

TESE DE DOUTORADO

**IMPLEMENTAÇÃO DE MÉTODO HÍBRIDO PARA  
DETERMINAÇÃO DE PARÂMETROS DE ENCRUAMENTO**

CRISTIANO PEREIRA DA SILVA

BRASÍLIA/DF, MARÇO DE 2024

**UNIVERSIDADE DE BRASÍLIA**

FACULDADE DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA MECÂNICA

**UNIVERSIDADE DE BRASÍLIA**  
**FACULDADE DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**TESE DE DOUTORADO EM CIÊNCIAS MECÂNICAS**

**IMPLEMENTAÇÃO DE MÉTODO HÍBRIDO PARA DETERMINAÇÃO  
DE PARÂMETROS DE ENCRUAMENTO**

**CRISTIANO PEREIRA DA SILVA**

**ORIENTADOR: PROF. DR. LUCIVAL MALCHER**

**BRASÍLIA/DF - 2024**

**UNIVERSIDADE DE BRASÍLIA**  
**FACULDADE DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**TESE DE DOUTORADO**

**IMPLEMENTAÇÃO DE MÉTODO HÍBRIDO PARA DETERMINAÇÃO  
DE PARÂMETROS DE ENCRUAMENTO**

**CRISTIANO PEREIRA DA SILVA**

TESE DE DOUTORADO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA MECÂNICA DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA (UNB) COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS MECÂNICAS.

BANCA EXAMINADORA:

PROF. LUCIVAL MALCHER, DOUTOR (ENM/FT/UNB)  
(ORIENTADOR)

PROF. RUI RICARDO LOUREIRO AMARAL, DOUTOR (INEGI/UP – PORTUGAL)  
(EXAMINADOR EXTERNO 1)

PROF. RAPHAEL ARAÚJO CARDOSO, DOUTOR (UFRN)  
(EXAMINADOR EXTERNO 2)

PROFA. DÉBORAH DE OLIVEIRA, DOUTORA (ENM/FT/UNB)  
(EXAMINADORA INTERNA)

PROF. JORGE LUIZ DE ALMEIDA FERREIRA, DOUTOR (ENM/FT/UNB)  
(EXAMINADOR SUPLENTE)

**BRASÍLIA/DF - 2024**

## FICHA CATALOGRÁFICA

SILVA, CRISTIANO PEREIRA DA

Implementação de Método Híbrido para determinação de parâmetros de encruamento. 156 p., 210x 297 mm (ENM/FT/UnB, Doutor, Ciências Mecânicas, 2024). Tese de doutorado – Universidade de Brasília, Faculdade de Tecnologia, Departamento de Engenharia Mecânica.

- |                       |                                  |
|-----------------------|----------------------------------|
| 1. Algoritmo Genético | 2. Método de Levenberg-Marquardt |
| 3. Modelo de Gurson   | 4. Manufatura Aditiva            |
| I. ENM/FT/UnB         | II. Título (série)               |

## REFERÊNCIA BIBLIOGRÁFICA

SILVA, C. P. (2024). Implementação de Método Híbrido para determinação de parâmetros de encruamento. Tese de doutorado em Ciências Mecânicas. Publicação ENM-DM 2024, Departamento de Engenharia Mecânica, Universidade de Brasília, DF, 156 p.

## CESSÃO DE DIREITO

AUTOR: Cristiano Pereira da Silva

TÍTULO: Implementação de Método Híbrido para determinação de parâmetros de encruamento.

GRAU: Doutor ANO: 2024

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese de doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta tese de doutorado pode ser reproduzida sem autorização por escrito do autor.

Cristiano Pereira da Silva

Correio Eletrônico: cristianopereiradf@gmail.com

## AGRADECIMENTOS

A realização deste trabalho não seria possível sem a colaboração e o apoio de pessoas especiais, às quais dedico **meus sinceros agradecimentos**:

Aos meus pais, por todo incentivo e carinho. Por sempre terem acreditado em mim, e, principalmente, por seu amor incondicional. Desde muito cedo incentivaram e apoiaram minha paixão pelos estudos e pela Educação. Hoje, olhando lá do céu, acredito estarem unidos e felizes;

A minha irmã, minha grande melhor amiga;

*In memoriam*, a minha avó Benevenuta Barbosa Coelho, minhas saudades;

*In memoriam*, a minha companheira Elen de Sousa Gonzaga, meu grande amor, minhas saudades;

Aos (às) professores(as) do Curso de Doutorado, pelos fundamentos teóricos, reflexões e amadurecimento como profissional e como ser humano;

Aos meus amigos e amigas, por auxiliarem no processo de elaboração deste trabalho apresentando sugestões e me apoiando nos momentos mais difíceis;

Agradeço, especialmente, a meu orientador Prof. Dr. Lucival Malcher, cuja atenção, paciência, dedicação e colaboração inestimável me acompanharam desde os primeiros momentos do curso de doutorado;

Aos professores participantes da banca de qualificação e de defesa de tese pelas correções e sugestões.

Agradeço, finalmente, a todos que auxiliaram, direta ou indiretamente, no desenvolvimento e na revisão deste trabalho.

Cristiano Pereira da Silva

## RESUMO

O processo de identificação de parâmetros utilizando variadas metodologias de otimização tem se mostrado uma ferramenta importante na determinação de parâmetros de modelos constitutivos característicos de materiais. O grau de complexidade da relação constitutiva do material é um fator determinante na escolha do método de otimização, uma vez que a função objetivo pode apresentar muitos mínimos ou máximos locais. No presente trabalho, em uma primeira etapa, desenvolveu-se rotinas computacionais na linguagem PYTHON que envolveram um algoritmo evolutivo, o Algoritmo Genético (GA), e um algoritmo baseado em gradiente, o Algoritmo de Levenberg-Marquardt Dividido (LMD), e propôs-se um modelo híbrido que unisse a robustez de busca do GA e a velocidade e precisão do Algoritmo LMD. As rotinas desenvolvidas foram testadas para diferentes funções objetivo obtendo-se soluções viáveis após um número reduzido de iterações. Em uma segunda etapa, utilizando-se os resultados obtidos via o teste de tração dos aços 4340 normalizado e recozido e a liga 1524 U2, inicialmente, desenvolveu-se uma rotina para automatizar a busca por características do material como o módulo de elasticidade, as tensões inicial de escoamento, máxima e de ruptura, além de propriedades como resiliência e tenacidade e, por fim, aplicou-se as rotinas idealizadas, anteriormente, na determinação de parâmetros de encruamento segundo o modelo de Kleiner e Ponthot (2003). O ponto crítico verificado foi o método dos Elementos Finitos, aqui representado pelo sistema HYPLAS. Um sistema acadêmico útil no desenvolvimento do método híbrido, mas que adicionou a cada iteração do GA e do Algoritmo LMD diversos segundos de processamento. Ao final do trabalho, em uma terceira etapa, foi realizado um estudo de caso envolvendo outro modelo constitutivo. Buscou-se verificar a aplicabilidade do modelo de materiais porosos de Gurson (1977) na caracterização das propriedades mecânicas de corpos de prova produzidos via manufatura aditiva. Foram mensuradas a curva de endurecimento do material até a fratura e o nível de porosidade inicial e crítica em diferentes pontos e direções de deposição do metal. Observou-se que a porosidade do material variou de 5% a 18% ao longo das direções de deposição, o que influenciou as características de resistência, como tensão de escoamento, módulo de elasticidade e nível de deformação plástica acumulada na fratura. Por fim, verificou-se que o modelo baseado em Gurson (1977) consegue descrever o comportamento mecânico de materiais fornecidos por manufatura aditiva e pode ser utilizado como alternativa para prever a fração de vazio volumétrico, um defeito presente nesses tipos de materiais.

**Palavras-chave:** Algoritmo Genético, Método de Levenberg-Marquardt, Modelo de Gurson, Manufatura Aditiva.

## ABSTRACT

The process of identifying parameters using various optimization methodologies has been shown to be an important tool in the determination of parameters of constitutive models characteristic of materials. The degree of complexity of the constitutive relationship of the material is a determining factor in the choice of the optimization method, since the objective function can have many local minimums or maximums. In the present work, in a first stage, computational routines were developed in the PYTHON language that involved an evolutionary algorithm, the Genetic Algorithm (GA), and a gradient-based algorithm, the Divided Levenberg-Marquardt Algorithm (LMD), and a hybrid model was proposed that would unite the search robustness of GA and the speed and precision of the LMD Algorithm. The developed routines were tested for different objective functions, obtaining viable solutions after a reduced number of iterations. In a second step, using the results obtained through the tensile test of the normalized and annealed 4340 steels and the 1524 U2 alloy, initially, a routine was developed to automate the search for material characteristics such as modulus of elasticity, initial yield strengths, maximum and rupture stresses, as well as properties such as resilience and toughness and, finally, the previously idealized routines were applied in the determination of hardening parameters according to the model of Kleinermann and Ponthot (2003). The critical point verified was the Finite Element method, represented here by the HYPLAS system. An academic system useful in the development of the hybrid method, but one that added several seconds of processing to each iteration of GA and the LMD Algorithm. At the end of the work, in a third stage, a case study involving another constitutive model was carried out. The aim of this study was to verify the applicability of porous materials model of Gurson (1977) in the characterization of the mechanical properties of specimens produced per additive manufacturing. The hardening curve of the material until fracture and the initial and critical porosity level were measured at different points and directions of metal deposition. It was observed that the porosity of the material varied from 5% to 18% along the deposition directions, which influenced the strength characteristics, such as yield stress, modulus of elasticity and level of plastic deformation accumulated in the fracture. Finally, it was found that the model based on Gurson (1977) can describe the mechanical behavior of materials supplied by additive manufacturing and can be used as an alternative to predict the volumetric void fraction, a defect present in these types of materials.

**Keywords:** Genetic Algorithm, Levenberg-Marquardt Method, Gurson Model, Additive Manufacturing.

# SUMÁRIO

<b>LISTA DE FIGURAS</b> .....	viii
<b>LISTA DE TABELAS</b> .....	xii
<b>LISTA DE QUADROS</b> .....	xv
<b>LISTA DE SÍMBOLOS</b> .....	xvi
<b>1. INTRODUÇÃO</b> .....	1
1.1. MOTIVAÇÃO .....	3
1.2. OBJETIVOS .....	5
1.3. CONTRIBUIÇÕES PARA O ESTADO DA ARTE .....	5
1.4. PUBLICAÇÕES RELACIONADAS À TESE .....	6
1.5. ESTRUTURA DO DOCUMENTO .....	6
<b>2. MÉTODO HÍBRIDO PARA IDENTIFICAÇÃO DE PARÂMETROS</b> .....	8
2.1. IDENTIFICAÇÃO DE PARÂMETROS .....	8
2.2. ESTRATÉGIAS EVOLUTIVAS (EE) E O ALGORITMO GENÉTICO (GA).....	15
2.3. O ALGORITMO DE LEVENBERG-MARQUARDT DIVIDIDO (LMD) .....	27
2.4. O MÉTODO HÍBRIDO GALM .....	33
<b>3. IDENTIFICAÇÃO DA CURVA DE ENDURECIMENTO ISOTRÓPICO</b> .....	35
3.1. O ENSAIO DE TRAÇÃO E SUAS CARACTERÍSTICAS .....	35
3.1.1. Ensaio convencional .....	35
3.1.2. Ensaio real.....	43
3.1.3. Relações entre Tensões e Deformações Reais e Convencionais.....	44
3.2. DADOS UTILIZADOS PARA VALIDAÇÃO DO MÉTODO .....	47
3.3. OS ENSAIOS AVALIADOS E RESULTADOS OBTIDOS .....	48
3.4. OBSERVAÇÕES SOBRE AS PROPRIEDADES VERIFICADAS.....	55
<b>4. SIMULAÇÕES NUMÉRICAS</b> .....	58
4.1. ALGORITMO GENÉTICO: RESULTADOS OBTIDOS.....	60
4.2. MÉTODO DE LEVENBERG-MARQUARDT: RESULTADOS OBTIDOS .....	84
4.3. MÉTODO HÍBRIDO – GALM: RESULTADOS OBTIDOS .....	99
4.4. OBSERVAÇÕES SOBRE AS SIMULAÇÕES REALIZADAS .....	104
<b>5. ESTUDO DE CASO – MANUFATURA ADITIVA</b> .....	107
5.1. O MODELO DE GURSON .....	110
5.2. PROCEDIMENTOS EXPERIMENTAIS.....	112
5.2.1. Confecção dos corpos de prova (CP's) .....	114
5.2.2. O Ensaio de Tração .....	116
5.3. PROCEDIMENTOS NUMÉRICOS.....	118
5.3.1. Modelo de Elementos Finitos (MEF).....	119
5.3.2. Simulações Numéricas .....	120
5.4. CARACTERIZAÇÃO MECÂNICA DOS CP's. ....	126
5.5. CONCLUSÕES.....	128
<b>6. CONSIDERAÇÕES FINAIS</b> .....	130
<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	132



## LISTA DE FIGURAS

		Pág.
<b>Figura 2.01</b>	Funcionamento do crossover de dois pontos.	19
<b>Figura 2.02</b>	Funcionamento do crossover uniforme.	19
<b>Figura 2.03</b>	Superfície referente à função $f_1$ com cortes nos planos xz e yz e os pontos de maior valoração obtidos ao longo de 6 gerações do GA ( $P_o$ = população inicial).	24
<b>Figura 2.04</b>	Superfície referente à função $f_2$ com cortes nos planos xz e yz e os pontos de maior valoração obtidos ao longo de 6 gerações do GA ( $P_o$ = população inicial).	25
<b>Figura 2.05</b>	Superfície referente à função $f_3$ com cortes nos planos xz e yz e os pontos de maior valoração obtidos ao longo de 6 gerações do GA ( $P_o$ = população inicial).	26
<b>Figura 3.01</b>	Esboço da curva obtida em um ensaio de tração (Curva tensão-deformação de engenharia).	36
<b>Figura 3.02</b>	(a) Curva tensão-deformação de engenharia com $\sigma_e$ definido para uma deformação de 0,2%; (b) Formação de histerese mecânica.	40
<b>Figura 3.03</b>	Representação de curvas tensão-deformação em situações extremas para materiais (a) dúcteis e (b) frágeis.	42
<b>Figura 3.04</b>	Representação esquemática das curvas tensão-deformação de engenharia e real para um material metálico.	43
<b>Figura 3.05</b>	Dimensões dos corpos de prova fabricados e utilizados no ensaio de tração. A região útil está destacada pela área hachurada.	48
<b>Figura 3.06</b>	Curvas Força [N] x Alongamento [mm] dos materiais em estudo.	48
<b>Figura 3.07</b>	Curvas Força [N] x Alongamento [mm] obtidas nos ensaios de tração de corpos de prova dos materiais (a) Aço 4340 Normalizado; (b) Aço 4340 Recozido; (c) Aço 1524 U2	49
<b>Figura 3.08</b>	Curvas Tensão [MPa] x Deformação [adimensional] Reais e Convencionais obtidas nos ensaios de tração de corpos de prova dos materiais (a) Aço 4340 Normalizado; (b) Aço 4340 Recozido; (c) Aço 1524 U2	49
<b>Figura 3.09</b>	Curvas Tensão [MPa] x Deformação [adimensional] Convencionais utilizadas para a obtenção do Limite de Escoamento e do Módulo de Elasticidade dos materiais (a) Aço 4340 Normalizado; (b) Aço 4340 Recozido; (c) Aço 1524 U2	50
<b>Figura 3.10</b>	Aço 1524 U2 – Busca pelo maior coeficiente de correlação ( $r^2$ ) na região de comportamento elástico: (a) $r^2 = 0,999$ ; (b) $r^2 = 0,9995$ ; (c) $r^2 = 0,9998$ , (d) $r^2 = 0,9999$ .	51
<b>Figura 3.11</b>	Região de comportamento elástico considerando-se o coeficiente de correlação linear $r^2 = 0,9998$ para os materiais (a) Aço 4340 Normalizado; e (b) Aço 4340 Recozido.	52
<b>Figura 3.12</b>	Região de deformação plástica das Curvas Tensão x Deformação Reais e a relação $\sigma = K\varepsilon^n$ para os materiais (a) Aço 4340 Normalizado; (b) Aço 4340 Recozido; (c) Aço 1524 U2.	55

	<b>Pág.</b>
<b>Figura 4.01</b>	Fluxo de trabalho referente ao processo de identificação paramétrica baseado em método híbrido de busca. 59
<b>Figura 4.02</b>	Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 6 indivíduos. As curvas representam indivíduos da geração inicial ou geração 0. 62
<b>Figura 4.03</b>	Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 6 indivíduos. As curvas representam indivíduos da geração inicial ou geração 1. 64
<b>Figura 4.04</b>	Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 6 indivíduos. As curvas representam indivíduos da geração inicial ou geração 2. 65
<b>Figura 4.05</b>	Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 6 indivíduos. As curvas representam indivíduos da geração inicial ou geração 3. 66
<b>Figura 4.06</b>	Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 10 indivíduos e um intervalo inicial aleatório fixo. As curvas representam indivíduos com diferentes avaliações. 68
<b>Figura 4.07</b>	Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 20 indivíduos e um intervalo inicial aleatório fixo. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações. 69
<b>Figura 4.08</b>	Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 6 gerações com população inicial de 6 indivíduos e um intervalo inicial aleatório fixo. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações. 70
<b>Figura 4.09</b>	Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 6 gerações com população inicial de 10 indivíduos e um intervalo inicial aleatório fixo. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações. 71
<b>Figura 4.10</b>	Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 6 gerações com população inicial de 20 indivíduos e um intervalo inicial aleatório fixo. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações. 72
<b>Figura 4.11</b>	Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 6 indivíduos. Empregou-se a mudança de limites, o redimensionamento da população e a reinserção de indivíduos da elite na população ao longo das gerações. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações, mas ainda distantes da curva experimental. 77

	<b>Pág.</b>
<b>Figura 4.12</b>	78
Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 10 indivíduos. Empregou-se a mudança de limites, o redimensionamento da população e a reinserção de indivíduos da elite na população ao longo das gerações. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações, mas ainda distantes da curva experimental.	
<b>Figura 4.13</b>	79
Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 20 indivíduos. Empregou-se a mudança de limites, o redimensionamento da população e a reinserção de indivíduos da elite na população ao longo das gerações. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações, mas ainda distantes da curva experimental.	
<b>Figura 4.14</b>	82
Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 4 indivíduos. Empregou-se a mudança de limites, o redimensionamento da população e a reinserção de indivíduos da elite na população ao longo das gerações. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações, mas ainda distantes da curva experimental.	
<b>Figura 4.15</b>	82
Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 6 gerações com população inicial de 4 indivíduos. Empregou-se a mudança de limites, o redimensionamento da população e a reinserção de indivíduos da elite na população ao longo das gerações. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações.	
<b>Figura 4.16.</b>	87
Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com valores aleatórios provenientes do estudo do limite de escoamento e de ruptura $\sigma$ . Os gráficos correspondem à evolução do método: (a) iteração 0; (b) iteração 6; (c) iteração 12; (d) iteração 18; (e) iteração 24; (f) iteração 30; (g) iteração 36 e (h) iteração 42 (final).	
<b>Figura 4.17.</b>	89
Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com os valores de melhor pontuação oriundos do Algoritmo Genético (GA). Os gráficos correspondem às etapas de evolução do método: (a) iteração 0; (b) iteração 6; (c) iteração 12; (d) iteração 18; (e) iteração 24 e (f) iteração 36 (final).	
<b>Figura 4.18.</b>	91
Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com os valores médios oriundos do Algoritmo Genético (GA). Os gráficos correspondem às etapas de evolução do método: (a) iteração 0; (b) iteração 6; (c) iteração 12; (d) iteração 18; (e) iteração 24 e (f) iteração 30 (final).	
<b>Figura 4.19.</b>	94
Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com os valores de melhor pontuação oriundos do Algoritmo Genético (GA) e foi adotado como segundo critério de parada a comparação de áreas sob a curva. Os gráficos correspondem às etapas de evolução do método: (a) iteração 0; (b) iteração 6; (c) iteração 12 e (d) iteração 18 (final).	

	<b>Pág.</b>	
<b>Figura 4.20</b>	Região de comportamento plástico do Aço 1524 U2. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com os valores de melhor pontuação oriundos do Algoritmo Genético (GA) e foi adotado como segundo critério de parada a comparação de áreas sob a curva. Os gráficos correspondem às etapas de evolução do método: (a) iteração 0; (b) iteração 6; (c) iteração 12 e (d) iteração 18 (final).	95
<b>Figura 4.21</b>	Região de comportamento plástico dos Aços 4340 Normalizado e 1524 U2. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com os valores médios oriundos do Algoritmo Genético (GA) e foi adotado como segundo critério de parada a comparação de áreas sob a curva. Os gráficos correspondem às etapas de evolução do método: (a) iteração 0; (b) iteração 6 e (c) iteração 12 (final) para o Aço 4340, e (d) iteração 0; (e) iteração 6; (f) iteração 12 e (g) iteração 18 (final) para o Aço 1524 U2.	96
<b>Figura 4.22</b>	Curvas iniciais e finais correspondentes aos experimentos cinco (5) e quatro (4) com maior e menor tempo, respectivamente.	101
<b>Figura 4.23</b>	Curvas iniciais e finais correspondentes aos experimentos cinco (5) e dois (2) com maior e menor tempo, respectivamente.	102
<b>Figura 4.24</b>	Curvas iniciais e finais correspondentes aos experimentos um (1) e cinco (5) com maior e menor tempo, respectivamente.	103
<b>Figura 5.01</b>	Esquema do processo de manufatura aditiva por deposição a arco elétrico.	108
<b>Figura 5.02</b>	Placa metálica produzida via processo WAAM-CMT com 180x100x3 mm.	114
<b>Figura 5.03</b>	Placa metálica após o processo de corte por jato d'água.	115
<b>Figura 5.04</b>	Dimensões nominais do corpo de prova.	115
<b>Figura 5.05</b>	Posicionamento do corpo de prova e <i>clip-gauge</i> na MTS 810.	116
<b>Figura 5.06</b>	a) Força de reação versus deslocamento experimentalmente determinados para os seis ensaios de tração, b) Três CP's na direção L da placa e c) Três CP's na direção T da placa.	117
<b>Figura 5.07</b>	Malha de elementos finitos utilizada para reprodução do ensaio de tração. Dimensões em [mm]	119
<b>Figura 5.08</b>	a) Curvas de força versus deslocamento e b) Porosidade versus deslocamento para os corpos de prova 1, 2 e 3, retirados da direção L da placa metálica.	121
<b>Figura 5.09</b>	a) Curvas de força versus deslocamento e b) Porosidade versus deslocamento para os corpos de prova 4, 5 e 6, retirados da direção T da placa metálica.	124
<b>Figura 5.10</b>	Contorno da deformação plástica equivalente na fratura.	125
<b>Figura 5.11</b>	Direção de deposição do metal e propriedades do material.	126

## LISTA DE TABELAS

		<b>Pág.</b>
<b>Tabela 2.01</b>	Valores finais obtidos no GA para diferentes populações e seu uso como valores iniciais no método BFGS.	23
<b>Tabela 2.02</b>	Valores advindos do GA e valores finais do LM para a Equação 2.23 em três testes.	31
<b>Tabela 2.03</b>	Valores advindos do GA e valores finais do LM para a Equação 2.24 em três testes.	32
<b>Tabela 2.04</b>	Valores advindos do GA e valores finais do LM para a Equação 2.25 em três testes.	32
<b>Tabela 3.01</b>	Índices de correlação testados e o percentual de pontos observados ( <i>np</i> )	51
<b>Tabela 3.02</b>	Resultados obtidos para a Região Elástica.	52
<b>Tabela 3.03</b>	Módulos de Resiliência para os diferentes índices de correlação testados.	53
<b>Tabela 3.04</b>	Resultados obtidos para o Limite de Resistência à Tração.	54
<b>Tabela 3.05</b>	Resultados obtidos para o Limite de Ruptura.	54
<b>Tabela 3.06</b>	Resultados obtidos para a Tenacidade.	54
<b>Tabela 3.07</b>	Resultados obtidos para os parâmetros de Hollomon.	55
<b>Tabela 4.01</b>	Aço 4340 Normalizado – Intervalo inicial de busca para cada parâmetro.	60
<b>Tabela 4.02</b>	Aço 4340 Normalizado – Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo com 3 gerações e população inicial fixa de 6 indivíduos.	62
<b>Tabela 4.03</b>	Aço 4340 Normalizado – Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo – 3 gerações e população inicial fixa de 10 indivíduos.	67
<b>Tabela 4.04</b>	Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo – 3 gerações e população inicial fixa de 20 indivíduos.	69
<b>Tabela 4.05</b>	Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo – 6 gerações e população inicial fixa de 6 indivíduos.	70
<b>Tabela 4.06</b>	Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo – 6 gerações e população inicial fixa de 10 indivíduos.	71
<b>Tabela 4.07</b>	Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo – 6 gerações e população inicial fixa de 20 indivíduos.	72
<b>Tabela 4.08</b>	Aço 4340 Normalizado – Tempos medidos para o Algoritmo Genético (GA) avaliado considerando-se quantidades de indivíduos fixas ao longo das gerações.	73
<b>Tabela 4.09</b>	Aço 4340 Normalizado – Intervalo inicial de busca modificado, levando-se em consideração os limites de escoamento e de resistência a tração.	73
<b>Tabela 4.10</b>	Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) com intervalo inicial aleatório não fixo – 3 gerações e população inicial fixa de 6 indivíduos.	74

	<b>Pág.</b>
<b>Tabela 4.11</b> Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) com intervalo inicial aleatório não fixo – 3 gerações e população inicial fixa de 10 indivíduos.	74
<b>Tabela 4.12</b> Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) com intervalo inicial aleatório não fixo – 3 gerações e população inicial fixa de 20 indivíduos.	75
<b>Tabela 4.13</b> Aço 4340 Normalizado – Tempos medidos para o Algoritmo Genético (GA) avaliado considerando-se quantidades de indivíduos fixas ao longo das gerações.	75
<b>Tabela 4.14</b> Aço 4340 Normalizado – Tempos medidos para o Algoritmo Genético (GA) avaliado considerando-se quantidades aleatórias de indivíduos ao longo das gerações.	76
<b>Tabela 4.15</b> Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em com intervalos não fixos ao longo de 3 gerações e população inicial de 6 indivíduos.	76
<b>Tabela 4.16</b> Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em com intervalos não fixos ao longo de 3 gerações e população inicial de 10 indivíduos.	77
<b>Tabela 4.17</b> Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) com intervalos não fixos ao longo de 3 gerações e população inicial de 20 indivíduos.	78
<b>Tabela 4.18</b> Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em com intervalos não fixos ao longo de 3 gerações e população inicial fixa de 4 indivíduos.	79
<b>Tabela 4.19</b> Aço 4340 Normalizado – Melhores Resultados para o GA em com intervalos não fixos ao longo de 6 gerações e população inicial fixa de 4 indivíduos.	80
<b>Tabela 4.20</b> Aço 4340 Normalizado – Regiões de busca a cada geração do Algoritmo Genético.	81
<b>Tabela 4.21</b> Aço 4340 Normalizado – Tempos medidos para o o Algoritmo Genético (GA) avaliado considerando-se quantidades aleatórias de indivíduos ao longo das gerações.	83
<b>Tabela 4.22</b> Resultados do Método LM para os parâmetros inicializados aleatoriamente.	85
<b>Tabela 4.23</b> Resultados do Método LM para os parâmetros inicializados com os valores de melhor pontuação oriundos do Algoritmo Genético (GA).	88
<b>Tabela 4.24</b> Resultados do Método LM para os parâmetros inicializados com os valores médios oriundos do Algoritmo Genético (GA).	90
<b>Tabela 4.25</b> Resultados do Método LM para os parâmetros inicializados com os valores de melhor pontuação oriundos do Algoritmo Genético (GA) e tendo como segundo critério de parada a comparação de áreas sob a curva.	92

	<b>Pág.</b>
<b>Tabela 4.26</b>	Resultados do Método LM para os parâmetros inicializados com os valores médios oriundos do Algoritmo Genético (GA) e tendo como segundo critério de parada a comparação de áreas sob a curva. 93
<b>Tabela 4.27</b>	Um panorama dos resultados obtidos com a aplicação do Método LM. 97
<b>Tabela 4.28</b>	Panorama final dos resultados obtidos com a aplicação do Método LM após a inclusão de um passo a mais na busca por todos os parâmetros. 98
<b>Tabela 4.29</b>	Intervalo inicial de busca para cada parâmetro dos materiais em estudo. 99
<b>Tabela 4.30</b>	Experimentos realizados – comportamento do Algoritmo Genético (GA). 100
<b>Tabela 4.31</b>	Aço 4340 Normalizado – comportamento do Método LM. 101
<b>Tabela 4.32</b>	Aço 4340 Recozido – comportamento do Método LM. 102
<b>Tabela 4.33</b>	Aço 1524 U2 – comportamento do Método de LM. 103
<b>Tabela 4.34</b>	Experimentos realizados – Valores finais obtidos para os parâmetros. 104
<b>Tabela 5.01</b>	Dimensões nominais e adaptadas para os corpos de prova produzidos via manufatura aditiva. 115
<b>Tabela 5.02</b>	Medidas reais de espessura e largura dos corpos de prova. 116
<b>Tabela 5.03</b>	Estimativa inicial para os parâmetros da curva de encruamento do material. PIP com abordagem de busca baseada no GA. 120
<b>Tabela 5.04</b>	Resultado dos parâmetros da curva de encruamento do material, após a abordagem de busca baseada no GA utilizando o modelo de von Mises. 121
<b>Tabela 5.05</b>	Resultado final dos parâmetros da curva de encruamento isotrópica do material baseado em von Mises, após a abordagem de busca híbrida. 121
<b>Tabela 5.06</b>	Resultado dos parâmetros da curva de encruamento do material, após a abordagem de busca baseada no GA utilizando o modelo de Gurson. 122
<b>Tabela 5.07</b>	Resultado final dos parâmetros da curva de encruamento isotrópica do material metálico poroso de Gurson, após a abordagem de busca híbrida. 122

## LISTA DE QUADROS

		<b>Pág.</b>
<b>Quadro 2.01</b>	Síntese das publicações selecionadas para leitura e análise.	10
<b>Quadro 2.02</b>	Sequência Básica de um Algoritmo Genético.	17
<b>Quadro 2.03</b>	Algoritmo Genético desenvolvido.	21
<b>Quadro 2.04</b>	Algoritmo Levenberg-Marguardt com adaptações.	30
<b>Quadro 2.05</b>	Visão geral do Método Híbrido desenvolvido.	34
<b>Quadro 3.01.</b>	Procedimento para o cálculo do limite de escoamento em metais e ligas em geral.	39
<b>Quadro 5.01</b>	Síntese de alguns trabalhos sobre propriedades mecânicas de peças fabricadas por manufatura aditiva.	109



## LISTA DE SÍMBOLOS

$\sigma_c$	Tensão convencional, nominal ou de engenharia
$\varepsilon_c$	Deformação convencional, nominal ou de engenharia
$E$	Módulo de elasticidade ou Módulo de Young
$U_r$	Módulo de Resiliência
$U_t$	Módulos de Tenacidade
$\sigma_u$	Limite de resistência à tração
$\sigma_f$	Limite de ruptura
$\sigma_e$	Limite de escoamento
$\sigma_{y_0}$	Tensão de escoamento inicial
$\sigma_y$	Tensão de escoamento
$\varepsilon_p$	Deformação plástica equivalente
$J$	Matriz Jacobiana
$f$	Fração volumétrica de vazios ou porosidade
$\dot{f}$	Taxa de crescimento da porosidade
$\dot{\varepsilon}^p$	Taxa de evolução do tensor das deformações plásticas
$\dot{\varepsilon}_v^p$	Taxa de evolução da parte volumétrica da deformação plástica
$\dot{\varepsilon}^p$	Taxa de evolução da deformação plástica acumulada
$\dot{\gamma}$	Taxa de evolução do multiplicador plástico
$\phi$	Função de escoamento proposta por Gurson
$J_2$	Segundo invariante do tensor desviador
$p$	Pressão hidrostática

# 1. INTRODUÇÃO

O desenvolvimento de modelos computacionais robustos tem possibilitado a simulação dos mais diversos processos de fabricação. Tendência que tem se traduzido no lançamento de programas comerciais capazes de simular processos como o forjamento, a laminação e a extrusão, dentre diversos outros (CHAPARRO *et al.*, 2008).

O sucesso nessas simulações está diretamente vinculado aos parâmetros dos materiais utilizados. Em geral, é necessária uma aferição cuidadosa desses parâmetros, observando-se que são poucos os programas comerciais em uso que os disponibilizam para modelos de maior complexidade, ou seja, partindo-se de medições diretas e considerando-se determinados modelos constitutivos, muitas dificuldades surgem, além do fato de que os valores obtidos nem sempre são os mais apropriados para o material em estudo (STAHLSCHMIDT *et al.*, 2011).

Procurando-se superar tais questões tem-se, como uma alternativa, o Processo de Identificação de Parâmetros (PIP). Metodologia que alia a capacidade de métodos numéricos e informações experimentais à obtenção e análise, de uma forma mais precisa, das propriedades dos materiais.

A identificação dos parâmetros dos materiais, para um determinado modelo constitutivo, pode ser vista como uma formulação inversa. A ideia central é simular o experimento realizado, buscando adaptar parâmetros dos materiais a fim de obter numericamente os mesmos resultados experimentais (STAHLSCHMIDT *et al.*, 2011). Essa abordagem consiste em um problema de otimização onde a função objetivo visa minimizar a distância entre os resultados experimentais e numéricos. As variáveis de otimização são os parâmetros dos materiais que aparecem no modelo constitutivo a ser adotado. Para resolver esse problema pode-se adotar diversos métodos e mesmo procedimentos, que são normalmente divididos em três grandes grupos:

1. Algoritmos de busca direta;
2. Algoritmos baseados em gradiente;
3. Algoritmos evolutivos.

Em geral, os algoritmos de busca direta são baseados em estratégias simples e não exigem o cálculo de derivadas. A simplicidade é o principal atributo dos métodos deste grupo, no entanto, a convergência é lenta e envolve a comparação de cada solução experimental com a melhor solução anterior, além do fato de que podem convergir para

extremos locais. Pode-se citar vários métodos de pesquisa direta, dentre eles: pesquisa de padrão, simplex e Powell. Esses métodos permanecem populares devido à sua simplicidade, flexibilidade e confiabilidade (CHAPRA *et al*, 2008).

Os algoritmos baseados em gradiente normalmente convergem rapidamente nas proximidades da solução e são muito interessantes em termos de velocidade. As limitações deste grupo são sua forte dependência aos valores inicialmente propostos como soluções dos testes e o fato de facilmente caírem em mínimos ou máximos locais, principalmente, quando o procedimento é aplicado a funções de várias variáveis ou multiparamétricas, como é o caso da identificação dos parâmetros de um material. Não são métodos de fácil implementação por envolverem derivadas parciais. Pode-se mencionar um grande número de métodos de otimização baseados em gradiente, como o Método de Descida Íngreme, o método de Newton, o método de Levenberg-Marquardt ou vários Métodos Quasi-Newton (CHAPRA *et al*, 2008).

No grupo dos algoritmos evolutivos estão os algoritmos de otimização baseados em população e que fazem uso de algum mecanismo para melhorar as soluções iniciais. As soluções experimentais para o problema de otimização são indivíduos em uma população. A evolução da população ocorre após a repetida aplicação de operadores genéticos (reprodução, mutação, recombinação etc.). Esses algoritmos tornaram-se muito populares nos últimos anos, devido, principalmente, ao aumento da velocidade de cálculo do computador que leva a resultados otimizados em um tempo aceitável. Além disso, verifica-se que os algoritmos evolutivos funcionam consistentemente bem nos mais diversos tipos de problemas, o que é evidenciado pelo seu sucesso em áreas como engenharia, arte, biologia, economia, genética, robótica, ciências sociais e outros. Embora sejam métodos robustos, sua convergência é muito demorada, e devem ser considerados como algoritmos semideias, pois mesmo com a otimização contínua variável, não é garantido encontrar o extremo global da função objetiva. Em geral, a solução final está nas proximidades do extremo global. É dentro deste grupo que se encontram os Algoritmos Genéticos (GAs) (LINDEN, 2012).

Esses três tipos de abordagem para a otimização variável não linear podem ser utilizados na resolução do problema da determinação dos parâmetros dos materiais em um dado modelo constitutivo. Observa-se que todos os algoritmos têm vantagens e desvantagens não sendo incomum combinar-se as vantagens de cada abordagem recaindo-se nos chamados métodos híbridos.

Os Métodos Híbridos consistem na combinação de dois ou mais métodos de otimização. Esta combinação de métodos é utilizada principalmente para melhorar a qualidade dos resultados e aumentar a taxa de convergência do processo de otimização (STAHLSCHMIDT *et al.*, 2011). Como exemplo, pode-se citar Ponthot e Kleinermann (2006) que usaram várias combinações de métodos de otimização baseados em gradiente para tentar evitar mínimos locais. No trabalho de Chaparro *et al.* (2008) foi empregada a combinação de um Algoritmo Genético com o método baseado em gradiente de Levenberg-Marquardt. Muñoz-Rojas *et al.* (2010) adotaram combinações entre um Algoritmo Genético e os métodos baseados em gradiente: Programação Linear Sequencial (BARBOSA, 2002) e o Método das Assíntotas Móveis Globalmente Convergente (GOMES-RUGGIERO, 2010). Na tentativa de acelerar o processo iterativo através da redução do número de execuções do programa de Elementos Finitos, Aguir *et al.* (2011) propuseram um método híbrido combinando Redes Neurais e Algoritmos Genéticos.

### 1.1. MOTIVAÇÃO

Diversos trabalhos foram desenvolvidos nos últimos anos utilizando a abordagem por identificação de parâmetros, podendo-se citar SEDIGHIANI *et al* (2020) que trabalharam com modelos de plasticidade cristalina, FERNÁNDEZ *et al* (2020) que se dedicaram à viscoelasticidade, PETUREAU *et al* (2019) cujo foco foi a elasticidade, LOTFOLAHPOUR *et al* (2018), HAN *et al* (2019) e CHEN *et al* (2021) que dedicaram-se à mecânica da fratura, ALVES *et al* (2020) e CAO *et al* (2019) com foco em análise de falhas, ZHOU *et al* (2021) com trabalho sobre fadiga, YIN *et al* (2017) , BLAISE *et al* (2019), MAROUANI *et al* (2019), CHOI *et al* (2020), DONG *et al* (2022) que dedicaram-se ao estudo de diferentes materiais e suas propriedades, além de trabalhos como os de WANG *et al* (2020) cujo foco foi a aplicação de métodos numéricos diversos e suas interrelações buscando eficácia e precisão computacionais.

Dentre os diversos processos de fabricação mecânica tem-se os processos de conformação. Processos em que o material muda de forma pela aplicação de forças que causam tensões superiores ao seu limite de escoamento. Para que o elemento se deforme desta maneira, ele deve ser bastante dúctil para suportar a deformação plástica e evitar a fratura (GROOVER, 2014). Os modelos simples representativos do endurecimento isotrópico de um material podem apresentar uma estimativa aceitável das forças atuantes durante o processo e são amplamente utilizados na indústria. Mas, modelos mais

sofisticados envolvendo, por exemplo, o endurecimento cinemático não linear (LUBLINER, 2008; SIMO e HUGHES, 2000; SIMÕES, 2017) e critérios de rendimento mais refinados, apresentam uma melhor avaliação da evolução de cada processo de deformação. Em geral, esses modelos possuem muitos parâmetros, o que aumenta a quantidade e os tipos de testes experimentais necessários para sua avaliação. Além disso, os resultados da avaliação dos parâmetros são muitas vezes inconsistentes (CHAPARRO *et al.*, 2008).

Além dos processos usuais de fabricação, tem-se hoje a chamada Manufatura Aditiva, tecnologia emergente com potencial para alavancar diversos setores de importância da indústria e ainda contribuir com a redução de impactos ambientais (BÖCKIN *et al.*, 2019). A questão é que as peças metálicas produzidas são submetidas a processos térmicos complexos levando a uma microestrutura tipicamente anisotrópica e heterogênea (LEWANDOWSKI *et al.*, 2016). A combinação de fatores como alta porosidade, defeitos de fabricação, contaminação da poça de fusão e tensões residuais pode levar a uma baixa ductilidade (SOLA *et al.*, 2019), a uma redução da resistência mecânica e da resistência à fadiga (JAFARI *et al.*, 2021). Com base em tais indagações, verifica-se a importância de medir a quantidade de vazios dentro do componente mecânico produzido, ou mesmo, correlacionar os parâmetros de deposição com o nível de porosidade. Um modelo de material que envolve a porosidade como um de seus vários parâmetros é o modelo de Gurson (GURSON, 1977).

Observando-se a relevância de se obter parâmetros condignos para os diferentes modelos constitutivos, um método híbrido combinando um Algoritmo Genético (GA) e uma variação do método gradiente de Levenberg-Marquardt (LM) conhecida por LM Dividido (LMD) pode apresentar-se como uma boa opção para melhorar a eficiência do processo de otimização. Além das vantagens já descritas do GA, a sua aplicação possibilitaria avaliar melhor o domínio do problema, estabelecendo-se novas restrições, diminuindo a região de busca e saindo de áreas de máximos e mínimos locais. Com os dados advindos do GA, a região de busca do método LM seria reduzida (melhora dos parâmetros iniciais) impondo-se um número menor de iterações na direção do máximo ou mínimo global. O método LM Dividido proposto é uma variação do método LM, em que o laço de iteração é dividido em vários problemas menores que possuem apenas uma fração da complexidade do problema inicial e são resolvidos com maior velocidade.

## 1.2. OBJETIVOS

O objetivo do presente trabalho é propor e desenvolver um modelo híbrido para identificação de parâmetros de encruamento que una a robustez de busca do Algoritmo Genético (GA) e a rapidez do Algoritmo Levenberg-Marquardt Dividido (LMD).

Para alcançar tal objetivo geral, foram delineados alguns objetivos específicos:

- identificar e explorar os problemas e dificuldades que podem surgir durante o procedimento de identificação de parâmetros;
- desenvolver rotinas computacionais que compreendam um algoritmo evolutivo, no caso, o Algoritmo Genético (GA) e um algoritmo baseado em gradiente, preferencialmente o Algoritmo de Levenberg-Marquardt Dividido (LMD);
- avaliar e comparar o desempenho dos métodos individuais e do método híbrido;
- automatizar a análise numérica das curvas obtidas no ensaio de tração, assim como, verificar algumas propriedades dos materiais (módulo de elasticidade, resiliência tenacidade, etc.);
- validar a rotina de automação do ensaio de tração via análise dos dados experimentais obtidos para os aços: 4340 normalizado, 4340 recozido e 1524 U2 com tratamento térmico;
- comparar os dados experimentais com os dados numéricos obtidos na busca pelos parâmetros do modelo de Kleiner mann e Ponthot (2003) via o uso das rotinas computacionais desenvolvidas, o método híbrido;
- realizar um estudo de caso, verificando os parâmetros dos materiais presentes no modelo de Gurson (1977), dentre eles a porosidade, para uma peça obtida por Manufatura Aditiva.

## 1.3. CONTRIBUIÇÕES PARA O ESTADO DA ARTE

Pode-se destacar:

- a. A automação de todo o processo de identificação da curva de endurecimento isotrópico, apresentando as características de um ensaio convencional e real, além dos cálculos de propriedades, como o módulo de elasticidade, tensões de

escoamento, máxima e de fratura, e do uso de métodos numéricos de integração para o cálculo de resiliência e tenacidade;

- b. A implementação de uma estratégia evolutiva, o Algoritmo Genético (GA), utilizando diferentes técnicas e dedicada à busca de parâmetros para diversos processos;
- c. A implementação de um método híbrido, onde o Algoritmo Genético (GA) em conjunto com o método de Levenberg-Marquardt Dividido (LMD) complementam-se permitindo a busca de um número aleatório de parâmetros em um menor tempo e com maior precisão.
- d. Uso de método híbrido para busca dos parâmetros de Gurson (1977) de forma a auxiliar processos de manufatura aditiva, permitindo, por exemplo, a avaliação da porosidade de peças produzidas.

#### 1.4. PUBLICAÇÕES RELACIONADAS À TESE

SILVA, C. P; MALCHER, L. (2022). **Identification of material parameters: a proposal to improve the performance of the applied Genetic Algorithm.** Jornadas de Mecánica Computacional. Sociedade Chilena de Mecánica Computacional. Octubre de 2022. Chile.

SILVA, C. P; SILVA, G. P.; SANTOS, M. C., ZIBEROV, M.; MALCHER, L. (2024) **Hybrid search methodology for mechanical characterization of material produced via WAAM assuming Gurson porous material.** Journal of the Brazilian Society of Mechanical Sciences and Engineering. 2024.

#### 1.5. ESTRUTURA DO DOCUMENTO

O texto do presente documento foi estruturado da seguinte forma:

- Capítulo 1: são apresentadas as motivações e objetivos do presente trabalho;
- Capítulo 2: discute-se brevemente a metodologia de identificação de parâmetros e apresenta-se em maiores detalhes o Algoritmo Genético (GA), o Algoritmo de Levenberg-Marquardt Dividido (LMD) e, ao final, o método híbrido implementado;
- Capítulo 3: avalia-se o ensaio de tração, algumas de suas características e por fim alguns resultados obtidos pela análise dos dados experimentais dos aços:

4340 normalizado, 4340 recozido e 1524U2 com tratamento térmico, utilizados para validar o módulo de automação montado para o ensaio de tração;

- Capítulo 4: são apresentadas as simulações numéricas obtidas individualmente via o Algoritmo Genético (GA), o Método de Levenberg-Marquardt Dividido (LMD), e ao final, o método híbrido implementado, tendo como base os dados dos materiais analisados anteriormente;
- Capítulo 5: discute-se brevemente a manufatura aditiva e o modelo de Gurson e são apresentados os procedimentos experimentais e numéricos realizados para a caracterização mecânica das peças produzidas via manufatura aditiva;
- Capítulo 6: tem-se um resumo do trabalho realizado e algumas considerações acerca dos resultados obtidos, além de sugestões para trabalhos futuros no sentido de enriquecer o trabalho aqui desenvolvido.



