

The procedure can detect, store and manage the not restrictive resources (idleness).

The procedure guides the organization's ability to develop, within their capabilities, business or products that do not have the need to work in resource limited, thereby providing a direct profit of the value above the variable cost raw material, since these costs were, anyway, absorbed by the company.

This procedure has a systematic which provides the industry manager to obtain the peak of the staff and machine resources that are already being paid by the company. Uses traditional concepts: the contribution margin, cost, pricing, analysis of manufacturing capabilities, idleness analysis, that interrelate with the objective of achieving operational excellence and better market positioning.

Factors of production inefficiency, presence of unused productive capacity are common to be found within the segment of cutting process which justifies the advantage of using the proposed procedure.

As a condition for deployment of the procedure there is the requirement of knowledge of the process and the use restrictive utilization. Therefore, it is possible to assess the present idle capacity and how much financial value could be added to the billing.

The procedure is interesting due to the resources needed to generate a profit are in industrial organizations. But are not due to the fact remain "masked" by the system. One of the functions of this procedure is to reveal these resources to use them effectively.

The proposal is the restriction on commercial terms where the contribution margin not only to establish parameters for the financial viability of the business, these situations faced

by the commercial department with products where there are dependencies of other products, popularly known as married sales.

The concept of contribution margin, included in the proposed procedure, can position the company in which one (s) product (s) should be intensified aiming the business of the criterion of maximization profit.

The procedure interface of idleness identification shows the manufacturing processes, the degree of occupation of each machine tool and the opportunity to gain work in products that contain the gap, by maximizing direct and indirect costs of providing analysis of market place the sales and marketing department. What can be a great competitive advantage for the enterprise.

6 BIBLIOGRAPHY

ATKINSON, ANTHONY.ET.AL. Contabilidade gerencial. São Paulo, Atlas, 2000.

CARVALHO, A.A.M. Modelo de Formação de Preço para Peças Usinadas Baseado no Conceito de Margem de Contribuição. Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção, da Faculdade de Engenharia, Arquitetura e Urbanismo, da Universidade Metodista de Piracicaba – UNIMEP, 2007.

CHERUBIN, P. F. Estratégias de Negócio em Software-Houses. Revista FAE, Curitiba, v. 3, n 2, p. 17-29, mai/ago. 2000.

CORBETT, N.T. Bússola Financeira: O processo decisório da Teoria das Restrições.1^a ed. São Paulo: Nobel, 2005, 208p.

CORBETT, N. T. Contabilidade de ganhos: a nova contabilidade gerencial de acordo com a Teoria das Restrições. São Paulo: Nobel, 1997.

COPPINI, N.L; BAPTISTA, E.A. Cutting process optimization: pratical procedure. In: AMST. Advanced manufacturing systems and techonology proceedings, Udine, Anais... 2005.

COPPINI, N.L; DINIZ, A; MARCONDES, F. Tecnologia da usinagem dos materiais. São Paulo, Artliber, 5 ed., 2006.

GOLDRATT, E.M.; COX, J. A meta: um processo de aprimoramento contínuo. São Paulo: IMAM, 1986.

GUERREIRO, R; PACCEZ, J. D. Controladoria: uma abordagem da gestão econômica. In: CATELLI, A. (coord.) 2. ed. São Paulo: Atlas, 2001.

GUPTA, M; KO, H; MIN, H. TOC-based performance measures and focusing steps in a jobshop manufacturing environment. International Journal of Production Research, v. 40, n. 4, p. 907-930, 2002a.

MARTINS, ELISEU. Contabilidade de custos. São Paulo, Atlas, 9 ed., 2006.

MENG, Q.; ARSECULARANTNE, J. A.; MATHEW, P. Calculation of optimum cutting conditions for turning operations using a machining theory. International Journal of machine tools & manufacture: Design, research and application, v. 40, n. 12, p. 1709-1733, Sept. 2000.

RAHMAN, S. Theory of constraints: A review of philosophy and its applications. International Journal of Operations & Production Management, v. 18 n. 4, p. 336-355, 1998.