## 2. MÉTODO HÍBRIDO PARA IDENTIFICAÇÃO DE PARÂMETROS

Para o desenvolvimento de um método híbrido de identificação paramétrica se fez necessário o estudo de diversos métodos de otimização que apresentassem características complementares. Analisou-se métodos heurísticos como a pesquisa por arrefecimento simulado - *simulated annealing* (FELCHAR *et al*, 2018), os algoritmos genéticos (GA) (LINDEN, 2012), as redes neurais (MENDES, 2021; BRAGA 2000), o modelo colônia de formigas (SOUZA, 2019; MARQUES, 2014)) e o método GRASP (MENEZES *et al*, 2020; MARTINS *et al*; 2006; RESENDE *et al*, 2005), métodos diretos como os métodos do aclave máximo, gradiente conjugado de Fletcher-Reeves e o método de Levenberg-Marquardt (LM) (FRANÇA, 2009), além dos métodos quase-Newton destacando-se os algoritmos de Davidson-Fletcher-Powell (DFP) e de Broyden-Fletcher-Goldfarb-Shanno (BFGS) (CHAPRA, 2008). Os algoritmos genéticos e o método de Levenberg-Marquardt foram os escolhidos para a criação do método híbrido, apesar de terem sido desenvolvidos módulos com outros métodos como o método do aclave máximo, o DFP e o BFGS tanto por comparação como para auxiliarem em algumas outras etapas desta pesquisa.

No presente capítulo serão apresentadas as ideias centrais, alguns testes e resultados do processo de identificação de parâmetros, do algoritmo genético (GA), do método de Levenberg-Marquardt Dividido (LMD) e do método híbrido desenvolvido com a junção do GA e do LM.

### 2.1. IDENTIFICAÇÃO DE PARÂMETROS

Conceitualmente, um problema de identificação de parâmetros consiste na determinação de um conjunto de fatores, denotado por  $p$ , que minimiza a diferença entre uma resposta obtida numericamente,  $R^{MEF}(p)$ , e uma resposta obtida experimentalmente,  $R^{Exp}$ , com respeito a uma medida de norma e dentro de uma certa tolerância. A resposta numérica é obtida através da solução de um problema direto, enquanto a resposta experimental representa os valores das grandezas medidas no experimento (STAHLSCHMIDT *et al*, 2011).

Este tipo de problema faz parte da classe dos ditos problemas de otimização, cuja resolução consiste na determinação do ponto crítico mínimo de uma função objetivo, observando-se uma série de restrições, como pode ser visto na equação:

$$\begin{aligned}
\text{Minimizar: } & g_o(p) & p \in \mathcal{R}^n \\
\text{Sujeito a } & h_l(p) = 0 & l = 1 \dots m_h \\
& g_j(p) \leq 0 & j = 1 \dots m_g \\
& p_i^{inf} \leq p_i \leq p_i^{sup} & i = 1 \dots n
\end{aligned}
\tag{Equação 2.01}$$

onde  $p \in \mathcal{R}^n$  é o vetor das variáveis de projeto, ou seja, os parâmetros a serem avaliados e que pertencem a uma região de busca delimitada pelos limites inferiores ( $p_i^{inf}$ ) e superiores ( $p_i^{sup}$ ),  $g_o(p)$  é a função objetivo a ser minimizada,  $h_l(p)$  e  $g_j(p)$  são as restrições de igualdade e desigualdade e  $m_h$  e  $m_g$  correspondem ao número de restrições de igualdade e desigualdade, respectivamente.

Em geral, a função objetivo a ser tratada é baseada na norma euclidiana da diferença relativa entre os resultados experimentais ( $R^{Exp}$ ) e os resultados numéricos ( $R^{MEF}$ ),

$$g_o(p) = \sqrt{\frac{1}{N} \sum_{k=1}^N \left( \frac{R_k^{MEF}(p) - R_k^{Exp}}{R_k^{Exp}} \right)^2}
\tag{Equação 2.02}$$

onde  $R^{MEF}$  é a resposta obtida através da solução de um problema e  $R^{Exp}$  é a resposta experimental associada às grandezas medidas no experimento,  $p$  é o conjunto de parâmetros a serem identificados e  $N$  representa o número de pontos experimentais.

Para uma análise do estado da arte atual relativo ao uso e aprimoramentos do processo de identificação de parâmetros realizou-se uma pesquisa bibliográfica. Utilizando o repositório ELSEVIER de publicações e livros fez-se algumas buscas empregando os descritores: identificação de parâmetros (*parameter identification*), método dos elementos finitos (*finite elements method*), algoritmo genético (*genetic algorithm*), algoritmo de Levenberg-Marquardt (*Levenberg Marquardt algorithm*), métodos gradiente (*gradiente methods*). Foram encontradas diversas publicações sendo necessária a separação por área de estudo e a adoção do critério de leitura dos resumos e quando estes não descreviam a metodologia e/ou a fundamentação teórica utilizada realizou-se a busca pelos dados omissos a partir da leitura panorâmica do trabalho completo. Foi definido como período de abrangência o intervalo anual de 2018 a 2022. Ao final da busca foram selecionadas para leitura as publicações de maior proximidade com o tema em foco observando-se as contribuições que poderiam apresentar para a montagem do método híbrido, os tipos de análise que realizaram e as diversas aplicações

em que foram utilizadas. No Quadro 2.01 são apresentadas algumas dessas publicações separadas por área de estudo e uma síntese dos assuntos nelas abordados.

**Quadro 2.01** Síntese das publicações selecionadas para leitura e análise.

Autor(es)	Síntese do(s) trabalho(s).
<b>Plasticidade – Revista: <i>International Journal of Plasticity</i></b>	
Sedighiani, K.; Diehl, M.; Traka, K.; Roters, F.; Sietsma, J.; Raabe, D. (2020)	A determinação dos parâmetros constitutivos de modelos de plasticidade cristalina é um processo complexo e, em geral, requer testes micromecânicos demorados que permitam a sondagem de grãos individuais. Neste trabalho é apresentada uma nova abordagem que utiliza a metodologia da superfície de resposta juntamente com um algoritmo genético (GA) para determinar um conjunto ideal de parâmetros constitutivos a partir de testes macroscópicos. A abordagem proposta é adequada para modelos complexos com um grande número de parâmetros permitindo uma compreensão quantitativa e completa da influência relativa dos diferentes parâmetros constitutivos e suas interações. Pode ser usada para identificar parâmetros de modelos de fadiga, trepidação e dano, por exemplo.
<b>Viscoelasticidade – Revista: <i>International Journal of Computer Mathematics</i></b>	
Fernández, J. R.; López-Campos, J. A.; Segade, A.; Vilán, J. A. (2020)	Os materiais viscoelásticos desempenham um papel fundamental nos projetos mecânicos devido às suas inúmeras aplicações. Nesta pesquisa, propôs-se a caracterização da viscoelasticidade de um material sendo sua elasticidade não linear definida previamente com um teste de tração. Foram estudados três diferentes modelos reológicos. O problema de otimização foi avaliado sob duas técnicas de otimização: um método de busca local determinístico, o método de Newton, e um método de busca global não determinístico, o algoritmo genético (GA). Os dados obtidos em ambos os métodos foram comparados com uma solução conhecida e o teste real. Ao final, comparou-se os resultados com uma simulação em Elementos Finitos.
<b>Elasticidade – Revista: <i>International Journal of Applied Mechanics and Engineering</i></b>	
Petureau, L.; Doumalin, P.; Bremand, F. (2019).	Neste trabalho explorou-se as possibilidades do método <i>Finite Element Model Updating</i> (FEMU) a fim de identificar as propriedades mecânicas de elasticidade locais em materiais heterogêneos. A função objetivo foi definida como um erro quadrático da discrepância entre campos medidos e simulados. Comparou-se duas formulações diferentes da função, uma baseada nos campos de deslocamento e outra baseada nos campos de tensão. Usou-se um algoritmo genético (GA) para minimizar essas funções. Verificou-se que a tensão funcional associada ao algoritmo genético foi a melhor combinação. Em um segundo momento procurou-se reduzir o custo computação aplicando-se computação paralela. Validou-se a abordagem com casos simulados em 2D.
<b>Mecânica da Fratura – Revistas: <i>Engineering Fracture Mechanics</i> e <i>International Journal of Adhesion and Adhesives</i></b>	
Han, Xiao; Chao; Yuexing; Zhang, Wei; Chao Yuezheng; Wu, Chengwei (2019)	Nesta pesquisa procurou-se desenvolver um processo que auxiliasse na determinação de um conjunto ideal de parâmetros em amostras submetidas a vários tratamentos pós-cura. O teste End-Notched Flexure (ENF) foi realizado para caracterizar a propriedade de fratura do Modo II sob condições recomendadas e pós-cura, fornecendo dados de referência para o estágio de análise numérica. Os resultados experimentais revelaram que a energia da fratura do Modo II foi efetivamente afetada pelo histórico pós-cura, com maior temperatura e maior duração de cura levando a uma maior resistência à fratura. Os parâmetros numericamente identificados do Modelo de Zona Coesiva (CZM) utilizando algoritmo genético (GA) de várias ilhas forneceram boa correlação nas energias de fratura do Modo II entre a modelagem em elementos finitos (FE) e os valores medidos experimentalmente.

<b>Mecânica da Fratura – Revistas: <i>Engineering Fracture Mechanics</i> e <i>International Journal of Adhesion and Adhesives</i></b>	
Chen, Dong; Li, Yazhi; Yang, Xuan; Jiang, Wei, Guan, Lingxiao (2021).	Neste trabalho desenvolveu-se uma estratégia de identificação de parâmetros para o modelo modificado de dano Gurson-Tvergaard-Needleman (GTN) proposto por Wei Jiang (2016), cujo objetivo é descrever o comportamento de materiais metálicos sob uma ampla gama de estados de tensão. Usado para simular a fratura dúctil da liga de alumínio 2024-T3, esse modelo é baseado em um algoritmo de aprendizagem de máquina combinando redes neurais e o algoritmo genético (GA). As simulações foram implementadas no ABAQUS/Explicit.
Lotfolahpour, Amirreza; Soltani, Nasser; Ganjiani, Mehdi; Baharlouei, Davoud (2018)	Nesta pesquisa foram identificados os parâmetros do modelo de dano de Gurson-Tvergaard-Needleman (GTN) para a liga 304 à temperatura ambiente e proposto um procedimento de otimização envolvendo algoritmo genético (GA) e redes neurais. Levou-se em consideração que os ensaios de dureza apresentam vantagens em relação aos testes padrão de tração e compressão e que a simulação em elementos finitos conjuntamente com algoritmos de otimização pode ser empregada para identificar os parâmetros elásticos, plásticos e de dano de um material. Foram utilizados os softwares ABAQUS e o MATLAB. Ao serem comparadas a curva experimental, obtida no ensaio de dureza, e a curva teórica, obtida na simulação, verificou-se semelhanças na maioria das regiões, porém, há algumas diferenças especialmente na fase final.
<b>Análise de Dano – Revista: <i>Engineering Failure Analysis</i></b>	
Alves, Vinícius N.; Oliveira, Matheus M. de;  Ribeiro, Diogo; Calçada, Rui.; Cury, Alexandre. (2020).	Neste trabalho avaliou-se o desempenho de uma abordagem baseada em algoritmos genéticos (GA) aplicada a dois estudos de caso. O primeiro caso referiu-se a um modelo bidimensional de uma hipotética ponte ferroviária, onde a eficiência e robustez de cinco indicadores diferentes são avaliados considerando três cenários de dano. No segundo caso, uma verdadeira ponte ferroviária foi considerada. Os resultados obtidos mostraram que a abordagem proposta foi capaz de detectar, localizar e quantificar múltiplos danos com vários parâmetros de atualização e poucas respostas de destino.
Cao, Ke; Yue, Zhen- ming; Zhao, Xiao-di; Qi, Jiashuo; Gao, Jun. (2019).	Neste artigo, o modelo de dano dúctil foi escolhido para investigar o comportamento de deformação do aço DP600. O algoritmo da região de confiança e o algoritmo genético são usados com a ajuda do MATLAB para a identificação de três parâmetros de dano. A eficiência do processo de otimização com o algoritmo de região de confiança é maior, no entanto, apresenta menor precisão. Verificou-se ainda que o processo de otimização é muito afetado pelos valores iniciais escolhidos para os parâmetros de dano dúctil.
<b>Fadiga – Revista: <i>Fatigue Fracture of Engineering Materials &amp; Structures</i></b>	
Zhou, Kun; Sun, Xingyue; Shi, Shouwen; Song, Kai; Chen Xu. (2021).	Neste trabalho foi proposto um método de aprendizagem de máquina integrando a rede neural artificial (ANN) e o algoritmo parcial de quadrados mínimos (PLS) para identificar as características genéticas através da otimização da previsão de vida em fadiga. Vinte e sete espécimes de aço inoxidável 316LN sob cargas uniaxial e multiaxial foram usados como exemplos. Como resultados, os dados de fadiga precoce foram comprovados como interessantes informativos para a previsão de vida em fadiga e cinco características genéticas foram verificadas favorecendo o desenvolvimento de um modelo para identificar essas características e prever a vida útil da fadiga de outros materiais sob diferentes cargas.

<b>Ident. Parâm. – Ver.: <i>Journal of Power Sources, Hindawi – Mathematical Problems in Engineering</i></b>	
Choi, Yun Young; Kim, Seongyoon; Kim, Soowhan; Choi, Jung-il (2020).	Este trabalho propõe um método de identificação de parâmetros para um modelo VRFB de baterias de fluxo de vanádio. O método proposto consiste de três aspectos: uma avaliação baseada na Matriz de Informações de Fisher (FIM) para verificar o melhor subconjunto de parâmetros a serem identificados, uma modelagem numérica do modelo VRFB e um algoritmo genético (GA) para estimar parâmetros ideais para o modelo. Na otimização introduziu-se uma função de aptidão envolvendo os erros quadrados médios da tensão entre os dados experimentais disponíveis e os resultados do modelo VRFB. O método foi validado calculando-se intervalos de confiança dos parâmetros de identificação a partir dos estados de tensão de carga obtidos de um pequeno experimento e comparando-se as curvas do modelo de parâmetro identificado com as obtidas experimentalmente. A robustez do método proposto foi verificada através de sua aplicação a uma pilha VRFB em escala kW utilizando eletrólitos mistos avançados. As curvas de tensão de capacidade previstas pelo modelo de parâmetro identificado mostraram boa concordância com as obtidas experimentalmente em várias condições de operação, com erros relativos médios inferiores a 1,9%.
Blaise, Bale Baidi; Betchewe, Gambo; Beda Tibi (2019).	Neste artigo é apresentado um método de identificação dos parâmetros do modelo de Ogden - densidade de energia utilizada na modelagem do comportamento de materiais hiperelásticos e que possui um alto número de parâmetros de materiais a serem identificados. Foi adotado um Algoritmo Genético (GA). O módulo permitiu identificar rapidamente bons parâmetros o que deu ao modelo Ogden uma previsibilidade muito boa em relação às tensões uniaxial, biaxial e de cisalhamento.
Sanches, Fábio Dalmazzo; Pederiva, Robson (2008).	Este trabalho apresentou uma metodologia de identificação dos parâmetros de rigidez e amortecimento dos mancais de rolamento de um sistema mecânico rotativo excitado estocasticamente. O método proposto é baseado na equação matricial de Ljapunov onde é possível apenas o acesso às variáveis de estado do sistema, não sendo necessário o conhecimento da excitação de caráter estocástico. Usando as propriedades de correlações das variáveis de saída foi possível encontrar relações entre os parâmetros físicos do sistema e as matrizes de correlações das variáveis medidas no domínio do tempo. O modelo utilizado foi aplicado a uma bancada experimental modelada por um sistema de rotativo com quarenta graus de liberdade. Os resultados numéricos demonstraram a viabilidade da metodologia proposta para a identificação de parâmetros físicos em sistemas rotativos.
Dong, Xiaoma; Chen Lifei. Parameter (2022).	Com o objetivo de superar as deficiências dos métodos de análise de deslocamento inteligente existentes foi proposto, neste trabalho, um método de identificação de parâmetros para o modelo elasto-plástico 3D da engenharia de túneis. Desenvolveu-se o SVR, um algoritmo com características peculiares, capaz de resolver o problema transformando a saída multidimensional em uma saída unidimensional padrão multicamadas. Combinou-se o algoritmo SVR com um algoritmo genético gerando-se o GA-SVR. O objetivo do algoritmo genético foi procurar parâmetros ideais para o modelo SVR, a fim de estabelecer a melhor relação de mapeamento não linear entre os parâmetros a serem identificados e o deslocamento. A título de comparação, o algoritmo genético também foi combinado com a rede neural BP para formar um segundo algoritmo, o GA-BP, e compilar o programa de cálculo correspondente. Os resultados indicaram que o algoritmo GA-SVR pode alcançar maior precisão de identificação e melhor eficiência de cálculo do que o algoritmo GA-BP.
Yin, Zhen-Yu; Jin, Yin-Fu; Shen, Shui-Long; Huang, Hong-Wei (2017).	Neste trabalho foi proposto um método de otimização para identificar os parâmetros do modelo constitutivo avançado para argilas estruturadas a partir de testes triaxiais convencionais. Primeiramente, propôs-se um novo algoritmo genético (RCGA) combinando dois novos operadores de crossover e mutação para melhorar o desempenho da otimização. Adotou-se um modelo elástico-viscoplastico que envolveu características de anisotropia do material. Foram selecionados testes laboratoriais sendo alguns deles usados para o processo de otimização e outros para a validação. O processo de otimização foi realizado utilizando o novo RCGA em conjunto com um algoritmo genético clássico (NSGA-II) para comparações de precisão e desempenho. A nova otimização mostrou-se confiável e houve uma redução nos custos de teste.

<b>Ident. Parâm. – Ver.: <i>Journal of Power Sources, Hindawi – Mathematical Problems in Engineering</i></b>	
Marouani, H.; Hergli, K.; Dhahri, H.; Fouad, Y. (2019).	A implementação e identificação computacional do modelo de histerese em simulações eletromagnéticas são necessárias para obter uma solução com alta precisão dentro de um tempo razoável. Muitos estudos sobre identificação de histerese foram relatados, mas poucos comparam métodos diferentes para identificar o ideal. Neste trabalho focou-se no modelo de histerese Preisach combinado com a função de distribuição modificada de Lorentz para descrever o comportamento magnético de uma folha de aço Fe-3wt% Si totalmente processada sob excitação estática. Três diferentes técnicas de identificação foram implementadas e avaliadas: otimização de enxame de partículas (PSO), algoritmos genéticos (GA) e aproximação de quadrados não lineares com base no método Levenberg-Marquardt (LM). Avaliou-se cada abordagem em relação à precisão, tempo central de computação da unidade de processamento e repetibilidade dos resultados. Todas as técnicas tiveram um bom desempenho neste problema de alta não linearidade, no entanto, a implementação do GA foi mais complexa do que os métodos PSO e LM. Os parâmetros otimizados são obtidos em poucos minutos no caso do método LM, mas algumas horas são necessárias para as outras duas técnicas. Portanto, o método LM mostrou-se ser a técnica mais adequada para a identificação da histerese Preisach.
<b>Materiais – Revistas: <i>International Journal of Impact Engineering, Journal of Magnetism and Magnetic Materials, Smart Materials and Structures,</i></b>	
Zhai, Yue; Zhao, Ruifeng; Li, Yubai; Li, Yan; Meng, Fandong; Wang, Tienan (2021)	No estudo das propriedades mecânicas dinâmicas de diferentes amostras de rocha tem-se resultados muito heterogêneos incidindo-se em um processo aleatório de deformação e estresse. Neste trabalho é desenvolvido um método que considera os parâmetros do modelo constitutivo dinâmico do material rochoso como variáveis aleatórias. Experimentos de compressão de choque sob congelamento e danos de resfriamento de alta temperatura são apresentados para ilustrar o método proposto. Diferentes algoritmos de otimização, como Algoritmo Genético e Otimização de Colônia de Formigas são usados para comparar a precisão dos parâmetros de inversão. Os resultados mostraram que a precisão de ajuste de estresse de pico obtida do modelo constitutivo dinâmico foi significativamente melhorada. O intervalo de confiança de 95% considerando erros de modelo cobre quase completamente as observações experimentais, indicando que o intervalo de distribuição de probabilidades do parâmetro pode cobrir com precisão o valor real, refletindo a incerteza do modelo.
Pelteret, Jean-Paul; Walter, Bastian; Steinmann, Paul (2018).	Neste trabalho avaliou-se a eficácia de uma coleção de algoritmos metaheurísticos canônicos e elitistas na realização da identificação de parâmetros para leis constitutivas não lineares que descrevem materiais acoplados responsivos à campos magnéticos. Para isso, definiu-se uma função objetiva que captura a influência de muitas medidas físicas registradas durante a análise experimental de um material acoplado e incorpora a influência da incerteza experimental. Além do ranking baseado em um teste estatístico não paramétrico, considerou-se um critério ad hoc que representa apenas as soluções de candidatos de melhor desempenho. Verificou-se que o algoritmo genético forneceu o melhor desempenho geral em termos de precisão dos parâmetros previstos, enquanto o algoritmo <i>Simulated Annealing</i> forneceu o melhor equilíbrio entre precisão e eficiência computacional.
Jin, Yin-Fu; Wu, Ze-Xiang; Yin, Zhen-Yu; Shen, Jack Shuilong (2017).	Neste artigo discutiu-se a seleção de um modelo numérico apropriado para aplicações geotécnicas. Foram avaliadas três fórmulas de linha de estado crítico em conjunto com duas fórmulas de efeito de intertravamento sendo estas combinadas em seis diferentes modelos elastoplásticos. Quatro foram os materiais granulares selecionados para simulações. Foi proposto um novo método híbrido baseado em algoritmo genético para a identificação dos parâmetros de cada material granular em cada um dos modelos e o desempenho foi avaliado por análise de elementos finitos. Todas as comparações demonstraram resultados simulados relativamente mais satisfatórios.

<b>Materiais – Revistas: <i>International Journal of Impact Engineering, Journal of Magnetism and Magnetic Materials, Smart Materials and Structures,</i></b>	
Wang, Xiaojuan; Zhang, Guangcai; Wang, Xiaomei; Ni Pinghe (2020).	Neste trabalho foram propostos quatro métodos diferentes para identificação de parâmetros com base na função de correlação para identificar estruturas sujeitas a múltiplas excitações ambientais desconhecidas. Desenvolveu-se os métodos gradiente, algoritmo genético, otimização de enxame de partículas (PSO) e um método híbrido PSO e gradiente. Investigou-se os efeitos da seleção do ponto de referência, do número de pontos de dados, as condições iniciais desconhecidas e erros de modelagem na exatidão dos resultados de identificação. Os resultados numéricos e experimentais mostraram que os métodos propostos são capazes de identificar os parâmetros estruturais destacando-se o método híbrido PSO e gradiente que alcançou o melhor desempenho considerando-se a precisão e os demais aspectos computacionais envolvidos.
Do, Huy Q.; Aragón, Alejandro M.; Schott, Dingena L. (2017).	Este trabalho visou desenvolver uma metodologia para calibração automatizada de propriedades microscópicas de materiais granulares modelados. O calibrador proposto pode ser aplicado para configurações experimentais diferentes. Duas abordagens de otimização foram adotadas: um algoritmo genético e um método de otimização direta, usados para identificar parâmetros discretos do modelo como, por exemplo, coeficientes de atrito deslizante e de rolamento. Foram desenvolvidos dois casos de teste que destacaram a robustez, estabilidade e confiabilidade dos dois algoritmos usados.
Skrlec Andrej; Klemenc Jernej (2020).	O objetivo deste artigo foi apresentar um método para determinar os valores de parâmetros dependentes da taxa de tensão aplicada ao material. O procedimento de otimização descrito combina a técnica de <i>Design-Of-Experiment</i> (DoE), simulações em elementos finitos, modelagem de superfície de resposta e um algoritmo evolutivo. Um experimento dinâmico foi projetado para estudar o comportamento de chapas metálicas finas e planas durante um impacto. Os dados experimentais desta dinâmica e os experimentos convencionais de tração para aço leve foram a base para a determinação dos parâmetros do modelo de Johnson-Cook. Os valores identificados dos parâmetros, estimados com o procedimento apresentado, foram muito semelhantes aos da literatura.
<b>Ligas e Compósitos – Revista: <i>Journal of Alloys and Compounds</i></b>	
Wang, Yuntia; Zeng, Xiangguo; Sheng, Ying; Yang, Xin; Wang, Fang. (2020).	Neste trabalho foi desenvolvido um modelo constitutivo para descrever o comportamento mecânico da liga Ti-6Al-4V em uma ampla faixa de taxas de tensão e temperaturas. Foram descritas as relações entre os parâmetros do modelo constitutivo e a microestrutura característica do material. O modelo constitutivo contém 12 parâmetros e para a obtenção destes foi desenvolvida uma abordagem a partir dos dados experimentais existentes. Inicialmente, fez-se uma análise da sensibilidade dos parâmetros constitutivos e em um segundo momento desenvolveu-se um algoritmo genético avançado com diversas novas características que foram aplicadas para melhorar o desempenho na busca dos parâmetros avaliados. Os resultados previstos concordaram razoavelmente bem com os dados experimentais.
<b>Física – Revista: <i>Physica B</i></b>	
Hergli, Khaoula; Marouani, Haykel; Zidi, Mondher (2018).	As propriedades magnéticas dos materiais ferromagnéticos são sensíveis à deformação mecânica, à tensão térmica e à frequência de excitação. Este trabalho trata da caracterização do comportamento de materiais ferromagnéticos sob deformação plástica. Levou-se em consideração a deformação plástica no modelo analítico de Jiles-Atherton cujos parâmetros foram identificados utilizando-se uma abordagem via algoritmo genético para cada estado de deformação. Ao final, o erro quadrático médio foi inferior a 5% para cada caso, o que confirmou uma boa concordância entre as curvas de histerese simulada e medida.

Inteligência Computacional e Neurociência – Revista: <i>Hindawi – Computational Intelligence and Neuroscience</i>	
Qin, Hong (2022).	A identificação de parâmetros tem sido amplamente utilizada na modelagem de sistemas complexos ou sistemas cujos parâmetros não são fáceis de se determinar. Com o desenvolvimento da tecnologia de controle, a escala do objeto de controle tem crescido, o que torna a quantidade de cálculos do algoritmo identificador cada vez maior. Neste trabalho é proposto o método dos mínimos quadrados para a estimação de parâmetros com uma menor quantidade de cálculos. Os resultados mostram que o método proposto pode superar o fenômeno da "saturação dos dados" melhorando os resultados na busca pelos melhores parâmetros.

**Fonte:** Quadro idealizado pelo autor do presente texto.

Na próxima seção será apresentado o Algoritmo Genético (GA) (LINDEN, 2012), primeiro componente do método híbrido desenvolvido neste trabalho.

## 2.2. ESTRATÉGIAS EVOLUTIVAS (EE) E O ALGORITMO GENÉTICO (GA)

Os Métodos Evolucionários ou Algoritmos Evolutivos baseiam-se em modelos computacionais dos processos naturais de evolução biológica como ferramentas para resolução de problemas. A ideia de aplicar os princípios da evolução natural remonta a trabalhos da década de 1950 (SPALL, 2003). Ao longo do tempo, três abordagens mais gerais foram desenvolvidas de forma independente: a Programação Evolutiva (PE) de Fogel *et al.* (1966), cujo objetivo era utilizar os conceitos de evolução no desenvolvimento da inteligência artificial, as Estratégias Evolutivas (EE) desenvolvidas por Rechenberg (1973) para solucionar problemas de otimização de parâmetros e os Algoritmos Genéticos (GA) elaborados por Goldberg (1989) e Holland (1992) que buscavam obter soluções computacionais eficientes para problemas de otimização de diversos tipos. Apesar de haver uma grande variedade de modelos computacionais já em aplicação ou ainda em estudo dentro desses grupos, todos são algoritmos estocásticos que têm em comum o conceito de simulação da evolução das espécies (GOUVÊA, 2016; SOBRINHO, 2014).

Normalmente, tem-se uma população de estruturas, os indivíduos ou cromossomos, que são submetidas aos chamados operadores genéticos. Estes consistem em aproximações computacionais de fenômenos presentes na natureza, como, por exemplo, a reprodução sexuada, a mutação genética e o crossover. A cada indivíduo atribui-se uma avaliação que corresponde à quantificação de sua “qualidade” como solução do problema em questão. É com base nessa avaliação que são continuamente aplicados os operadores genéticos procurando-se simular a sobrevivência do indivíduo mais apto (GOUVÊA, 2016; SOBRINHO, 2014).



Dentre estes algoritmos ditos evolucionários, os Algoritmos Genéticos são os mais comumente utilizados. O algoritmo genético ou GA é um algoritmo de busca aleatória seletivo projetado para alcançar um ideal global dentro de um grande espaço de soluções. Durante o processo de otimização utiliza-se apenas o valor da função objetivo, não sendo exigidas características como a continuidade e a diferenciabilidade da função. Para problemas não convexos, como é o caso de identificação de parâmetros, as estratégias evolutivas em conjunto com esses métodos alcançam boa aproximação na obtenção do máximo global dentro da região de busca. Além disso, o algoritmo, em geral, é paralelizável, podendo ser resolvido com multiprocessamento e em uma rede de computadores (GOUVÊA, 2016; SOBRINHO, 2014; LINDEN, 2012).

A estrutura básica destes métodos consiste em dois passos fundamentais: seleção e reprodução onde há a aplicação dos operadores genéticos. O passo inicial é a geração de um conjunto de vetores de variáveis de projeto  $\{p_1, p_2, \dots, p_{n_i}\}$  denominado população inicial. Em geral, a população inicial é criada a partir da escolha aleatória de pontos dentro da região viável, sendo que cada vetor  $p_i$  é denominado de indivíduo da população. O número de indivíduos da população inicial,  $n_i$ , é uma variável do método que é definida *a priori*. Na metodologia mais usual dos algoritmos genéticos, cada parâmetro do vetor de variáveis de projeto é expresso como um número binário visando uma maior facilidade na aplicação das operações de reprodução. Cada algarismo (1 ou 0) do vetor de parâmetros é denominado de gene do indivíduo. O número de algarismos usados para cada parâmetro é dependente da precisão desejada e a transformação dos parâmetros em números binários é conhecida como processo de codificação (SOBRINHO, 2014; LINDEN, 2012).

No processo de decodificação, para a conversão de binário em decimal, utiliza-se a expressão:

$$v_{real} = \text{inf}_i + \frac{\text{sup}_i - \text{inf}_i}{2^k - 1} \times \text{vinteiro} \quad \text{Equação 2.03}$$

onde **inf<sub>i</sub>** e **sup<sub>i</sub>** correspondem aos limites inferior e superior da faixa de operação de cada variável e **vreal** é o valor real correspondente ao **vinteiro** oriundo da conversão do número binário em inteiro. Após a criação da população inicial, realiza-se a avaliação da função objetivo de cada um dos indivíduos (LINDEN, 2012).

O próximo passo corresponde ao processo de seleção, ou seja, a escolha dos indivíduos que irão para a etapa de reprodução. O método de seleção utilizado no presente estudo é conhecido como método da roleta. Nesta técnica, cada indivíduo possui uma fração da roleta correspondente ao seu valor na sua função objetivo. Os indivíduos com melhores valores ocupam maiores regiões apresentando desta forma maiores probabilidades de serem selecionados (LINDEN, 2012).

Realizada a seleção dos indivíduos, os operadores genéticos de combinação (*crossover*) e mutação são aplicados. No processo de combinação ocorre a geração de dois novos indivíduos (filhos) a partir da combinação dos genes de dois outros indivíduos previamente selecionados (pais). É selecionado de forma aleatória o gene a partir do qual será feita a combinação. No processo de mutação o indivíduo sofre perturbações em seus parâmetros de acordo com uma determinada taxa. A mutação impede que o método tenha uma convergência precoce para um mínimo local (SOBRINHO, 2014; LINDEN, 2012).

A taxa de mutação é uma variável do algoritmo. Para cada gene é gerado um número aleatório, se este número estiver abaixo ou igual à taxa de mutação, o gene é alterado de 0 para 1 ou vice-versa. O processo básico de funcionamento de um Algoritmo Genético é apresentado na Quadro 2.02.

**Quadro 2.02** Sequência Básica de um Algoritmo Genético.

---

1. Gerar aleatoriamente a população inicial e determinar um parâmetro de convergência  $\epsilon > 0$ .
2. Iniciar as iterações de  $n = 1$  à  $n_{max}$ :
  - 2.1. Calcular a função objetivo de cada indivíduo da população. Se o critério de convergência for satisfeito ou  $n = n_{max}$ , o processo é encerrado. Caso não o seja, segue-se para o próximo passo.
  - 2.2. Aplicar o processo de seleção para determinar os indivíduos que poderão se reproduzir.
  - 2.3. Aplicar os operadores genéticos de combinação (*crossover*) e mutação.
  - 2.4. Atualizar a população e voltar para o passo 2.1.
3. Retornar o grupo de indivíduos com melhores aptidões.

---

**Fonte:** Quadro idealizado pelo autor do presente texto.

No desenvolvimento do Algoritmo Genético (GA) é comum utilizar um único operador genético, no caso, o operador de combinação (*crossover*) associado à mutação de *bits*. O operador de combinação recebe uma probabilidade bem maior que o operador de mutação, já que a reprodução é a responsável pela combinação de esquemas, enquanto

a mutação tem como função apenas preservar a diversidade genética da população de possíveis soluções (SOBRINHO, 2014; LINDEN, 2012).

Os Algoritmos Genéticos (GAs), assim como os demais Algoritmos Evolutivos trabalham com uma população e não com um único indivíduo, um único ponto, apresentando a vantagem de dificilmente ficarem limitados a um mínimo local em comparação aos métodos que realizam a busca ponto a ponto, além de serem facilmente adaptáveis a problemas com diversos tipos de variáveis e funções objetivo (RANGAIAH, 2010).


É importante observar que os GA's podem sofrer convergência prematura em algumas aplicações, além de apresentarem vários parâmetros a serem ajustados. Contudo, essas desvantagens podem ser atenuadas adicionando-se procedimentos específicos e mesmo estratégias evolutivas para manter a diversidade da população (LACERDA *et al*, 1999).

Segundo Linden (2012), um bom Algoritmo Genético deve embutir o máximo de conhecimento sobre o problema, observando-se sua representação, os operadores genéticos e a função de avaliação. Certamente, é possível utilizar um algoritmo pronto mudando sua função de avaliação e tentando resolver o problema, no entanto, a experiência tem mostrado que dificilmente se obtém um rendimento melhor do que o apresentado por um algoritmo específico desenhado para a classe de problemas em discussão.

A criação de um Algoritmo Genético para ser usado na busca por parâmetros de encruamento de materiais foi um dos motivos para o desenvolvimento de um GA que fosse capaz de abarcar diversas estratégias evolucionárias. Nos trabalhos de Dong *et al*. (2022), Zhai *et al* (2021), Zhou *et al* (2021), Sedighiani *et al* (2020), Fernández *et al* (2020), Wang *et al* (2020), Choi *et al* (2020), Alves *et al* (2020), Blaise *et al* (2019), Petureau *et al* (2019), Han *et al* (2019) e Yin *et al* (2017) observa-se um rol de estratégias aplicadas a situações semelhantes às enfrentadas no presente trabalho.

No desenvolvimento do método, após a montagem do Algoritmo Genético padrão representativo da sequência de ações descritas no Quadro 2.01, procurou-se melhorar o desempenho do algoritmo inserindo diversos aperfeiçoamentos descritos nos trabalhos indicados anteriormente além das adaptações referentes ao problema em avaliação.


Inicialmente, separou-se os operadores de combinação dos operadores de mutação, atribuindo-se a cada um deles diferentes valores de avaliação.



**Figura 2.01** Funcionamento do crossover de dois pontos.  
**Fonte:** Figura adaptada de Linden (2012, p. 135)

Além do crossover de um ponto, foram inseridos tipos diferenciados de combinação (LINDEN, 2012):

- o crossover de dois pontos (Figura 2.01). Seu funcionamento é similar ao do crossover de 1 ponto, no entanto, são sorteados dois pontos de corte. O primeiro filho será formado pela parte do primeiro pai fora dos pontos de corte e pela parte do segundo pai entre os pontos de corte e o segundo filho será formado pelas partes restantes;
- o crossover uniforme (Figura 2.02). Para cada gene é sorteado um número zero ou um. Se o valor sorteado for igual a um (1), o primeiro filho recebe o gene da posição corrente do primeiro pai e o segundo filho o gene corrente do segundo pai, caso o valor sorteado seja igual a zero (0), as atribuições serão invertidas, o primeiro filho receberá o gene da posição corrente do segundo pai e o segundo filho recebe o gene corrente do primeiro pai;
- o crossover baseado em maioria. A operação básica aqui realizada consiste em sortear n pais e fazer com que cada bit do filho seja igual ao valor da maioria dos correspondentes bits nos pais selecionados.



**Figura 2.02** Funcionamento do crossover uniforme.  
**Fonte:** Figura adaptada de Linden (2012, p. 139)

Boa parte dos pesquisadores procura resolver o problema da convergência genética tornando a mutação mais provável que o crossover. O problema é que ao utilizar o operador de mutação tradicional, todas as partes de cada uma das soluções têm igual probabilidade de serem modificadas, sem distinção, e caso estejam concentradas no esquema dominante não apresentarão mudanças significativas o que torna necessária a aplicação de modificações agressivas. Com este intuito desenvolveu-se um operador de mutação dirigida gerando-se um novo operador que se concentra nos esquemas dominantes, de forma a criar variedade genética nos genes de maior interesse. O operador funciona de maneira simples. Ele só começa a agir após um maior número de gerações. Quando ativado, ele busca as  $n$  melhores soluções dentro da população padrão e verifica qual é a bagagem cromossômica que elas têm em comum. Ao descobrir o esquema dominante dentro de uma codificação binária, pode-se aplicar um operador lógico XOR (ou exclusivo) entre todos os  $n$  elementos dois a dois. O resultado desta operação é o 0 (zero) nas posições onde todos os indivíduos são iguais e 1 (um) onde há algum elemento diferente (SOBRINHO, 2014; LINDEN, 2012).

Em relação à população, foram inseridos o elitismo e o *steady state* sem duplicatas, além do fato de se trabalhar com populações de tamanho variável ao longo do tempo. O elitismo é uma pequena modificação no tratamento da população que não altera o tempo de processamento, mas que garante que o desempenho do GA sempre cresça com o decorrer das gerações. O *steady state* sem duplicatas não permite que um indivíduo idêntico a alguém já presente na população seja inserido novamente no grupo, possibilitando assim uma maior variabilidade genética. O aumento e a possível redução da população em momentos específicos é outro fator que possibilita um maior rendimento do algoritmo, favorecendo a inserção de um maior número de indivíduos quando a avaliação apresenta melhoras ou se mantém constante ao longo das gerações e a retirada de indivíduos quando a avaliação apresenta quedas (LINDEN, 2012).

É importante salientar que a diversidade dentro da população deve ser mantida. A convergência só deve ocorrer no conjunto de possíveis soluções finais ao longo das gerações. Para ajudar na determinação da ocorrência de convergência genética desenvolveu-se uma função de densidade dos indivíduos, ou seja, estruturou-se uma “tabela de frequências” onde foram geradas classes e verificada a frequência de cada uma. O objetivo é eliminar um efeito espúrio da convergência genética que é o fato de haver

várias soluções que representam aproximadamente os mesmos esquemas (LINDEN, 2012).

O conjunto de ações realizadas pelo módulo em linguagem PYTHON desenvolvido para o Algoritmo Genético (GA) pode ser visualizado no Quadro 2.03.

**Quadro 2.03** Algoritmo Genético desenvolvido.

---

1. Gerar aleatoriamente a população inicial e determinar um parâmetro de convergência  $\epsilon > 0$ .
  2. Iniciar as iterações de  $n = 1$  à  $n_{max}$ :
    - 2.1. Calcular a função objetivo de cada indivíduo da população. Se o critério de convergência for satisfeito ou  $n = n_{max}$ , o processo é encerrado. Caso não o seja, segue-se para o próximo passo.
    - 2.2. Aplicar o processo de seleção para determinar os indivíduos que poderão se reproduzir.
    - 2.3. Aplicar os operadores genéticos de combinação (crossover) e mutação.
    - 2.4. Verificar a existência de indivíduos idênticos na população. Caso haja, deve-se substituí-los. Verifica-se novamente a existência de indivíduos idênticos. Se não houver, segue-se para o próximo passo.
    - 2.5. Atualizar a população.
    - 2.6. Verificar a geração. Em uma geração mais avançada iniciar a inserção dos indivíduos de melhor avaliação de gerações anteriores (Elite).
    - 2.7. Analisar os valores obtidos para a função de avaliação de gerações anteriores e da atual. Caso estejam constantes ou em ascensão aumentar o tamanho da população, se não, reduzir o tamanho.
    - 2.8. Voltar para o passo 2.1.
  3. Retornar o grupo de indivíduos com melhores aptidões.
- 

**Fonte:** Quadro idealizado pelo autor do presente texto.

Após a montagem do módulo GA constituído por diversas rotinas representativas das ações desempenhadas pelo algoritmo genético idealizado (Quadro 2.03), realizou-se alguns testes para verificar o seu funcionamento e a sua convergência. Em seu trabalho, Sobrinho (2014) estudou algumas funções que foram aqui reutilizadas como base para os testes. São elas:

$f_1: [-2, 1] \times [-2, 1] \rightarrow \mathbb{R}$ , definida por:

$$f_1(x, y) = 6 + x^2 + y^2 - 3 \times \cos(2\pi x) - 3 \times \cos(2\pi y) \quad \text{Equação 2.04}$$

$f_2: [-20,3 , 19,6] \times [-20,3 , 19,6] \rightarrow \mathbb{R}$ , definida por:

$$f_2(x, y) = 0,5 - \frac{\text{sen}^2(\sqrt{x^2 + y^2}) - 0,50}{(1 + 0,001 \times (x^2 + y^2))^2} \quad \text{Equação 2.05}$$

$f_3: [-4 , 2] \times [-4 , 2] \rightarrow \mathbb{R}$ , definida por:

$$f_3(x, y) = \frac{1}{0,30 + x^2 + y^2} \quad \text{Equação 2.06}$$

Estas funções apresentam características desafiadoras para a busca de um valor máximo. As funções  $f_1$  (Equação 2.04) e  $f_2$  (Equação 2.05), por exemplo, têm diversos cumes e a função  $f_3$  (Equação 2.06) tem um máximo no ponto (0, 0). Um método gradiente, se iniciado em um ponto qualquer, pode finalizar sua busca em um máximo local não alcançando um máximo global. Nas Figuras 2.03, 2.04 e 2.05 pode-se observar a superfície correspondente a cada uma das funções avaliadas e uma representação dos pontos pertencentes à elite do GA para populações fixas e mutáveis ao longo de 6 gerações. Considerando-se as regiões de domínio indicadas para cada função, verifica-se uma real proximidade entre os valores obtidos no GA e os valores máximos das funções.

Para finalizar o estudo sobre o GA desenvolvido foi adicionado ao módulo uma rotina de busca gradiente que utilizasse os valores finais advindos do próprio GA como pontos de partida. O método escolhido foi o algoritmo de *Broyden-Fletcher-Goldfarb-Shanno*, conhecido por “BFGS” (CHAPRA, 2008). Observando-se os resultados discriminados na Tabela 2.01, tem-se que:

- para a função  $f_1$ , as populações iniciais de 6, 10 ou 20 indivíduos fixas ou mutáveis apresentaram boa convergência com o GA, recaindo em uma área que permitiu a convergência do método BFGS para o máximo global da função na região de domínio especificada. Em apenas um momento o GA recaiu em uma área de máximo local;
- para a função  $f_2$ , o GA apresentou diversos pontos que apontaram regiões distintas para o BFGS, no entanto, quatro dentre as seis convergiram para o valor de máximo global;

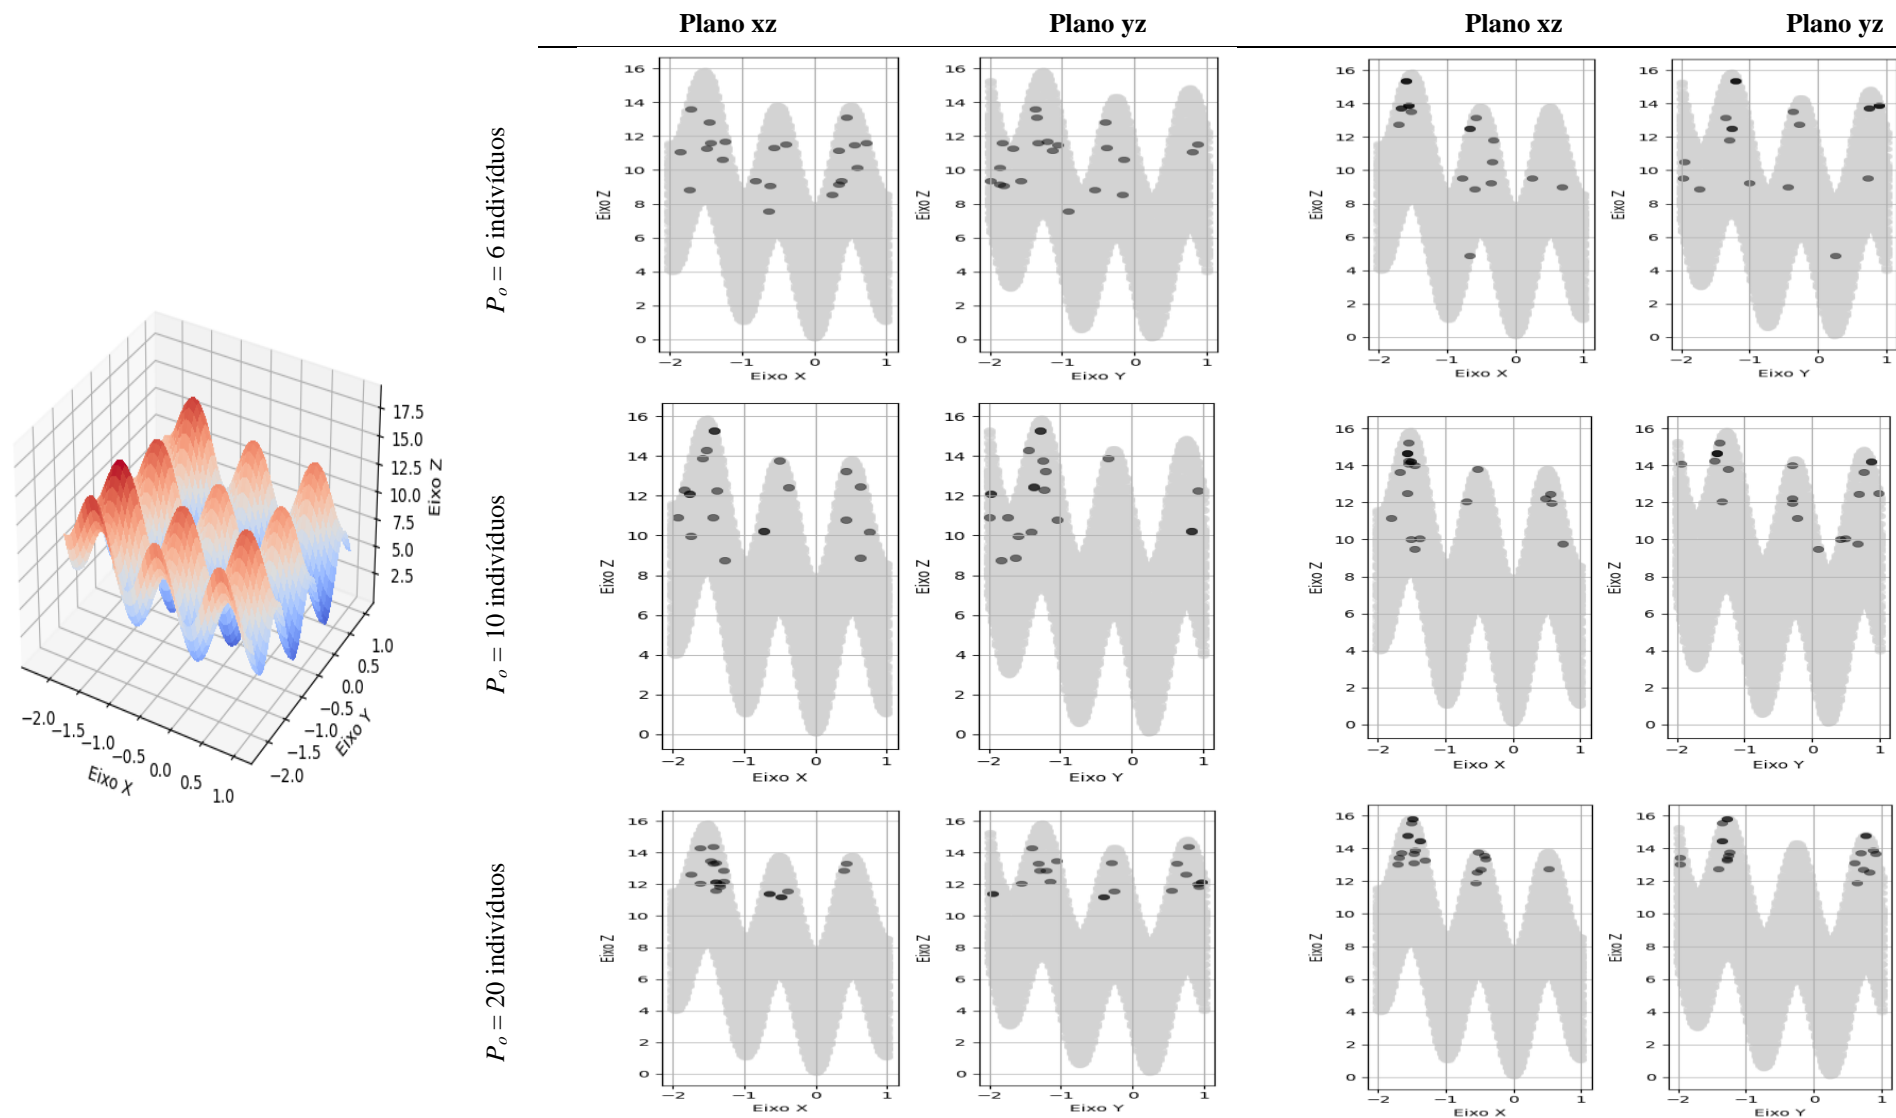
- para a função  $f_3$ , todos os resultados oriundos do GA levaram o BFGS para o máximo global da função, no entanto, observando-se os valores obtidos, verificou-se a necessidade de aumentar a precisão dos parâmetros em análise no GA.

**Tabela 2.01.** Valores finais obtidos no GA para diferentes populações e seu uso como valores iniciais no método BFGS.

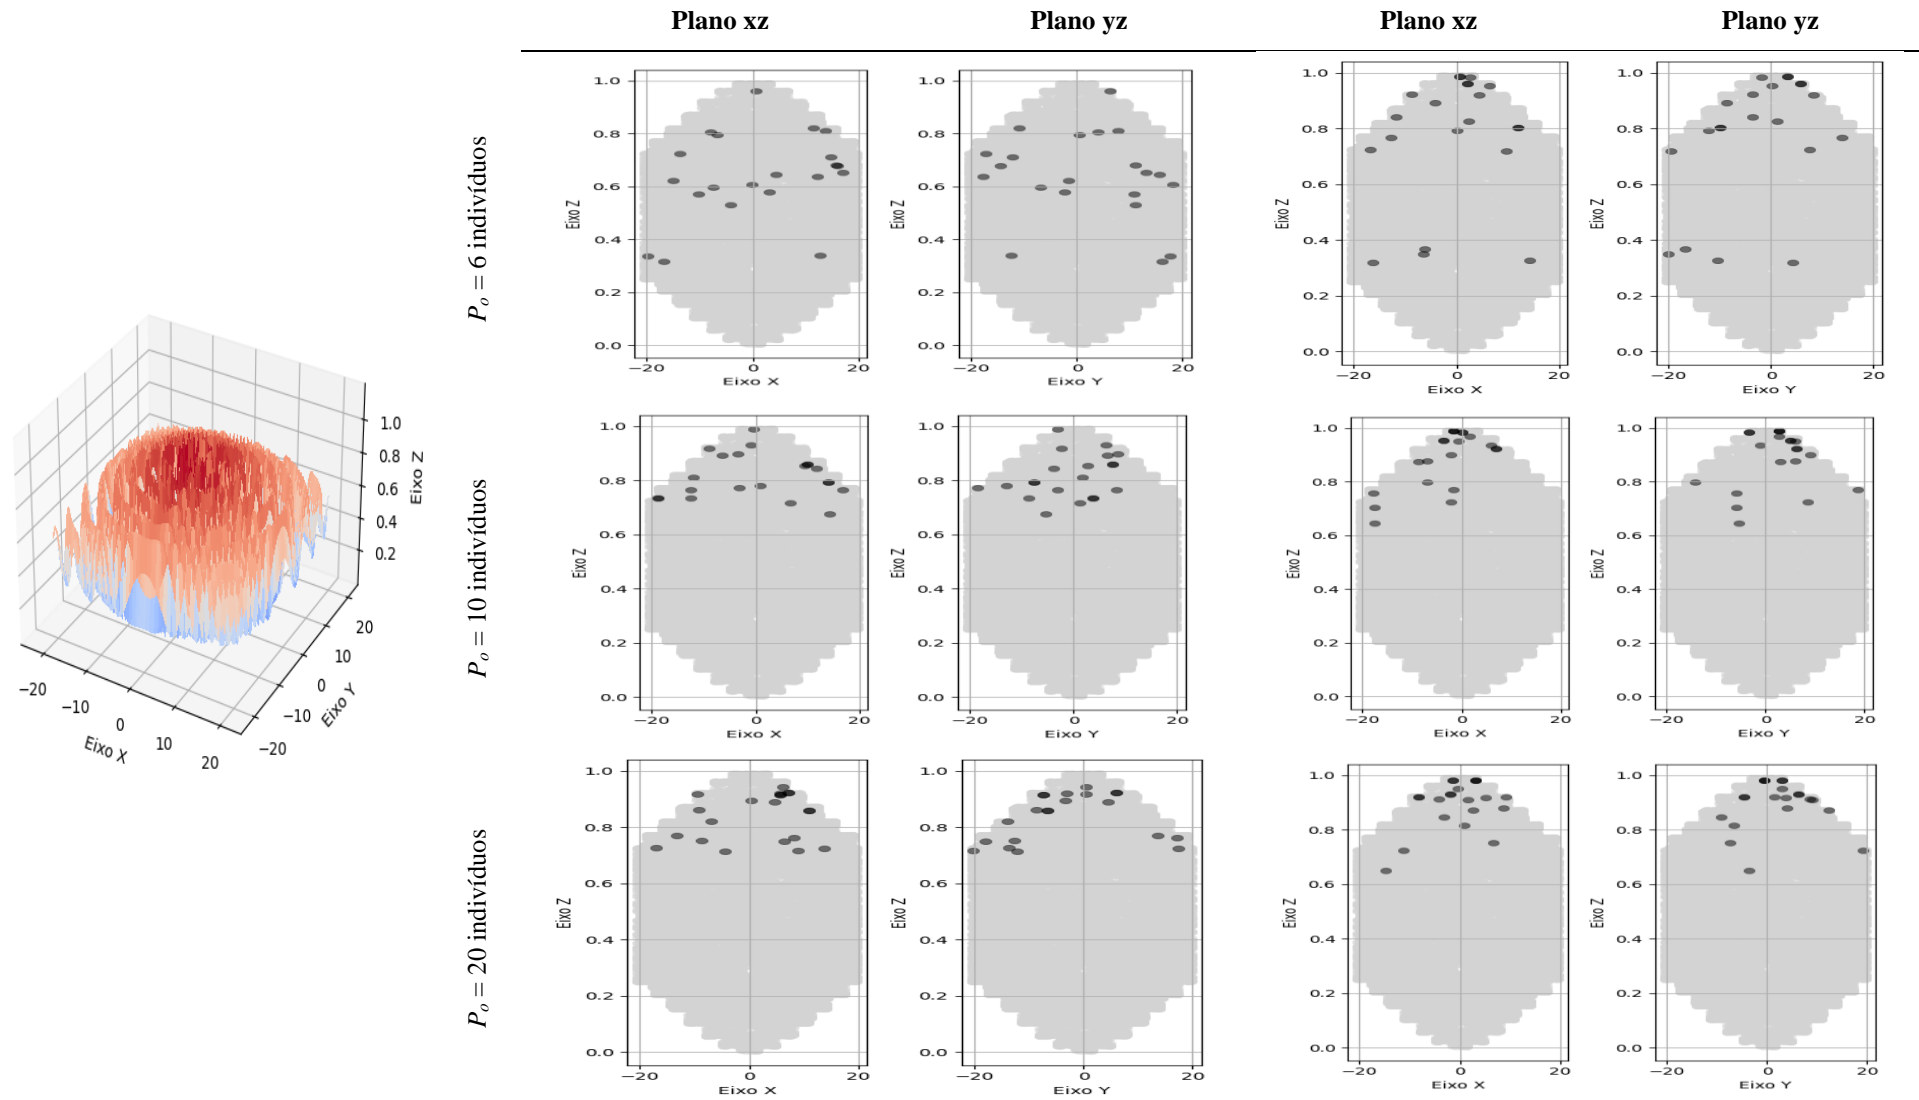
Tamanho da população	GA			BFGS		
	x	y	z	x	y	z
<i>Função <math>f_1</math></i>						
P6/Fixa	-1,71832	-1,36846	13,62520	-1,52587	-1,27152	15,87812
P6/Mutável	-1,60197	-1,21370	15,36672	-1,52588	-1,27154	15,87812
P10/Fixa	-1,42536	-1,29043	15,27668	-1,52589	-1,27155	15,87812
P10/Mutável	-1,54929	-1,37639	15,25474	-1,52588	-1,27153	15,87812
<b>P20/Fixa</b>	<b>-1,43435</b>	<b>0,77956</b>	<b>14,36185</b>	<b>-1,52588</b>	<b>0,76290</b>	<b>14,86090</b>
P20/Mutável	-1,49019	-1,27514	15,80360	-1,52588	-1,27154	15,87812
<i>Função <math>f_2</math></i>						
<b>P6/Fixa</b>	<b>0,53550</b>	<b>6,30502</b>	<b>0,96041</b>	<b>0,53122</b>	<b>6,25462</b>	<b>0,96278</b>
<b>P6/Mutável</b>	<b>0,62992</b>	<b>3,14372</b>	<b>0,98579</b>	<b>0,61661</b>	<b>3,07732</b>	<b>0,99028</b>
<b>P10/Fixa</b>	<b>-0,37901</b>	<b>-3,14110</b>	<b>0,98965</b>	<b>-0,37597</b>	<b>-3,11589</b>	<b>0,99028</b>
<b>P10/Mutável</b>	<b>-1,60928</b>	<b>2,75618</b>	<b>0,98752</b>	<b>-1,58251</b>	<b>-2,71033</b>	<b>0,99028</b>
<b>P20/Fixa</b>	<b>6,11454</b>	<b>0,37943</b>	<b>0,94180</b>	<b>6,26509</b>	<b>0,38877</b>	<b>0,96278</b>
<b>P20/Mutável</b>	<b>-1,42124</b>	<b>2,90664</b>	<b>0,98108</b>	<b>-1,37862</b>	<b>2,81948</b>	<b>0,99028</b>
<i>Função <math>f_3</math></i>						
P6/Fixa	-0,16047	-0,08780	2,99887	6,87e-07	3,1e-07	3,33333
P6/Mutável	-0,29264	0,40938	1,80757	4,63e-07	-6,67e-07	3,33333
P10/Fixa	0,00426	-0,28302	2,63076	-1,46e-08	-4,55e-07	3,33333
P10/Mutável	-0,12826	0,17045	2,89432	6,05e-07	-8,21e-07	3,33333
<b>P20/Fixa</b>	<b>0,00880</b>	<b>0,00690</b>	<b>3,33194</b>	<b>2,44e-07</b>	<b>1,90e-07</b>	<b>3,33333</b>
P20/Mutável	-0,29216	-0,03856	2,58502	2,78e-07	2,968e-08	3,33333

**Fonte:** Tabela idealizada pelo autor do presente texto.

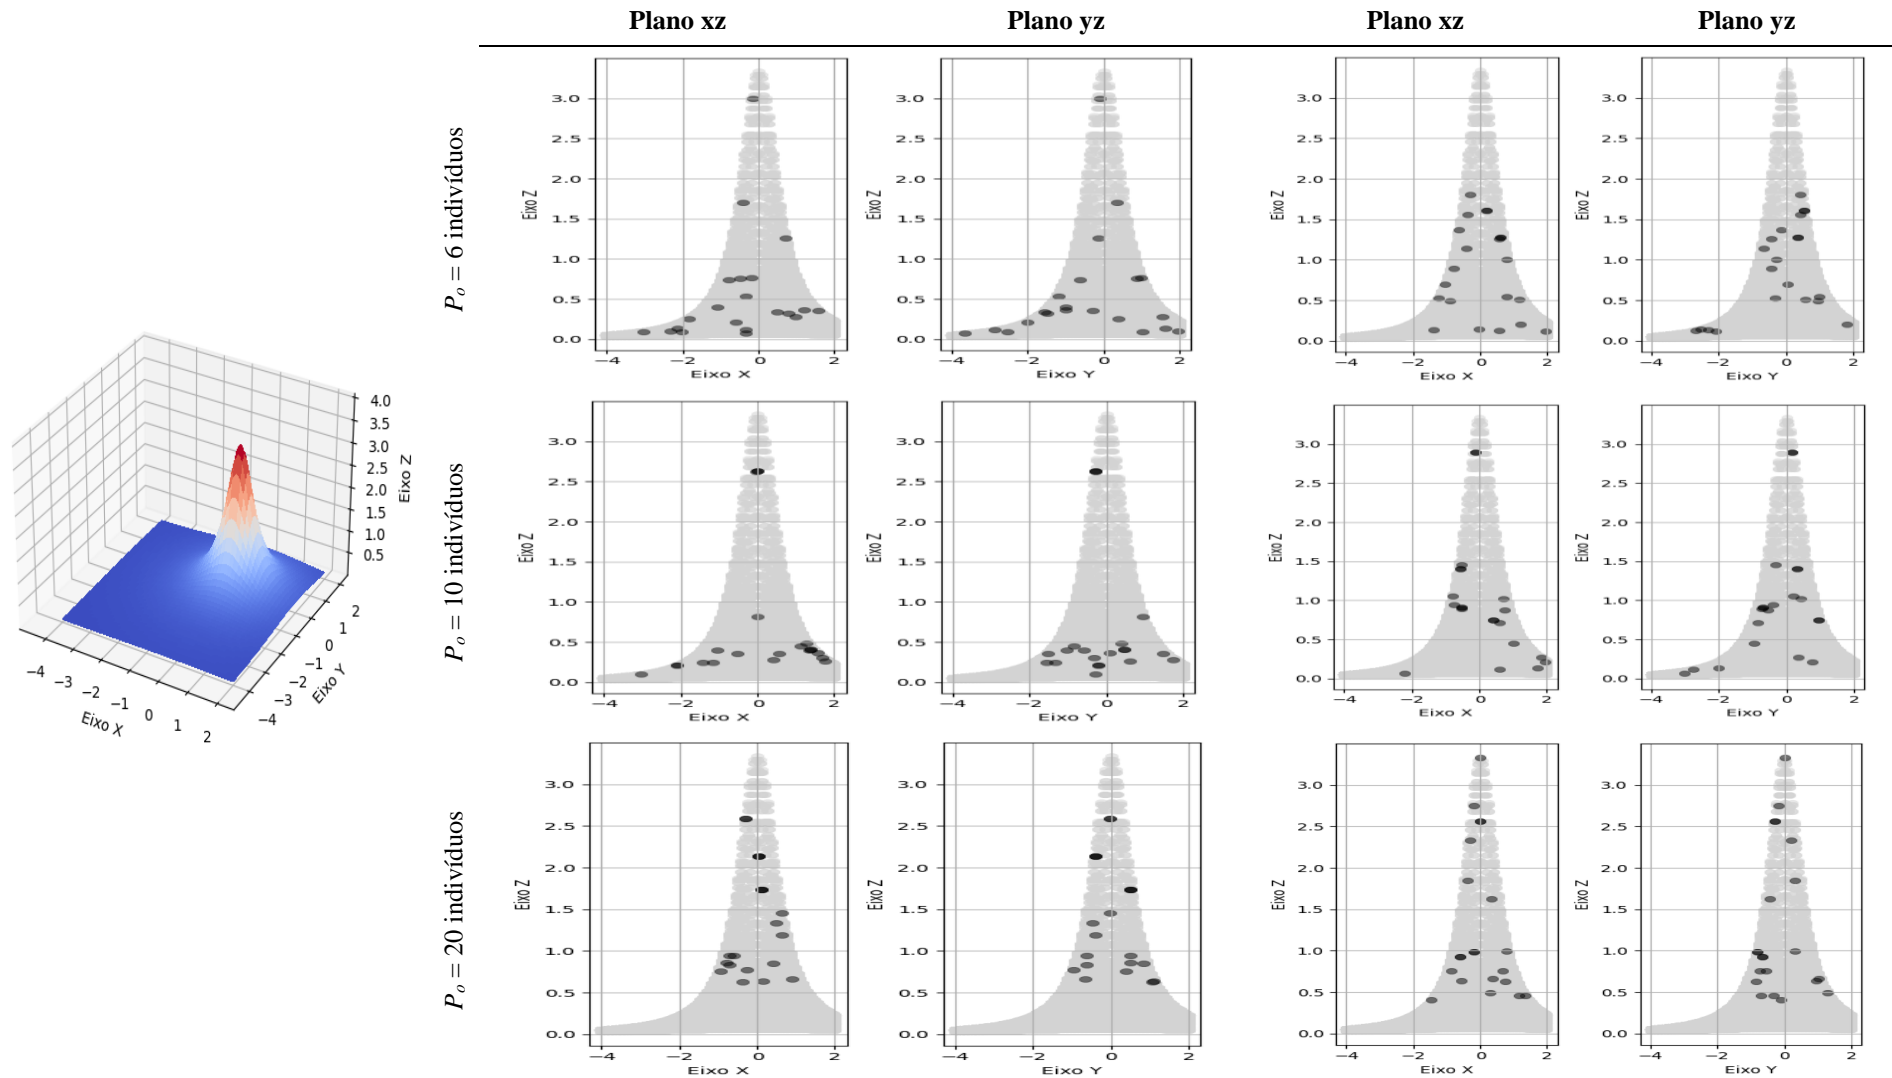




**Figura 2.03.** Superfície referente à função  $f_1$  com cortes nos planos xz e yz e os pontos de maior valoração obtidos ao longo de 6 gerações do GA ( $P_o$  = população inicial). **Fonte:** Figura idealizada pelo autor do presente texto



**Figura 2.04.** Superfície referente à função  $f_2$  com cortes nos planos  $xz$  e  $yz$  e os pontos de maior valoração obtidos ao longo de 6 gerações do GA ( $P_0$  = população inicial). **Fonte:** Figura idealizada pelo autor do presente texto



**Figura 2.05.** Superfície referente à função  $f_3$  com cortes nos planos  $xz$  e  $yz$  e os pontos de maior valoração obtidos ao longo de 6 gerações do GA ( $P_o$  = população inicial). **Fonte:** Figura idealizada pelo autor do presente texto

Deve-se salientar que os valores obtidos ao se analisar as funções  $f_1$ ,  $f_2$  e  $f_3$  revelaram a necessidade de alterar os parâmetros do GA para cada situação a ser enfrentada, seja aumentando ou reduzindo a população, o número de gerações, a precisão das variáveis pesquisadas, os percentuais para aplicação dos operadores genéticos crossover e mutação, além do estudo da elite formada e da própria função objetivo em avaliação. Na próxima seção será apresentado o algoritmo de Levenberg-Marquardt (FRANÇA *et al.*, 2009), segunda etapa do método híbrido desenvolvido no presente trabalho.

### 2.3. O ALGORITMO DE LEVENBERG-MARQUARDT DIVIDIDO (LMD)

Técnicas para a otimização multidimensional sem restrições podem ser classificadas de diversas formas. É muito comum a divisão em grupos levando-se em consideração o fato de trabalharem ou não com o cálculo de derivadas. As abordagens que exigem o cálculo de derivadas são chamadas métodos gradientes ou de declive (ou aclone) e aquelas que não o exigem são chamadas de não-gradientes ou métodos diretos (CHAPRA *et al.*, 2008, p. 306).

Dentre os diversos métodos gradientes observados em literatura foi selecionado, para a realização do presente trabalho, o Algoritmo de Levenbert-Marquardt ou Algoritmo LM. Este método tem por objetivo obter soluções numéricas para problemas de minimização de funções, muitas vezes não lineares e dependentes de diversas variáveis. Baseado nos métodos de Gauss-Newton e da máxima inclinação ascendente, oferece o melhor dos dois mundos, caminha de forma lenta, mas confiável, para valores iniciais insatisfatórios e acelera rapidamente quando se aproxima do ponto ótimo. Mais estável que o método de Gauss-Newton pode chegar a soluções mesmo não estando próximo ao ponto procurado, no entanto, se próximo de um mínimo local não é capaz de contorná-lo para continuar a busca até o mínimo global, levando-se em consideração um intervalo de pesquisa limitado (CHAPRA *et al.*, 2008, p. 321).

Nos parágrafos seguintes será apresentada de forma modesta o desenvolvimento do algoritmo de Levenbert-Marquardt (FRANÇA *et al.*, 2009).

Considerando-se uma relação não-linear

$$\mathcal{F}(Y) = X \quad \text{Equação 2.07}$$

onde  $\mathbf{X} \in \mathbb{R}^m$  e  $\mathbf{Y} \in \mathbb{R}^n$  são vetores e  $m \geq n$ , são comuns os problemas onde é necessário estimar o vetor  $\hat{\mathbf{Y}}$  que melhor se ajuste a um vetor  $\hat{\mathbf{X}}$  medido. Reformulando-se tal ideia chega-se a seguinte questão: dado o vetor  $\hat{\mathbf{X}}$  qual deverá ser  $\hat{\mathbf{Y}}$  de forma a minimizar  $\|\epsilon\|$  estando sujeito a lei:

$$\hat{\mathbf{X}} = \mathcal{F}(\hat{\mathbf{Y}}) + \epsilon. \quad \text{Equação 2.08}$$

Para uma estimativa inicial  $\hat{\mathbf{Y}}$ , o conhecido método de Newton (PRESS *et al*, 1992) propõe seu refinamento assumindo que

$$\mathcal{F}(\hat{\mathbf{Y}} + \Delta) = \mathcal{F}(\hat{\mathbf{Y}}) + \mathbf{J}\Delta \quad \text{Equação 2.09}$$

onde  $\mathbf{J}$  é a matriz jacobiana, ou seja,

$$\mathbf{J} = \frac{\partial \mathbf{X}}{\partial \mathbf{Y}} \quad \text{Equação 2.10}$$

e  $\Delta$  é um incremento de  $\hat{\mathbf{Y}}$ . Desta forma, minimizar  $\|\epsilon\|$  corresponde a minimizar

$$\|\epsilon - \mathbf{J}\Delta\| \quad \text{Equação 2.11}$$

ou ainda, a resolver

$$\mathbf{J}^T \mathbf{J} \Delta = \mathbf{J}^T \epsilon \quad \text{Equação 2.12}$$

A solução da Equação 2.12 tem a apreciável característica de poder ser continuamente refinada, sendo dada por

$$\hat{\mathbf{Y}}_r = \hat{\mathbf{Y}} + \Delta \quad \text{Equação 2.13}$$

Levenberg (1944) propôs uma alteração no algoritmo de Newton para acelerar sua convergência introduzindo um parâmetro  $\lambda_k$  (parâmetro de Levenberg-Marquardt). Assim, tem-se uma reestruturação da Equação 2.12 e a equação do problema passa a ser

$$(\mathbf{J}^T \mathbf{J} + I\lambda_k)\Delta = \mathbf{J}^T \epsilon \quad \text{Equação 2.14}$$

É importante observar que este método apresenta instabilidades numéricas quando o parâmetro  $\lambda_k$  cresce. Em vista disso, Marquardt (1963) apresentou uma pequena alteração no algoritmo propondo que cada componente do gradiente fosse ponderada de acordo com sua curvatura. Com esta alteração tem-se uma maior tendência de convergência na direção em que o gradiente é menor.

Na prática, tal alteração é implementada substituindo-se a Equação 2.14 por:

$$(\mathbf{J}^T \mathbf{J} + \text{diag}(\mathbf{J}^T \mathbf{J}) \cdot \lambda_k) \Delta = \mathbf{J}^T \boldsymbol{\epsilon} \quad \text{Equação 2.15}$$

A complexidade do algoritmo Levenberg-Marquardt aumenta com o número de variáveis a serem tratadas, mas, em geral, este fator pode ser minimizado observando-se as características do problema em questão.

Considerando-se que  $\mathbf{Y}$  na Equação 2.07 pode ser particionado

$$\mathbf{Y} = [\mathbf{c}^T, \mathbf{d}^T]^T \quad \text{Equação 2.16}$$

e a matriz jacobiana,  $\mathbf{J}$  da Equação 2.11, também pode ser dividida em blocos, no caso,

$$\mathbf{J} = [\mathbf{C} \mid \mathbf{D}] \quad \text{onde } \mathbf{C} = \frac{\partial \mathbf{X}}{\partial \mathbf{c}} \text{ e } \mathbf{D} = \frac{\partial \mathbf{X}}{\partial \mathbf{d}} \quad \text{Equação 2.17}$$

Retornando-se a Equação 2.12, tem-se

$$\begin{bmatrix} \mathbf{C}^T \mathbf{C} & \mathbf{C}^T \mathbf{D} \\ \mathbf{D}^T \mathbf{C} & \mathbf{D}^T \mathbf{D} \end{bmatrix} \begin{bmatrix} \delta_c \\ \delta_d \end{bmatrix} = \begin{bmatrix} \mathbf{C}^T \boldsymbol{\epsilon} \\ \mathbf{D}^T \boldsymbol{\epsilon} \end{bmatrix} \quad \text{onde } \Delta = [\delta_c^T, \delta_d^T]^T \quad \text{Equação 2.18}$$

Com algumas manipulações algébricas a Equação 2.18 pode ser reduzida a

$$\begin{bmatrix} \mathbf{U} - \mathbf{G}\mathbf{V}^{-1} & \mathbf{0} \\ \mathbf{G}^T & \mathbf{V} \end{bmatrix} \begin{bmatrix} \delta_c \\ \delta_d \end{bmatrix} = \begin{bmatrix} \boldsymbol{\epsilon}_c - \mathbf{G}\mathbf{V}^{-1}\boldsymbol{\epsilon}_d \\ \boldsymbol{\epsilon}_d \end{bmatrix} \quad \text{Equação 2.19}$$

onde  $\mathbf{C}^T \mathbf{C}$ ;  $\mathbf{G} = \mathbf{C}^T \mathbf{D}$ ;  $\mathbf{V} = \mathbf{D}^T \mathbf{D}$ ;  $\boldsymbol{\epsilon}_c = \mathbf{C}^T \boldsymbol{\epsilon}$  e  $\boldsymbol{\epsilon}_d = \mathbf{D}^T \boldsymbol{\epsilon}$

A solução para a Equação 2.19 é desenvolvida em duas etapas. A primeira consiste na busca por  $\delta_c$  :

$$(\mathbf{U} - \mathbf{G}\mathbf{V}^{-1}\mathbf{G}^T) \delta_c = \boldsymbol{\epsilon}_c - \mathbf{G}\mathbf{V}^{-1}\boldsymbol{\epsilon}_d \quad \text{Equação 2.20}$$

e a segunda consiste na busca por  $\delta_d$  :

$$\mathbf{V}\delta_d = \boldsymbol{\epsilon}_d - \mathbf{G}^T \delta_c \quad \text{Equação 2.21}$$

O parâmetro  $\lambda_k$  é ajustado a cada nova iteração. Se o processo de minimização for rápido, pode-se usar um valor menor para  $\lambda_k$ , o que aproxima o algoritmo LM do algoritmo de Newton, caso não seja eficiente, aumenta-se o valor de  $\lambda_k$ , aproximando o algoritmo LM do algoritmo da máxima inclinação ascendente.

Considera-se que os vetores  $\mathbf{d}$ , na Equação 2.16, e  $\mathbf{X}$  também podem ser divididos em  $n$  partes menores, ou seja,  $\mathbf{d} = [d_1^T, d_2^T, \dots, d_n^T]^T$  e  $\mathbf{X} = [X_1^T, X_2^T, \dots, X_n^T]^T$ , além disso, cada observação  $X_i$  depende apenas dos vetores  $\mathbf{c}$  e  $\mathbf{d}_i$  e de nenhum outro  $\mathbf{d}_k$ , assim, a matriz jacobiana apresentará uma estrutura esparsa em que  $\partial X_i / \partial d_k = 0$  para  $i \neq k$ . A Equação 2.11 pode ser reescrita como:

$$\begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix} - \begin{bmatrix} C_1 & D_1 & & \\ & C_2 & D_2 & \\ & \vdots & \ddots & \\ & & & C_n & D_n \end{bmatrix} \begin{bmatrix} \delta_c \\ \delta_{d_1} \\ \vdots \\ \delta_{d_n} \end{bmatrix} \quad \text{Equação 2.22}$$

onde  $C_i = [\partial X_i / \partial \mathbf{c}]$  e  $D_i = [\partial X_i / \partial \mathbf{d}_i]$  e  $\epsilon = \hat{\mathbf{X}} - \mathcal{F}(\hat{\mathbf{c}}, \hat{\mathbf{d}}) = [\epsilon_1^T, \epsilon_2^T, \dots, \epsilon_n^T]^T$

No Quadro 2.04 pode-se observar um algoritmo que resume as ideias apresentadas nas linhas anteriores e que permitiu a codificação do método LM em linguagem computacional para sua posterior união ao Algoritmo Genético neste trabalho.

**Quadro 2.04** Algoritmo Levenberg-Marquardt com adaptações.

- 
1. Entrada: uma estimativa inicial particionada em um vetor  $\hat{\mathbf{Y}} = [\mathbf{c}^T, \mathbf{d}_1^T, \mathbf{d}_2^T, \dots, \mathbf{d}_n^T]^T$  para todos os parâmetros a serem refinados e um conjunto de observações em vetor  $\mathbf{X} = [X_1^T, \dots, X_n^T]^T$
  2. Substituir  $\hat{\mathbf{Y}}$  em  $\mathcal{F}(\mathbf{Y}) = \mathbf{X}$  encontrando-se  $\hat{\mathbf{X}} = [\hat{X}_1^T, \dots, \hat{X}_n^T]^T$
  3. Calcular todas as matrizes  $\mathbf{C}_i = [\partial \hat{X}_i / \partial \mathbf{c}]$  e  $\mathbf{D}_i = [\partial \hat{X}_i / \partial \mathbf{d}_i]$
  4. Calcular:
    - 4.1.  $\mathbf{U} = \sum_{i=1}^n \mathbf{C}_i^T \mathbf{C}_i$ .
    - 4.2.  $\mathbf{V} = \text{diag}(V_1, \dots, V_n)$ , onde  $V_i = D_i^T D_i$
    - 4.3.  $\mathbf{G} = [G_1, \dots, G_n]$ , onde  $G_i = C_i^T D_i$
    - 4.4.  $\epsilon_c = \sum_{i=1}^n C_i^T \epsilon_i$
    - 4.5.  $\epsilon_D = [\epsilon_{D_1}^T, \dots, \epsilon_{D_n}^T]^T$  onde  $\epsilon_{D_i} = D_i^T \epsilon_i$
  5. Calcular  $\delta_c$  resolvendo:  $(\mathbf{U} - \sum_{i=1}^n G_i V_i^{-1} G_i^T) \delta_c = \epsilon_c - \sum_{i=1}^n G_i V_i^{-1} \epsilon_{D_i}$
  6. Calcular cada  $\delta_{d_i}$  resolvendo  $\delta_{d_i} = V_i^{-1} (\epsilon_{D_i} - G_i^T \delta_c)$ .
  7. Computar os parâmetros refinados,  $\hat{\mathbf{Y}}_r = \hat{\mathbf{Y}} + [\delta_c^T, \delta_{d_1}^T, \dots, \delta_{d_n}^T]^T$
  8. Repetir todos os passos de 2 a 7 até a convergência do resíduo.
- 

**Fonte:** Quadro adaptado de FRANÇA *et al.* (2009)

Após a montagem do módulo LM, constituído por rotinas representativas das ações indicadas no Quadro 2.04 e de uma rotina já desenvolvida na Linguagem PYTHON

acessível em pacotes para otimização (LMFIT, 2023) e distribuídos livremente pelos órgãos gestores do projeto PYTHON, realizou-se alguns testes para verificar o seu funcionamento e a sua convergência. Utilizando as funções  $f_1$  (Equação 2.04),  $f_2$  (Equação 2.05) e  $f_3$  (Equação 2.06) já citadas anteriormente, montou-se as Equações 2.23, 2.24 e 2.25 nas quais os parâmetros a serem investigados são os próprios coeficientes das equações:

$f_1: [-2, 1] \times [-2, 1] \rightarrow \mathbb{R}$ , definida por:

$$f_1(x, y) = c_1 + c_2x^2 + c_3y^2 + c_4 \cos(2\pi x) + c_5 \cos(2\pi y) \quad \text{Equação 2.23}$$

$f_2: [-20,3, 19,6] \times [-20,3, 19,6] \rightarrow \mathbb{R}$ , definida por:

$$f_2(x, y) = c_1 - \frac{\text{sen}^2(\sqrt{x^2 + y^2}) - c_2}{(c_3 + c_4 \times (x^2 + y^2))^2} \quad \text{Equação 2.24}$$

$f_3: [-4, 2] \times [-4, 2] \rightarrow \mathbb{R}$ , definida por:

$$f_3(x, y) = \frac{1}{c_1 + c_2x^2 + c_3y^2} \quad \text{Equação 2.25}$$

O objetivo de tal procedimento foi verificar se o módulo LM retornaria os valores dos coeficientes tendo por base um conjunto de pontos gerados pela própria função inicial. Foram criados arquivos de dados com diversos pontos tomando-se o cuidado de varrer todo o espaço do domínio indicado para cada função. Utilizou-se o módulo GA inicialmente para obter os valores de partida e após executou-se o LM. Os resultados obtidos podem ser vistos nas Tabelas 2.02, 2.03 e 2.04.

**Tabela 2.02.** Valores advindos do GA e valores finais do LM para a Equação 2.23 em três testes.

T e s t e	GA					LM					It e r a ç õ e s n o L M
	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>	C <sub>5</sub>	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>	C <sub>5</sub>	
(A)	6,91	0,79	-0,22	-1,73	-3,95	6,00	1,00	1,00	-3,00	-3,00	6
(B)	5,97	3,65	-2,37	-3,44	-3,56	6,00	1,00	1,00	-3,00	-3,00	6
(C)	6,73	2,29	-0,58	-0,71	-3,43	6,00	1,00	1,00	-3,00	-3,00	6

**Fonte:** Tabela idealizada pelo autor do presente texto.



**Tabela 2.03.** Valores advindos do GA e valores finais do LM para a Equação 2.24 em três testes.

T e s t e	GA				LM				Iterações no LM
	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>	
(A)	0,53	2,62	9,57	4,86	0,50	-0,50	-1,00	-0,001	40
(B)	0,52	-7,84	0,004	2,97	0,50	-0,50	1,00	0,001	22
(C)	0,51	-3,42	0,61	-0,46	0,50	-0,50	-1,00	-0,001	15

**Fonte:** Tabela idealizada pelo autor do presente texto.

**Tabela 2.04.** Valores advindos do GA e valores finais do LM para a Equação 2.25 em três testes.

T e s t e	GA			LM			Iterações no LM
	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	
(A)	0,31	6,67	0,34	0,3	1,00	1,00	6
(B)	0,27	0,57	0,91	0,3	1,00	1,00	5
(C)	0,32	0,67	2,16	0,3	1,00	1,00	5

**Fonte:** Tabela idealizada pelo autor do presente texto.

Verifica-se pelos resultados apresentados nas Tabelas 2.02, 2.03 e 2.04 que foi possível obter os coeficientes das funções em análise, a convergência do LM foi alcançada. As diferenças verificadas entre os valores advindos do GA e os valores finais do LM podem ser justificadas levando-se em consideração que:

- o GA é um algoritmo de maximização e o LM de minimização, o que levou ao uso de funções objetivo distintas. Para o LM utilizou-se a norma euclidiana da diferença relativa entre os resultados experimentais e os resultados numéricos (Equação 2.02) e para o GA utilizou-se o inverso desta norma:

$$h(p) = \frac{1}{1 + g(p)} \quad \text{Equação 2.26}$$

- o GA é um algoritmo estocástico, que trabalha em um intervalo de busca amplo, necessitando de muitas iterações para alcançar indivíduos com os mais altos valores para a função objetivo, ou seja, nem sempre irá convergir para um muito valor próximo a um ponto de máximo da função;

- o GA possui diversas variáveis que podem ser ajustadas para uma busca mais precisa, desde o tamanho da população, a mudança ou não dos intervalos de busca ao longo das iterações, os índices relativos aos operadores genéticos, a precisão para cada parâmetro, uso ou não da elite ao longo das gerações, e diversos outros parâmetros de ajuste, isso o faz muito interessante para tratar diferentes tipos de problema, a questão é que nem sempre o ajuste ideal para todas essas variáveis é encontrado imediatamente sendo necessário uma série de execuções para a realização de ajustes. Nos testes foram ajustados os seguintes parâmetros:

1. Intervalo de buscas para cada parâmetro: [-10, 10];
2. Mudança nos limites de busca a cada geração: Sim;
3. Percentual de mudança dos limites: 1%;
4. Ocorrência de mutação e crossover independentes: Sim;
5. Tipo de crossover utilizado: crossover 2 pontos;
6. Aplicação do operador crossover: por interpolação linear;
7. Probabilidade inicial do crossover: 90%;
8. Probabilidade final do crossover: 30%;
9. Probabilidade de mutação: 20%;
10. Quantidade de gerações a serem analisadas: 6;
11. Tamanho da população inicial: 20;
12. Adição da elite à população: Sim;
13. Frequência de adição da elite à população: a cada 2 gerações;
14. Redimensionamento da população: Sim;
15. Frequência de redimensionamento: a cada 2 gerações;

#### 2.4. O MÉTODO HÍBRIDO GALM

Observando-se os resultados obtidos com o Algoritmo Genético (GA) individualmente e o conjunto formado pelo GA e o método de Levenberg-Marquardt (LMD) na busca por parâmetros, estruturou-se um método híbrido composto por ambos. Foi desenvolvida uma rotina para gerenciar a execução dos métodos permitindo ajustes do GA e do LM, montagens de gráficos, tabelas e arquivos com os resultados. Além do uso dos melhores indivíduos do GA, incluiu-se um estudo estatístico da elite, o que

também permitiu usar valores médios como entrada para o LM. O Quadro 2.05 fornece uma visão geral das atividades desenvolvidas no método híbrido.

**Quadro 2.05** Visão geral do Método Híbrido desenvolvido.

---

1. Definir e montar a função objetivo para os módulos GA e LM;
2. Aferir as configurações do GA e do LM:
  - 2.1. Indicar o número de parâmetros a ser analisado;
  - 2.2. Configurar o intervalo de busca e a precisão desejada para cada parâmetro;
  - 2.3. Indicar se serão usados ambos os módulos GA e LM ou apenas um deles;
  - 2.4. Indicar a quantidade de testes que deseja realizar;
  - 2.5. Configurar os diversos parâmetros do módulo GA:
    - 2.5.1. Tamanho da população;
    - 2.5.2. Tipo de crossover e percentuais de troca;
    - 2.5.3. Percentuais para a mutação;
    - 2.5.4. Mudança de intervalos de busca e os percentuais de aumento e reclusão;
    - 2.5.5. Tamanho da elite;
  - 2.6. Indicar as pastas locais onde serão gerados os arquivos e gráficos dos módulos;
  - 2.7. Configurar os parâmetros do módulo LM:
    - 2.7.1. Precisão de busca;
    - 2.7.2. Quantidade de iterações;
    - 2.7.3. Indicar quais dados advindos do GA devem ser usados: a melhor solução, as três melhores soluções, a média dos melhores valores da elite, etc;
3. Executar o módulo GA seguindo os passos indicados no Quadro 2.03. Ao finalizar serão criados arquivos com a elite obtida, as estatísticas e gráficos representativos das etapas do processo;
4. Executar o módulo LM com os valores advindos do GA e seguindo os passos indicados no Quadro 2.04. Ao finalizar serão criados arquivos com as iterações realizadas e gráficos representativos de cada etapa.

---

**Fonte:** Quadro idealizado pelo autor do presente texto.

Nas próximas seções serão apresentadas aplicações em que o método híbrido foi utilizado. As atividades foram iniciadas com um estudo sobre o ensaio de tração. O objetivo foi automatizar etapas do ensaio para posteriormente utilizar os valores obtidos na caracterização da curva de endurecimento isotrópico de alguns materiais.

### 3. IDENTIFICAÇÃO DA CURVA DE ENDURECIMENTO ISOTRÓPICO

O procedimento para a determinação de parâmetros constitutivos requer o conhecimento prévio de curvas experimentais do comportamento do material em análise. Essas curvas são obtidas através de ensaios mecânicos, tais como os ensaios de tração, compressão, dureza, torção, flexão e diversos outros. Neste trabalho foram utilizados os resultados do ensaio de tração de corpos de prova produzidos a partir de chapas dos aços 4340 e 1524 U2. Nas linhas seguintes serão apresentados importantes aspectos do ensaio de tração e os resultados obtidos para os materiais em estudo.

#### 3.1. O ENSAIO DE TRAÇÃO E SUAS CARACTERÍSTICAS

O Ensaio de Tração consiste na aplicação gradativa de carga de tração uniaxial crescente às extremidades de um corpo de prova específico até a ruptura. Mede-se a variação no comprimento como função da carga aplicada. No Brasil, a norma técnica que atualmente especifica o método de ensaio de tração para materiais metálicos e define as propriedades mecânicas que podem ser determinadas é a norma ABNT NBR ISO 6892-1 de 2013 em sua versão corrigida de 2018.

Este ensaio é muito utilizado na indústria de componentes mecânicos por ser relativamente simples e de realização rápida além de fornecer dados quantitativos das características mecânicas dos materiais, podendo-se destacar: o limite de resistência à tração, o limite de escoamento, o módulo de elasticidade, o módulo de resiliência, o módulo de tenacidade, a ductilidade, o coeficiente de encruamento e o coeficiente de resistência. Observa-se ainda, que seus resultados são fortemente influenciados por fatores como: temperatura, velocidade de deformação, anisotropia do material, tamanho de grão, porcentagem de impurezas e mesmo pelas condições ambientais.

##### 3.1.1. Ensaio convencional

Para a definição da tensão e deformação convencionais, considera-se uma barra cilíndrica e uniforme que é submetida a uma carga de tração uniaxial crescente.

A tensão convencional, nominal ou de engenharia ( $\sigma_c$ ) é dada por:

$$\sigma_c = \frac{P}{S_o} \quad \text{Equação 3.01}$$

onde:  $\sigma_c$  é a tensão convencional ou de engenharia (Pa);

P é a carga aplicada (N);

$S_o$  é a área da seção transversal original ( $m^2$ )

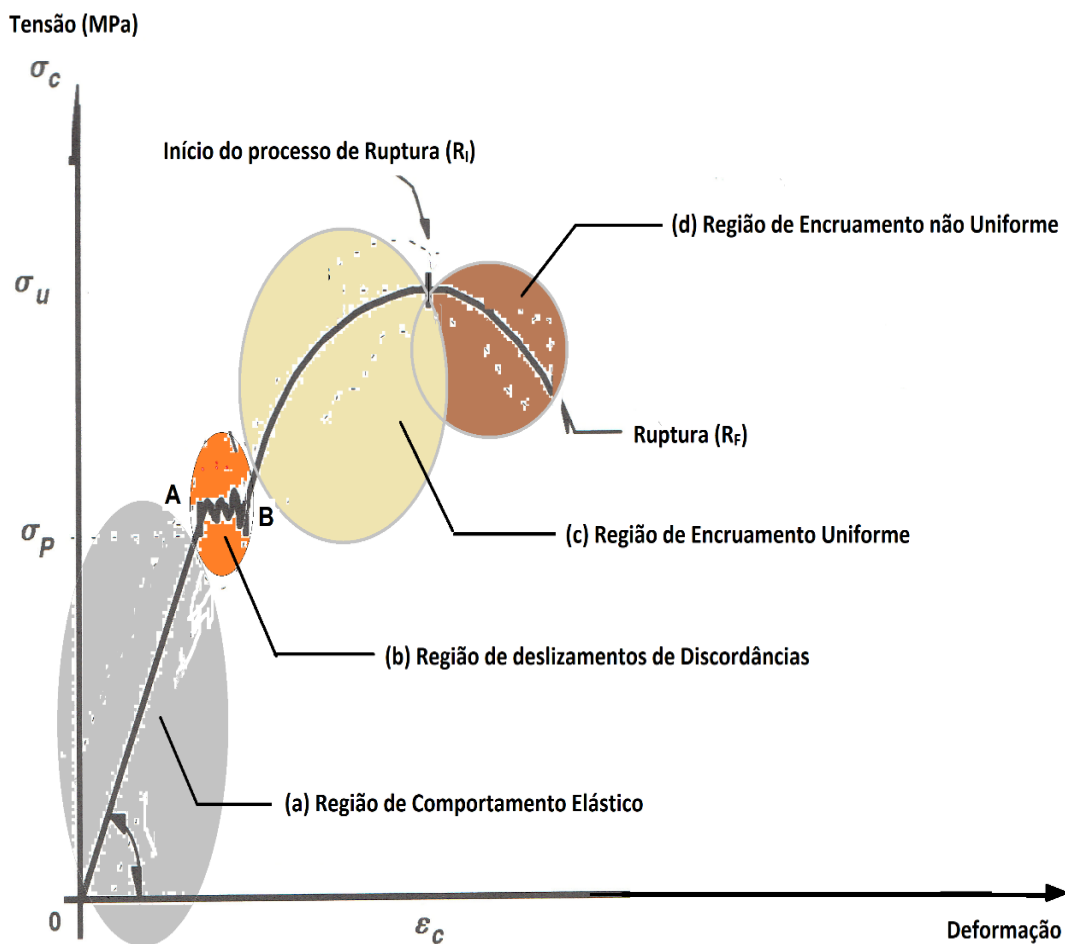
A deformação convencional, nominal ou de engenharia ( $\epsilon_c$ ) é dada por:

$$\epsilon_c = \frac{\Delta l}{l_o} = \frac{l - l_o}{l_o} = \frac{l}{l_o} - 1 \quad \text{Equação 3.02}$$

onde:  $\epsilon_c$  é a deformação convencional ou de engenharia (adimensional);

$l_o$  é o comprimento inicial de referência (m);

$l$  é o comprimento de referência para cada carga P aplicada (m)



**Figura 3.01** Esboço da curva obtida em um ensaio de tração (Curva tensão-deformação convencional ou de engenharia).

**Fonte:** Figura adaptada de Garcia (1999, p. 8)

Na Figura 3.01 tem-se quatro regiões de comportamentos distintos: (a) região de comportamento elástico; (b) região de deslizamentos de discordâncias; (c) região de

encruamento uniforme; e (d) região de encruamento não uniforme. O processo de ruptura do corpo de prova tem início no ponto  $R_I$  e é concluído no ponto  $R_F$ .

A região de comportamento elástico ou regime elástico, região (a) da Figura 3.01, corresponde aos valores de deformação que podem ser recuperados ao se interromper a aplicação da força permitindo que as dimensões originais sejam recuperadas. Essa deformação é denominada *deformação elástica*. Esse comportamento é descrito pela lei de Hooke:

$$\sigma = E \cdot \varepsilon \quad \text{Equação 3.03}$$

que descreve uma relação linear entre tensão ( $\sigma$ ) e deformação ( $\varepsilon$ ) e tem como coeficiente angular o módulo de elasticidade ( $E$ ) ou módulo de Young.

As principais tensões definidas na região elástica são:

- a) o limite de escoamento ( $\sigma_e$ ): máxima tensão que o material pode suportar sem apresentar deformação permanente após a interrupção da aplicação de carga;
- b) o limite de proporcionalidade ( $\sigma_p$ ): máxima tensão acima da qual o material não mais obedece à lei de Hooke, isto é, perde-se a linearidade entre a relação tensão-deformação.

Normalmente, considera-se  $\sigma_e = \sigma_p$

O módulo de elasticidade ( $E$ ) fornece uma indicação da rigidez do material e depende fundamentalmente das forças de ligação interatômicas, o que pode explicar seu comportamento inversamente proporcional à temperatura. É determinado pelo quociente entre a tensão convencional ou de engenharia e a deformação convencional ou de engenharia ou alongamento específico na região linear da curva tensão-deformação:

$$E = \frac{\sigma}{\varepsilon} = \frac{P \cdot l_0}{S_0 \cdot \Delta l} \quad \text{Equação 3.04}$$

Quanto maior o módulo de elasticidade ( $E$ ), menor a deformação elástica resultante na aplicação de uma determinada carga.

A inclinação da curva tensão-deformação na região de comportamento elástico indica que para manter-se a separação elástica entre os átomos do sistema é necessária uma força que cresça proporcionalmente com a distância de separação. As forças de ligação entre os átomos, e consequentemente o módulo de elasticidade ( $E$ ), são maiores para os metais com temperatura de fusão mais elevadas.

Como o espaçamento interatômico e, em alguns casos, a interação atômica devem variar com a direção em um monocristal, o módulo de elasticidade (E) é dependente da direção de aplicação da tensão nos eixos cristalográficos, ou seja, os monocristais possuem anisotropia elástica.

Para um material de alta capacidade de deformação permanente, o diâmetro do corpo de prova começa a decrescer rapidamente ao se ultrapassar a tensão máxima (ponto R<sub>1</sub>) e assim, a tensão necessária para continuar a deformação diminui até a ruptura total. É comum uma grande variação nas características das curvas tensão-deformação para diferentes tipos de materiais.

Outra importante característica do material observada nesta região é o Módulo de Resiliência ( $U_r$ ). Resiliência é a capacidade de um material absorver energia quando deformado elasticamente e liberá-la quando descarregado. O Módulo de Resiliência ( $U_r$ ) é a energia de deformação por unidade de volume necessária para tracionar o material da origem até o limite de proporcionalidade<sup>1</sup> ( $\sigma_p$ ), sua quantificação é dada pelo trabalho útil realizado, ou seja, a área sob a curva tensão-deformação calculada da origem até o limite de proporcionalidade:

$$U_r = \int_0^{\varepsilon_p} \sigma \cdot d\varepsilon = \int_0^{\varepsilon_p} E \cdot \varepsilon \cdot d\varepsilon = E \frac{\varepsilon_p^2}{2} = \frac{\sigma_p^2}{2E} \quad \text{Equação 3.05}$$

Na região de escoamento, região (b) da Figura 3.01, tem-se o de escoamento do material, fenômeno localizado que se caracteriza por um aumento relativamente grande na deformação, acompanhado por uma pequena variação na tensão. Pode ser nítido, como apresentado na curva tensão-deformação da Figura 3.01, ou imperceptível.

A norma ABNT NBR ISO 6892-1 de 2013 em sua sessão A.4.7 (pág. 39) indica que os métodos mais convenientes para determinação da inclinação na porção elástica são aqueles baseados nas características de um segmento continuamente variável e cita como parâmetros base:

- a) o comprimento do segmento continuamente variável (número de pontos empregados);
- b) a equação escolhida como referência para definir a inclinação da curva.

---

<sup>1</sup> Na prática, substitui-se o limite de proporcionalidade ( $\sigma_p$ ) pelo limite de escoamento ( $\sigma_e$ ).

Observando-se que na região de escoamento a relação entre a tensão e a deformação é linear, a inclinação da curva corresponderá à inclinação média em uma porção em que as seguintes condições devem ser atendidas:

- a) a inclinação do segmento continuamente variável é constante;
- b) a porção selecionada é representativa.

Segundo a norma, em qualquer caso, é recomendável que os limites pertinentes da porção possam ser selecionados pelo usuário com o intuito de eliminar valores não representativos da inclinação da curva na porção elástica.

A principal tensão observada na região de escoamento é o limite de escoamento ( $\sigma_e$ ). Nos casos em que o limite é imperceptível, convencionou-se adotar uma deformação dita padrão, conhecida por limite  $n$  de escoamento. O procedimento utilizado para a determinação do limite de escoamento é o apresentado na norma ASTM Standard E8-69 (Quadro 3.01), em que  $n = 0,2\%$  (Figura 3.02 (a)).

**Quadro 3.01.** Procedimento para o cálculo do limite de escoamento em metais e ligas em geral.

---

1. Obter a curva tensão-deformação de engenharia do material por meio do ensaio de tração;
2. Construir uma linha paralela à região elástica da curva, partindo de uma deformação de 0,002 ou 0,2% (eixo horizontal);
3. Definir  $\sigma_e$  na interseção da reta paralela com a curva tensão-deformação.

---

**Fonte:** Quadro idealizado pelo autor do presente texto.

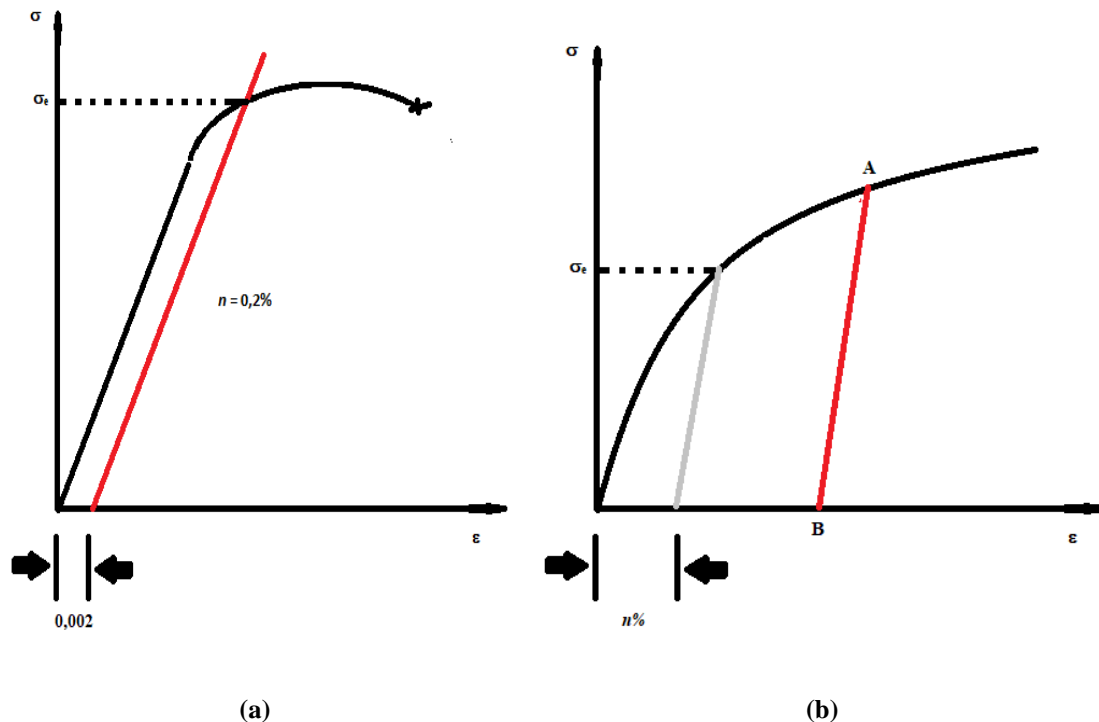
Em função do campo elástico do material,  $n$  pode assumir diferentes valores, por exemplo:

- Ligas metálicas muito duras:  $n = 0,1\%$  ( $\varepsilon = 0,001$ );
- Metais e ligas em geral:  $n = 0,2\%$  ( $\varepsilon = 0,002$ );
- Cobre e suas ligas<sup>2</sup>:  $n = 0,5\%$  ( $\varepsilon = 0,005$ )

---

<sup>2</sup> Nesse caso, traça-se uma perpendicular ao eixo de deformações a partir da deformação especificada até atingir a curva tensão-deformação.





**Figura 3.02** (a) Curva tensão-deformação de engenharia com  $\sigma_e$  definido para uma deformação de 0,2%; (b) Formação de histerese mecânica.

**Fonte:** Figura adaptada de Garcia (1999, p. 25)

Em alguns casos, a curva tensão-deformação não apresenta a parte linear (região elástica) bem definida, o que torna impreciso o traçado de uma linha paralela para a determinação do limite  $n$ . O procedimento mais adequado em um caso como esse é descarregar e carregar novamente o corpo de prova já na região plástica, permitindo a formação da histerese mecânica. Na Figura 3.02 (b) é apresentado um esboço de uma curva de histerese, após unir os pontos A e B por uma reta traça-se uma segunda reta paralela a esta a partir do ponto correspondente a  $n\%$  de deformação.

Após a região de escoamento tem-se a região de comportamento plástico do material. Na Figura 3.01, o ponto B da curva indica o início dessa região. O regime plástico é caracterizado pela presença de deformações permanentes no corpo de prova. Para materiais de alta capacidade de deformação, o diagrama tensão-deformação apresenta variações relativamente pequenas na tensão, acompanhadas de grandes variações na deformação. Nessa região, pode-se determinar uma série de características do material ensaiado, tais como:

- o limite de resistência à tração ( $\sigma_u$ ): tensão correspondente ao ponto de máxima carga atingida durante o ensaio, corresponde à carga máxima dividida pela área inicial do corpo de prova;
- o limite de ruptura ( $\sigma_f$ ): última tensão suportada pelo material antes da fratura;
- o alongamento ( $\Delta l$ ): diferença entre o comprimento final ( $l_f$ ) e o comprimento inicial ( $l_o$ ) do corpo de prova, e que é dado por:

$$\Delta l = l_f - l_o \quad \text{Equação 3.06}$$

- o alongamento específico<sup>3</sup> ( $\delta$ ): caracteriza-se pelo quociente entre o alongamento ( $\Delta l$ ) e o comprimento inicial do corpo de prova:

$$\delta = \frac{l_f - l_o}{l_o} \quad \therefore \quad \delta = \varepsilon_f \quad \text{Equação 3.07}$$

- o coeficiente de estricção: diferença entre as seções inicial ( $S_o$ ) e final ( $S_f$ ) após a ruptura do corpo de prova e expressa em porcentagem da seção inicial:

$$\varphi = \frac{S_o - S_f}{S_o} \quad \text{Equação 3.08}$$

onde:  $\varphi$  é o coeficiente de estricção;

$S_o$  é a seção transversal inicial da amostra ( $m^2$ );

$S_f$  é a seção estrita ( $m^2$ );

A partir da região de escoamento, o material entra no campo de deformações permanentes onde ocorre endurecimento por deformação a frio. É necessário aumentar-se a tensão para dar continuidade à deformação plástica tendo-se então o fenômeno do encruamento. Esse fenômeno está intimamente ligado à interação entre as discordâncias e diversos outros obstáculos como solutos, contornos de grão etc., que impedem a livre movimentação das discordâncias. É preciso uma energia cada vez maior para que ocorra essa movimentação, e, conseqüentemente deformação plástica, até o limite onde a fratura tem início.

Assim, como a Resiliência e o Módulo de Resiliência ( $U_r$ ) avaliados na região elástica tem-se a Tenacidade e o Módulo de Tenacidade ( $U_t$ ) do material que podem ser avaliados na região de encruamento. Tenacidade é a capacidade que o material apresenta de absorver energia até a fratura. É quantificada pelo Módulo de Tenacidade ( $U_t$ ) que

---

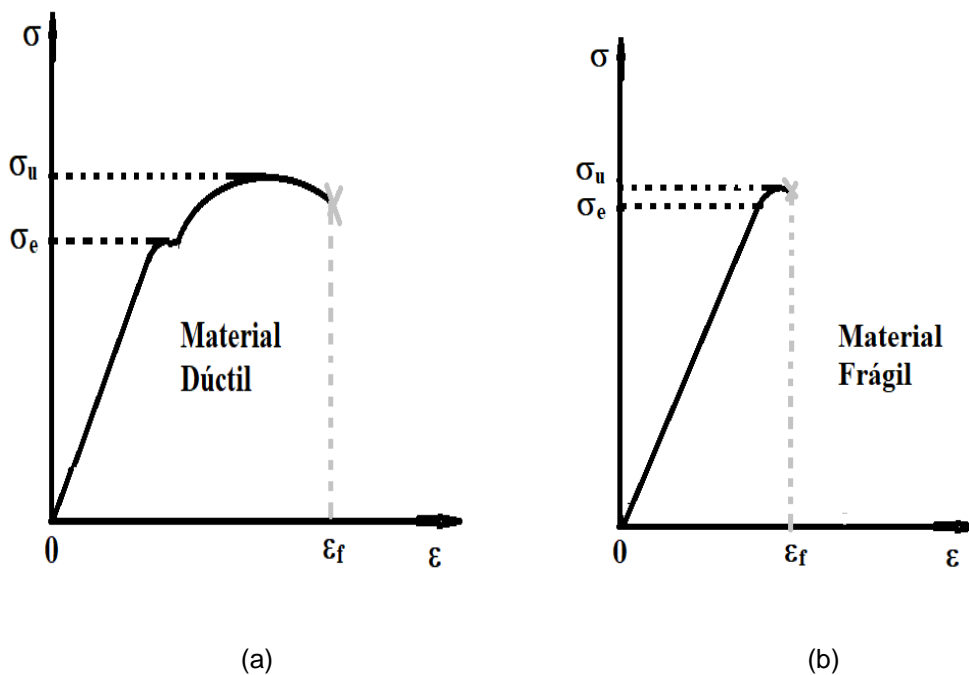
<sup>3</sup> É também conhecido como deformação linear média ou deformação convencional de engenharia no ponto de fratura.

corresponde à energia absorvida por unidade de volume, desde o início do ensaio de tração até a fratura. Uma forma de se avaliar a tenacidade consiste em considerar a área total sob a curva tensão-deformação, mas a ausência de uma expressão analítica que represente a variação de  $\sigma$  com  $\varepsilon$  não permite o cálculo direto da área sob a curva e consequentemente, a determinação do Módulo de Tenacidade ( $U_t$ ). Para uma aproximação desses valores utilizam-se algumas expressões, no caso de materiais dúcteis (Figura 3.03 (a)):

$$U_t = \frac{\sigma_e - \sigma_u}{2} \cdot \varepsilon_f \quad (N \cdot m/m^3) \quad \text{Equação 3.09}$$

e no caso de materiais frágeis (Figura 2.03 (b)):

$$U_t = \frac{2}{3} \cdot \sigma_u \varepsilon_f \quad (N \cdot m/m^3) \quad \text{Equação 3.10}$$



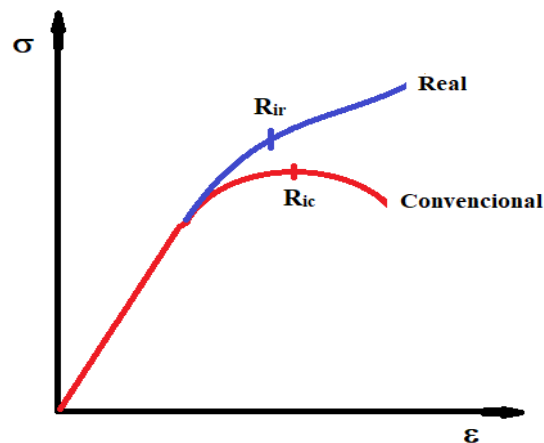
**Figura 3.03** Representação de curvas tensão-deformação em situações extremas para materiais (a) dúcteis e (b) frágeis.

**Fonte:** Figura adaptada de Garcia (1999, p. 29)

A Tenacidade é um parâmetro que compreende tanto a resistência mecânica do material quanto a ductilidade. De um modo geral, os materiais que apresentam Módulos de Resiliência ( $U_r$ ) altos têm a tendência de apresentarem Módulos de Tenacidade ( $U_t$ ) baixos.

### 3.1.2. Ensaio real

A curva tensão-deformação convencional, nominal ou de engenharia baseia-se nas dimensões originais do corpo de prova. A questão é que estas dimensões são continuamente alteradas durante o ensaio sendo necessárias medidas de tensão e deformação que se baseiem nas dimensões instantâneas do corpo de prova para se obter informações reais das características do material em estudo. Na Figura 3.04 é possível observar diferenças entre as curvas no regime plástico do material.



**Figura 3.04** Representação esquemática das curvas tensão-deformação de engenharia e real para um material metálico.

Fonte: Figura adaptada de Garcia (1999, p. 30)

A tensão real ( $\sigma_r$ ) é dada por:

$$\sigma_r = \frac{P}{S} \quad \text{Equação 3.11}$$

onde:  $\sigma_r$  é a tensão real (Pa);

P é a carga aplicada (N);

S é a área da seção transversal instantânea (m<sup>2</sup>)

As mudanças em S são avaliadas a cada instante do ensaio, o que favorece uma melhor caracterização da região plástica além de apresentar um crescimento contínuo da tensão até a fratura (Figura 3.04).

Para uma variação infinitesimal da deformação real ( $\epsilon_r$ ), tem-se:

$$d\epsilon_r = \frac{dl}{l} \quad \text{Equação 3.12}$$

válida para uma deformação uniaxial uniforme. A deformação real ( $\varepsilon_r$ ) é dada pela integração desta relação (Equação 3.12) dentro dos limites inicial ( $l_o$ ) e instantâneo ( $l$ ):

$$\varepsilon_r = \int_{l_o}^l \frac{dl}{l} = \ln \frac{l}{l_o} \quad \text{Equação 3.13}$$

A Equação 3.13 não é aplicável na região de encruamento não uniforme (Figura 3.01), entre os pontos  $R_I$  (início do processo de ruptura) e  $R_f$  (ruptura), além do fato de que é preciso analisar as outras direções e não apenas a direção de aplicação da carga ao se avaliar a deformação nas demais regiões da curva tensão-deformação. Considerando-se o fato de que o volume permanece constante na região plástica e desprezando-se variações elásticas, tem-se:

$$V = V_o \therefore S \cdot l = S_o \cdot l_o = \text{constante} \quad \text{Equação 3.14}$$

derivando-se,

$$S \cdot dl + l \cdot dS = 0 \quad \text{Equação 3.15}$$

e rearranjando-se,

$$\frac{dl}{l} = -\frac{dS}{S} \Rightarrow \int_0^\varepsilon d\varepsilon_r = \int_{S_o}^S -\frac{dS}{S} \Rightarrow \varepsilon_r = \ln \frac{S_o}{S} \quad \text{Equação 3.16}$$

A Equação 3.16 não é aplicável na região elástica já que nesta região o volume não permanece constante durante o tracionamento.

### 3.1.3. Relações entre Tensões e Deformações Reais e Convencionais

A deformação real pode ser determinada a partir da deformação de engenharia. Observando-se as Equações 3.02, 3.13 e 3.16, obtêm-se a relação:

$$\varepsilon_r = \ln (1 + \varepsilon_c) \quad \text{Equação 3.17}$$

A Equação 3.17 é aplicável somente até o ponto ( $R_I$ ) de início da estricção (Figura 3.01) a partir do qual prevalece um estado triaxial de tensões.

Considerando-se as Equações 3.16 e 3.17, obtêm-se a relação:

$$S = \frac{S_o}{1 + \varepsilon_c} \quad \text{Equação 3.18}$$

Introduzindo-se a relação indicada pela Equação 3.18 na Equação 3.11, tem-se:

$$\sigma_r = \frac{P}{S} = \frac{P}{S_o} \cdot (1 + \varepsilon_c) \therefore \sigma_r = \sigma_c \cdot (1 + \varepsilon_c) \quad \text{Equação 3.19}$$

Ao se caracterizar uma curva tensão real-deformação real tem-se algumas relações para as regiões elástica e plástica. Para a região elástica tem-se a relação

$$\sigma_r = E \cdot \varepsilon_r \quad \text{Equação 3.20}$$

Para a região plástica tem-se um conjunto maior de modelos, cujo objetivo comum é melhor representar a coexistência das deformações elásticas e plásticas a partir do limite de proporcionalidade ( $\sigma_p$ ).

Uma das relações mais comuns para o estudo da região plástica é a relação de Hollomon:

$$\sigma_r = k \cdot \varepsilon_r^n \quad \text{Equação 3.21}$$

onde:  $k$  é o coeficiente de resistência, que quantifica o nível de resistência que o material pode suportar (Pa);

$n$  é o coeficiente de encruamento, que representa a capacidade com que o material distribui a deformação (adimensional).

Ambos os coeficientes são características particulares do material, embora possam ser modificados pela ação de tratamentos térmicos e/ou químicos.

Para a determinação do coeficiente de encruamento ( $n$ ) deve-se levar em consideração a Equação 3.21, observando-se que ela também pode ser expressa por:

$$P = S \cdot k \cdot \varepsilon_r^n \quad \text{Equação 3.22}$$

que pode ser diferenciada obtendo-se

$$\begin{aligned} dP &= S \cdot k \cdot n \cdot \varepsilon_r^{n-1} \cdot d\varepsilon_r + \varepsilon_r^n \cdot k \cdot dS \\ &= k \cdot (S \cdot n \cdot \varepsilon_r^{n-1} \cdot d\varepsilon_r + \varepsilon_r^n \cdot dS) \end{aligned} \quad \text{Equação 3.23}$$

Segundo as Equações 3.12 e 3.16, tem-se:

$$\begin{aligned} dP &= k \cdot (S \cdot n \cdot \varepsilon_r^{n-1} \cdot d\varepsilon_r - S \cdot \varepsilon_r^n \cdot d\varepsilon_r) \therefore dP \\ &= k \cdot S \cdot (n \cdot \varepsilon_r^{n-1} - \varepsilon_r^n) \cdot d\varepsilon_r \end{aligned} \quad \text{Equação 3.24}$$

No ponto  $R_{ic}$  do diagrama tensão-deformação (Figura 3.04), a curva apresenta seu ponto de máxima carga, ou seja, um ponto crítico onde  $dP = 0$ , e desta forma, a Equação 3.24 é reduzida à relação:

$$\begin{aligned} k \cdot S \cdot (n \cdot \varepsilon_{r_u}^{n-1} - \varepsilon_{r_u}^n) \cdot d\varepsilon_r &= 0 \therefore n \cdot \varepsilon_{r_u}^{n-1} - \varepsilon_{r_u}^n = 0 \\ n \cdot \varepsilon_{r_u}^{n-1} &= \varepsilon_{r_u}^n \therefore n = \varepsilon_{r_u} \end{aligned} \quad \text{Equação 3.25}$$

ou seja, o coeficiente de encruamento corresponde à deformação real no ponto de máxima carga.

A estricção ou deformação localizada no corpo de prova no ensaio de tração tem início no ponto de máxima carga, a partir do qual o estado uniaxial de tensão dá lugar a um complexo estado triaxial de tensões. Esta situação de instabilidade tem início definido pela condição:

$$\frac{dP}{d\varepsilon_r} = 0 \quad \text{Equação 3.26}$$

como  $P = \sigma_r \cdot S$ , tem-se que:

$$S \frac{d\sigma_r}{d\varepsilon_r} + \sigma_r \frac{dS}{d\varepsilon_r} = 0 \quad \text{Equação 3.27}$$

Como o volume do corpo de prova permanece constante durante a deformação plástica, tem-se:

$$\frac{dV}{d\varepsilon_r} = 0 \therefore \frac{d}{d\varepsilon_r} (S \cdot l) = S \frac{dl}{d\varepsilon_r} + l \frac{dS}{d\varepsilon_r} = 0 \quad \text{Equação 3.28}$$

Isolando-se  $\frac{dS}{d\varepsilon_r}$  na Equação 3.28 e substituindo-se o resultado na Equação 3.27, obtém-se:

$$S \frac{d\sigma_r}{d\varepsilon_r} + \sigma_r \left( -\frac{Sdl}{ld\varepsilon_r} \right) = 0 \quad \text{Equação 3.29}$$

Observando-se a Equação 3.12 e realizando-se as devidas substituições na Equação 3.29, tem-se que:

$$\frac{d\sigma_r}{d\varepsilon_r} = \sigma_r \quad \text{Equação 3.30}$$

A Equação 3.30 indica que o coeficiente angular da reta tangente à curva tensão-deformação reais no ponto de máxima carga é igual à magnitude da tensão real aplicada. Esta condição também é apresentada em termos da deformação convencional ou de engenharia, onde:

$$\frac{d\sigma_r}{d\varepsilon_c} = \frac{\sigma_r}{1 + \varepsilon_c} \quad \text{Equação 3.31}$$

A Equação 3.31 permite uma construção geométrica conhecida como *Construção de Considère* (GARCIA, 1999), muito utilizada na determinação do ponto de carga máxima no ensaio real.

### 3.2. DADOS UTILIZADOS PARA VALIDAÇÃO DO MÉTODO

Os dados dos ensaios de tração utilizados para a validação do método híbrido proposto foram obtidos de dois outros trabalhos anteriores que analisaram o efeito da tensão de triaxialidade na liga AISI 4340 recozida e normalizada (TRAJANO, 2018) e um estudo numérico e experimental do efeito da tensão de triaxialidade em aço aplicado à indústria naval, no caso o aço U2 da série 1524 (BURBA, 2018). Nestas pesquisas foram utilizadas chapas do aço 4340, com tratamentos térmicos de normalização e recozimento (recozimento à temperatura de 850°C durante 1 h), e chapas do aço 1524 U2 com tratamentos térmicos de têmpera e revenimento.

O Aço 4340 é um aço liga que possui em sua composição cromo (Cr), níquel (Ni) e molibdênio (Mo) (CHIAVERINIV, 1988). Dentre suas principais características estão a alta temperabilidade, boa resistência mecânica, usinabilidade média e baixa soldabilidade (FERRARESI, 1977). É usado na fabricação de peças maiores que demandam alta dureza e resistência mecânica, sendo bastante utilizado nas indústrias siderúrgicas, de mineração e de petróleo e na construção de engrenagens, eixos, cilindros, entre outros produtos. Para o Aço 4340 recozido encontra-se na literatura (LEE & SU, 1999) alguns valores típicos para as propriedades mecânicas:


- Limite de escoamento: 470 MPa;
- Limite de resistência a tração: 745 MPa;
- Módulo de elasticidade: 190 GPa podendo chegar a 210 GPa.

O Aço 1524 U2 é um aço carbono que apresenta um alto teor de manganês (Mn) na sua composição (CHIAVERINIV, 1988). Dentre suas principais características destacam-se sua boa usinabilidade, uma alta resistência mecânica aliada a boa tenacidade o que lhe permite dobras de até 90° e uma pequena variação de dureza ao longo do diâmetro de peças. É usado na aplicação de solda, em eixos de geradores e motores e peças que precisam de maior usinagem e menor deformação (FERRARESI, 1977). Também conhecido como aço-mola é muito utilizado em indústrias de peças automotivas, de ferramentas, de molas, de peças de corte, dentre outras (CHIAVERINIV, 1979).



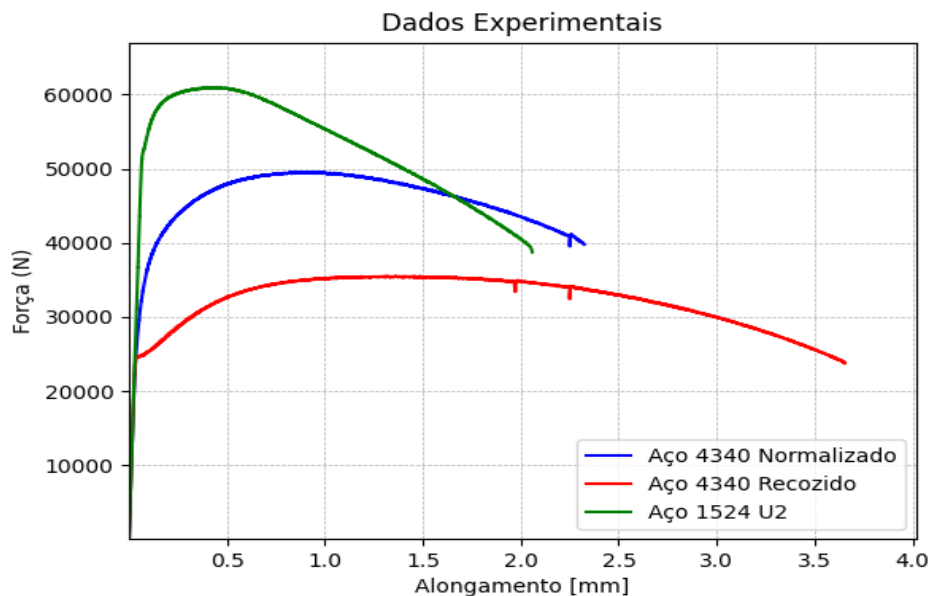
### 3.3. OS ENSAIOS AVALIADOS E RESULTADOS OBTIDOS

Os corpos de prova foram fabricados seguindo-se a norma ABNT NBR ISO 6892-1 de 2013. Com o formato cilíndrico e as dimensões indicadas na Figura 3.05, os corpos de prova foram submetidos a ensaios de tração com o uso de *clip gauge* em uma máquina de ensaios mecânicos MTS 810.



**Figura 3.05.** Dimensões dos corpos de prova fabricados e utilizados no ensaio de tração. A região útil está destacada pela área hachurada.

**Fonte:** Figura adaptada de ABNT6892 (2015, p. 32)

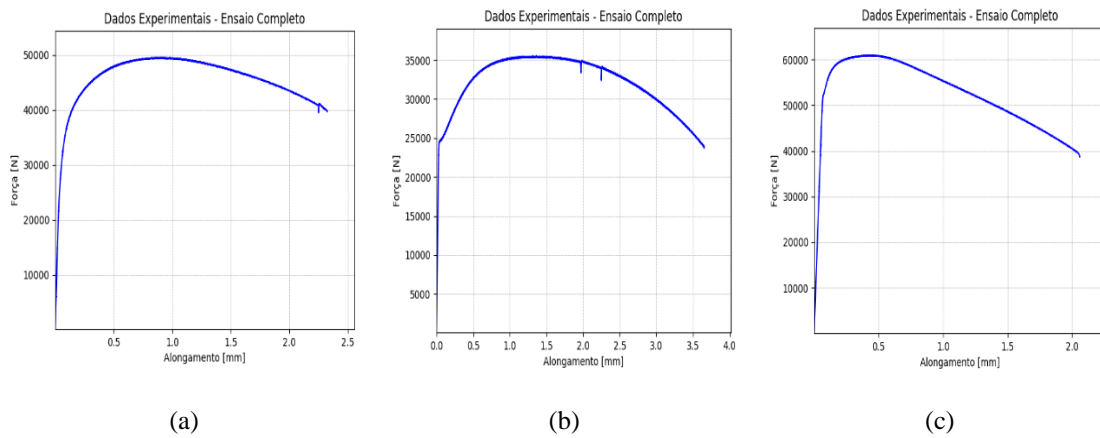


**Figura 3.06.** Curvas Força [N] x Alongamento [mm] dos materiais em estudo.

**Fonte:** Figura idealizada pelo autor do presente texto

No ensaio de tração foram obtidos os valores da carga aplicada ( $P$ ) e do alongamento ( $\Delta l$ ). Os dados foram armazenados em um arquivo texto para posterior leitura e uso por outros aplicativos de computador. As correspondentes curvas da carga

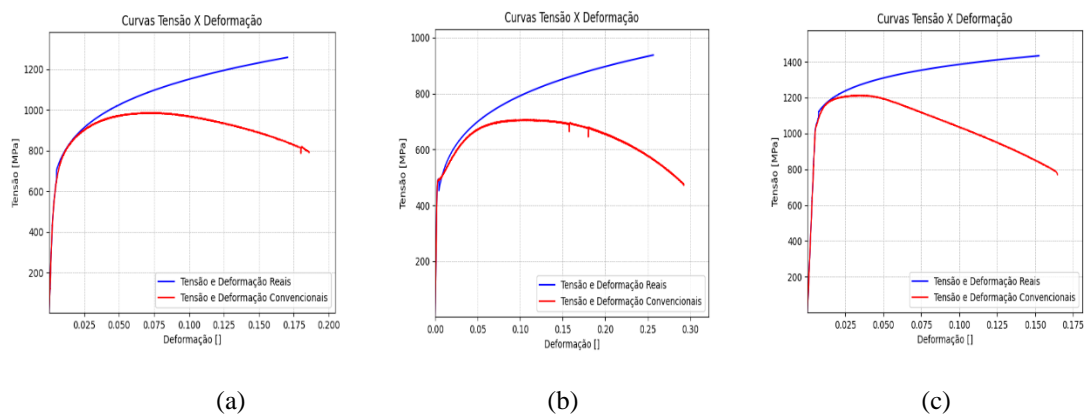
(Força) [N] em função do alongamento [mm] podem ser apreciadas nas Figura 3.06 e 3.07.



**Figura 3.07.** Curvas Força [N] x Alongamento [mm] obtidas nos ensaios de tração de corpos de prova dos materiais (a) Aço 4340 Normalizado; (b) Aço 4340 Recozido; (c) Aço 1524 U2.

**Fonte:** Figura idealizada pelo autor do presente texto

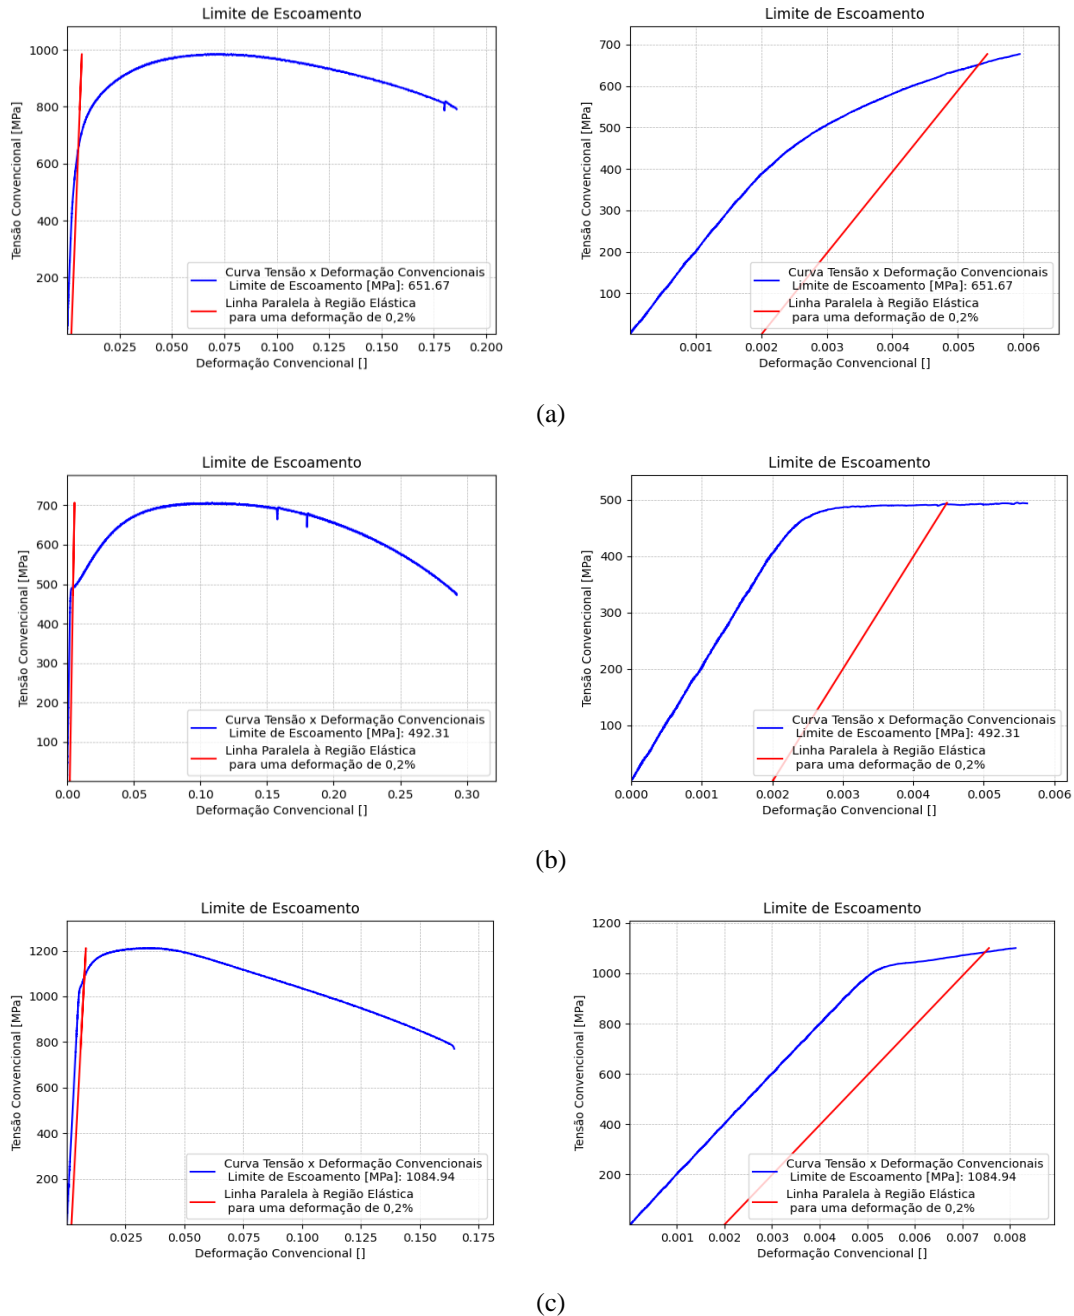
Para o cálculo da deformação convencional ( $\epsilon_c$ ) ou de engenharia, da tensão convencional ( $\sigma_c$ ) ou de engenharia, da deformação real ( $\epsilon_r$ ) e da tensão real ( $\sigma_r$ ) e do limite de escoamento ( $\sigma_e$ ) gerou-se uma rotina na linguagem PYTHON que realizasse as operações indicadas nas Equações 3.01, 3.02, 3.17 e 3.19, respectivamente. Os valores obtidos também foram armazenados em arquivo texto e utilizados para a montagem das curvas tensão-deformação convencionais ou de engenharia e das curvas tensão-deformação reais. Na Figura 3.08 tem-se uma visão comparada de ambas as curvas para cada material.



**Figura 3.08.** Curvas Tensão [MPa] x Deformação [adimensional] Reais e Convencionais obtidas nos ensaios de tração de corpos de prova dos materiais (a) Aço 4340 Normalizado; (b) Aço 4340 Recozido; (c) Aço 1524 U2

**Fonte:** Figura idealizada pelo autor do presente texto

A identificação do limite de escoamento ( $\sigma_e$ ) e o cálculo do módulo de elasticidade ( $E$ ) foram realizados (Figura 3.09) seguindo-se o algoritmo descrito no Quadro 3.01, também implementado na linguagem PYTHON.



**Figura 3.09.** Curvas Tensão [MPa] x Deformação [adimensional] Convencionais utilizadas para a obtenção do Limite de Escoamento e do Módulo de Elasticidade dos materiais (a) Aço 4340 Normalizado; (b) Aço 4340 Recozido; (c) Aço 1524 U2

**Fonte:** Figura idealizada pelo autor do presente texto


Inicialmente, procurou-se definir a região elástica da curva verificando-se os pontos que permitissem o melhor ajuste ou linha de tendência com altos coeficientes de correlação ( $0,9990 \leq r^2 \leq 0,9999$ ).

**Tabela 3.01.** Índices de correlação testados e o percentual de pontos observados (*np*)

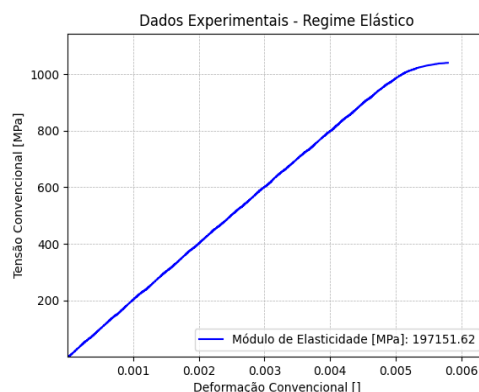
Índice de Correlação									
Ensaio Convencional									
Material	0,999		0,9995		0,9998		0,9999		
	<i>np</i> *	%	<i>np</i>	%	<i>np</i>	%	<i>np</i>	%	
Aço 4340 Normalizado	1383	9,35	1366	9,23	1346	9,10			
Aço 4340 Recozido	948	4,27	946	4,26	945	4,26	944	4,25	
U2	2357	19,62	2349	19,56	2341	19,49	2337	19,46	
Ensaio Real									
Material	0,999		0,9995		0,9998		0,9999		
	<i>np</i>	%	<i>np</i>	%	<i>np</i>	%	<i>np</i>	%	
Aço 4340 Normalizado	1389	9,39	1373	9,28	1354	9,15			
Aço 4340 Recozido	949	4,27	947	4,27	945	4,26	945	4,26	
U2	2363	19,68	2353	19,59	2345	19,53	2341	19,49	

\**np* – número de pontos

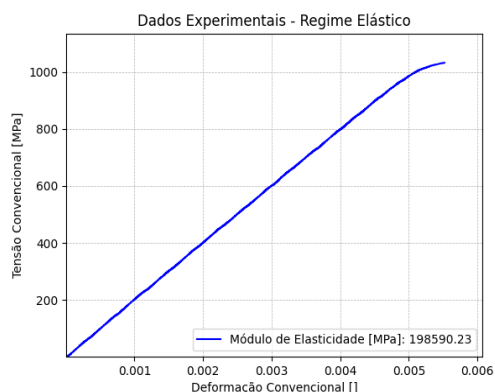
Fonte: Tabela idealizada pelo autor do presente texto.




(a)  $R^2 = 0,999$



(b)  $R^2 = 0,9995$



(c)  $R^2 = 0,9998$

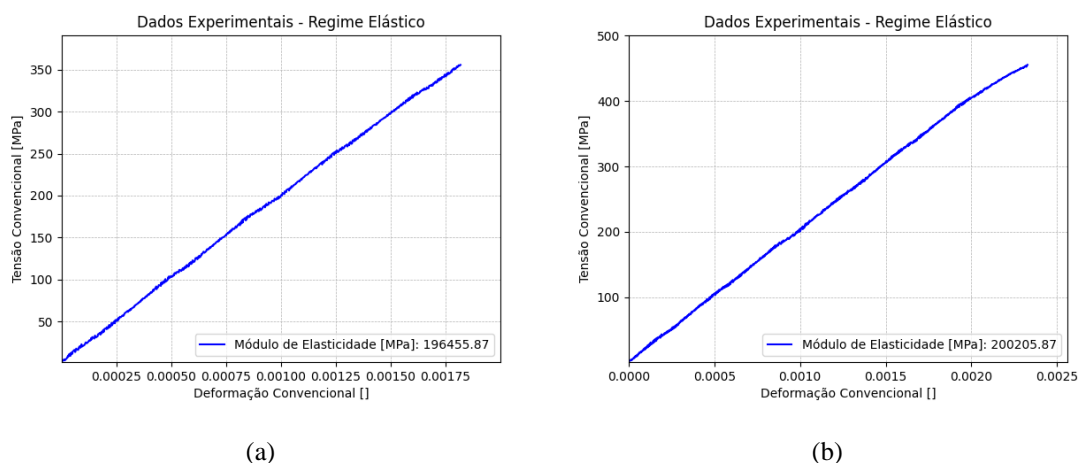


(d)  $R^2 = 0,9999$

**Figura 3.10.** Aço 1524 U2 – Busca pelo maior coeficiente de correlação ( $r^2$ ) na região de comportamento elástico: (a)  $r^2 = 0,999$ ; (b)  $r^2 = 0,9995$ ; (c)  $r^2 = 0,9998$ , (d)  $r^2 = 0,9999$ .

Fonte: Figura idealizada pelo autor do presente texto

Na Figura 3.10 são apresentadas as curvas obtidas para o Aço 1524 U2. Seguindo-se a norma (ABNT6892, 2015) e utilizando uma relação linear, optou-se pelas curvas de coeficiente de correlação da ordem de 0,9998, não apenas por representarem um bom índice de correlação, mas por corresponderem a uma quantidade significativa de valores (Figura 3.11). Na Tabela 3.01 são apresentados os valores obtidos para diferentes coeficientes de correlação.



**Figura 3.11.** Região de comportamento elástico considerando-se o coeficiente de correlação linear  $r^2 = 0,9998$  para os materiais (a) Aço 4340 Normalizado; e (b) Aço 4340 Recozido.

**Fonte:** Figura idealizada pelo autor do presente texto

Após a determinação do limite de escoamento ( $\sigma_e$ ) outros importantes resultados foram obtidos para a região elástica (Tabela 3.02).

**Tabela 3.02.** Resultados obtidos para a Região Elástica.

<b>Resultados para a Região Elástica</b>					
<b>Ensaio Convencional</b>					
<b>Material</b>	<b><math>E</math> [GPa]</b>	<b><math>\sigma_{y_0}</math> [MPa]</b>	<b><math>\varepsilon_{y_0}</math> [%]</b>	<b><math>F_{y_0}</math> [kN]</b>	<b><math>\Delta l_{y_0}</math> [mm]</b>
Aço 4340 Normalizado	196,46	651,67	0,53	32,76	0,0665
Aço 4340 Recozido	201,87	492,31	0,45	24,75	0,0561
U2	199,51	1085,98	0,75	54,59	0,0940
<b>Ensaio Real</b>					
<b>Material</b>	<b><math>E</math> [GPa]</b>	<b><math>\sigma_{y_0}</math> [MPa]</b>	<b><math>\varepsilon_{y_0}</math> [%]</b>	<b><math>F_{y_0}</math> [kN]</b>	<b><math>\Delta l_{y_0}</math> [mm]</b>
Aço 4340 Normalizado	196,37	656,78	0,53	32,84	0,0670
Aço 4340 Recozido	202,44	494,52	0,45	24,75	0,0561
U2	201,00	1094,65	0,75	54,61	0,0943

**Fonte:** Tabela idealizada pelo autor do presente texto.

É importante salientar que os termos limite de escoamento ( $\sigma_e$ ) e tensão de escoamento inicial ( $\sigma_{y_0}$ ), no presente trabalho, serão utilizados como referências ao mesmo ponto ou característica do material em análise.

Como última característica da região elástica a ser verificada calculou-se o Módulo de Resiliência (Equação 3.05) tanto para a o ensaio convencional como para o ensaio real. Os valores estão listados na Tabela 3.03 para os diferentes índices de correlação testados.

**Tabela 3.03.** Módulos de Resiliência para os diferentes índices de correlação testados.

<b>Módulo de Resiliência (<math>U_r</math>) [N · mm/mm<sup>3</sup>]</b>				
<b>Ensaio Convencional</b>				
<b>Material</b>	<b>0,999</b>	<b>0,9995</b>	<b>0,9998</b>	<b>0,9999</b>
Aço 4340 Normalizado	1,168	1,121	1,080	
Aço 4340 Recozido	0,62	0,611	0,605	0,6026
U2	3,03	2,99	2,969	2,952
<b>Ensaio Real</b>				
<b>Material</b>	<b>0,999</b>	<b>0,9995</b>	<b>0,9998</b>	<b>0,9999</b>
Aço 4340 Normalizado	1,187	1,148	1,098	
Aço 4340 Recozido	0,63	0,619	0,612	0,6083
U2	3,10	3,06	3,039	3,025

**Fonte:** Tabela idealizada pelo autor do presente texto.

Após os estudos da região elástica realizou-se a caracterização da região de comportamento plástico da curva. Região de importância para o presente estudo porque é nela que ocorre o fenômeno do encruamento.

Foram avaliados o limite de resistência à tração ( $\sigma_u$ ) e o limite de ruptura ( $\sigma_f$ ) além de suas respectivas deformações ( $\epsilon_u$  e  $\epsilon_f$ ). Calculou-se a Tenacidade do material utilizando-se a Equação 3.09 e uma aproximação numérica via o método 1/3 de Simpson para integração. O objetivo foi obter uma melhor aproximação do valor da área sob a curva e com isso um valor de Tenacidade fidedigno ao material em estudo. Todas essas ações foram realizadas por rotinas desenvolvidas na linguagem PYTHON. Os valores obtidos podem ser observados nas Tabelas 3.04, 3.05 e 3.06.

**Tabela 3.04.** Resultados obtidos para o Limite de Resistência à Tração.

Resultados para a Região Plástica e de Ruptura – Limite de Resistência à Tração				
Ensaio Convencional				
Material	$\sigma_u$ [MPa]	$\epsilon_u$ [%]	$F_u$ [kN]	$\Delta l_u$ [mm]
Aço 4340 Normalizado	984,93	7,26	49,51	0,9081
Aço 4340 Recozido	706,43	10,44	35,51	1,3046
U2	1212,06	3,39	60,93	0,4237
Ensaio Real				
Material	$\sigma_{y_0}$ [MPa]	$\epsilon_{y_0}$ [%]	$F_{y_0}$ [kN]	$\Delta l_{y_0}$ [mm]
Aço 4340 Normalizado	1066,94	8,95	49,04	1,1699
Aço 4340 Recozido	805,48	14,79	34,92	1,9928
U2	1259,92	4,13	60,77	0,5273

Fonte: Tabela idealizada pelo autor do presente texto.

**Tabela 3.05.** Resultados obtidos para o Limite de Ruptura.

Resultados para a Região Plástica e de Ruptura – Limite de Ruptura						
Material	Ensaio Convencional		Ensaio Real		$F_f$ [kN]	$\Delta l_f$ [mm]
	$\sigma_f$ [MPa]	$\epsilon_f$ [%]	$\sigma_f$ [MPa]	$\epsilon_f$ [%]		
Aço 4340 Normalizado	791,17	18,59	938,25	17,05	39,77	2,3238
Aço 4340 Recozido	472,51	29,24	610,66	25,65	23,75	3,6546
U2	770,29	16,47	897,17	15,25	38,72	2,0588

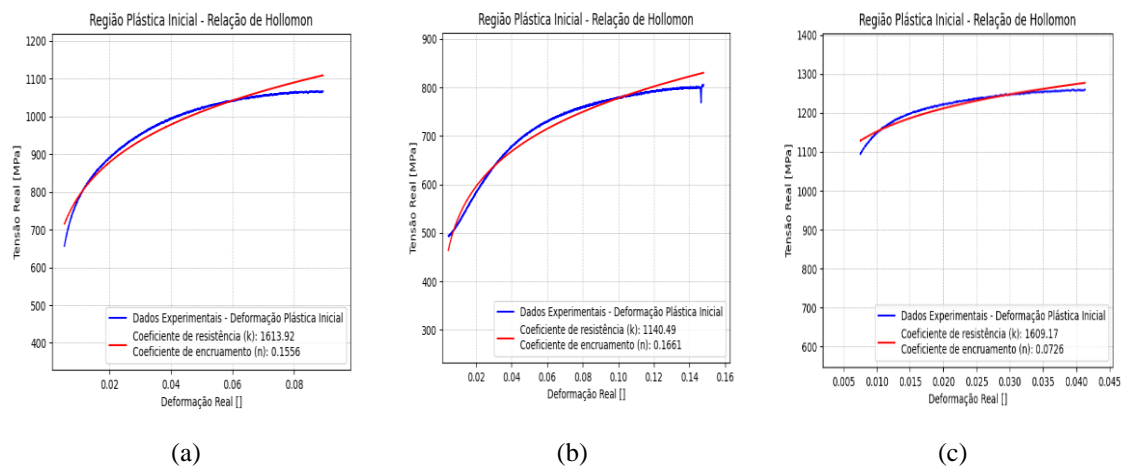
Fonte: Tabela idealizada pelo autor do presente texto.

**Tabela 3.06.** Resultados obtidos para a Tenacidade.

Resultados para a Região Plástica e de Ruptura – Módulo de Tenacidade		
Material	Ensaio Convencional	
	Norma	1/3 de Simpson
Aço 4340 Normalizado	151,89	162,74
Aço 4340 Recozido	190,04	185,83
U2	178,78	192,24

Fonte: Tabela idealizada pelo autor do presente texto.

A curva tensão-deformação real para diversos metais, na região de deformação plástica inicial ou uniforme, pode ser expressa pela relação de Hollomon (Equação 3.21). Para obtenção dos coeficientes de encruamento e de resistência utilizou-se de procedimento numérico para a aproximação logarítmica da curva (Figura 3.12).



**Figura 3.12.** Região de deformação plástica das Curvas Tensão x Deformação Reais e a relação  $\sigma = K\varepsilon^n$  para os materiais (a) Aço 4340 Normalizado; (b) Aço 4340 Recozido; (c) Aço 1524 U2  
**Fonte:** Figura idealizada pelo autor do presente texto

O coeficiente de encruamento pode variar do valor de  $n = 0$  (sólido perfeitamente plástico) até  $n = 1$  (sólido elástico). Para a maioria dos metais este coeficiente tem um valor entre 0,10 e 0,5. Frequentemente são observados desvios na relação representada pela Equação 2.21, muitas vezes a baixas deformações ( $10^{-3}$ ) ou grandes deformações ( $\varepsilon \approx 1$ ). Os resultados obtidos podem ser visualizados na Tabela 3.07.

**Tabela 3.07.** Resultados obtidos para os parâmetros de Hollomon.

Resultados para a Região Plástica e de Ruptura – Parâmetros de Hollomon		
Material	Coeficiente de Encruamento (n)	Coeficiente de Resistência (k) [MPa]
Aço 4340 Normalizado	0,1674	1691,00
Aço 4340 Recozido	0,1792	1196,46
U2	0,0813	1670,26

**Fonte:** Tabela idealizada pelo autor do presente texto.

### 3.4. OBSERVAÇÕES SOBRE AS PROPRIEDADES VERIFICADAS

O teste de tração de engenharia é amplamente usado para a obtenção de informações básicas sobre a resistência de materiais e também como um teste de controle de especificações. Este capítulo teve por objetivos apresentar algumas características importantes deste teste, indicar os resultados obtidos para alguns materiais, no caso, os aços 4340 normalizado e recozido e a liga 1524 U2 e, por fim, verificar a aplicação das rotinas de computador estruturadas na linguagem PYTHON, primeira etapa na implementação de um método híbrido para determinação de parâmetros de encruamento.



Segundo Garcia *et al.* (1999), os parâmetros de maior uso para descrever a curva tensão deformação de um material são a resistência à tração, a tensão limite de escoamento, o alongamento e a redução de área. Os dois primeiros são parâmetros de resistência e os dois últimos são uma indicação da ductilidade do material. Dentre estes a resistência à tração (Tabela 3.04) é o valor mais frequentemente citado. A tendência atual é de se basear o projeto estático de metais dúcteis não na resistência à tração, mas na tensão limite de escoamento. No entanto, para materiais frágeis, a resistência à tração ainda é um critério válido para projetos, além do fato de ser uma propriedade reprodutível e de fácil obtenção. Correlações empíricas entre a resistência à tração e propriedades como a dureza e resistência à fadiga são em geral muito úteis.

A observação da tensão na qual a deformação plástica ou escoamento tem início depende da sensibilidade das medidas de deformação. Na maioria dos metais existe uma transição gradual do comportamento elástico para o plástico, e o ponto no qual a deformação plástica tem início é difícil de ser definido com precisão. Vários são os critérios para determinar o início do escoamento dependendo da sensibilidade das medidas de deformação e da finalidade de utilização dos dados (RODRIGUES *et al.*, 2010). Dentre os materiais avaliados o aço U2 apresentou maior resistência à tração e o aço 4340 Reozido a menor resistência.

O módulo de elasticidade é uma medida da rigidez do material. Quanto maior é o módulo de elasticidade, menor é a deformação elástica resultante da aplicação de uma determinada carga. Uma vez que o módulo de elasticidade é necessário para o cálculo da deflexão de vigas e outros componentes, ele se torna um valor importante para projetos. O módulo de elasticidade é uma das propriedades mecânicas mais insensíveis à estrutura. Ele pode ser apenas ligeiramente afetado pela adição de elementos liga, tratamentos térmicos ou deformação a frio, no entanto, aumentando-se a temperatura de deformação o módulo de elasticidade diminui (GARCIA *et al.*, 1999). Os resultados obtidos podem ser vistos na Tabela 3.02, levando-se em consideração que o módulo de elasticidade de um aço, em geral, recai no intervalo de 190 GPa à 220 GPa.

O módulo de resiliência, que é a energia necessária para tensionar o material da tensão zero até a tensão de escoamento, tem seu ideal onde o material possui uma tensão de escoamento alta e um módulo de elasticidade baixo, como exemplos de aplicações para tais materiais tem-se as molas mecânicas (RODRIGUES *et al.*, 2010). Os valores obtidos para os materiais em estudo estão listados na Tabela 3.03.

Segundo Garcia *et al.* (1999), a tenacidade é um conceito muito utilizado e de difícil definição. Corresponderia à capacidade de suportar tensões ocasionais acima da tensão de escoamento sem fraturar, sendo particularmente desejável em peças como engate de vagões de carga, engrenagens, correntes e ganchos de guindastes. Na literatura são sugeridas algumas aproximações matemáticas para a área sob a curva tensão-deformação (Equações 3.09 e 3.10), no entanto, tentou-se, no presente estudo, melhorar estas aproximações utilizando-se um método numérico para integração, no caso, a regra 1/3 de Simpson (CHAPRA *et al.*, 2008). Na Tabela 3.06 pode-se observar os valores obtidos para os materiais em estudo e que serão utilizados em etapas posteriores deste trabalho.

## 4. SIMULAÇÕES NUMÉRICAS

A *busca* é um problema básico da ciência da computação que pode ser descrito como uma tentativa de alcançar um determinado objetivo chegando-se a um estado onde condições preestabelecidas são satisfeitas. Tem-se em literatura diversas técnicas tradicionais de busca. Cada uma com suas qualidades e problemas para os quais é mais adequada. No presente trabalho foram adotadas duas técnicas de busca com o objetivo de se obter os valores que melhor se enquadram no modelo constitutivo (Equação 4.01) proposto por Kleinermann e Ponthot (2003) gerando-se um método híbrido.

No modelo proposto por Kleinermann e Ponthot (2003) são quatro os parâmetros a serem obtidos e a relação entre eles pode ser observada na equação:

$$\sigma_y = \sigma_o + \zeta \varepsilon_p + (\sigma_\infty - \sigma_o)(1 - e^{-\delta \varepsilon_p}) \quad \text{Equação 4.01}$$

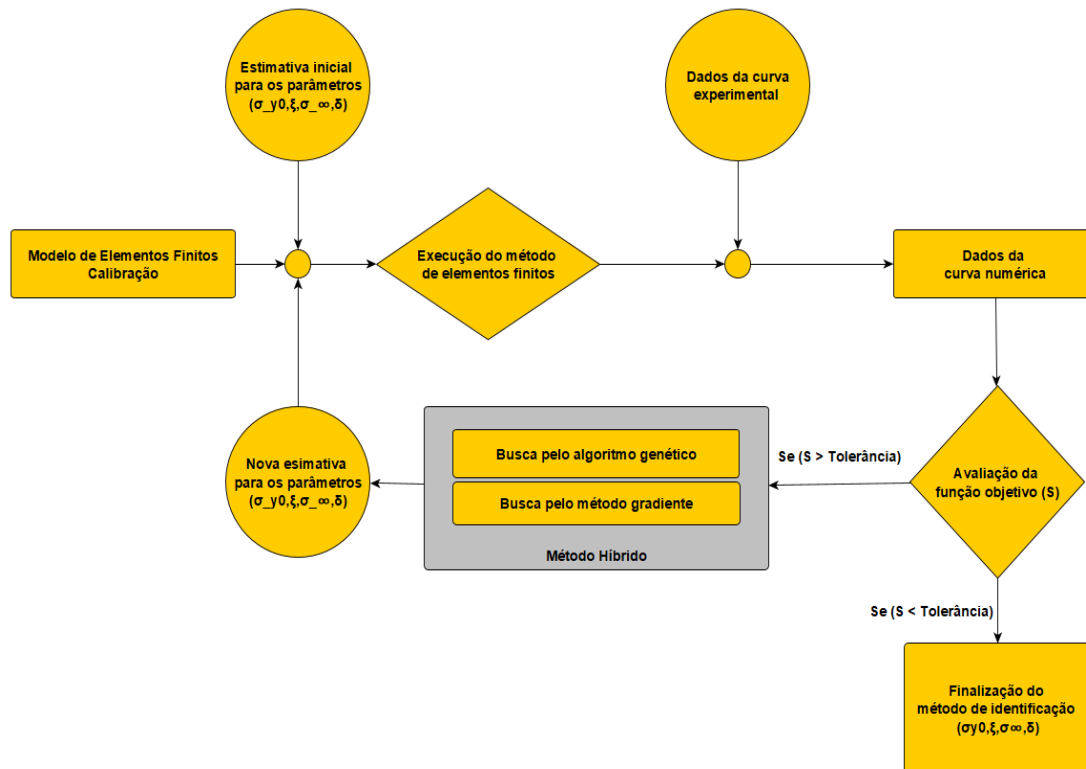
onde  $\sigma_y$  é a tensão de escoamento,  $\varepsilon_p$  é a deformação plástica equivalente e os símbolos  $\zeta, \sigma_o, \sigma_\infty$  e  $\delta$  representam os parâmetros procurados.

No presente trabalho, a *força* constitui a resposta medida (procedimento experimental) e calculada (procedimento numérico), enquanto o conjunto de valores  $p = \{\zeta, \sigma_o, \sigma_\infty, \delta\}$  representa os parâmetros da equação de encruamento (Equação 4.01) que serão usados nos métodos numéricos, neste caso, no método de Elementos Finitos (STAHLSCHMIDT *et al.*, 2011).

Para as simulações numéricas relativas ao método de Elementos Finitos será utilizado o sistema acadêmico Hyplas (NETO *et al.*, 2008). Escrito na linguagem FORTRAN 77 terá como entrada os parâmetros apresentados na Equação 4.01. O programa apresenta três módulos básicos: o módulo de entrada de dados e inicialização de variáveis; o módulo principal, onde estão os procedimentos relacionados ao método de Elementos Finitos, consistindo em um ciclo de incrementos e análise de equilíbrio relacionados aos carregamentos realizados sobre os elementos finitos acoplados; e o módulo de saída e apresentação dos resultados.

O Hyplas é configurado inicialmente definindo-se, em seu módulo de entrada, o tipo de elemento finito, o número de nós por cada elemento, o algoritmo de busca, no caso, o método de Newton-Raphson, as condições de contorno necessárias ao processo e algumas características importantes do material em estudo como o seu módulo de elasticidade e o coeficiente de Poisson correspondente.

O módulo referente ao método de Elemento Finitos é ativado para cada indivíduo gerado no Algoritmo Genético e para cada iteração do Algoritmo Levenberg-Marquardt. A Figura 4.01 ilustra o processo de identificação de parâmetros adotado no presente trabalho.



**Figura 4.01.** Fluxo de trabalho referente ao processo de identificação paramétrica baseado em método híbrido de busca

**Fonte:** Figura idealizada pelo autor do presente texto.

Nas seções seguintes o método híbrido desenvolvido terá cada uma de suas etapas analisadas. A primeira técnica corresponde ao Algoritmo Genético que além de permitir buscas direcionadas e inteligentes, pode ser usado em espaços de busca grandes que dificilmente poderiam ser resolvidos por técnicas tradicionais. A segunda técnica é o Método de Levenberg-Marquardt que traz consigo a busca direcionada dos métodos de máxima inclinação ascendente e a velocidade do método de Newton-Raphson (CHAPRA *et al.*, 2008).

O objetivo do método híbrido é usar o Algoritmo Genético para varrer um espaço extenso de possíveis soluções e a partir dos resultados iniciais próximos da solução ótima apresentados obter uma solução direta com o Método de Levenberg-Marquardt. As simulações numéricas apresentadas neste texto foram realizadas em um computador

desktop de processador Intel(R) Core (TM) i5 – 7400 CPU 3.00 GHz com memória RAM de 8 GB e HD de 2Tb Sata Seagate.

#### 4.1. ALGORITMO GENÉTICO: RESULTADOS OBTIDOS

Em um primeiro momento foram estabelecidos alguns parâmetros para o funcionamento do Algoritmo Genético e posterior comparação de desempenho:

- desenvolvimento de 3 e 6 gerações;
- uso de populações iniciais na ordem de 6, 10 e 20 indivíduos;
- cada indivíduo com em média 11 bits para os parâmetros (depende da precisão desejada);
- 80% de probabilidade de combinação (crossover) inicial e 50% de probabilidade final;
- 10% de taxa de mutação.

Para ilustrar os estudos realizados serão apresentados, nas linhas seguintes, os resultados referentes ao aço 4340 normalizado. Inicialmente, os testes foram desenvolvidos indicando-se um intervalo de busca aleatório para cada um dos parâmetros em estudo (Tabela 4.01). Estes valores não foram alterados em nenhum momento da execução do algoritmo.

O número de bits foi obtido utilizando-se a Equação 4.01 e considerando-se que a diferença entre dois valores consecutivos seja igual a precisão desejada:

$$inf_i + \frac{sup_i - inf_i}{2^k - 1} \times (vinteiro + 1) - \left[ inf_i + \frac{sup_i - inf_i}{2^k - 1} \times vinteiro \right] = precisão \quad \text{Equação 4.02}$$

logo,

$$\frac{sup_i - inf_i}{2^k - 1} = precisão \quad \text{Equação 4.03}$$

**Tabela 4.01** Aço 4340 Normalizado – Intervalo inicial de busca para cada parâmetro.

Aço 4340 Normalizado – Parâmetros				
Limites	$\sigma_{yo}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []
Inferior ( $inf_i$ )	5	5	5	5
Superior ( $sup_i$ )	1500	1500	1500	100
Precisão	1	1	1	0,1
Número de bits mínimo	11	11	11	10

Fonte: Tabela idealizada pelo autor do presente texto.

Outro importante aspecto a ser considerado diz respeito a função de avaliação (Equação 2.02). Quanto maior for o valor desta função, ou seja, quanto maior for o erro pior será o indivíduo, portanto, tem-se um problema de minimização. Para contornar tal questão adotou-se a inversa da função de avaliação inicial:

$$f^* = \frac{1}{g_o(p)} = \frac{1}{\sqrt{\frac{1}{N} \sum_{k=1}^N \left( \frac{R_k^{MEF}(p) - R_k^{Exp}}{R_k^{Exp}} \right)^2}} \quad \text{Equação 4.04}$$

Mas, na hipótese de se encontrar uma solução perfeita, o denominador da equação se igualaria a zero causando um erro de execução em qualquer sistema. Com isso, desenvolveu-se uma outra função de avaliação:

$$f = \frac{1}{1 + g_o(p)} = \frac{1}{1 + \sqrt{\frac{1}{N} \sum_{k=1}^N \left( \frac{R_k^{MEF}(p) - R_k^{Exp}}{R_k^{Exp}} \right)^2}} \quad \text{Equação 4.05}$$

onde o valor mínimo ideal é a unidade (1). Todas as avaliações do Algoritmo Genético aplicado neste trabalho farão uso da Equação 4.05 como função de avaliação observando-se o seu valor mínimo.

Na Tabela 4.02, podem ser verificados os valores de cada parâmetro obtidos para o aço 4340 normalizado, considerando-se uma população fixa de 6 indivíduos, e sua avaliação segundo a Equação 4.05. Observa-se que os valores da função objetivo listados na tabela (coluna  $f$ ) apresentam um certo distanciamento do que seria o ideal, ou seja, valores próximos a unidade (1). Foi ao longo das gerações, mais especificamente na 3ª. geração que se alcançou uma única avaliação no patamar almejado. O processo pode ser melhor entendido observando-se as Figuras 4.02, 4.03, 4.04 e 4.05 que ilustram as curvas obtidas para os conjuntos de parâmetros avaliados, ou melhor, para cada indivíduo gerado.

A análise conjunta dos valores em tabela e dos gráficos de comparação das curvas experimental e teórica auxiliam na verificação e distinção dos máximos e mínimos locais e globais das funções em estudo.

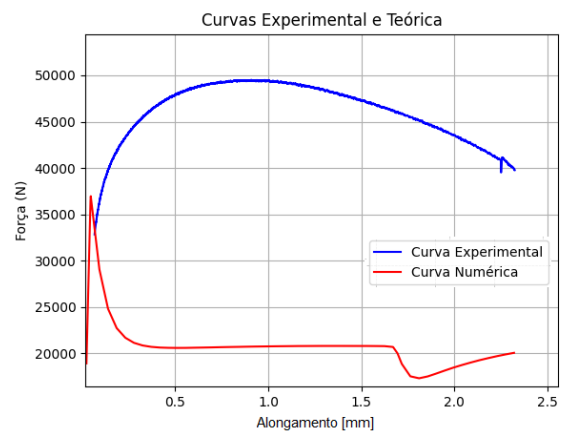
**Tabela 4.02** Aço 4340 Normalizado – Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo com 3 gerações e população inicial fixa de 6 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	1	744,1011	904,6823	299,3258	53,7536	0,6469
	2	1020,8988	489,3695	594,3820	42,5171	0,7461
	3	234,3258	871,6129	622,1348	54,2179	0,7350
	4	135,7303	140,1955	890,1685	26,5444	0,7482
	5	1049,3820	365,8455	1044,2696	16,7008	0,8878
	6	78,0337	380,4349	1204,9438	78,4555	0,8641
1	1	1453,9887	577,8787	214,6067	78,4555	0,6462
	2	736,0674	458,2453	44,4382	83,3773	0,8196
	3	275,2247	842,4340	1085,8988	7,9716	0,7317
	4	1278,7078	899,8191	888,7078	25,6158	0,8536
	5	1397,7528	649,8533	1101,9662	85,6060	0,7940
	6	815,6741	556,4809	228,4831	73,6265	0,6059
2	1	1478,0898	321,1045	26,9101	76,8768	0,6413
	2	711,9662	715,0195	232,1348	84,9560	0,6123
	3	64,8876	966,9305	900,3932	21,7155	0,7328
	4	1489,0449	775,3225	1074,2134	11,8719	0,6138
	5	1026,7415	556,4809	1125,3370	97,3069	0,8561
	6	1186,6853	649,8533	205,1123	61,9257	0,6275
3	1	311,7415	761,7057	1225,3932	73,7194	0,8267
	2	198,5393	106,1534	1053,0337	91,4565	0,9178
	3	1118,7640	41,9599	12,3033	30,2590	0,5446
	4	1217,3595	861,8866	1493,4269	73,0694	0,6614
	5	756,5168	938,7243	1221,7415	82,5415	0,7981
	6	295,6741	366,8181	1125,3370	24,8729	0,8382


**Fonte:** Tabela idealizada pelo autor do presente texto.

Ao observar as curvas correspondentes a cada indivíduo e compará-las a curva força-deformação experimental verificou-se diversas discrepâncias. Em alguns casos, mesmo com o valor da função objetivo ( $f$ ) não muito distante da unidade (1), como no caso dos indivíduos 5 e 6 da geração 0, o indivíduo 4 da geração 1, o indivíduo 5 da geração 2 ou o indivíduo 2 da geração 3, as curvas foram muito distintas. É importante observar que em um espaço de busca tão geral quanto ao que está sendo usado pode-se chegar a diversos máximos locais. O indivíduo 2 da geração 3 apresenta um valor bem próximo à unidade (1) o que caracterizaria uma curva similar à obtida experimentalmente, no entanto, os valores obtidos não correspondem a um máximo global (Figura 4.05 (Indivíduo 2)).


Com a intenção de melhorar a busca, mas mantendo-se fixo o intervalo inicial e a quantidade de três (3) gerações, aumentou-se o número de indivíduos da população de seis (6) para dez (10). Ao longo das gerações não ocorreram alterações desta quantidade.




Indivíduo 1




Indivíduo 2




Indivíduo 3



Indivíduo 4



Indivíduo 5




Indivíduo 6


**Figura 4.02.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 6 indivíduos. As curvas representam indivíduos da geração inicial ou geração 0.

**Fonte:** Figura idealizada pelo autor do presente texto







Indivíduo 1



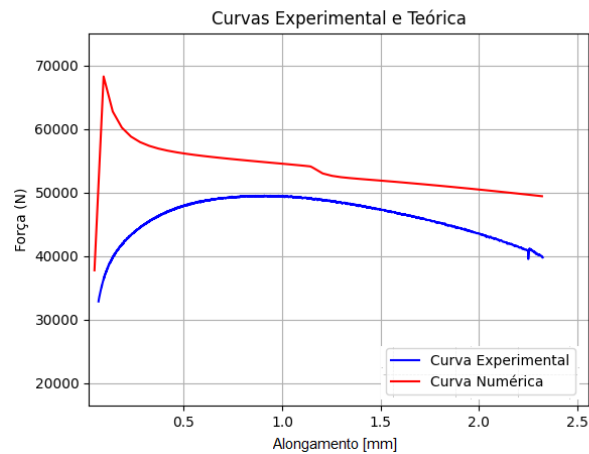
Indivíduo 2




Indivíduo 3



Indivíduo 4




Indivíduo 5




Indivíduo 6

**Figura 4.03.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 6 indivíduos. As curvas representam indivíduos da geração inicial ou geração 1.


**Fonte:** Figura idealizada pelo autor do presente texto




Indivíduo 1




Indivíduo 2




Indivíduo 3



Indivíduo 4




Indivíduo 5




Indivíduo 6

**Figura 4.04.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 6 indivíduos. As curvas representam indivíduos da geração inicial ou geração 2.


**Fonte:** Figura idealizada pelo autor do presente texto




Indivíduo 1




Indivíduo 2




Indivíduo 3



Indivíduo 4



Indivíduo 5



Indivíduo 6

**Figura 4.05.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 6 indivíduos. As curvas representam indivíduos da geração inicial ou geração 3.


**Fonte:** Figura idealizada pelo autor do presente texto

Na Tabela 4.03 pode-se observar que houve um aumento do número de indivíduos com uma melhor avaliação, próxima à unidade (1). Alguns estão representados graficamente na Figura 4.06.


**Tabela 4.03** Aço 4340 Normalizado – Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo – 3 gerações e população inicial fixa de 10 indivíduos.

<b>Aço 4340 Normalizado – Parâmetros</b>						
<b>Geração</b>	<b>Indivíduo</b>	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	1	468,7640	1466,4044	1107,8089	81,5200	0,8310
	2	771,1235	1444,4943	278,1460	50,3176	0,6625
	3	514,7752	855,8426	604,6067	37,1309	0,7493
	4	492,8651	632,3595	281,0674	87,4633	0,6655
	5	990,9550	823,7078	782,0786	86,1632	0,8608
	6	1080,7865	567,3595	757,9775	43,3528	0,8610
	7	1056,6853	567,3595	244,5505	45,8602	0,6442
	8	38,5955	624,3258	1044,2696	34,3450	0,7978
	9	1448,1460	207,3033	1143,5955	55,1466	0,6318
	10	604,6067	1018,7078	1231,2359	22,4584	0,8322
1	1	468,7640	1419,6629	371,6292	45,8602	0,6722
	2	771,1235	1491,2359	1014,3258	85,9775	0,8724
	3	494,3258	1273,5955	232,1348	40,1026	0,6832
	4	513,3146	214,6067	653,5393	84,4916	0,7383
	5	988,0337	215,3370	779,8876	44,5601	0,8257
	6	1083,7078	1175,7303	760,1685	84,9560	0,8746
	7	129,1573	614,1011	993,8764	45,8602	0,8417
	8	<b>966,1235</b>	<b>577,5842</b>	<b>294,9438</b>	<b>34,3450</b>	<b>0,9175</b>
	9	1451,7977	1007,7528	1231,2359	22,4584	0,7166
	10	<b>600,9550</b>	<b>218,2584</b>	<b>1143,5955</b>	<b>55,1466</b>	<b>0,9424</b>
2	1	<b>121,1235</b>	<b>1290,3932</b>	<b>989,4943</b>	<b>69,9120</b>	<b>0,8641</b>
	2	61,9662	746,2921	653,5393	70,7478	0,7387
	3	633,8202	1422,5842	435,8988	89,2277	0,7037
	4	1153,0898	1096,1235	1226,1235	28,3088	0,7605
	5	<b>1283,8202</b>	<b>947,8651</b>	<b>1287,4719</b>	<b>20,6011</b>	<b>0,7295</b>
	6	796,6853	1315,2247	484,1011	14,7507	0,7805
	7	524,2696	123,31460	129,8876	31,2805	0,5647
	8	211,6853	1310,1123	68,5393	32,2091	0,5597
	9	1153,0898	277,4157	62,6966	32,4877	0,5822
	10	<b>975,6179</b>	<b>766,7415</b>	<b>1129,7191</b>	<b>73,1622</b>	<b>0,8459</b>
3	1	260,6179	53,9325	53,2022	71,8621	0,5826
	2	1066,1797	1415,2808	1354,6629	83,5630	0,6888
	3	1209,3258	394,2696	1111,4606	66,7546	0,8369
	4	422,0224	654,2696	1190,3370	9,9217	0,8099
	5	<b>746,2921</b>	<b>956,6292</b>	<b>1034,7752</b>	<b>33,8807</b>	<b>0,9193</b>
	6	724,3820	1413,0898	116,0112	72,9765	0,8135
	7	1453,9887	781,3483	308,8202	26,9159	0,6763
	8	963,2022	1323,2584	1421,8539	38,8954	0,6897
	9	1206,4044	683,4831	1188,1460	86,2561	0,7944
	10	216,7977	318,3146	166,4044	54,3108	0,5573


Fonte: Tabela idealizada pelo autor do presente texto




(a) Geração 1 – Indivíduo 10



(b) Geração 2 – Indivíduo 5



(c) Geração 2 – Indivíduo 10



(d) Geração 3 – Indivíduo 5

**Figura 4.06.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 10 indivíduos e um intervalo inicial aleatório fixo. As curvas representam indivíduos com diferentes avaliações.

**Fonte:** Figura idealizada pelo autor do presente texto

Em uma segunda tentativa para aumentar a quantidade de indivíduos com melhores avaliações elevou-se o tamanho da população passando de dez (10) para vinte (20) indivíduos. Essa quantidade foi mantida fixa ao longo das 3 gerações em estudo.


Um dos parâmetros indicados inicialmente para o funcionamento do Algoritmo Genético foi a quantidade de indivíduos participantes que poderiam compor a elite a cada geração, foi escolhida a quantidade três (3), ou seja, a cada geração os três indivíduos de melhor avaliação seriam inseridos no conjunto elite. Para ilustrar os resultados obtidos com o aumento da população são apresentados na Tabela 4.04 os indivíduos que foram acrescentados ao conjunto “elite” ao longo de cada geração.

**Tabela 4.04** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo – 3 gerações e população inicial fixa de 20 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	5	<b>687,1348</b>	<b>476,0674</b>	<b>1094,6629</b>	<b>46,6031</b>	<b>0,9439</b>
	15	931,7978	45,8989	177,3596	99,6285	0,9209
	17	638,9326	307,3596	1178,6517	53,8465	0,9075
1	4	525,7303	901,8539	1035,5056	61,1828	0,9217
	3	603,1461	104,3258	1194,7191	15,4936	0,9055
	15	878,4831	754,3258	535,2247	45,7674	0,9044
2	12	<b>424,2135</b>	<b>100,6742</b>	<b>1164,7753</b>	<b>49,5748</b>	<b>0,9310</b>
	7	845,6180	1277,2472	876,2921	94,6139	0,9291
	13	799,6067	503,0899	1131,9101	8,0645	0,9284
3	5	454,1573	1164,7753	1054,4944	33,1378	0,8711
	18	1340,7865	580,5056	936,1798	78,4555	0,8529
	11	1072,7528	453,4270	806,1798	94,5210	0,8380

**Fonte:** Tabela idealizada pelo autor do presente texto

Verifica-se que houve uma sensível melhora em relação à presença de indivíduos com avaliação próxima a unidade ao longo das primeiras gerações e uma queda na última geração. É importante observar que um bom retorno da função de avaliação não necessariamente indica uma curva ótima compatível à curva experimental de imediato, na Figura 4.07 são apresentados dois exemplos cujos parâmetros encontram-se na Tabela 4.04.



**Figura 4.07.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 20 indivíduos e um intervalo inicial aleatório fixo. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações.

**Fonte:** Figura idealizada pelo autor do presente texto


Devido a redução dos valores da função de avaliação ao longo das três (3) gerações propostas inicialmente, procurou-se realizar os mesmos testes para um número maior de gerações, no caso, seis (6) gerações. Verificou-se que fenômenos idênticos aos

que já haviam sido observados novamente ocorreram. Para uma população de 6 indivíduos continuou-se a ter baixos valores para a função de avaliação (Tabela 4.05).

**Tabela 4.05** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo – 6 gerações e população inicial fixa de 6 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	3	1240.7303	687.8652	1024.5506	81.3343	0.8560
	1	831.0112	1312.3034	1070.5618	84.4917	0.8480
	6	690.0562	293.4831	473.8764	17.7224	0.7991
1	3	1240.7303	687.8652	1024.5506	81.3343	0.8560
	1	831.0112	1312.3034	1070.5618	84.4917	0.8480
	6	690.0562	293.4831	473.8764	17.7224	0.7991
2	1	764.5506	1443.7640	942.0225	76.7840	0.9164
	5	220.4494	798.1461	1042.0787	60.6256	0.8858
	3	183.9326	1123.8764	1404.3258	62.5758	0.7195
3	6	549.1011	942.0225	742.6404	50.7820	0.8302
	4	1148.7079	1080.7865	195.6180	96.09979	0.8078
	1	1091.7416	467.3034	1239.2700	57.5611	0.8045
4	1	999.7191	470.2247	1146.5169	53.2893	0.8617
	6	1272.8652	755.7865	652.0787	98.4213	0.8067
	3	1171.3483	356.2921	668.8764	95.9140	0.7837
5	5	1025.2809	619.2135	1140.6742	12.8935	0.8639
	6	881.4045	83.1461	877.7528	86.6276	0.8263
	1	1284.5506	838.3146	479.7191	51.2463	0.7517
6	3	795.9551	335.1124	1180.8427	66.8475	0.8788
	5	1031.1236	116.0112	945.6742	81.2415	0.8633
	6	116.7416	1428.4270	1223.9326	85.0489	0.7714

**Fonte:** Tabela idealizada pelo autor do presente texto



(a) Geração 2 – Indivíduo 1

(b) Geração 6 – Indivíduo 3

**Figura 4.08.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 6 gerações com população inicial de 6 indivíduos e um intervalo inicial aleatório fixo. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações.

**Fonte:** Figura idealizada pelo autor do presente texto


Em uma população de 10 indivíduos foi possível verificar uma melhora significativa dos valores da função de avaliação (Tabela 4.06) e em uma população de 20

indivíduos tem-se uma constância no aparecimento de valores mais próximos da unidade (1). Nas Figuras 4.08, 4.09 e 4.10 são apresentados alguns indivíduos que obtiveram um alto valor para função de avaliação ( $f$ ).

**Tabela 4.06** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo – 6 gerações e população inicial fixa de 10 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	9	68,5393	414,4770	933,9888	75,4839	0,8581
	1	245,2809	309,4330	1119,4944	28,4946	0,8386
	7	668,1460	371,6813	734,6067	86,5347	0,7968
1	5	88,2584	342,5024	1205,6742	72,6051	0,8660
	4	1137,0225	819,0909	573,2022	40,1955	0,8121
	6	248,9326	489,3695	806,9101	56,8182	0,8064
2	5	88,2584	342,5024	1205,6742	72,6051	0,8660
	4	1137,0225	819,0909	573,2022	40,1955	0,8121
	6	248,9326	489,3695	806,9101	56,8182	0,8064
3	5	88,2584	342,5024	1205,6742	72,6051	0,8660
	4	1137,0225	819,0909	573,2022	40,1955	0,8121
	6	248,9326	489,3695	806,9101	56,8182	0,8064
4	9	744,8315	727,6637	974,1573	78,4555	0,9558
	2	694,4382	417,3949	1102,6966	17,7224	0,9326
	5	246,7416	633,3187	1107,8090	63,7830	0,8897
5	2	351,9101	94,4819	1158,2022	43,2600	0,9117
	8	906,2360	941,6422	1050,1124	27,2874	0,8943
	10	212,4157	439,7653	1145,7865	62,6686	0,8881
6	8	744,8315	990,2737	988,7640	87,9277	0,9280
	3	1168,4270	111,0166	928,1461	88,7634	0,8750
	10	1162,5843	513,6852	721,4607	64,8974	0,8194

**Fonte:** Tabela idealizada pelo autor do presente texto



(a) Geração 4 – Indivíduo 9

(b) Geração 6 – Indivíduo 8

**Figura 4.09.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 6 gerações com população inicial de 10 indivíduos e um intervalo inicial aleatório fixo. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações.

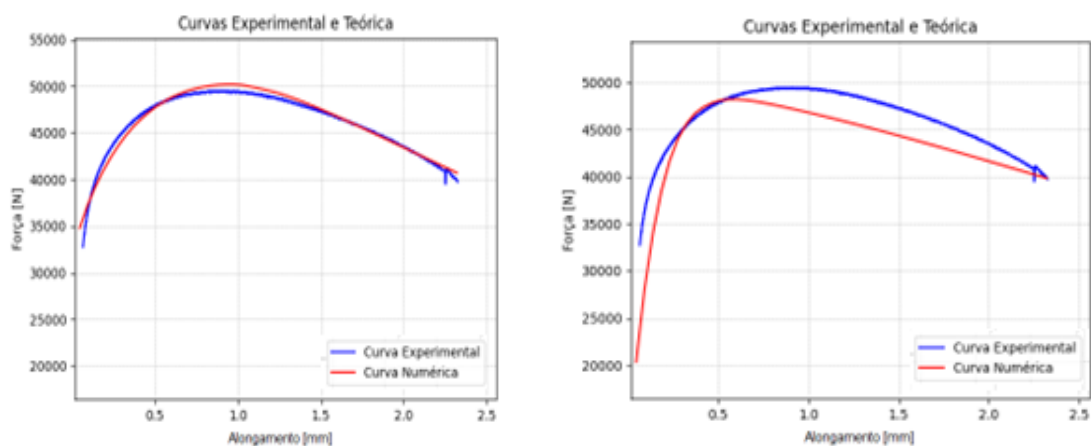
**Fonte:** Figura idealizada pelo autor do presente texto



**Tabela 4.07** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em um intervalo inicial aleatório fixo – 6 gerações e população inicial fixa de 20 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	8	923,7640	537,0283	919,3820	51,8035	0,9075
	3	346,7978	344,4477	1042,8090	45,6745	0,9030
	16	336,5730	400,8602	925,2247	98,2356	0,9021
1	13	1212,9775	290,9531	955,8989	77,8055	0,8614
	17	351,9101	829,7898	1185,2247	36,8524	0,8415
	19	507,4719	815,2004	1272,1348	47,2532	0,8080
2	17	690,0562	94,4819	1115,8427	30,6305	0,9858
	4	279,6067	595,3861	876,2921	58,4897	0,8519
	20	40,05618	947,4780	894,5506	42,2385	0,7936
3	17	690,0562	94,4819	1115,8427	30,6305	0,9858
	4	279,6067	595,3861	876,2921	58,4897	0,8519
	20	40,0562	947,4780	894,5506	42,2385	0,7936
4	16	286,9101	363,9003	1001,9101	96,5640	0,9352
	4	906,9662	61,4125	187,5843	48,7390	0,9204
	3	430,0562	379,4624	936,9101	80,9629	0,9099
5	3	859,4944	19,5894	27,6404	96,7498	0,8970
	1	538,8764	445,6012	1206,4045	40,6598	0,8828
	19	807,6404	782,1310	67,0787	11,4076	0,8683
6	17	963,9326	256,9110	546,9101	28,9589	0,9250
	20	939,1011	874,5308	926,6854	78,3627	0,9243
	2	572,4719	1000,0000	1034,7753	81,9844	0,9117

Fonte: Tabela idealizada pelo autor do texto



(a) Geração 2 – Indivíduo 17

(b) Geração 4 – Indivíduo 16

**Figura 4.10.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 6 gerações com população inicial de 20 indivíduos e um intervalo inicial aleatório fixo. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações.

Fonte: Figura idealizada pelo autor do presente texto

Com estes estudos verifica-se que uma maior população favorece o aparecimento de indivíduos com melhor avaliação dentro de um espaço de busca amplo. Ao se permitir o desenvolvimento de um número maior de gerações foi possível verificar diversos conjuntos de valores que poderiam ser candidatos a máximos locais ou globais favorecendo a diversidade necessária ao bom andamento do Algoritmo Genético desenvolvido. Mas, uma outra importante variável que deve ser avaliada é o tempo de processamento para os cálculos e análises a serem realizadas. Na Tabela 4.08 podem ser verificados os tempos em minutos para todo o processo realizado levando-se em consideração o número de gerações e a quantidade de indivíduos das populações, que neste primeiro momento é fixa.

**Tabela 4.08** Aço 4340 Normalizado – Tempos medidos para o Algoritmo Genético (GA) avaliado considerando-se quantidades de indivíduos fixas ao longo das gerações.

Geração	Populações fixas – Qtde de indivíduos		
	6	10	20
Tempo de execução (min)			
3	16:43	22:12	46:22
6	28:37	70:58	76:38

**Fonte:** Tabela idealizada pelo autor do presente texto

Como o Algoritmo Genético é apenas uma das etapas a serem cumpridas ao se procurar a solução do presente problema de otimização buscou-se realizar mais uma série de análises com o objetivo de se reduzir os tempos verificados (Tabela 4.08).

Os testes seguintes foram desenvolvidos levando-se em consideração uma mudança dos limites iniciais da região de busca para os parâmetros em análise. Como visto em capítulo anterior, foram verificados em meio aos dados experimentais o limite de escoamento e o limite de resistência à tração e a partir destes criou-se um novo intervalo para os parâmetros (Tabela 4.09) adotando-se um percentual de erro de 30%, valor este que pode ser alterado na rotina PYTHON desenvolvida.

**Tabela 4.09** Aço 4340 Normalizado – Intervalo inicial de busca modificado, levando-se em consideração os limites de escoamento e de resistência a tração.

Aço 4340 Normalizado – Parâmetros				
Limites	$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []
Inferior ( <i>inf<sub>i</sub></i> )	484,5987	5	687,2340	5
Superior ( <i>sup<sub>i</sub></i> )	899,9689	1500	1276,2918	100
Precisão	1	1	1	0,1
Número de bits mínimo	11	11	11	10

**Fonte:** Tabela idealizada pelo autor do presente texto.

Ao serem aplicados tais recursos observou-se uma melhora nos valores da função de avaliação ( $f$ ), aproximando-se do valor máximo unitário (1) (Tabelas 4.10, 4.11, 4.12).

**Tabela 4.10** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) com intervalo inicial aleatório não fixo – 3 gerações e população inicial fixa de 6 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	2	814.6189	610.4494	889.9206	72.9765	0.9126
	1	602.4630	149.6067	959.0182	14.9365	0.8503
	3	742.2745	644.7752	754.0285	93.8710	0.8341
1	6	580.8622	855.4924	1045.0743	22.0326	0.8974
	1	723.8170	587.6664	837.7747	67.5280	0.8800
	4	623.7870	348.2920	879.0284	28.0902	0.8615
2	6	583.7706	383.6835	904.8145	91.8550	0.9007
	1	716.3236	396.2799	891.6864	89.7131	0.8932
	4	643.9569	848.1755	865.0199	27.6834	0.8873
3	6	659.4702	783.4603	850.3566	73.8207	0.9031
	1	713.2029	591.5911	882.2558	16.5765	0.8810
	4	725.7572	758.1442	801.4676	64.3169	0.8712

**Fonte:** Tabela idealizada pelo autor do presente texto

Avaliando-se novamente a população com de seis (6) indivíduos e três (3) gerações, obteve-se resultados superiores aos alcançados no cenário anterior. Verificou-se uma maior quantidade de indivíduos com avaliação próxima a unidade (1). Aspectos que se repetiram para os demais cenários com dez (10) e vinte (20) indivíduos ao longo de três gerações. Nas Tabelas 4.11 e 4.12 é possível verificar o conjunto elite obtido a cada geração.

**Tabela 4.11** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) com intervalo inicial aleatório não fixo – 3 gerações e população inicial fixa de 10 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	9	525.2415	314.6629	1038.4806	57.7468	0.9645
	7	893.4661	151.0674	1199.7085	9.3646	0.9294
	8	576.4516	145.9551	993.5671	86.9990	0.9209
1	9	526.0544	677.6404	1020.6303	80.4057	0.9570
	7	578.0773	145.2247	1046.5420	80.3128	0.9479
	8	891.8404	151.7978	1146.7336	16.0508	0.9356
2	7	696.7545	1296.9663	875.5252	54.9609	0.9306
	1	725.2045	461.4607	907.7708	45.4888	0.9099
	8	730.0817	1326.9101	855.3717	18.8368	0.9062
3	6	895.0918	240.1685	1112.7606	30.8162	0.9246
	7	603.2759	1308.6517	978.5959	79.1056	0.9152
	10	660.9888	319.0449	1145.5820	9.9218	0.8960

**Fonte:** Tabela idealizada pelo autor do presente texto

**Tabela 4.12** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) com intervalo inicial aleatório não fixo – 3 gerações e população inicial fixa de 20 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	8	678,8716	455,6180	984,3541	48,1818	0,9603
	7	608,1530	663,7640	972,2620	53,1965	0,9565
	10	575,6387	653,5393	940,5922	52,8250	0,9347
1	12	665,8659	645,5056	1003,9317	80,5914	0,9648
	10	567,5101	1491,9663	928,5001	77,5269	0,9211
	18	596,7730	1425,5056	983,2024	36,0166	0,8982
2	11	839,8175	641,1236	1016,5996	46,8817	0,9413
	18	832,5017	1459,1011	861,1299	89,5064	0,9264
	20	738,2103	611,9101	1088,5764	60,5327	0,9180
3	17	748,7774	1082,9775	938,8648	58,3040	0,9423
	4	774,7889	1191,7978	903,7401	72,0479	0,9383
	5	811,3674	21,7978	1061,5131	34,9022	0,9337

**Fonte:** Tabela idealizada pelo autor do presente texto

Voltando-se a analisar os tempos de execução do Algoritmo Genético e considerando-se apenas o desenrolar de três (3) gerações (Tabela 4.13) verifica-se uma redução nos tempos para as três populações propostas. Este fenômeno pode ser explicado pelo uso de parâmetros com melhores índices de avaliação ao se executar o módulo de Elementos Finitos, reduzindo o tempo de trabalho deste (tempo de execução).

**Tabela 4.13** Aço 4340 Normalizado – Tempos medidos para o Algoritmo Genético (GA) avaliado considerando-se quantidades de indivíduos fixas ao longo das gerações.

Qtde. Gerações	Populações fixas – Qtde de indivíduos		
	6	10	20
Tempo de execução (min)			
3	11:14	18:46	41:03

**Fonte:** Tabela idealizada pelo autor do presente texto

Dando-se continuidade aos estudos para melhoria do Algoritmo Genético (GA) aplicado no presente trabalho realizou-se mais alguns testes. Desta vez permitindo uma mudança dos limites da região de busca a cada geração. Tomando-se muito cuidado para não restringir demais a região de busca e com isso eliminar-se uma das mais interessantes características do Algoritmo Genético que é sua aleatoriedade, não se prendendo a máximos ou mínimos locais. Desenvolveu-se uma rotina para a avaliação estatística dos valores obtidos e de acordo com os valores médios e os desvios padrão encontrados realizou-se a redução dos intervalos de cada parâmetro. A cada geração são analisados os valores de avaliação dos indivíduos da população e caso haja uma piora dos índices de

avaliação a rotina permite o aumento da região de busca até que sejam novamente alcançados os limites iniciais.

**Tabela 4.14** Aço 4340 Normalizado – Tempos medidos para o Algoritmo Genético (GA) avaliado considerando-se quantidades aleatórias de indivíduos ao longo das gerações.

		Populações – Qtde inicial de indivíduos		
		6	10	20
Qtde. Gerações	Populações – Qtde final de indivíduos			
	28	32	42	
		Tempo de execução (min)		
3		15:26	32:46	49:27

**Fonte:** Tabela idealizada pelo autor do presente texto

Os tempos de execução são apresentados na Tabela 4.14. Verifica-se que houve um aumento dos valores, mas isso ocorrera porque neste momento também foram utilizados outros aspectos do Algoritmo Genético com o objetivo de aumentar a variabilidade do conjunto em estudo. Acrescentou-se o conjunto elite à população para que houvesse um aumento de indivíduos com melhor avaliação, esta ação ocorreu a cada duas gerações, parâmetro este que pode ser modificado, sendo possível acrescentar a elite em um intervalo qualquer de gerações. Esta ação deve ser bem avaliada para que não favoreça a convergência genética precoce do algoritmo.


**Tabela 4.15** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) com intervalos não fixos ao longo de 3 gerações e população inicial de 6 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	6	843,8818	942,7528	1011,4173	71,8622	0,9117
	3	790,2331	807,6404	1064,9680	66,1046	0,9028
	2	574,0130	331,4607	862,2815	97,3998	0,8666
1	1	651,1704	698,4009	1032,6772	56,5557	0,9514
	3	665,0044	1010,3267	923,2250	94,5285	0,9505
	4	700,2182	307,1719	1022,1578	87,5585	0,9485
2	11	694,8003	621,6563	982,0888	81,5175	0,9654
	14	655,8405	454,2592	1013,8198	94,4469	0,9632
	9	636,5028	578,6113	1042,8238	52,6312	0,9625
3	25	683,4975	409,0721	1034,2139	39,6701	0,9785
	19	654,1194	134,1311	1072,6560	39,8874	0,9760
	9	625,0791	561,5697	1045,9136	2,2775	0,9630

**Fonte:** Tabela idealizada pelo autor do presente texto

Foi inserida também a possibilidade de redimensionamento da população em meio às gerações, o que promoveu um crescimento populacional amplo a partir da 2ª geração. Neste caso deve-se tomar cuidado com o crescimento rápido da população, aumentando-

se o tempo de processamento e favorecendo a não convergência a um valor máximo local instantaneamente. Os resultados podem ser vistos nas Tabelas 4.15, 4.16 e 4.17. As Figuras 4.11, 4.12 e 4.13 ilustram alguns indivíduos encontrados em cada teste realizado, a função de avaliação de cada um pode ser encontrada na correspondente Tabela.




**Figura 4.11.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 6 indivíduos. Empregou-se a mudança de limites, o redimensionamento da população e a reinserção de indivíduos da elite na população ao longo das gerações. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações, mas ainda distantes da curva experimental.

**Fonte:** Figura idealizada pelo autor do presente texto

**Tabela 4.16** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em com intervalos não fixos ao longo de 3 gerações e população inicial de 10 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	3	681,3102	703,2022	1048,8452	82,0772	0,9310
	1	760,1574	932,5281	918,7113	16,3294	0,9196
	9	768,2860	1454,7191	953,8359	38,8954	0,9134
1	8	616,8027	729,8472	945,3475	64,7617	0,9539
	3	604,1323	865,2622	975,5220	61,8203	0,9521
	7	620,6037	455,6634	945,8561	53,4954	0,9317
2	9	608,1059	722,1535	950,9921	70,4901	0,9583
	4	721,0228	607,9676	963,1333	49,0105	0,9581
	16	597,3859	835,2886	990,2854	67,4216	0,9529
3	9	590,0822	743,0437	946,1564	81,1814	0,9584
	5	727,7762	606,6085	959,4925	53,8903	0,9570
	23	724,2903	788,6616	982,5277	61,3935	0,9563

**Fonte:** Tabela idealizada pelo autor do presente texto



(a) Geração 2 – Indivíduo 9

(b) Geração 3 – Indivíduo 5

**Figura 4.12.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 10 indivíduos. Empregou-se a mudança de limites, o redimensionamento da população e a reinserção de indivíduos da elite na população ao longo das gerações. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações, mas ainda distantes da curva experimental.


**Fonte:** Figura idealizada pelo autor do presente texto

Observa-se nas Figuras 4.11, 4.12 e 4.13 que apesar dos bons valores da função de avaliação, as curvas ainda apresentam certa distância do ideal, mesmo que se configurem como boas candidatas para o início de uma segunda fase em que será usado um método de análise direta na busca por valores máximos dos parâmetros envolvidos.


**Tabela 4.17** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) com intervalos não fixos ao longo de 3 gerações e população inicial de 20 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	12	651,2345	524,2697	1003,3559	79,0127	0,9731
	10	543,9373	768,9326	919,8629	98,7928	0,9462
	19	765,0346	726,5730	902,0127	71,5836	0,9320
1	11	644,4899	434,5189	1017,9400	61,6820	0,9802
	17	705,1813	825,2637	968,6679	59,6313	0,9576
	16	734,2076	754,1835	961,0875	86,7523	0,9556
2	9	662,8863	368,4095	1022,3803	65,1850	0,9730
	22	669,0215	650,9250	957,8871	81,3131	0,9624
	26	723,3614	777,5841	966,7714	63,0972	0,9592
3	37	759,5433	383,9352	1023,7426	45,0520	0,9664
	39	648,7002	690,9471	962,0601	60,2552	0,9619
	31	696,1330	750,8387	985,7290	53,9601	0,9613

**Fonte:** Tabela idealizada pelo autor do presente texto



(a) Geração 1 – Indivíduo 11



(b) Geração 0 – Indivíduo 12

**Figura 4.13.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 20 indivíduos. Empregou-se a mudança de limites, o redimensionamento da população e a reinserção de indivíduos da elite na população ao longo das gerações. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações, mas ainda distantes da curva experimental.

**Fonte:** Figura idealizada pelo autor do presente texto

Com as melhorias inseridas no algoritmo inicial obteve-se um conjunto maior de possíveis soluções com bons índices de avaliação. Como uma das metas é a redução do tempo de execução de cada fase do processamento, realizou-se mais um conjunto de testes levando-se em consideração uma população inicial menor, no caso, com apenas quatro (4) indivíduos. Os resultados podem ser vistos nas Tabelas 4.18 e 4.19 para três (3) e seis (6) gerações, respectivamente.

**Tabela 4.18** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em com intervalos não fixos ao longo de 3 gerações e população inicial fixa de 4 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	3	812,9932	1013,5955	892,2238	65,8260	0,9349
	4	896,7175	1367,0787	918,7113	85,6061	0,9162
	2	674,8074	366,5169	970,5345	20,9726	0,9083
1	2	824,4913	947,7900	933,6952	68,4199	0,9403
	3	824,8837	621,6815	926,8595	80,7135	0,9316
	1	786,0353	1199,3886	825,7471	81,4282	0,9120
2	15	755,3529	939,7848	919,0520	63,0021	0,9458
	14	807,0140	976,7858	914,4935	64,1754	0,9407
	10	861,8380	651,4561	945,2208	88,4376	0,9338
3	14	811,1257	665,1099	967,3095	74,9465	0,9471
	22	749,6409	1114,2750	906,4425	59,3395	0,9411
	5	817,3433	1160,0553	901,3068	60,9002	0,9357

**Fonte:** Tabela idealizada pelo autor do presente texto



**Tabela 4.19** Aço 4340 Normalizado – Melhores Resultados para o Algoritmo Genético (GA) em com intervalos não fixos ao longo de 6 gerações e população inicial fixa de 4 indivíduos.

Aço 4340 Normalizado – Parâmetros						
Geração	Indivíduo	$\sigma_{y_0}$	$\zeta$	$\sigma_{\infty}$	$\delta$	$f$
0	2	895,9046	518,4270	725,8136	45,3030	0,8078
	1	701,6317	115,2809	796,0629	48,8319	0,8015
	3	573,2001	1063,2584	1257,2899	71,5836	0,7817
1	2	805,7122	591,5299	827,1794	49,2993	0,8729
	1	769,2238	369,1891	818,3587	46,8436	0,8433
	4	640,3883	1064,4600	1237,3388	52,6554	0,7980
2	16	622,2527	197,3501	1053,9940	47,9046	0,9727
	15	662,5928	450,6079	944,4503	49,4703	0,9320
	9	853,3363	1195,3859	896,3175	46,9689	0,9313
3	25	667,8332	149,6247	1101,1475	49,3409	0,9707
	33	720,0201	970,7058	973,4433	44,8058	0,9433
	15	559,6221	15,4571	1054,1620	48,3086	0,9383
4	60	687,3811	328,3926	1047,2175	48,1425	0,9829
	30	713,4158	827,1799	969,2139	47,5103	0,9551
	15	618,1191	242,8299	1018,7863	47,6310	0,9550
5	6	617,3789	272,2307	1035,6928	46,6619	0,9694
	28	747,2184	343,8355	1038,0809	45,9953	0,9694
	5	603,4052	163,8425	1056,3896	49,9947	0,9673
6	5	741,9080	260,0782	1046,8106	46,0445	0,9664
	100	597,9211	171,5667	1044,0179	46,7118	0,9592
	61	668,3004	92,7552	1059,8431	47,9783	0,9585

**Fonte:** Tabela idealizada pelo autor do presente texto


Na Tabela 4.20 tem-se uma representação das mudanças ocorridas nos limites da região de busca a cada geração para o aço 4340 Normalizado. Para este exemplo, foram desenvolvidas 3 gerações com população inicial de 6, 10 e 20 indivíduos respectivamente. Observa-se inicialmente uma queda na extensão ( $\Delta l$ ) do intervalo para que posteriormente seja alcançada uma constância deste. A redução ou o aumento da região de busca são controlados pela melhora ou piora da função de avaliação, caso haja melhora reduz-se o intervalo de  $n$  desvios-padrão, caso haja piora aumenta-se o intervalo levando-se em consideração os mesmos  $n$  desvios-padrão. O valor de  $n$  é indicado pelo usuário do sistema e o desvio-padrão é calculado sobre a média das funções de avaliação obtidas para a geração desenvolvida. No presente estudo adotou-se  $n = 2$ .

**Tabela 4.20** Aço 4340 Normalizado – Regiões de busca a cada geração do Algoritmo Genético.


Aço 4340 Normalizado – Parâmetros									
G	Lim	$\sigma_{y_0}$	$\Delta l$	$\zeta$	$\Delta l$	$\sigma_{\infty}$	$\Delta l$	$\delta$	$\Delta l$
<i>3 gerações e população inicial de 6 indivíduos</i>									
0	li	484,5987	415,3703	5,0000	1495,0000	687,2340	589,0577	5,0000	95,0000
	ls	899,9689		1500,0000		1276,2918		100,0000	
1	li	579,4852	214,2173	288,0578	832,4799	807,0103	256,2234	39,5488	57,0428
	ls	793,7024		1120,5377		1063,2337		96,5916	
2	li	587,8742	145,3172	96,0296	979,0335	819,4677	253,5997	27,6727	83,7133
	ls	733,1914		1075,0631		1073,0674		111,3859	
3	li	567,3360	172,5538	0,0000	1139,2797	794,9255	284,9733	19,1286	111,1849
	ls	739,8898		1139,2797		1079,8987		130,3134	
<i>3 gerações e população inicial de 10 indivíduos</i>									
0	li	484,5987	415,3703	5,0000	1495,0000	687,2340	589,0577	5,0000	95,0000
	ls	899,9689		1500,0000		1276,2918		100,0000	
1	li	550,0723	215,8178	255,2661	858,1869	816,5126	173,4186	11,4268	56,7758
	ls	765,8901		1113,4530		989,9312		68,2027	
2	li	551,6475	182,5966	325,6554	716,9891	783,2228	225,8263	14,8515	59,2282
	ls	734,2440		1042,6445		1009,0491		74,0797	
3	li	521,2351	222,6635	269,2871	856,6959	761,8750	248,0523	10,4892	75,2530
	ls	743,8987		1125,9830		1009,9274		85,7422	
<i>3 gerações e população inicial de 20 indivíduos</i>									
0	li	484,5987	415,3703	5,0000	1495,0000	687,2340	589,0577	5,0000	95,0000
	ls	899,9689		1500,0000		1276,2918		100,0000	
1	li	560,4895	224,7341	425,0939	803,8740	800,7343	298,2569	36,6630	52,4476
	ls	785,2235		1228,9679		1098,9913		89,1107	
2	li	579,1853	223,9332	358,5399	841,7894	777,2403	336,6150	39,7141	53,3949
	ls	803,1185		1200,3294		1113,8554		93,1090	
3	li	543,8486	255,1389	269,5476	1104,4877	724,6541	366,8675	33,7090	60,7532
	ls	798,9875		1374,0352		1091,5217		94,4622	

**Fonte:** Tabela idealizada pelo autor do presente texto

As Figuras 4.14 e 4.15 ilustram os indivíduos de melhor avaliação encontrados nos testes para 3 e 6 gerações e população inicial de 4 indivíduos, respectivamente.




(a) Geração 3 – Indivíduo 14




(b) Geração 2 – Indivíduo 15

**Figura 4.14.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 3 gerações com população inicial de 4 indivíduos. Empregou-se a mudança de limites, o redimensionamento da população e a reinserção de indivíduos da elite na população ao longo das gerações. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações, mas ainda distantes da curva experimental.

**Fonte:** Figura idealizada pelo autor do presente texto



(a) Geração 4 – Indivíduo 60



(b) Geração 2 – Indivíduo 16

**Figura 4.15.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Algoritmo Genético (GA). Foram desenvolvidas 6 gerações com população inicial de 4 indivíduos. Empregou-se a mudança de limites, o redimensionamento da população e a reinserção de indivíduos da elite na população ao longo das gerações. Ambas as curvas (a) e (b) representam indivíduos com boas avaliações.

**Fonte:** Figura idealizada pelo autor do presente texto

Observando-se as Figuras 4.14 e 4.15 e a Tabela 4.21, verifica-se que ao utilizar todos os aspectos inseridos no Algoritmo Genético (GA) desenvolvido, buscando melhores candidatos a solução ideal do problema de otimização proposto, mesmo com uma população inicial muito pequena, foi possível chegar a curvas mais próximas para os

parâmetros em estudo, no entanto, houve um aumento do tempo de processamento necessário.

**Tabela 4.21** Aço 4340 Normalizado – Tempos medidos para o Algoritmo Genético (GA) avaliado considerando-se quantidades aleatórias de indivíduos ao longo das gerações.

População	Gerações	
	3	6
Qtde inicial de indivíduos	4	4
Qtde final de indivíduos	50	342
Tempo de execução (min)	24:22	169:42

**Fonte:** Tabela idealizada pelo autor do presente texto

Reinserindo-se os indivíduos pertencentes à elite, redimensionando-se a população, e mudando-se a região de busca a cada geração levou o algoritmo a alcançar bons conjuntos de parâmetros, no entanto, o tempo de execução foi um entrave. Para uma sequência de seis (6) gerações obteve-se uma interessante solução (Figura 4.15 (a)), mas em um tempo extenso considerando-se o problema proposto.

Observa-se que existem muitas variáveis a serem estudadas e calibradas a ponto de equilibrarem o tempo de processamento e a busca por boas soluções. Inserindo-se o conjunto elite à população em espaços regulares entre gerações, como, por exemplo, a cada duas ou três gerações, e realizando um redimensionamento menor da população, também em espaços regulares entre gerações é possível trabalhar-se com um número menor de indivíduos e alcançar valores ótimos (próximos a unidade) para a função de avaliação.

Com todas as análises realizadas decidiu-se que o conjunto solução do Algoritmo Genético seria composto pelos três melhores grupos de parâmetros, ou seja, os três indivíduos de melhor avaliação dentro do conjunto elite, além da média de todos os indivíduos participantes deste conjunto e que tivessem avaliação superior a 0,9000, parâmetro que pode ser ajustado no sistema, e dos valores correspondentes ao desvio padrão em relação à média calculada para cada parâmetro. Esse conjunto solução corresponde a entrada do método numérico subsequente que de forma mais direta tenderá a aproximar-se de uma solução ótima. No sistema também é possível escolher com qual ou quais dos seis grupos de parâmetros deseja-se trabalhar.

## 4.2. MÉTODO DE LEVENBERG-MARQUARDT: RESULTADOS OBTIDOS

Diferente do Algoritmo Genético que pode ter diversas implementações de acordo com os problemas em que será aplicado, esta rotina não necessita de mudanças em seu núcleo básico tendo sido introduzido apenas um segundo critério de parada que pode ou não ser ativado, além do primeiro critério que diz respeito à precisão com que os parâmetros serão avaliados. A função de avaliação ( $f_2$ ) indicada em todas as tabelas desta seção corresponde à Equação 2.02.

Para análise, utilizou-se o Algoritmo LM com os parâmetros inicializados:

- aleatoriamente (Tabela 4.21 e Figura 4.16);
- com os valores de melhor pontuação oriundos do Algoritmo Genético (Tabela 4.22 e Figura 4.17); e
- com os valores médios oriundos do Algoritmo Genético (Tabela 4.23 e Figura 4.18).

observando-se ainda que nos casos em que os valores iniciais foram resultados oriundos do Algoritmo Genético buscou-se verificar o impacto de um segundo critério de parada, como citado anteriormente, a comparação de áreas sob as curvas experimentais e teóricas ou numéricas (Tabelas 4.24 e 4.25 e Figuras 4.19, 4.20 e 4.21).

Para a verificação da área sob a curva utilizou-se uma aproximação pela Regra 1/3 de Simpson, trabalhando-se com valores (pontos) igualmente espaçados. Estes pontos foram obtidos seguindo-se duas metodologias:

- uma simples interpolação dos dados utilizando-se métodos básicos de interpolação;
- o cálculo da média de todos os valores que estivessem presentes dentro de cada intervalo avaliado. Ao final, essa média foi usada como valor para a função nos pontos de desenvolvimento do método de Simpson.

Na Tabela 4.22 são apresentados os resultados obtidos via o Método LM para os parâmetros inicializados aleatoriamente. Estes valores iniciais foram estimados observando-se a curva experimental de tensão-deformação de engenharia para cada material em estudo. Para o Aço 4340 Normalizado foram necessárias 42 iterações e um tempo estimado de 23 minutos para se obter valores que convergissem para o ponto de mínimo da função objetivo indicada na Equação 2.02. Os valores correspondentes ao aço

4340 Recozido foram alcançados com 36 iterações em um tempo médio de 22 minutos e quanto ao aço 1524 U2 foram necessárias 54 iterações e o tempo médio de 34 minutos.

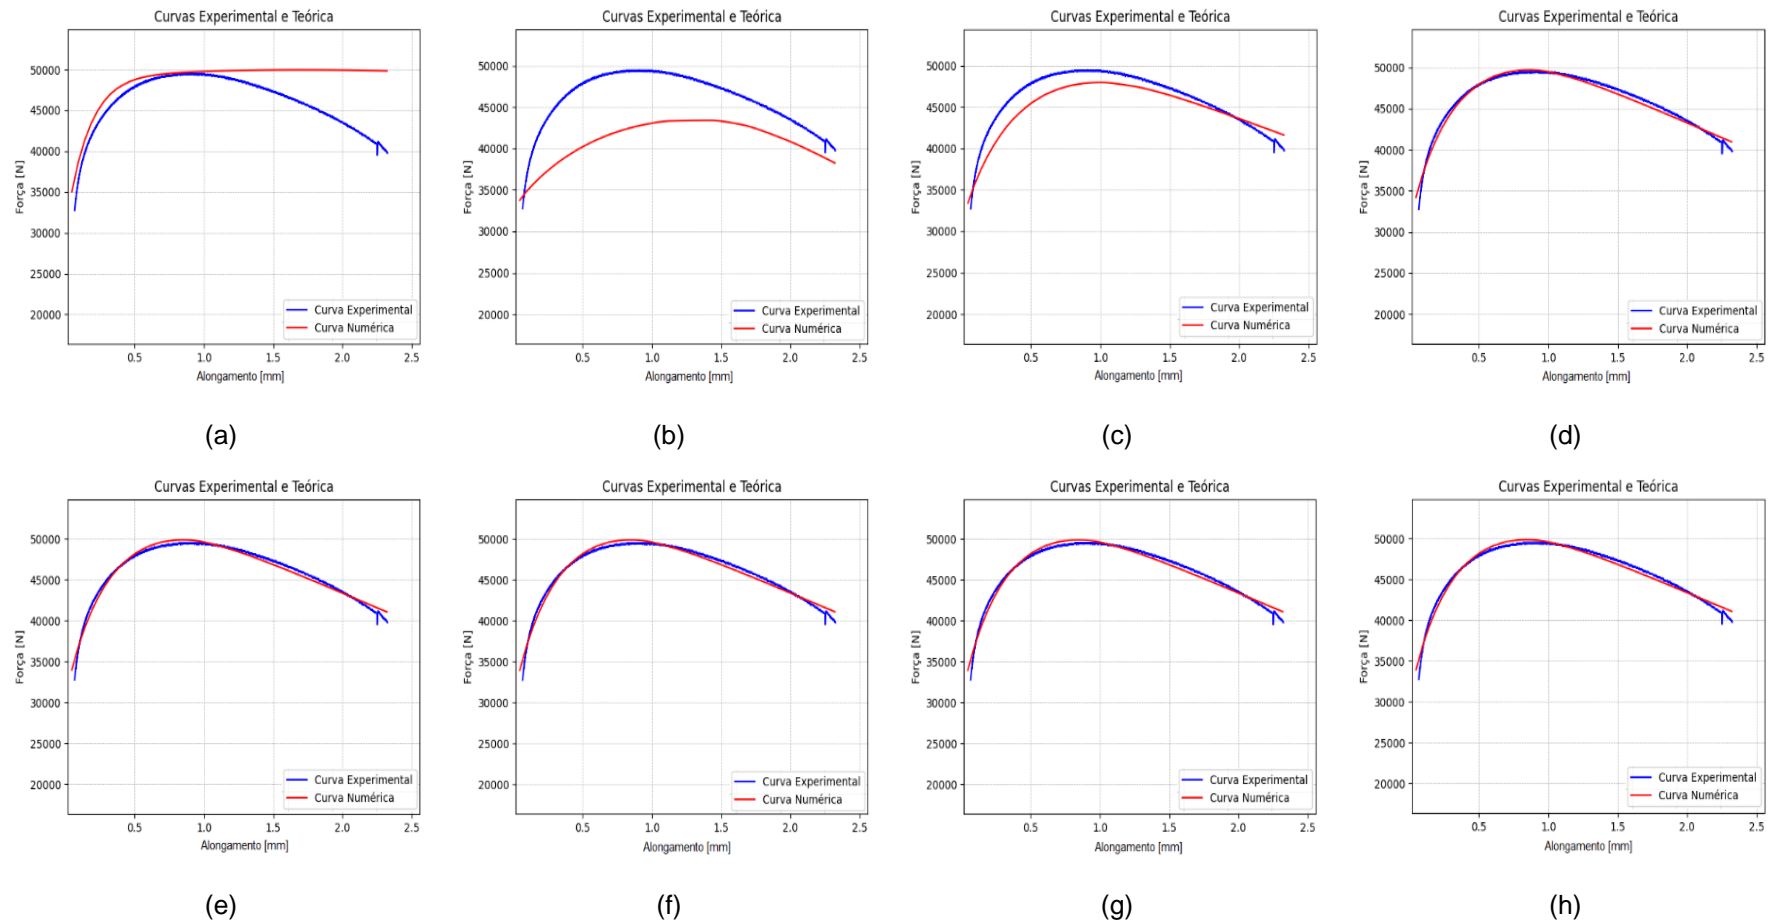
**Tabela 4.22** Resultados do Método LM para os parâmetros inicializados aleatoriamente.

Aço 4340 Normalizado						
Iteração	$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []	$f_2$	<i>tempo [min]</i>
0	692,2838	1154,5311	981,7629	74,9288	6,5201	
6	639,0574	807,2187	957,9067	79,7022	3,4410	02:56
12	661,5106	298,2934	1046,4850	30,9294	3,9048	03:09
18	676,7800	218,9095	1076,9350	38,1268	1,0239	03:29
24	671,3409	226,4123	1078,4028	39,5098	1,0221	03:14
30	670,3852	230,3606	1077,2858	39,8745	1,0284	03:19
36	670,0703	231,7993	1076,9319	39,9840	1,0301	03:12
42	670,0428	231,9621	1076,8930	39,9960	1,0303	03:07
<i>tempo total [min]</i>						22:29
Aço 4340 Recozido						
0	476,7107	42,6186	801,4633	27,0212	8,7249	
6	472,4780	139,9115	821,8421	17,0218	3,1568	03:22
12	480,6431	-7,9107	880,9478	14,4451	2,3845	03:23
18	483,8966	-34,7344	893,5608	13,9965	2,3947	03:50
24	484,7571	-41,8510	896,4749	13,8205	2,4027	03:32
30	485,2960	-46,3643	898,3984	13,6827	2,4073	03:32
36	485,3573	-46,8356	898,6017	13,6690	2,4079	03:32
<i>tempo total [min]</i>						21:14
Aço 1524 U2						
0	1098,6823	1495,3124	1213,5371	219,5916	15,8234	
6	1195,6583	733,5039	1076,8804	220,9319	8,4770	02:56
12	1129,8727	-122,0589	1262,8085	349,9102	4,2919	05:42
18	809,9033	-45,8403	1267,8424	279,1715	1,9529	03:38
24	1053,7179	-83,6383	1281,4695	125,1156	1,3160	03:39
30	1024,7794	-143,3794	1291,4698	101,3320	0,9273	03:33
36	1099,0451	-203,7512	1301,5147	52,8538	0,4918	03:47
42	1093,9388	-236,3132	1308,2577	53,6498	0,5688	03:37
48	1094,9920	-238,9697	1308,8795	52,8739	0,5722	03:30
54	1095,0465	-239,0660	1308,8997	52,8380	0,5722	03:33
<i>tempo total [min]</i>						33:59

**Fonte:** Tabela idealizada pelo autor do presente texto

Observa-se que nos casos dos aços 4340 Recozido e 1524 U2, obteve-se um valor negativo para o parâmetro ( $\zeta$ ), que corresponde ao componente linear da Equação 2.03,

modelo constitutivo proposto por Kleinermann e Ponthot (2003), este fenômeno pode ser explicado observando-se o formato da curva tensão-deformação de engenharia e os tratamentos a que os materiais foram expostos na tentativa de se obter diversas propriedades. O valor negativo não implica em uma tensão negativa, mas sim, em um termo de uma equação matemática que tende a ter um sinal negativo para balancear os demais termos da equação, inclusive o termo exponencial representado por seu expoente  $\delta$ .



**Figura 4.16.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com valores aleatórios provenientes do estudo do limite de escoamento e de ruptura o. Os gráficos correspondem à evolução do método: (a) iteração 0; (b) iteração 6; (c) iteração 12; (d) iteração 18; (e) iteração 24; (f) iteração 30; (g) iteração 36 e (h) iteração 42 (final).

**Fonte:** Figura idealizada pelo autor do presente texto




Na Tabelas 4.23 e 4.24 pode-se observar o comportamento do Método LM quando os valores iniciais dos parâmetros advêm de valores obtidos no Algoritmo Genético (GA).


**Tabela 4.23** Resultados do Método LM para os parâmetros inicializados com os valores de melhor pontuação oriundos do Algoritmo Genético (GA).

Aço 4340 Normalizado						
Iteração	$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []	$f_2$	<i>tempo</i> [min]
0	721,1596	211,0570	1144,2416	17,6689	5,5980	
6	713,8177	212,8317	1061,2307	28,0290	3,1265	02:10
12	681,5331	221,5337	1077,5736	37,5933	0,9775	03:10
18	671,6995	225,4483	1078,5111	39,4053	1,0200	03:14
24	670,4586	230,0320	1077,5153	39,8306	1,0295	03:14
30	670,1514	231,4322	1077,0225	39,9671	1,0300	03:10
36	670,0689	231,8263	1076,9259	40,0001	1,0306	03:09
<i>tempo total</i> [min]						19:10
Aço 4340 Recozido						
0	537,8984	588,6514	700,1034	28,4293	7,9120	
6	480,2737	439,6924	723,4160	31,5138	5,4521	03:42
12	463,6000	171,0606	809,0778	14,7111	6,1710	03:23
18	472,9318	101,6182	836,3132	17,9920	2,3716	03:19
24	479,4798	11,0944	874,2034	14,8757	2,3606	03:20
30	483,3377	-30,3917	891,4700	14,1212	2,3902	03:30
36	485,0477	-44,2917	897,5149	13,7391	2,4047	03:30
42	485,4059	-46,0256	898,2545	13,6917	2,4069	03:28
48	485,5045	-46,8761	898,6156	13,6689	2,4079	03:28
<i>tempo total</i> [min]						27:44
Aço 1524 U2						
0	1062,9188	445,3933	1304,2855	65,2688	10,3310	
6	1088,7898	-301,2694	1302,9015	60,3065	1,7408	03:13
12	1092,7192	-233,8315	1307,3258	54,3680	0,5648	03:07
18	1094,4605	-237,8828	1308,7961	53,2311	0,5721	03:11
24	1094,8965	-238,8054	1308,8447	52,9510	0,5722	03:11
30	1095,0059	-239,0041	1308,8868	52,8776	0,5723	03:10
<i>tempo total</i> [min]						15:54


**Fonte:** Tabela idealizada pelo autor do presente texto




(a)




(b)




(c)



(d)



(e)



(f)

**Figura 4.17.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com os valores de melhor pontuação oriundos do Algoritmo Genético (GA). Os gráficos correspondem às etapas de evolução do método: (a) iteração 0; (b) iteração 6; (c) iteração 12; (d) iteração 18; (e) iteração 24 e (f) iteração 36 (final).


**Fonte:** Figura idealizada pelo autor do presente texto

Inicialmente, avaliou-se os resultados obtidos quando os parâmetros foram inicializados tomando-se os valores de maior pontuação (Tabela 4.23) no Algoritmo Genético (GA) e após tomando-se os valores médios das soluções (Tabela 4.24) que fizeram parte da elite ao longo das gerações desenvolvidas.


**Tabela 4.24** Resultados do Método LM para os parâmetros inicializados com os valores médios oriundos do Algoritmo Genético (GA).

Aço 4340 Normalizado						
Iteração	$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []	$f_2$	<i>tempo [min]</i>
0	727,1597	276,1327	1111,2785	32,7288	3,8754	
6	676,3942	217,3576	1079,6838	38,2259	0,9935	03:16
12	671,3122	226,6547	1078,2287	39,5093	1,0220	03:14
18	670,3871	230,3599	1077,4354	39,8591	1,0284	03:10
24	670,1393	231,4638	1077,0138	39,9705	1,0301	03:12
30	670,0587	231,8955	1076,9098	40,0047	1,0307	03:09
<i>tempo total [min]</i>						16:02
Aço 4340 Recozido						
0	506,0200	623,7580	701,7912	44,0329	7,9270	
6	434,9662	435,5751	720,3218	41,9253	5,2724	04:38
12	419,2823	351,6270	748,0907	37,1841	4,2775	03:21
18	454,4040	231,3686	789,7442	21,7475	3,3599	03:21
24	477,7725	43,5173	859,3783	14,7156	2,6489	03:20
30	483,4771	-33,4353	892,6824	14,0408	2,3960	03:22
36	484,7056	-41,5091	896,3223	13,8309	2,4024	03:20
42	485,2831	-46,2606	898,3540	13,6854	2,4080	03:23
48	485,3590	-46,9043	898,6288	13,6679	2,4080	03:22
<i>tempo total [min]</i>						28:11
Aço 1524 U2						
0	932,6847	897,8089	1189,2672	81,5177	11,3537	
6	1082,6684	-614,0427	1306,1748	68,1782	7,4168	03:09
12	1089,3682	-232,5580	1302,6112	58,2009	0,6869	03:20
18	1093,2597	-235,1569	1308,1977	53,9332	0,5673	03:11
24	1094,6375	-238,2983	1308,7363	53,1241	0,5721	03:09
30	1095,0304	-239,0438	1308,8948	52,8471	0,5722	03:08
36	1095,0638	-239,0992	1308,9069	52,8268	0,5723	03:10
<i>tempo total [min]</i>						19:09


**Fonte:** Tabela idealizada pelo autor do presente texto




(a)




(b)




(c)



(d)



(e)



(f)

**Figura 4.18.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com os valores médios oriundos do Algoritmo Genético (GA). Os gráficos correspondem às etapas de evolução do método: (a) iteração 0; (b) iteração 6; (c) iteração 12; (d) iteração 18; (e) iteração 24 e (f) iteração 30 (final).

**Fonte:** Figura idealizada pelo autor do presente texto

Comparando-se os resultados obtidos pelo Método LM quando os parâmetros foram inicializados aleatoriamente e inicializados com valores advindos do Algoritmo Genético houve uma melhora na quantidade de iterações necessárias e redução do tempo de trabalho para o aço 4340 Normalizado em ambas as situações, para o aço 1524 U2 houve redução do número de iterações e do tempo somente no caso dos valores médios, e para o aço 4340 Recozido houve uma piora tanto no número de iterações quanto no tempo de trabalho.

Observando-se os valores obtidos e as correspondentes curvas força-alongamento verifica-se que algumas iterações foram realizadas sem que houvessem reais ganhos na procura por um valor mínimo da Equação 2.02, com isso tentou-se inserir no Método LM um segundo critério de parada (Tabelas 4.25 e 4.26).

**Tabela 4.25** Resultados do Método LM para os parâmetros inicializados com os valores de melhor pontuação oriundos do Algoritmo Genético (GA) e tendo como segundo critério de parada a comparação de áreas sob a curva.

Aço 4340 Normalizado							
Iteração	$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []	$f_2$	Área	tempo [min]
0	721,1596	211,0570	1144,2416	17,6689	5,5980		
6	713,8177	212,8317	1061,2307	28,0290	3,1265	157,5911	03:24
12	681,5331	221,5337	1077,5736	37,5933	0,9775	165,7450	03:20
18	671,8485	225,2993	1078,5111	39,4053	1,0190	165,9949	03:18
<i>tempo total [min]</i>							10:03
Aço 4340 Recozido							
0	537,8984	588,6514	700,1034	28,4243	7,9120		
6	480,2737	439,6924	723,4160	31,5138	5,4521	14,6369	03:43
12	463,6000	171,0606	809,0778	14,7111	6,1710	179,1506	03:23
18	472,9318	101,6182	836,3132	17,9920	2,3716	182,3562	03:21
24	479,4798	11,2434	874,0544	14,8757	2,3606	182,8675	03:19
<i>tempo total [min]</i>							13:47
Aço 1524 U2							
0	1062,9188	445,3933	1304,2855	65,2688	10,3310		
6	1088,7898	-301,2694	1302,9015	60,3065	1,7408	163,2094	03:14
12	1092,7192	-233,8315	1307,3258	54,3680	0,5648	165,7869	03:08
18	1094,4605	-238,0318	1308,6471	53,2311	0,5716	165,8488	03:06
<i>tempo total [min]</i>							09:29

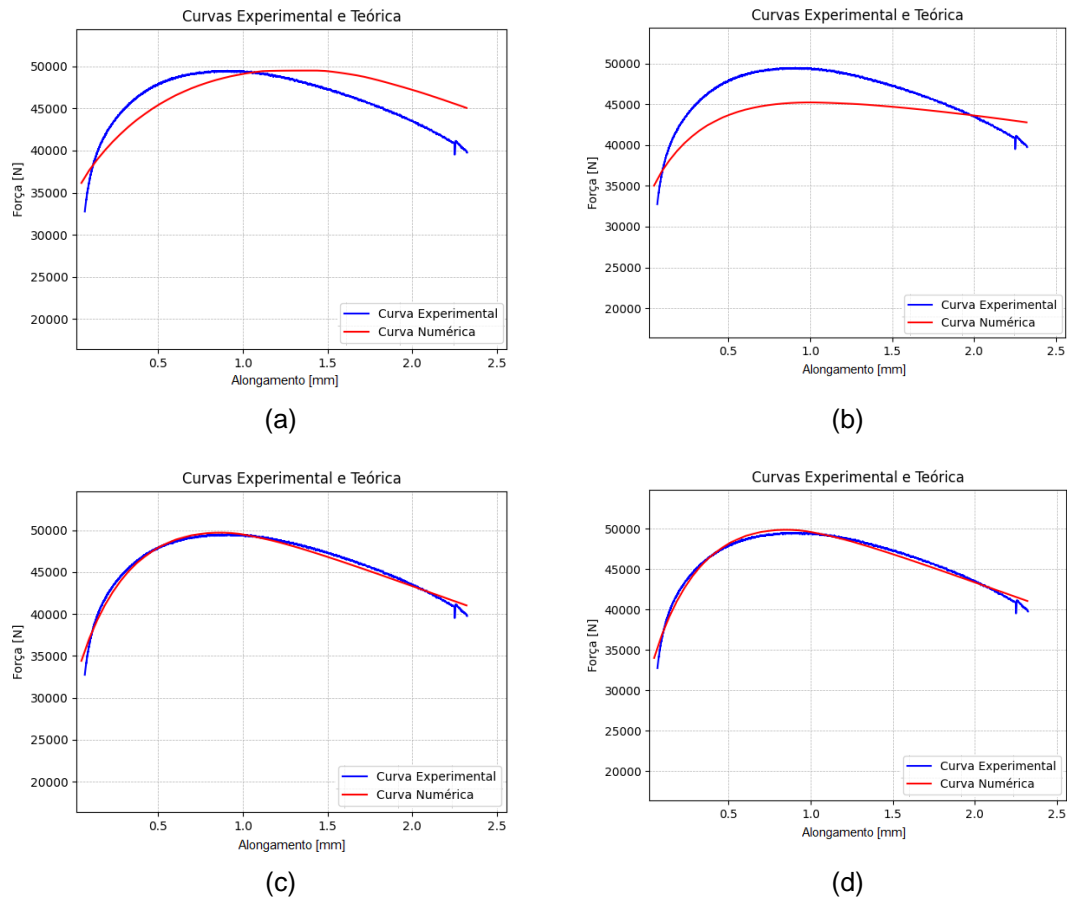
**Fonte:** Tabela idealizada pelo autor do presente texto

**Tabela 4.26** Resultados do Método LM para os parâmetros inicializados com os valores médios oriundos do Algoritmo Genético (GA) e tendo como segundo critério de parada a comparação de áreas sob a curva.

Aço 4340 Normalizado							
Iteração	$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []	$f_2$	Área	tempo [min]
0	727,1597	276,1327	1111,2785	32,7288	3,8754		
6	676,3942	217,3576	1079,6838	38,2259	0,9935	165,8975	03:20
12	671,4612	226,5057	1078,2287	39,5093	1,0210	165,9924	03:18
<i>tempo total [min]</i>							06:38
Aço 4340 Recozido							
0	506,0200	623,7580	701,7912	44,0329	7,9270		
6	434,9662	435,5751	720,3218	41,9253	5,2724	2,3072	04:37
12	419,2823	351,6270	748,0907	37,1841	4,2775	173,4032	03:21
18	454,4040	231,3686	789,7443	21,7475	3,3599	181,5941	03:21
24	477,9215	43,3683	859,3783	14,7156	2,6489	181,8474	03:19
<i>tempo total [min]</i>							14:40
Aço 1524 U2							
0	932,6847	897,8089	1189,2672	81,5177	11,3537		
6	1082,6684	-614,0427	1306,1748	68,1782	7,4168	154,0348	03:12
12	1089,3682	-232,5580	1302,6112	58,2009	0,6869	165,1582	03:20
18	1093,2597	-235,3059	1308,0487	53,9332	0,5676	165,8414	03:10
<i>tempo total [min]</i>							09:43

**Fonte:** Tabela idealizada pelo autor do presente texto

As Tabelas 4.25 e 4.26 apresentam as iterações para os todos os materiais avaliados. Com esse segundo critério, o cálculo da área sob a curva, no caso, o cálculo da tenacidade, e a comparação deste valor ao final de cada iteração com o valor obtido na interação anterior, obteve-se uma redução do número de iterações o que levou a uma melhora no tempo de busca pela solução de interesse para todos os materiais, independentemente de se adotar como valores iniciais o melhor valor ou a média, ambos obtidos no Algoritmo Genético (GA) para os parâmetros em estudo. Pode-se observar a sequência de iterações na Figura 4.19 para o aço 4340 Normalizado e para o aço 1524 U2 na Figura 4.20.



**Figura 4.19.** Região de comportamento plástico do Aço 4340 Normalizado. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com os valores de melhor pontuação oriundos do Algoritmo Genético (GA) e foi adotado como segundo critério de parada a comparação de áreas sob a curva. Os gráficos correspondem às etapas de evolução do método: (a) iteração 0; (b) iteração 6; (c) iteração 12 e (d) iteração 18 (final).

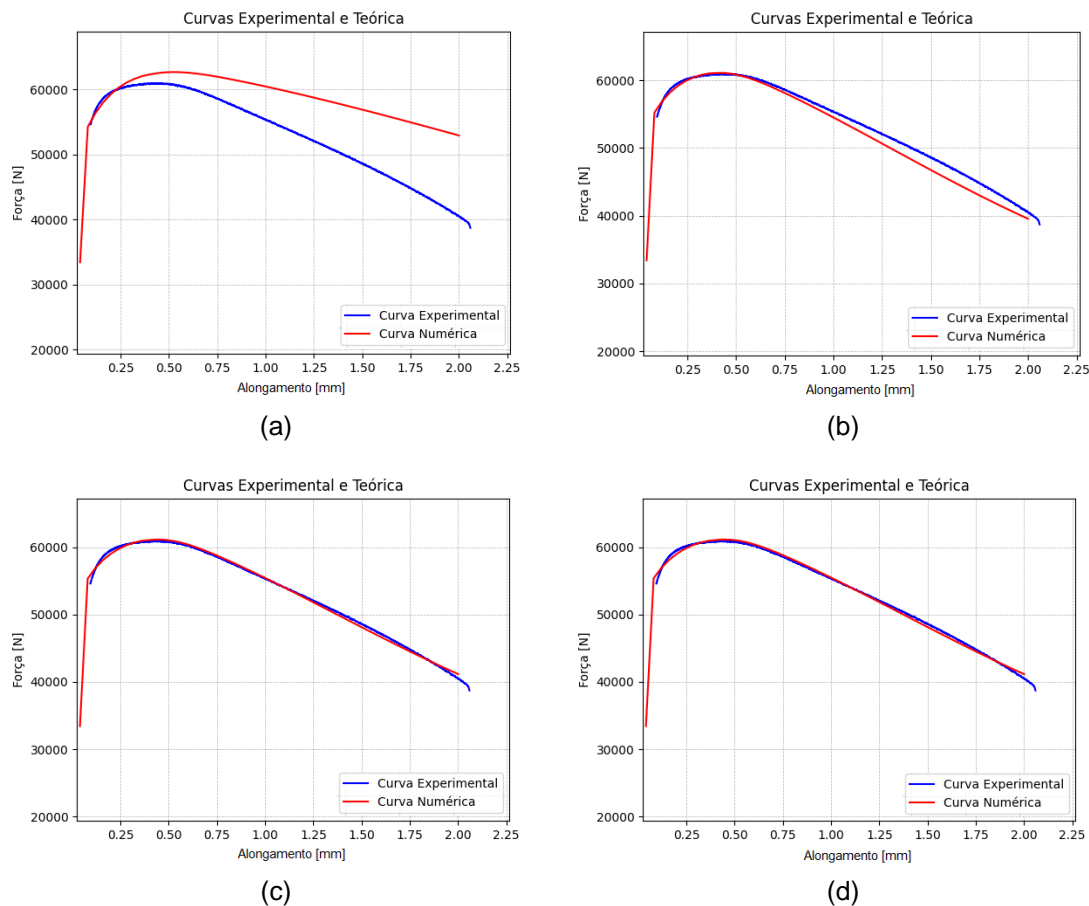
**Fonte:** Figura idealizada pelo autor do presente texto

As áreas foram calculadas levando-se em consideração as curvas tensão-deformação dos materiais e não as curvas força-alongamento apresentadas nas figuras, aqui utilizadas para ilustrar o andamento dos métodos em estudo.

Para a comparação entre as áreas obtidas via o método 1/3 de Simpson, a cada iteração utilizou-se o valor do erro calculado segundo a equação:

$$erro = \frac{|Área_i - Área_{i-1}|}{Área_{i-1}} \quad \text{Equação 4.20}$$

A precisão exigida foi de  $10^{-2}$ , podendo ser alterada na rotina desenvolvida em PYTHON para diferentes valores.



**Figura 4.20.** Região de comportamento plástico do Aço 1524 U2. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com os valores de melhor pontuação oriundos do Algoritmo Genético (GA) e foi adotado como segundo critério de parada a comparação de áreas sob a curva. Os gráficos correspondem às etapas de evolução do método: (a) iteração 0; (b) iteração 6; (c) iteração 12 e (d) iteração 18 (final).


**Fonte:** Figura idealizada pelo autor do presente texto

A Figura 4.21 apresenta a sequência de iterações para os aços 4340 Normalizado e 1524 U2 em que os valores iniciais dos parâmetros são as médias provenientes no Algoritmo Genético (GA).


Observando-se todos os dados apresentados verifica-se que ao adotar a área sob a curva como segundo critério de parada houve uma redução no número de iterações para todos os materiais em análise, no entanto, para o aço 4340 Recozido tem-se um afastamento de alguns parâmetros dos valores alcançados anteriormente. Uma análise comparativa pode ser vista na Tabela 4.27, onde também são apresentados a média e o desvio padrão dos valores obtidos.




### Aço 4340 Normalizado



(a)




(b)




(c)


### Aço 1524 U2




(d)



(e)



(f)



(g)

**Figura 4.21.** Região de comportamento plástico dos Aços 4340 Normalizado e 1524 U2. Os gráficos referem-se aos resultados do Método LM. Os parâmetros foram inicializados com os valores médios oriundos do Algoritmo Genético (GA) e foi adotado como segundo critério de parada a comparação de áreas sob a curva. Os gráficos correspondem às etapas de evolução do método: (a) iteração 0; (b) iteração 6 e (c) iteração 12 (final) para o Aço 4340, e (d) iteração 0; (e) iteração 6; (f) iteração 12 e (g) iteração 18 (final) para o Aço 1524 U2.

**Fonte:** Figura idealizada pelo autor do presente texto

**Tabela 4.27** Um panorama dos resultados obtidos com a aplicação do Método LM.

Aço 4340 Normalizado							
*Testes	Qtd Iterações	$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []	$f_2$	tempo [min]
(A)	42	670,0428	231,9621	1076,8930	39,9960	1,0303	22:29
(B)	36	670,0689	231,8263	1076,9259	40,0001	1,0306	19:10
(C)	30	670,0587	231,8955	1076,9098	40,0047	1,0307	16:02
(D)	18	671,8485	225,2993	1078,5111	39,4053	1,0190	10:03
(E)	12	671,4612	226,5057	1078,2287	39,5093	1,0210	06:38
Média	28	670,6960	229,4978	1077,4937	39,7831	1,0263	14:52
Desvio	12	0,8860	3,3100	0,8061	0,2997	0,0058	06:30
Aço 4340 Recozido							
(A)	36	485,3573	-46,8356	898,6017	13,6690	2,4079	21:14
(B)	48	485,5045	-46,8761	898,6156	13,6689	2,4079	27:44
(C)	48	485,3590	-46,9043	898,6288	13,6679	2,4080	28:11
(D)	24	479,4798	11,2434	874,0544	14,8757	2,3606	13:47
(E)	24	477,9215	43,3683	859,3783	14,7156	2,6489	14:40
Média	36	482,7244	-17,2009	885,8558	14,1194	2,4467	21:07
Desvio	12	3,7148	42,1866	18,2260	0,6199	0,1149	06:53
Aço 1524 U2							
(A)	54	1095,0465	-239,0660	1308,8997	52,8380	0,5722	33:59
(B)	30	1095,0059	-239,0041	1308,8868	52,8776	0,5723	15:54
(C)	36	1095,0638	-239,0992	1308,9069	52,8268	0,5723	19:09
(D)	18	1094,4605	-238,0318	1308,6471	53,2311	0,5716	09:29
(E)	18	1093,2597	-235,3059	1308,0487	53,9332	0,5676	09:43
Média	31	1094,5673	-238,1014	1308,6778	53,1413	0,5712	17:39
Desvio	15	0,7729	1,6249	0,3681	0,4732	0,0020	10:01

\***Testes:** (A): dados iniciais aleatórios; (B): dados iniciais correspondentes aos melhores valores do Algoritmo Genético; (C) dados iniciais correspondentes aos valores médios advindos do Algoritmo Genético; (D) dados iniciais correspondentes aos melhores valores do Algoritmo Genético e aplicação do critério de área sob a curva; (E) dados iniciais correspondentes aos valores médios advindos do Algoritmo Genético e aplicação do critério de área sob a curva.

**Fonte:** Tabela idealizada pelo autor do presente texto

Para contornar essa piora nos valores, no caso dos aços 4340 Recozido, introduziu-se na rotina PYTHON a necessidade de se realizar um ciclo a mais de iterações para todos os materiais, mesmo após se alcançar a precisão desejada. Os resultados podem ser vistos na Tabela 4.28. Apesar do aumento no número de iterações para todos os aços, essa quantidade continuou abaixo dos valores obtidos quando não aplicado o critério da

área sob a curva e os valores, em todos os casos, apresentaram melhoras, observando-se a redução dos desvios obtida.

**Tabela 4.28** Panorama final dos resultados obtidos com a aplicação do Método LM após a inclusão de um passo a mais na busca por todos os parâmetros.

Aço 4340 Normalizado							
*Testes	Qtd Iterações	$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []	$f_2$	tempo [min]
(A)	42	670,0428	231,9621	1076,8930	39,9960	1,0303	22:29
(B)	36	670,0689	231,8263	1076,9259	40,0001	1,0306	19:10
(C)	30	670,0587	231,8955	1076,9098	40,0047	1,0307	16:02
(D)	24	670,4586	230,1810	1077,3663	39,8306	1,0270	12:39
(E)	18	670,3871	230,5089	1077,2864	39,8591	1,0275	09:31
Média	30	670,2032	231,2748	1077,0763	39,9381	1,0292	15:58
Desvio	09	0,2023	0,8580	0,2303	0,0858	0,0018	05:08
*Aço 4340 Recozido							
(A)	36	485,3573	-46,8356	898,6017	13,6690	2,4079	21:14
(B)	48	485,5045	-46,8761	898,6156	13,6689	2,4079	27:44
(C)	48	485,3590	-46,9043	898,6288	13,6679	2,4080	28:11
(D)	30	483,3377	-30,3917	891,6190	14,1063	2,3882	16:52
(E)	30	483,4771	-33,5843	892,5334	14,0408	2,3961	17:48
Média	38	484,6071	-40,9184	895,9997	13,8306	2,3961	22:22
Desvio	09	1,0979	8,2301	3,5962	0,2230	0,0205	05:22
Aço 1524 U2							
(A)	54	1095,0465	-239,0660	1308,8997	52,8380	0,5722	33:59
(B)	30	1095,0059	-239,0041	1308,8868	52,8776	0,5723	15:54
(C)	36	1095,0638	-239,0992	1308,9069	52,8268	0,5723	19:09
(D)	24	1094,8965	-238,8054	1308,9938	52,9361	0,5727	12:30
(E)	24	1094,6375	-238,2983	1308,8853	53,1092	0,5722	12:44
Média	34	1094,9300	-238,8546	1308,9145	52,9175	0,5723	18:51
Desvio	12	0,1760	0,3312	0,0452	0,1154	0,0002	08:53

**\*Testes:** (A): dados iniciais aleatórios; (B): dados iniciais correspondentes aos melhores valores do Algoritmo Genético; (C) dados iniciais correspondentes aos valores médios advindos do Algoritmo Genético; (D) dados iniciais correspondentes aos melhores valores do Algoritmo Genético e aplicação do critério de área sob a curva; (E) dados iniciais correspondentes aos valores médios advindos do Algoritmo Genético e aplicação do critério de área sob a curva.

**Fonte:** Tabela idealizada pelo autor do presente texto

#### 4.3. MÉTODO HÍBRIDO – GALM: RESULTADOS OBTIDOS

Verificou-se, por exemplo, que o parâmetro zeta ( $\zeta$ ) (Equação 2.03) do modelo constitutivo de Kleinermann e Ponthot (2003) pode ser negativo e desta forma os limites iniciais para o Algoritmo Genético (GA) são ainda maiores, isto é, tem-se uma região de busca muito vasta. Para reduzir o impacto de tal questão realizou-se a cada iteração um estudo estatístico que permitisse alterar os limites para cada parâmetro, em alguns momentos reduzindo o intervalo de busca e em outros aumentando este mesmo intervalo.

Inicialmente, a quantidade de gerações a serem desenvolvidas é fixa, mas foram inseridos critérios que ao serem satisfeitos podem dar fim a busca do Algoritmo Genético (GA) e iniciar o trabalho do método gradiente antes de se chegar à última geração indicada, este processo leva em consideração a quantidade de indivíduos com uma avaliação superior ou igual a um valor a ser indicado pelo pesquisador.

Quanto ao método gradiente foram também inseridos critérios de parada levando-se em consideração a precisão com que se deseja alcançar os valores dos parâmetros e procurando não estender o tempo de processamento com mudanças mínimas nos valores procurados que não trarão melhorias na solução final, buscou-se aqui inserir o cálculo da área sob as curvas experimentais e a comparação destas a cada novo conjunto de parâmetros avaliado.

Com as rotinas prontas e interligadas, realizou-se cinco testes para cada material envolvido neste trabalho. Foram definidos como limites iniciais para o Algoritmo Genético (GA) os valores apresentados na Tabela 4.29 e foi indicado ao sistema que os valores poderiam ser alterados a cada geração (cálculo de média e desvio padrão do conjunto elite).

**Tabela 4.29** Intervalo inicial de busca para cada parâmetro dos materiais em estudo.

Parâmetros				
Limites	$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []
Inferior ( <i>infi</i> )	5	-750	5	5
Superior ( <i>supi</i> )	1500	750	1500	100
Precisão	1	1	1	0,1
Número de bits mínimo	11	11	11	10

Fonte: Tabela idealizada pelo autor do presente texto.

Na Tabela 4.30 pode-se observar uma boa resposta do Algoritmo Genético às restrições impostas a cada geração com a redução ou ampliação do espaço de busca. Verifica-se que nos cinco testes para cada material, as três (3) gerações propostas

inicialmente como limite nem sempre foram necessárias. É importante observar que as populações se mantiveram fixas e foram limitadas ao número de seis (6) indivíduos a cada geração.

**Tabela 4.30** Experimentos realizados – comportamento do Algoritmo Genético.

<b>Experimentos com o método híbrido – Algoritmo Genético</b>						
<b>Experimento</b>	<b>Qtde de Gerações</b>		<b>Tempo (min)</b>	<b>Melhor Avaliação</b>	<b>Qtde de Avaliações superiores a 0,90</b>	<b>% de Avaliações superiores a 0,90</b>
	<b>Propostas</b>	<b>Utilizadas</b>				
<b>Aço 4340 Normalizado</b>						
#1	3	1	06:30	0,96334	5	83,33
#2	3	1	06:28	0,96511	6	100,00
#3	3	2	09:33	0,97751	5	55,56
#4	3	1	06:27	0,97267	4	66,67
#5	3	2	09:35	0,95986	4	44,44
<b>Aço 4340 Recozido</b>						
#1	3	3	17:12	0,94574	6	50,00
#2	3	3	19:57	0,95770	4	33,33
#3	3	2	12:03	0,93741	5	55,55
#4	3	2	12:20	0,94828	6	66,67
#5	3	3	17:53	0,92473	3	25,00
<b>Aço 1524 U2</b>						
#1	3	1	06:09	0,92904	5	83,33
#2	3	3	13:08	0,94136	5	41,67
#3	3	1	06:20	0,95111	5	83,33
#4	3	1	07:04	0,92856	5	83,33
#5	3	3	12:19	0,93791	2	16,67


**Fonte:** Tabela idealizada pelo autor do presente texto.

Com relação ao método de Levenberg-Marquardt, os resultados dos experimentos realizados podem ser vistos nas Tabelas 4.31, 4.32 e 4.33 para os aços 4340 normalizado, 4340 recozido e 1524 U2, respectivamente. As Figuras 4.22, 4.23 e 4.24 representam os dados iniciais e finais dos experimentos com maior e menor tempo de processamento.


**Tabela 4.31** Aço 4340 Normalizado – comportamento do Método LM.

Experimentos com o método híbrido – Método de Levenberg-Marquardt							
Aço 4340 Normalizado							
Experimento	Valores	Parâmetros				Qtde de Iterações	Tempo (min)
		$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []		
#1	Iniciais	556,14	212,39	1065,67	76,93	30	16:03
	Finais	669,96	232,37	1076,79	40,04		
	%	20,47	9,41	1,04	(47,95)		
#2	Iniciais	577,88	541,51	1037,96	81,31	30	15:52
	Finais	670,00	232,14	1076,85	40,03		
	%	15,94	(57,13)	3,75	(50,77)		
#3	Iniciais	658,16	44,71	1140,61	30,43	24	13:02
	Finais	670,30	230,80	1077,33	39,90		
	%	1,84	416,21	5,55	31,12		
#4	Iniciais	594,13	51,39	1124,09	40,94	18	09:53
	Finais	670,10	231,84	1076,96	39,97		
	%	12,79	351,14	(4,19)	(2,37)		
#5	Iniciais	704,75	190,39	1061,91	57,63	30	17:40
	Finais	669,99	232,21	1076,83	40,03		
	%	(4,93)	21,97	1,41	(30,54)		


Fonte: Tabela idealizada pelo autor do presente texto.




(a) Experimento #5 – Valores iniciais



(b) Experimento #5 – Valores finais



(c) Experimento #4 – Valores iniciais



(d) Experimento #4 – Valores finais


**Figura 4.22.** Curvas iniciais e finais correspondentes aos experimentos cinco (5) e quatro (4) com maior e menor tempo, respectivamente.

Fonte: Figura idealizada pelo autor do presente texto


**Tabela 4.32** Aço 4340 Recozido – comportamento do Método LM.

Experimentos com o método híbrido – Método de Levenberg-Marquardt							
Aço 4340 Recozido							
Experimento	Valores	Parâmetros				Qtde de Iterações	Tempo (min)
		$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []		
#1	Iniciais	406,45	79,72	821,05	33,31	36	22:32
	Finais	485,36	-46,87	898,61	13,67		
	%	19,41	(158,79)	9,45	(58,96)		
#2	Iniciais	530,81	87,29	833,62	18,37	36	19:40
	Finais	485,27	-47,15	898,73	13,66		
	%	(8,58)	(154,02)	7,81	(25,64)		
#3	Iniciais	480,27	404,91	711,65	63,19	48	26:05
	Finais	485,35	-46,74	898,56	13,67		
	%	1,06	(111,54)	26,26	(78,37)		
#4	Iniciais	393,89	384,94	712,11	40,36	42	22:58
	Finais	485,37	-46,94	898,64	13,67		
	%	23,22	(112,19)	26,19	(66,13)		
#5	Iniciais	484,23	388,87	694,88	82,09	54	29:23
	Finais	485,48	-46,7	898,54	13,67		
	%	0,26	(112,01)	29,31	(83,35)		


Fonte: Tabela idealizada pelo autor do presente texto.




(a) Experimento #5 – Valores iniciais



(b) Experimento #5 – Valores finais



(c) Experimento #2 – Valores iniciais



(d) Experimento #2 – Valores finais


**Figura 4.23.** Curvas iniciais e finais correspondentes aos experimentos cinco (5) e dois (2) com maior e menor tempo, respectivamente.

Fonte: Figura idealizada pelo autor do presente texto


**Tabela 4.33** Aço 1524 U2 – comportamento do Método LM.

Experimentos com o método híbrido – Método de Levenberg-Marquardt							
Aço 1524 U2							
Experimento	Valores	Parâmetros				Qtde de Iterações	Tempo (min)
		$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ []		
#1	Iniciais	1075,17	462,14	1144,73	53,56	36	18:35
	Finais	1095,08	-239,13	1308,91	52,81		
	%	1,85	(151,74)	14,34	(1,40)		
#2	Iniciais	1106,89	132	1176,58	22,02	30	17:38
	Finais	1095,03	-239,04	1308,9	52,86		
	%	(1,07)	(281,09)	11,25	140,05		
#3	Iniciais	1048,63	141,55	1225,34	50,15	24	15:43
	Finais	1095,04	-239,05	1309,05	52,84		
	%	4,43	(268,88)	6,83	5,36		
#4	Iniciais	1000,48	-510,07	1463,22	81,53	30	18:11
	Finais	1095,04	-239,06	1308,90	52,86		
	%	9,45	53,13	(10,55)	(35,16)		
#5	Iniciais	1243,69	-458,79	1370,53	73,78	24	12:39
	Finais	1095,05	-239,07	1309,05	52,84		
	%	(11,95)	47,89	(4,49)	(28,38)		


Fonte: Tabela idealizada pelo autor do presente texto.




(a) Experimento #1 – Valores iniciais



(b) Experimento #1 – Valores finais



(c) Experimento #5 – Valores iniciais



(d) Experimento #5 – Valores finais

**Figura 4.24.** Curvas iniciais e finais correspondentes aos experimentos um (1) e cinco (5) com maior e menor tempo, respectivamente.

Fonte: Figura idealizada pelo autor do presente texto



Os resultados finais obtidos estão expostos na Tabela 4.34.

**Tabela 4.34** Experimentos realizados – Valores finais obtidos para os parâmetros.

Experimentos com o método híbrido – Valores Finais							
Experimento	Parâmetros				Tempo (min)		
	$\sigma_{y_0}$ [MPa]	$\zeta$ [MPa]	$\sigma_{\infty}$ [MPa]	$\delta$ [°]	GA	LM	Total
<b>Aço 4340 Normalizado</b>							
#1	669,96	232,37	1076,79	40,04	06:30	16:03	22:33
#2	670,00	232,14	1076,85	40,03	06:28	15:52	22:20
#3	670,30	230,80	1077,33	39,90	09:33	13:02	22:35
#4	670,10	231,84	1076,96	39,97	06:27	09:53	16:20
#5	669,99	232,21	1076,83	40,03	09:35	17:40	27:15
<b>Média</b>	670,1	231,9	1077,0	40,0			
<b>Desvio</b>	0,1	0,6	0,2	0,1			
<b>Aço 4340 Recozido</b>							
#1	485,36	-46,87	898,61	13,67	17:12	22:32	39:44
#2	485,27	-47,15	898,73	13,66	19:57	19:40	39:37
#3	485,35	-46,74	898,56	13,67	12:03	26:05	38:08
#4	485,37	-46,94	898,64	13,67	12:20	22:58	35:18
#5	485,48	-46,7	898,54	13,67	17:53	29:23	47:16
<b>Média</b>	485,4	-46,9	898,6	13,7			
<b>Desvio</b>	0,1	0,2	0,1	0,0			
<b>Aço 1524 U2</b>							
#1	1095,08	-239,13	1308,91	52,81	06:09	18:35	24:44
#2	1095,03	-239,04	1308,9	52,86	13:08	17:38	30:46
#3	1095,04	-239,05	1309,05	52,84	06:20	15:43	22:03
#4	1095,04	-239,06	1308,9	52,86	07:04	18:11	25:15
#5	1095,05	-239,07	1309,05	52,84	12:19	12:39	24:58
<b>Média</b>	1095,05	-239,07	1309,0	52,8			
<b>Desvio</b>	0,02	0,04	0,1	0,0			

**Fonte:** Tabela idealizada pelo autor do presente texto.

#### 4.4. OBSERVAÇÕES SOBRE AS SIMULAÇÕES REALIZADAS

Observando-se as principais características do Algoritmo Genético (GA) e do Algoritmo de Levenberg-Marquardt Dividido (LMD), desenvolveu-se rotinas computacionais na linguagem PYTHON. Este capítulo teve por objetivos apresentar os diversos resultados das simulações numéricas realizadas considerando-se o modelo constitutivo proposto por Kleinermaann e Ponthot (2003). Ao final, foi proposto um modelo híbrido que unisse a robustez de busca do GA e a velocidade e precisão do Algoritmo LMD.

Para as simulações numéricas relativas ao método de Elementos Finitos foi utilizado o sistema acadêmico HYPLAS (NETO *et al.*, 2008). Após a configuração do

HYPLAS, foram estabelecidos alguns parâmetros para as simulações do GA e posterior comparação de desempenho.

Iniciando-se com três (3) gerações, os testes do GA foram desenvolvidos indicando-se um intervalo de busca aleatório para cada um dos parâmetros em estudo. Observou-se diversas discrepâncias. Em alguns casos, mesmo com o valor da função objetivo ( $f$ ) apontando para um bom indivíduo as curvas foram muito distintas. Em um espaço de busca tão geral quanto ao que foi utilizado poder-se-ia obter diversos máximos locais.

Com o objetivo de melhorar a *busca*, mas mantendo-se fixo o intervalo inicial e a quantidade de três (3) gerações, aumentou-se o número de indivíduos da população de seis (6) para dez (10) em um segundo conjunto de simulações e de (10) para vinte (20) em um terceiro conjunto de simulações. Verificou-se que uma maior população permite o aparecimento de indivíduos com melhor avaliação dentro de um espaço de pesquisa amplo e favorece a diversidade necessária ao bom andamento do Algoritmo Genético desenvolvido (LINDEN, 2012).

O tempo de processamento para os cálculos e análises foi outra variável estudada. Uma nova bateria de testes foi desenvolvida levando-se em consideração uma mudança dos limites iniciais da região de busca para os parâmetros em análise, estes limites foram mantidos fixos ao longo das simulações. Avaliando-se novamente a população com seis (6) indivíduos e três (3) gerações, obteve-se resultados superiores aos alcançados no cenário anterior. Aspectos que se repetiram para os demais cenários com dez (10) e vinte (20) indivíduos ao longo de três gerações. Fenômeno que pode ser explicado pelo uso de parâmetros com melhores índices de avaliação ao se executar o módulo de Elementos Finitos, reduzindo o tempo de processamento deste. Diversos outros parâmetros do GA foram estudados e calibrados a ponto de equilibrarem o tempo de processamento e a busca por boas soluções.

Com todas as análises realizadas decidiu-se que o conjunto solução do Algoritmo Genético seria composto pelos três melhores grupos de valores (parâmetros), ou seja, os três indivíduos de melhor avaliação dentro do conjunto elite, além do valor médio de todos os indivíduos participantes deste conjunto e que tivessem avaliação superior a 0,9000, parâmetro que pode ser ajustado no sistema, e dos valores correspondentes ao desvio padrão em relação à média calculada para cada parâmetro.

Diferente do Algoritmo Genético, que pode apresentar variadas implementações de acordo com os problemas em que será aplicado, o Algoritmo LM não necessita de mudanças em seu núcleo básico (LEVENBERG, 1944) tendo sido introduzido apenas um segundo critério de parada, no caso, a área sob a curva, que pode ou não ser ativado, além do primeiro critério que diz respeito à precisão com que os parâmetros serão avaliados.

Para análise, utilizou-se o Algoritmo LM com os parâmetros inicializados: aleatoriamente, com os valores de melhor pontuação oriundos do GA; e com os valores médios oriundos do GA, observando-se ainda que nos casos em que os valores iniciais foram resultados oriundos do GA buscou-se verificar o impacto de um segundo critério de parada, a comparação de áreas sob as curvas experimentais e numéricas. Verificou-se que os tempos totais obtidos no LM, tendo como entrada os valores médios provenientes do GA, foram significativamente melhores que os demais tempos obtidos nas demais simulações, fato que pode ser explicado pela representatividade que a média apresenta em relação aos valores do conjunto analisado (MARTINS, 2006).

Ao final, desenvolveu-se um método híbrido com as rotinas já prontas. Interligando-as, realizou-se cinco testes para cada material em análise. Com um extenso espaço de busca, o GA apresentou soluções variadas, mas próximas ao possível ponto de máximo global procurado, e o LM convergiu em praticamente todas as situações para o ponto de máximo global procurado.


## 5. ESTUDO DE CASO – MANUFATURA ADITIVA

A manufatura aditiva é uma tecnologia emergente com potencial para alavancar setores de importância, como o biomédico, o aeroespacial, o automotivo e o de design de ferramentas em geral, além de contribuir para a redução de impactos ambientais na indústria de manufatura (BÖCKIN *et al.*, 2019). É um processo de fabricação em que o material é depositado camada por camada tomando-se por base um modelo tridimensional usualmente desenvolvido em ferramentas CAD (*Computer Aided Design*). Tecnologia que teve origem na década de 1980, ao longo dos anos tem possibilitado diversos avanços na indústria manufatureira, desde a redução do tempo e do custo de produção com menor perda de material à fabricação de peças com geometrias complexas. Além disso, a manufatura aditiva tem desempenhado um importante papel no atual contexto industrial ao permitir a integração entre sistemas de manufatura inteligentes e tecnologias da informação (MEHRPOUYA *et al.*, 2019).

No processo de usinagem, também conhecido como manufatura subtrativa, a fabricação de peças apresenta elevados níveis de precisão, com estreitas tolerâncias dimensionais e geométricas, no entanto, apresentam nível de complexidade limitado (NEWMAN *et al.*, 2015). A manufatura aditiva, além de uma alta velocidade de fabricação, permite o desenvolvimento de peças com uma complexidade quase inalcançável por outras técnicas e ainda apresenta uma redução do desperdício de matéria-prima, no entanto, uma de suas principais desvantagens é a baixa precisão dimensional, de modo que a maioria das peças produzidas por essa técnica necessitam passar por algum processo de usinagem de acabamento, a fim de melhorar a qualidade superficial. Nesse sentido, ao se combinar as técnicas de manufatura aditiva com manufatura subtrativa, é possível aumentar a produtividade e qualidade das peças e desta forma melhorar os diferenciais competitivos de uma indústria.

Atualmente, há diversas técnicas de manufatura aditiva em metais. Uma das técnicas mais utilizadas é o *Wire Arc Additive Manufacturing* (WAAM) ou Manufatura Aditiva por Deposição a Arco (MADA), método que permite a construção de grandes componentes com razoável precisão geométrica em menor tempo e menores custos, tendo sido empregado, por exemplo, para fabricar a primeira ponte metálica impressa em 3D do mundo (HERBERT *et al.*, 2020). As taxas de deposição a arco chegam a números maiores que 130 g/min, bem superiores quando comparadas aos processos a laser e feixe de elétrons que apresentam taxas entre 2 e 10 g/min (SURYAKUMAR *et al.* 2011).

O uso dos processos de soldagem MIG/MAG (GMAW – *Gas Metal Arc Welding*) e TIG (GTAW – *Gas Tungsten Arc Welding*) tem elevado a expectativa comercial quanto a MADA. Ambos os processos possuem o arco elétrico como fonte de calor e proteção gasosa. O processo GMAW é a técnica de soldagem mais comum nas indústrias, uma vez que possui grande versatilidade, altas taxas de deposição, menor investimento financeiro e fácil execução e automação (WANG *et al.*, 2016). Essa técnica de soldagem fundamenta-se na fonte de calor de um arco elétrico com alta energia situado em meio a uma peça que será soldada e um arame (eletrodo), que é adicionado ao sistema e consumido ao longo do processo. A proteção da solda é feita a partir de gases (inertes ou ativos) ou por misturas de proteção (SCOTTI *et al.*, 2014). A Figura 5.01 é uma representação típica do processo de deposição de material para a formação de uma peça utilizando deposição a arco elétrico.



**Figura 5.01.** Esquema do processo de manufatura aditiva por deposição a arco elétrico.

**Fonte:** MCANDREW *et al* (2018) com adaptações.

Os estudos relacionados a microestrutura e as propriedades mecânicas das peças obtidas por manufatura aditiva ainda estão em seu estágio inicial. O surgimento de defeitos é uma relevante inquietação (KIM *et al.*, 2018). Porosidade é um defeito habitual onde parte dos mecanismos de ligação são estimulados por alterações de temperatura, gravidade e forças capilares sem aplicação de pressão externa. Os poros se formam quando um material sofre fusão e solidificação rápidas retendo gases na poça de fusão sem que haja uma liberação oportuna (CHEN *et al.*, 2021). As peças metálicas produzidas

são submetidas a processos térmicos complexos levando a uma microestrutura tipicamente anisotrópica e heterogênea (LEWANDOWSKI *et al.*, 2016). A combinação de fatores como alta porosidade, defeitos de fabricação, contaminação da poça de fusão e tensões residuais pode levar a uma baixa ductilidade (SOLA *et al.*, 2019), a uma redução da resistência mecânica e da resistência à fadiga (JAFARI *et al.*, 2021). No Quadro 5.01 são apresentados alguns trabalhos que verificaram diversas implicações associadas à porosidade do material.

**Quadro 5.01** Síntese de alguns trabalhos sobre propriedades mecânicas de peças fabricadas por manufatura aditiva.

Autor(es)	Síntese do(s) trabalho(s).
KUMAR <i>et al</i> (2021)	Neste trabalho foi analisada a microdureza Vickers de peças retangulares obtidas pelos processos WAAM-GMAW do fio ER70S-6 em diferentes posições. Verificou-se que os valores de microdureza apresentavam-se maiores na parte superior das peças em comparação com a parte inferior, atribuíram tal fato às maiores taxas de resfriamento nessa zona.
RAGUVARUN <i>et al.</i> (2015)	Neste trabalho foram comparadas as microestruturas de amostras de Ti6Al4V fabricadas por GTAW. Observou-se que uma mudança na alimentação do fio modificou significativamente a qualidade do material. A alimentação constante de arame produziu melhores resultados (menor porosidade) do que a alimentação de arame pulsada/variada.
ZHANG <i>et al.</i> (2022)	Neste trabalho foi utilizada a liga Al-6Mg. Verificou-se melhor resistência mecânica em peças obtidas por CMT quando comparadas àquelas obtidas por outros métodos WAAM.
BISWAL <i>et al.</i> (2019)	Nesta pesquisa utilizaram WAAM de Ti-6Al-4V para produzir espécimes cilíndricos usando diferentes parâmetros de deposição, com e sem contaminação do fio. Foram realizados ensaios de fadiga com razão de carga $R = 0,1$ e frequência de 50 Hz nas amostras e obtidas as curvas S-N. Observou-se que as amostras com maior porosidade apresentavam resistência à fadiga consideravelmente menor.
CHASTAND <i>et al</i> (2016)	Neste trabalho, peças fabricadas de Ti-6Al-4V pela WAAM foram submetidas a testes de fadiga. Após a fratura das amostras por fadiga, observou-se a presença de porosidade, zonas não fundidas e defeitos superficiais que contribuíram para o início e o crescimento das fissuras.
NOVELINO (2023)	Neste trabalho, peças fabricadas de aço ER70S-6 por WAAM-CMT foram submetidas a testes de fadiga. Os resultados obtidos mostraram que, para os ensaios uniaxiais, o método da raiz quadrada de área forneceu estimativas não conservadoras dos limites de fadiga à tração em ambas as direções de fabricação e à torção. Para os ensaios multiaxiais, o critério de Mataka obteve melhor desempenho para os corpos extraídos na direção transversal, com valores conservadores, e o modelo de MWCM forneceu as melhores estimativas para os corpos extraídos na direção longitudinal.

**Fonte:** Quadro idealizado pelo autor do presente texto.

Em geral, a porosidade nas peças depositadas está associada a contaminantes e ao mau controle da atmosfera na região de deposição, no entanto, a relação entre os parâmetros de deposição e a porosidade da peça final ainda não está completamente esclarecida.

Com base em tais questões e tendo como desafio a capacidade de medir a quantidade de vazios dentro do componente mecânico produzido, ou mesmo, correlacionar os parâmetros de deposição com o nível de porosidade, buscou-se no presente trabalho avaliar as propriedades mecânicas de endurecimento e os níveis de porosidade inicial e crítica de corpos de prova produzidos via WAAM-CMT à base de fio ER70S-6, utilizando o modelo de material poroso de Gurson (GURSON, 1977) e o método híbrido de identificação paramétrica GALM desenvolvido.

### 5.1. O MODELO DE GURSON

Para condições monotônicas aplicadas a componentes mecânicos produzidos via manufatura aditiva, além da determinação da curva de encruamento isotrópica em diferentes direções, há a necessidade de se quantificar o volume de vazios ou a porosidade da matriz do material metálico,  $f_0$ . A porosidade é um parâmetro que pode ser relacionado à perda de ductilidade e a sua quantidade inicial é um importante fator para se avaliar a qualidade do material obtido. Parâmetros relacionados a morfologia do cordão de deposição, como a velocidade de deposição, a espessura do cordão e a temperatura podem resultar em um volume maior ou menor de porosidade inicial e interferir significativamente nas propriedades de resistência do material.

O modelo de Gurson (1977) para materiais metálicos porosos estabelece que todo material possui uma quantidade de vazios em seu estado inicial. Essa quantidade de vazios é chamada de fração volumétrica de vazios ou porosidade,  $f$ , e é calculada pela razão entre o volume de vazios dentro de uma matriz metálica e o volume representativo elementar. Assim, a porosidade faz o papel de variável interna de dano do material, e computa a perda de ductilidade do material metálico. Para Gurson, a fração volumétrica inicial de vazios cresce de acordo com a carga axial aplicada, estabelecendo o chamado mecanismo de crescimento de vazios. A Equação 5.01 representa matematicamente o mecanismo de crescimento de vazios proposto por Gurson:

$$\dot{f} = (1 - f)\dot{\epsilon}_v^p \quad \text{Equação 5.01}$$

onde  $\dot{f}$  representa a taxa de crescimento da porosidade e  $\dot{\epsilon}_v^p$  é a taxa de evolução da parte volumétrica da deformação plástica. A função de escoamento que define o modelo baseado em Gurson é representada pela equação:

$$\phi = J_2 - \frac{1}{3} \left\{ 1 + f^2 - 2f \cosh \left( \frac{3p}{2\sigma_y} \right) \right\} \sigma_y^2 \quad \text{Equação 5.02}$$

onde:

- $\phi$  é a função de escoamento proposta por Gurson;
- $J_2$  representa o segundo invariante do tensor desviador,  $\mathbf{S} = \boldsymbol{\sigma} - \frac{1}{3} \text{tr}(\boldsymbol{\sigma}) \mathbf{I}$ , que é matematicamente determinado por  $J_2 = \frac{1}{2} \mathbf{S} : \mathbf{S}$ ;
- $p$  é a pressão hidrostática, determinada como sendo  $p = \frac{1}{3} \text{tr}(\boldsymbol{\sigma})$ ; e
- $\sigma_y$  é a lei de encruamento do material.

De acordo com o princípio da normalidade, a taxa de evolução da deformação plástica pode ser determinada de acordo com a equação:

$$\dot{\epsilon}^p \equiv \dot{\gamma} \frac{\partial \phi}{\partial \boldsymbol{\sigma}} \quad \text{Equação 5.03}$$

$$\dot{\epsilon}^p = \dot{\gamma} \left[ \mathbf{S} + \frac{1}{3} f \sigma_y \sinh \left( \frac{3p}{2\sigma_y} \right) \mathbf{I} \right]$$

onde  $\dot{\epsilon}^p$  representa a taxa de evolução do tensor das deformações plásticas e  $\dot{\gamma}$  é a taxa de evolução do chamado multiplicador plástico. Assim, da Equação 5.03, pode-se escrever que

$$\dot{\epsilon}^p = \dot{\epsilon}_d^p + \frac{1}{3} \dot{\epsilon}_v^p \mathbf{I} \quad \text{Equação 5.04}$$

onde  $\dot{\epsilon}_v^p = \dot{\gamma} f \sigma_y \sinh \left( \frac{3p}{2\sigma_y} \right)$ .

Desta forma, a taxa de evolução da porosidade pode ser reescrita pela equação:

$$\dot{f} = \dot{\gamma} (1 - f) f \sigma_y \sinh \left( \frac{3p}{2\sigma_y} \right) \quad \text{Equação 5.05}$$

Além disso, a taxa de evolução da chamada deformação plástica acumulada pode ser matematicamente calculada pela equação:



$$\dot{\varepsilon}^p = \dot{\gamma} \sqrt{\frac{2}{3} \left\{ \mathbf{S} : \mathbf{S} + \frac{1}{3} \left[ f \sigma_y \sinh \left( \frac{3p}{2\sigma_y} \right) \right]^2 \right\}} \quad \text{Equação 5.06}$$

onde  $\dot{\varepsilon}^p$  representa a taxa de evolução da deformação plástica acumulada.

O modelo constitutivo para materiais metálicos porosos de Gurson está presente na ferramenta académica de elementos finitos HYPLAS. Através de uma estratégia implícita de integração, pode-se utilizar o método de decomposição do operador, onde se tem um preditor elástico e um corretor plástico. No corretor plástico, há a necessidade de se calcular, através do método de Newton-Raphson, o sistema de equações residuais e não lineares:

$$\left\{ \begin{array}{l} R_{\Delta\gamma} = J_{2n+1} - \frac{1}{3} \left\{ 1 + f_{n+1}^2 - 2f_{n+1} \cosh \left( \frac{3p_{n+1}}{2\sigma_y} \right) \right\} \sigma_y^2 \\ R_{p_{n+1}} = p_{n+1} - p_{n+1}^{trial} - \Delta\gamma f_{n+1} \sigma_y \sinh \left( \frac{3p_{n+1}}{2\sigma_y} \right) \\ R_{f_{n+1}} = f_{n+1} - f_{n+1}^{trial} - \Delta\gamma (1 - f_{n+1}) f_{n+1} \sigma_y \sinh \left( \frac{3p_{n+1}}{2\sigma_y} \right) \\ R_{\dot{\varepsilon}_{n+1}^p} = \dot{\varepsilon}_{n+1}^p - \dot{\varepsilon}_n^p - \Delta\gamma \sqrt{\frac{2}{3} \left\{ \mathbf{S}_{n+1} : \mathbf{S}_{n+1} + \frac{1}{3} \left[ f_{n+1} \sigma_y \sinh \left( \frac{3p_{n+1}}{2\sigma_y} \right) \right]^2 \right\}} \end{array} \right. \quad \text{Equação 5.07}$$

onde  $R_{\Delta\gamma}$ ,  $R_{p_{n+1}}$ ,  $R_{f_{n+1}}$  e  $R_{\dot{\varepsilon}_{n+1}^p}$  representam as equações residuais para as variáveis internas do problema. O índice  $(*)^{trial}$  representa o valor da grandeza termodinâmica/variável interna no estado tentativa (preditor elástico). Já os subíndices  $(n+1, n)$  representam o pseudo-tempo atual e anterior, respectivamente.


## 5.2. PROCEDIMENTOS EXPERIMENTAIS

A confecção dos corpos de prova e o ensaio de tração foram realizados por Santos (2022). Durante a fase de produção da placa metálica, a deposição das camadas foi realizada utilizando-se o processo WAAM-CMT com o intuito de garantir um maior controle de deposição. O processo *Cold Metal Transfer* (CMT) baseia-se na transferência de metal através de curtos-circuitos controlados que sistematicamente descontinuem o arco. O resultado é uma sequência “quente-frio-quente” com significativa redução da temperatura do processo. Toda vez que ocorre um curto circuito, um processo digital de controle interrompe o suprimento de energia e retrai o arame. O movimento de retração do arame evita a divisão das gotículas de metal transferido durante o curto circuito e a

baixa corrente de transferência utilizada reduz a geração de calor do processo. O reduzido aporte de calor significa menor distorção da peça soldada e melhor precisão, resultando em cordões de solda de boa qualidade, livres de respingos (FRONIUS, 2023).


### 5.2.1. Confeção dos corpos de prova (CP's)

Os corpos de prova (CP) foram retirados de uma placa com dimensões 180 x 100 x 3 mm obtida por manufatura aditiva. Na produção da placa foi usado o arame ER70S-6. É um arame sólido cobreado para soldagem com proteção gasosa. Possui em sua composição silício e manganês nas faixas de 0,8% a 1,15% e 1,4% a 1,85%, respectivamente. O sistema foi configurado para depositar um total de 100 camadas ou layers com 180 mm de comprimento através do método de deposição bidirecional com arco contínuo. Utilizou-se os seguintes parâmetros: tensão de 20.6 V, corrente de 62 A, velocidade do arame de 2,6 m/min, velocidade horizontal da tocha de 8 mm/s, velocidade vertical da tocha de 24 mm/s e deslocamento vertical da tocha após cada camada de 1 mm. A Figura 5.02 apresenta a placa metálica produzida.




**Figura 5.02.** Placa metálica produzida via processo WAAM-CMT com 180x100x3 mm.  
**Fonte:** Santos (2022)

Para a obtenção dos corpos de prova, inicialmente realizou-se um processo de lixamento e fresamento da placa metálica, com o intuito de se retirar irregularidades. Os CP's foram extraídos via um processo de corte à jato d'água com um diâmetro de jato de aproximadamente 1,5 mm. A Figura 5.03 apresenta a placa metálica após o processo de corte.



**Figura 5.03.** Placa metálica após o processo de corte por jato d'água.  
**Fonte:** Santos (2022)

A Figura 5.04 e a Tabela 5.01 apresentam as dimensões nominais e adaptadas do corpo de prova. As dimensões nominais seguem as recomendações da norma ASTM E8/E8M (ASTME8E8M, 2022). Devido as limitações da placa metálica produzida, houve a necessidade de se adaptar dimensionalmente os CP's.



**Figura 5.04.** Dimensões nominais do corpo de prova.  
**Fonte:** Santos (2022)

**Tabela 5.01.** Dimensões nominais e adaptadas para os corpos de prova produzidos via manufatura aditiva.

Dimensões	L [mm]	G [mm]	A [mm]	B [mm]	C [mm]	R [mm]
Nominais	80,94	32	42	15	10	6
Adaptadas	100	25	32	30	10	6

**Fonte:** Tabela idealizada pelo autor do presente texto.

Antes da execução dos ensaios, foram aferidas as medidas de espessura ( $e$ ) e largura ( $W$ ) dos corpos de prova para que fossem utilizados os valores reais dentro dos cálculos analíticos. A diferença entre as dimensões adaptadas da Tabela 5.01 e as reais se deve à necessidade de se efetuar um melhor acabamento superficial dos CP's. A Tabela 5.02 apresenta as medidas reais dos CP's.


**Tabela 5.02.** Medidas reais de espessura e largura dos corpos de prova.

Referência	Espessura $e$ [mm]	Largura $W$ [mm]
CP 1	2,31	6,24
CP 2	2,18	6,25
CP 3	2,19	6,22
CP 4	2,21	6,22
CP 5	2,44	6,25
CP 6	2,46	6,26
<b>Média</b>	2,30	6,24

**Fonte:** Tabela idealizada pelo autor do presente texto.

### 5.2.2. O Ensaio de Tração


Para este trabalho, foi realizado uma bateria de ensaios experimentais de tração, sob controle de deformação. Foi utilizada uma máquina de ensaio universal MTS 810, com capacidade de 100 kN. Para instrumentação do corpo de prova, utilizou-se um clip-gauge de 25 mm de comprimento útil. Os ensaios foram realizados até a fratura, sob uma taxa de deslocamento de 1mm/min, onde se registrou os dados de força de reação das agarras e deformação no *clip-gauge*, com uma pressão de aperto na agarra de 10 MPa. Além disso, com base no comprimento útil do *clip-gauge* e os registros de deformação, foram calculados os deslocamentos do comprimento útil do corpo de prova. A Figura 5.05 apresenta o registro do posicionamento de um dos corpos de prova, bem como do clip-gauge na MTS 810.




**Figura 5.05.** Posicionamento do corpo de prova e *clip-gauge* na MTS 810.

**Fonte:** Santos (2022)


Após a realização dos seis ensaios, onde três CPs foram retirados da direção L e três da direção T da placa fabricada via manufatura aditiva, foram obtidos os dados para a montagem dos gráficos de força [N] versus deslocamento [mm] (Figura 5.06).



(a)



(b)



(c)

**Figura 5.06.** a) Força de reação versus deslocamento experimentalmente determinados para os seis ensaios de tração, b) Três CP's na direção L da placa e c) Três CP's na direção T da placa.  
**Fonte:** Malcher *et al* (2023)

### 5.3. PROCEDIMENTOS NUMÉRICOS

Para a caracterização da curva de encruamento isotrópica serão avaliados os quatro parâmetros  $(\sigma_{y0}, \xi, \sigma_{\infty}, \delta)$  da equação de Kleiner e Ponthot (2003) e as porosidades inicial e crítica  $(f_0, f_{cr})$  do modelo de materiais metálicos porosos de Gurson (1977). O valor do módulo de elasticidade será calculado utilizando-se o módulo desenvolvido anteriormente e ao coeficiente de Poisson será atribuído o valor 0.3 (GARCIA, 1999, p. 24).

A porosidade crítica  $(f_{cr})$ , dentro da mecânica do dano, representa a completa perda de ductilidade do material, ou seja, o início de uma trinca macroscópica. O seu valor é uma consequência da execução do modelo de Gurson sendo o maior nível de porosidade atingida para o deslocamento da fratura experimental.

A Figura 4.01 representa esquematicamente o fluxo de trabalho utilizado no processo de identificação paramétrica. Inicialmente, tem-se a modelagem do ensaio de tração dentro de uma ferramenta de elementos finitos. Importante destacar que somente a região do corpo de prova equivalente ao comprimento do *clipe gauge* é modelada. O pesquisador tem a opção de utilizar como conjunto de valores iniciais para os parâmetros  $(\sigma_{y0}, \xi, \sigma_{\infty})$ :

- o resultado de um fitting simples com a equação de Kleiner e Ponthot (2003) tomando por base os dados de tensão verdadeira versus deformação verdadeira até o valor de tensão máxima (limite de resistência); ou
- um intervalo de valores para cada parâmetro a ser analisado.

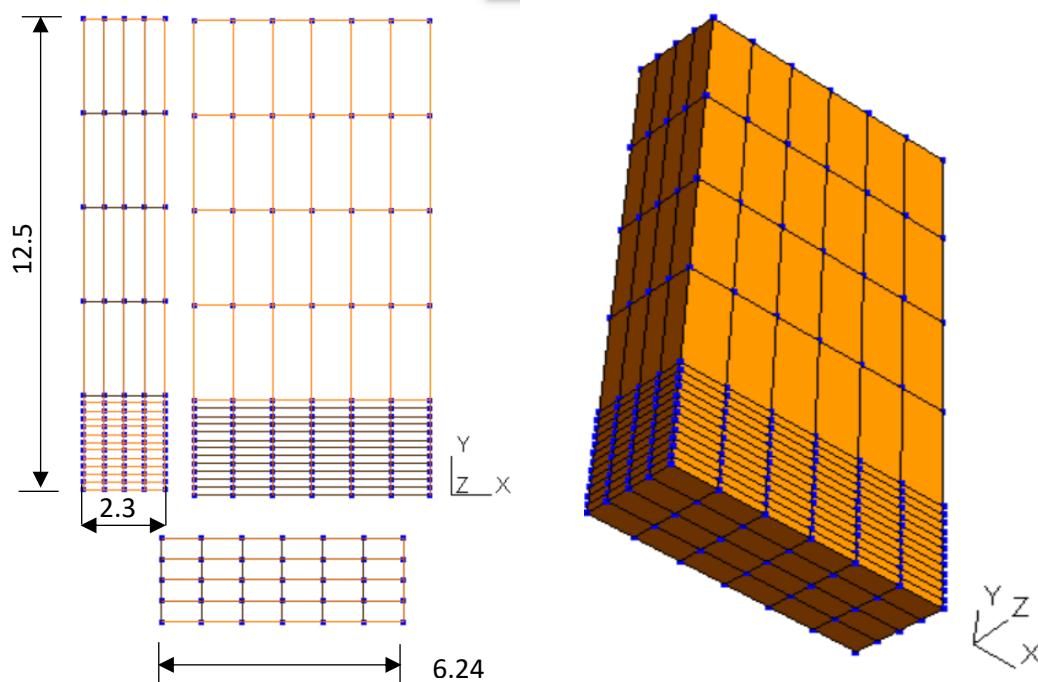
Com relação a porosidade inicial, em todos os casos, utilizou-se uma estimativa inicial de  $f_0 = 0.0001$ .

Após a modelagem, processa-se a execução do método de elementos finitos obtendo-se os dados de uma curva de reação numérica. Em próximo passo, compara-se as curvas de reação experimental e numérica até o nível de deslocamento na fratura utilizando a função objetivo. A tolerância estabelecida foi de  $10^{-6}$  para cada um dos parâmetros. Caso o valor obtido seja menor que a tolerância indicada, o método apresenta a solução obtida e é finalizado, caso não, se o valor for maior, o módulo do modelo híbrido é ativado e se inicia a busca por melhores parâmetros.

O método de busca se inicia com a abordagem do algoritmo genético (GA), utilizando os intervalos de valores indicados para cada parâmetro. Neste momento procura-se manter a maior variabilidade possível para que a busca não fique retida em um ponto crítico local. O GA foi configurado para executar até três gerações de filhos tendo cada geração uma população fixa de 6 indivíduos. Após a execução do GA, inicia-se o método de busca baseado no gradiente, até se atingir a tolerância estabelecida para a função objetiva (Equação 4.05).

Nas próximas seções serão apresentados o modelo de elementos finitos desenvolvido e as etapas das simulações realizadas para o presente problema.

### 5.3.1. Modelo de Elementos Finitos (MEF)



**Figura 5.07** Malha de elementos finitos utilizada para reprodução do ensaio de tração. Dimensões em [mm]

**Fonte:** Malcher *et al* (2023)

Para a montagem do MEF foi utilizado um desenvolvimento acadêmico de elementos finitos denominado HYPLAS (NETO *et. al*, 2008), escrito na linguagem FORTRAN e acoplado ao processo de identificação de parâmetros. Na descrição do comportamento do material, adotou-se o modelo de material metálico poroso de Gurson em uma estratégia explícita de integração. As simulações foram executadas em grandes deformações e até o nível de deslocamento na fratura observado experimentalmente. Como escolha dos autores, utilizou-se uma modelagem tridimensional, onde somente 1/2



do problema foi tratado, ou seja, na região central do corpo de prova, aplicou-se restrição axial de deslocamento, deixando as outras direções (transversais) livres, permitindo, assim, a ação do efeito de Poisson. Já na outra extremidade, aplicou-se restrições de deslocamento nas direções transversais e se impôs o deslocamento na fratura experimentalmente observado, na direção axial. Como se está resolvendo somente 1/2 do problema tridimensional, somente metade do deslocamento na fratura foi imposto.

A malha de elementos finitos foi construída com base nos valores médios de  $e$  e  $W$ , apresentados na Tabela 5.02 onde se assume que a área da seção transversal teria uma variação máxima de 10%. Observa-se ainda, que na discretização do problema, uma malha com maior densidade de elementos na região central do corpo de prova foi utilizada, tendo elementos finitos tridimensionais hexaédricos com 8 nós e integração reduzida. Ao total, a malha contém 384 elementos e 595 nós. A Figura 5.07 apresenta o aspecto da malha de elementos finitos utilizada, bem como as dimensões do modelo proposto.

### 5.3.2. Simulações Numéricas

Na execução do processo de identificação paramétrica (PIP), inicialmente, foi realizada uma análise prévia dos dados experimentais. Importantes parâmetros do material em estudo, dentre eles, o módulo de elasticidade ( $E$ ), o limite de escoamento ( $\sigma_{y0}$ ), o módulo de encruamento isotrópico linear ( $\xi$ ) e o valor da tensão máxima ( $\sigma_{\infty}$ ) foram avaliados. Com os valores obtidos e a equação de Kleinermann e Ponthot (Equação 4.01) realizou-se um fitting. Este procedimento teve como objetivo definir uma região de busca para o método baseado no algoritmo genético (GA). A Tabela 5.03 apresenta os valores iniciais adotados.

**Tabela 5.03.** Estimativa inicial para os parâmetros da curva de encruamento do material. PIP com abordagem de busca baseada no GA.

Direção	L				T	
	CP1	CP2	CP3	CP4	CP5	CP6
$E$ [MPa]	164046,5	190675,2	197313,6	188053,9	208162,3	205426,1
$\sigma_{y0}$ [MPa]	305,8	239,3	260,0	330,7	297,3	328,5
$\xi$ [MPa]	411,5	351,8	365,2	413,1	419,3	453,3
$\sigma_{\infty}$ [MPa]	517,2	464,3	470,3	495,4	541,3	578,1
$\delta$	25	25	25	25	25	25

**Fonte:** Tabela idealizada pelo autor do presente texto.

Com base nos valores da Tabela 5.03, um coeficiente de Poisson fixo ( $\nu = 0.3$ ) e porosidade inicial nula ( $f_0 = 0.0$ ), foi iniciado o PIP com a abordagem do GA. Realizou-se uma primeira análise utilizando-se o modelo baseado em von Mises, recuperado ao se trabalhar com a porosidade ( $f$ ) igual a 0 (zero) no modelo de Gurson. Após a execução de três gerações e escolha dos indivíduos com maior ranking foram identificados os parâmetros apresentados na Tabela 5.04.

**Tabela 5.04.** Resultado dos parâmetros da curva de encruamento do material, após a abordagem de busca baseada no GA utilizando o modelo de von Mises.

Direção	L			T		
	CP1	CP2	CP3	CP4	CP5	CP6
$E$ [MPa]	164046,5	190675,2	197313,6	188053,9	208162,3	205426,1
$\sigma_{y0}$ [MPa]	259,8	190,8	273,3	292,0	342,1	324,8
$\xi$ [MPa]	402,1	326,0	298,5	323,3	474,8	609,0
$\sigma_{\infty}$ [MPa]	484,6	446,4	434,8	452,9	422,1	465,1
$\delta$	13,61	18,86	16,88	23,83	16,29	15,06
Rank	0,95	0,93	0,96	0,95	0,97	0,96

**Fonte:** Tabela idealizada pelo autor do presente texto.

O ciclo de simulações seguinte iniciou-se com os dados da Tabela 5.04,  $\nu = 0.3$  e novamente  $f_0 = 0.0$ . O processo PIP foi executado com abordagem de busca baseada no gradiente até uma tolerância de  $10^{-6}$  para a função objetiva. A Tabela 5.05 apresenta o resultado final para a identificação da curva de endurecimento isotrópico com referência no modelo de von Mises, para os corpos de prova obtidos via manufatura aditiva.

**Tabela 5.05.** Resultado final dos parâmetros da curva de encruamento isotrópica do material baseado em von Mises, após a abordagem de busca híbrida.

Direção	L			T		
	CP1	CP2	CP3	CP4	CP5	CP6
$E$ [MPa]	164046,5	190675,2	197313,6	188053,9	208162,3	205426,1
$\sigma_{y0}$ [MPa]	338,0	280,8	295,4	330,5	306,4	346,8
$\xi$ [MPa]	-163,7	-280,2	-335,19	75,4	578,2	602,6
$\sigma_{\infty}$ [MPa]	976,1	900,3	991,42	692,4	407,2	459,0
$\delta$	2,24	2,65	2,30	2,80	24,60	28,14

**Fonte:** Tabela idealizada pelo autor do presente texto.

As etapas anteriores foram realizadas novamente utilizando-se, desta vez, o modelo baseado em Gurson. Os parâmetros identificados são apresentados na Tabela 5.06.

**Tabela 5.06.** Resultado dos parâmetros da curva de encruamento do material, após a abordagem de busca baseada no GA utilizando o modelo de Gurson.

Direção	L			T		
	CP1	CP2	CP3	CP4	CP5	CP6
$E$ [MPa]	164046,5	190675,2	197313,6	188053,9	208162,3	205426,1
$\sigma_{y0}$ [MPa]	282,1	220,6	269,0	393,0	317,0	380,4
$\xi$ [MPa]	635,2	476,3	548,2	740,9	987,3	669,1
$\sigma_{\infty}$ [MPa]	529,5	530,8	438,2	585,9	570,6	620,0
$\delta$	17,86	26,37	11,27	6,70	25,97	20,82
$f_0$	0,053	0,064	0,094	0,100	0,140	0,076
Rank	0,92	0,93	0,87	0,97	0,97	0,97

**Fonte:** Tabela idealizada pelo autor do presente texto.

Por fim, para se chegar a caracterização do modelo de material metálico poroso de Gurson, utilizou-se as melhores estimativas iniciais verificadas com a execução do GA segundo o próprio modelo de Gurson (Tabela 5.06). Com esses resultados, executa-se o PIP somente com a abordagem de busca baseada no gradiente. A Tabela 5.07 apresenta os parâmetros da curva de encruamento isotrópica do material poroso, bem como, os níveis de porosidade inicial e crítica estimados.

**Tabela 5.07.** Resultado final dos parâmetros da curva de encruamento isotrópica do material metálico poroso de Gurson, após a abordagem de busca híbrida.

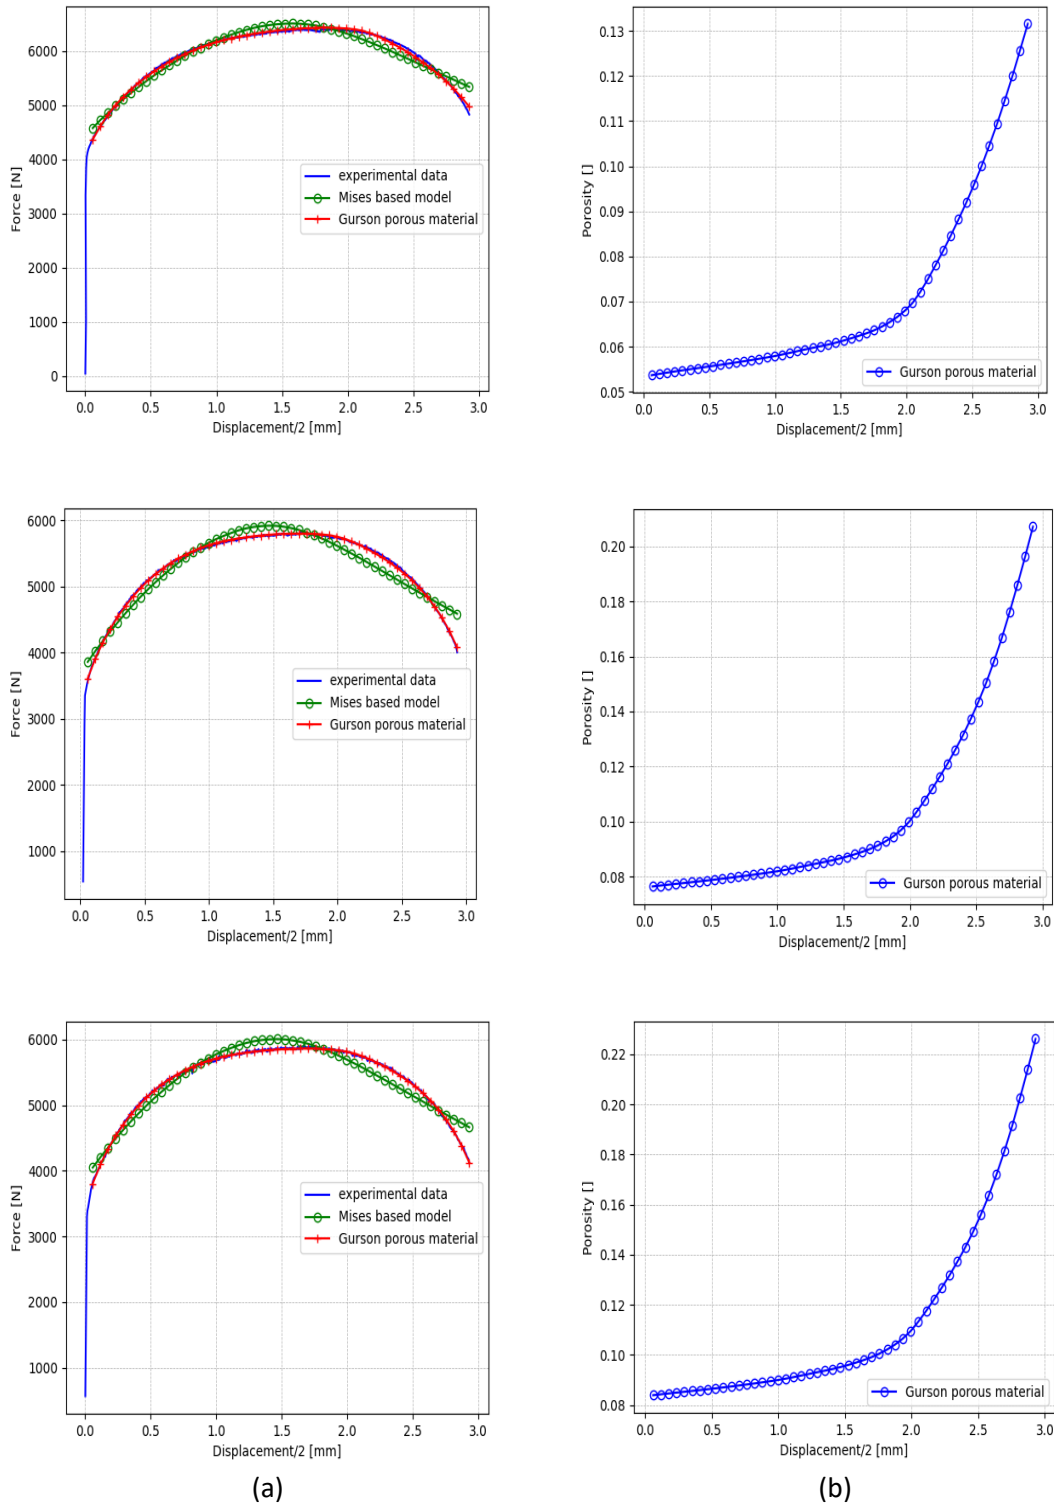
Direção	L			T		
	CP1	CP2	CP3	CP4	CP5	CP6
$E$ [MPa]	164046,5	190675,2	197313,6	188053,9	208162,3	205426,1
$\sigma_{y0}$ [MPa]	335,0	227,2	292,5	356,8	358,4	375,0
$\xi$ [MPa]	437,4	470,9	509,8	-51,8	689,6	619,4
$\sigma_{\infty}$ [MPa]	550,7	491,8	495,9	703,1	601,0	599,8
$\delta$	15,09	22,30	23,65	9,83	20,90	22,09
$f_0$	0,053	0,076	0,084	0,100	0,141	0,076
$f_{cr}$	0,132	0,205	0,205	0,134	0,177	0,102
$\bar{\epsilon}_f^p$	2,90	2,90	2,95	1,90	2,30	2,05

\*  $\bar{\epsilon}_f^p$  representa a deformação plástica acumulada na fratura.

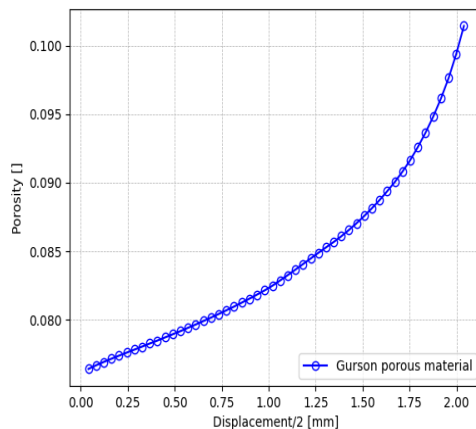





**Fonte:** Tabela idealizada pelo autor do presente texto.

As Figuras 5.08 e 5.09, apresentam os gráficos para as curvas de reação experimental e numéricas, segundo von Mises e Gurson, bem como, a evolução da porosidade do material até o nível de deformação na fratura, onde se caracteriza a chamada porosidade crítica. Observa-se que o modelo baseado em von Mises não é capaz

de representar o material provindo da manufatura aditiva. Ao contrário do modelo de material poroso de Gurson, onde se tem um perfeito ajuste das curvas.



**Figura 5.08.** a) Curvas de força versus deslocamento e b) Porosidade versus deslocamento para os corpos de prova 1, 2 e 3, retirados da direção L da placa metálica.  
**Fonte:** Figuras idealizadas pelo autor do presente texto.




(a)


(b)

**Figura 5.09.** a) Curvas de força versus deslocamento e b) Porosidade versus deslocamento para os corpos de prova 4, 5 e 6, retirados da direção T da placa metálica.


**Fonte:** Figuras idealizadas pelo autor do presente texto.




CP1 – direção L




CP4 – direção T




CP2 – direção L



CP5 – direção T



CP3 – direção L



CP6 – direção T

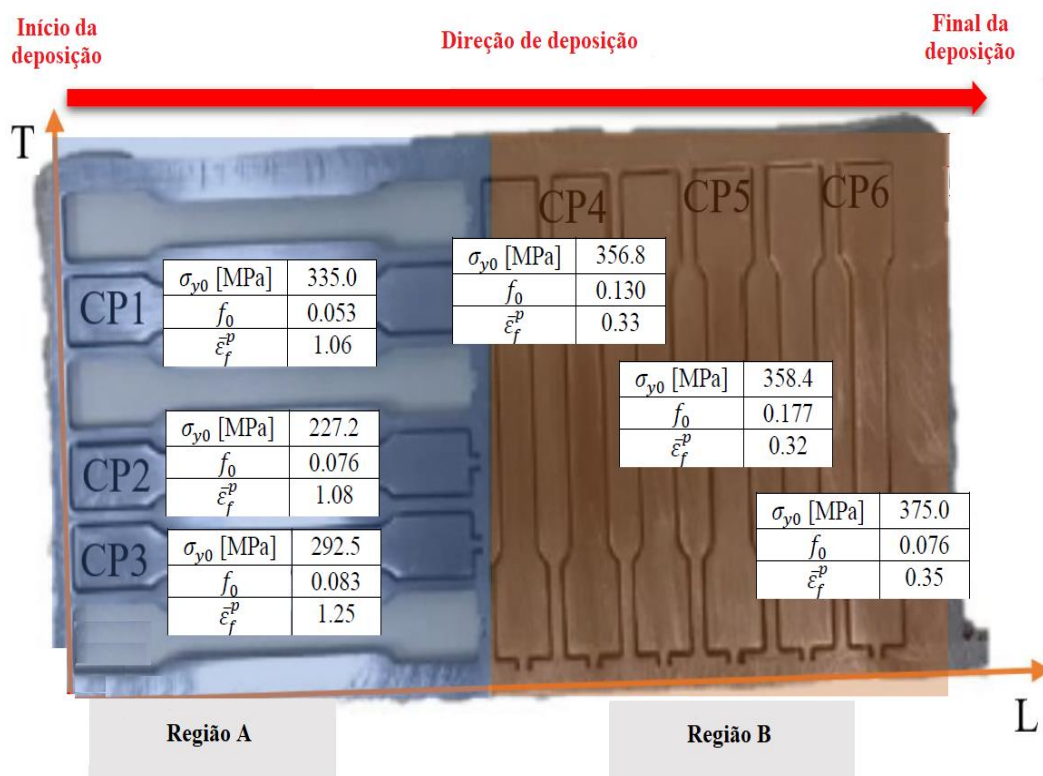
**Figura 5.10.** Contorno da deformação plástica equivalente na fratura.

Fonte: Malcher *et al* (2023)

O comportamento mecânico dos corpos de prova CP1, CP2 e CP3 assemelha-se ao de um material dúctil, em contraste com os corpos de prova CP4, CP5 e CP6, que se comportam como um material frágil. Esse comportamento pode ser confirmado mais uma vez quando se analisa o contorno da deformação plástica na fratura (Figura 5.10). Observa-se nos corpos de prova CP1, CP2 e CP3 uma redução de volume na parte central (parte inferior da figura), ou melhor, a formação de um “pescoço” pronunciado, o que não pode ser observado para os corpos de prova CP4, CP5 e CP6.

Conclui-se que na direção L, a placa tem um maior nível de ductilidade em relação à direção T (Figura 5.03). Esse comportamento pode ser explicado pela direção de deposição e resfriamento do metal e, também, por estar associado à maior coesão no menor número de camadas apresentadas na direção L.

#### 5.4. CARACTERIZAÇÃO MECÂNICA DOS CP's.



**Figura 5.11.** Direção de deposição do metal e propriedades do material.

Fonte: Malcher *et al* (2023)

Ao analisar as propriedades do corpo de prova é importante considerar a direção de deposição do material. Como pode ser observado na Figura 5.11, a deposição foi bidirecional e contínua sem interrupção do arco elétrico. Isso leva a uma menor

microestrutura colunar com menores tensões residuais, mas, com maiores variações ao longo da altura da placa.

A ductilidade foi maior na direção L, identificada na Figura 5.11 como região A, quando comparada à região B, na direção T. Nesse sentido, o nível de deformação plástica equivalente na fratura é de 3 a 4 vezes maior do que os da região B. Isso pode estar associado às características de deposição, na região A os corpos de prova possuem um menor número de camadas longas com microestrutura semelhante, uma vez que o gradiente térmico é maior na direção T.

Em estudos sobre o ER70S-6 depositado pelo processo WAAM, Aldalur *et al.* (2020) e Nemani *et al.* (2020) avaliaram as diferentes microestruturas ao longo da altura da placa produzida. Aldalur *et al.* (2020) observou ferrita poligonal, acicular e alotriomórfica além de bainita. Verificou variações nos tamanhos de grão observando uma menor microestrutura próxima ao substrato, o que evidenciou o efeito dos gradientes térmicos na microestrutura final e, portanto, no comportamento mecânico. Nemani *et al.* (2020) focou seus estudos nas propriedades intercamadas e verificou que essas podem apresentar extensas variações como, por exemplo, a dureza HV que variou cerca de 14% desde a zona afetada pelo calor até o limite da zona da piscina fundida.

Considerando esses efeitos e observando os valores da Figura 5.11, é possível inferir que a variação do nível de deformação plástica equivalente na fratura pode estar associada à direção de deposição e à transferência de calor. Isso afetou também a tensão de escoamento que foi cerca de 25% maior na região B do que na região A, acentuando a anisotropia na placa.

Destacando-se a porosidade, foi possível notar que, de acordo com o modelo de Gurson, os corpos de prova extraídos da placa ao longo da direção L (região A) possuem cerca de 5% a 8% do volume de vazios quando comparados àqueles extraídos ao longo da direção T (região B), onde se verificou de 7% a 18% do volume de vazios. Esse maior nível de vazios pode ser associado ao maior número de intercamadas onde os defeitos podem se concentrar. Além disso, a maior porosidade da região B pode estar associada ao comportamento frágil e à menor deformação plástica apresentada.

Considerando o número de camadas no corpo de prova, Hauser *et al.* (2021) observou que diferentes defeitos podem ocorrer durante a deposição, com a concentração de alguns deles na região intercamadas. Neste estudo avaliou-se a liga AlSi5 e verificou-



se que a oxidação tem um efeito significativo nas propriedades mecânicas da liga, inclusive em ligas de aço. Haden *et al.* (2017) observou que para a liga ER70S-6 a porosidade pode estar associada à oxidação, principalmente nas bordas da peça.

Outro defeito que pode aumentar a fragilidade e a presença de vazios é a falta de fusão dentro das camadas, que também pode levar à delaminação (delamination). Wu *et al.* (2018) indicou que a combinação de materiais pode levar à delaminação e mencionou que isso pode ocorrer com o substrato. Considerando-se que no presente trabalho não se combinou materiais, a causa poderia ser semelhante ao apontado por Jafari *et al.* (2021), ou seja, a falta de fusão, uma vez que o material da camada anterior não está completamente derretido fragiliza as regiões o que poderia levar à formação de fissuras.

Gordon e Harlow (2019) estudando a fadiga em aço inoxidável 304 produzido pela WAAM concluíram que uma das principais causas da porosidade são o gás retido e a energia insuficiente durante a deposição, o que resultaria em falta de fusão e falta de adesão dentro das camadas. Os autores ressaltam que esses poros podem ser precursores de fissuras, uma vez que são geradores de tensões e afetam as propriedades mecânicas do material.

Hosseini *et al.* (2019) também observou alta porosidade ao avaliar o aço inoxidável duplex 2205. Verificou-se que a porosidade foi mais severa dentro das camadas devido à diferente microestrutura presente. Esses resultados podem corroborar a hipótese de que os corpos de prova da região B apresentaram um comportamento mais frágil devido ao maior número de intercamadas e vazios quando comparados aos corpos de prova da região A.

## 5.5. CONCLUSÕES

Neste estudo de caso buscou-se verificar a aplicabilidade do modelo de materiais porosos de Gurson na caracterização das propriedades mecânicas de corpos de prova produzidos via manufatura aditiva (MA). Para isso, foram mensuradas a curva de endurecimento do material até a fratura e o nível de porosidade inicial e crítica em diferentes pontos e direções de deposição do metal, através de corpos de prova retirados de uma placa metálica produzida via WAAM-CMT com o fio ER70S-6. Assim, concluiu-se que o modelo baseado em Gurson consegue descrever o comportamento mecânico de materiais fornecidos por MA e pode ser utilizado como alternativa para prever a fração de vazio volumétrico que é um defeito presente nesses tipos de materiais, diferentemente

do modelo baseado em von Mises que não conseguiu descrever o comportamento mecânico, principalmente na região “pós-pescoço” (Figura 3.01).

Observou-se que, nas diferentes direções de deposição, o material apresentou de 5% a 18% de porosidade, o que influenciou fortemente as características de resistência, como tensão de escoamento, módulo de elasticidade e nível de deformação plástica acumulada esperado na fratura, que variou de 0,3 a 1,5 na região central do corpo de prova. Assim, os corpos de prova extraídos na direção L da placa metálica tiveram um comportamento próximo a um material dúctil. Por outro lado, os corpos de prova gerados na direção T apresentaram um comportamento frágil, justificável devido à direção preferencial de resfriamento e ao alongamento de vazios no interior da matriz metálica.

## 6. CONSIDERAÇÕES FINAIS

O processo de identificação de parâmetros utilizando métodos de otimização tem se tornado uma ferramenta importante na determinação de parâmetros de materiais. O grau de complexidade da relação constitutiva do material é um fator determinante na escolha do método de otimização, uma vez que a função objetivo pode apresentar muitos mínimos ou máximos locais.

O presente estudo procurou identificar e explorar os problemas e dificuldades que podem surgir durante o processo de identificação de parâmetros. Desenvolveu-se rotinas computacionais que englobaram um algoritmo evolutivo, o Algoritmo Genético (GA) e um algoritmo baseado em gradiente, o Algoritmo de Levenberg-Marquardt Dividido (LMD) e propôs-se um modelo híbrido que unisse a robustez de busca do GA e a velocidade e precisão do Algoritmo LMD.

As rotinas desenvolvidas foram testadas e muitas análises foram aqui apresentadas, tanto do Algoritmo Genético, quanto do Algoritmo de Levenberg-Marquardt Dividido (LMD) que recebeu como entrada os valores advindos do Algoritmo Genético. Em geral, o desempenho de ambos foi bom, chegando-se às soluções dentro de uma precisão desejada em poucas iterações. O ponto crítico verificado foi o método dos Elementos Finitos, aqui representado pelo sistema HYPLAS. Um sistema acadêmico que ajudou no desenvolvimento do método híbrido, mas que adicionou a cada iteração do Algoritmo Genético e o do Algoritmo LMD diversos segundos de processamento.

Quanto ao teste de tração, amplamente usado para a obtenção de informações sobre um dado material e também como um teste de controle de especificações, foram avaliadas algumas características importantes e criada uma rotina para automatizá-lo. Em conjunto com os resultados obtidos para alguns materiais, no caso, os aços 4340 normalizado e recozido e a liga 1524 U2 verificou-se a aplicação das rotinas estruturadas na linguagem PYTHON para o GA, o LMD e o método híbrido na determinação de parâmetros de encruamento segundo o modelo de Kleinermann e Ponthot (2003).

No estudo de caso buscou-se verificar a aplicabilidade do modelo de materiais porosos de Gurson na caracterização das propriedades mecânicas de corpos de prova produzidos via manufatura aditiva (MA). Foram mensuradas a curva de endurecimento do material até a fratura e o nível de porosidade inicial e crítica em diferentes pontos e direções de deposição do metal. Concluiu-se que o modelo baseado em Gurson consegue descrever o comportamento mecânico de materiais fornecidos por manufatura aditiva e

pode ser utilizado como alternativa para prever a fração de vazio volumétrico que é um defeito presente nesses tipos de materiais.

Observou-se que, nas diferentes direções de deposição, o material apresentou de 5% a 18% de porosidade, o que influenciou fortemente as características de resistência, como tensão de escoamento, módulo de elasticidade e nível de deformação plástica acumulada esperado na fratura, que variou de 0,3 a 1,5 na região central do corpo de prova.

Para evolução e enriquecimento do trabalho desenvolvido sugere-se como ações para projetos futuros:

- a. Acoplar as rotinas desenvolvidas a outros sistemas, inclusive comerciais, que utilizem o método dos Elementos Finitos já otimizado. Elas foram implementadas na linguagem PYTHON sendo possível vincula-las a outros programas, além do HYPLAS. Um exemplo é o programa ABAQUS CAE que possui comunicação direta com essa linguagem;
- b. Aperfeiçoar o uso do Algoritmo Genético (GA) desenvolvido avaliando diversos outros parâmetros implementados e que não foram utilizados em sua potencialidade. A intenção de incluí-los no desenvolvimento das rotinas foi generalizar o uso do GA, aplicando-o no futuro a outros modelos ou mesmo diferentes problemas;
- c. Aplicar o método híbrido na determinação de parâmetros de encruamento segundo outros modelos além do modelo de Kleinermann e Ponthot (2003), com maior ou menor número de parâmetros, dependendo do problema a ser avaliado;
- d. Aplicar o método híbrido na determinação de parâmetros de modelos que se proponham a analisar os diferentes aspectos envolvidos na fabricação de peças via manufatura aditiva, como o tempo do passo, dimensões do cordão de solda, tensão do arco voltaico envolvido, etc.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABNT13715 (2018). **ABNT NBR 13715-2 – Estruturas oceânicas – Amarras. Parte 2: Requisitos e métodos de ensaios.** Associação Brasileira de Normas Técnicas – 6 páginas. Versão publicada em 10/2012 e confirmada em 10/2018.
- ABNT13715 (2019). **ABNT NBR 13715-1 – Estruturas oceânicas – Amarras. Parte 1: Aprovação de fornecedor e materiais.** Associação Brasileira de Normas Técnicas – 6 páginas. Versão publicada em 02/2008 e confirmada em 01/2019.
- ABNT6892 (2015). **ABNT NBR ISO 6892-1:2013 – Materiais metálicos – Ensaio de Tração. Parte 1: Método de ensaio à temperatura ambiente.** Associação Brasileira de Normas Técnicas – 70 páginas. Versão corrigida em 27/03/2015.
- AGUIR, H., BELHADJSALAH, H., HAMBALI, R. (2011). **Parameter identification of an elasto-plastic behaviour using artificial neural networks – genetic algorithm method.** *Materials and Design*, Vol. 32, p. 48-53.
- ALDALUR, E., VEIGA, F., SUÁREZ, A., BILBAO, J., LAMIKIZ, A. (2020). **High deposition wire arc additive manufacturing of mild steel: strategies and heat input effect on microstructure and mechanical properties.** *Journal of Manufacturing Processes* 58, 615–626.
- ALVES, Vinícius N.; OLIVEIRA, Matheus M. de; RIBEIRO, Diogo; CALÇADA, Rui.; CURY, Alexandre. (2020). **Model-based damage identification of railway bridges using genetic algorithms.** *Engineering Failure Analysis* 118 (2020) 104845.
- ANDRADE, F.X.C., PIRES, F.M.A., DE SÁ, J.M.A.C., MALCHER, L. (2009). **Improvement of the numerical prediction of ductile failure with an integral nonlocal damage model.** *International Journal of Material Forming*, 2009, 2(SUPPL. 1), pp. 439–442.
- ASTME869 (1989). **ASTM Standard E8-69 – Standard Terminology Relating to Methods of Mechanical Testing.** American Society for Testing and Materials. 1989
- ASTME8E8M (2022). **ASTM E8/E8M, 2022 Edition, May 1, 2022 - Standard Test Methods for Tension Testing of Metallic Materials.** [https://doi.org/10.1520/E0008\\_E0008M-08](https://doi.org/10.1520/E0008_E0008M-08).
- BARBOSA, P. S. F. (2002) **Técnicas quantitativas para o gerenciamento de recursos hídricos.** Porto Alegre: Editora da UFRGS-ABRH. 2ed.
- BISWAL, R.; ZHANG, X.; SYED, A.K.; AWD, M.; DING, J.; WALTHER, F.; WILLIAMS, S. (2019). **Criticality of porosity defects on the fatigue performance of wire + arc additive manufactured titanium alloy.** *Int J Fatigue* 122, 208–217.
- BLAISE, Bale Baidi; BETCHEWE, Gambo; BEDA Tibi (2019). **Optimization of the model of Ogden energy by the genetic algorithm method.** *Appl. Rheol.* (2019) 29 (1): 21-29.
- BÖCKIN, D.; TILLMAN, A. M. (2019). **Environmental assessment of additive manufacturing in the automotive industry.** *Journal of Cleaner Production*, 226, 977–987. <https://doi.org/10.1016/J.JCLEPRO.2019.04.086>

- BOOSE, J. H (1984). **Personal Construct Theory and Transfer of Human Expertise**. Proceedings of AAAI – 84, p. 27 -33. California, American Association for Artificial Intelligence, 1984
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. LTC – Livros Técnicos e Científicos Editora S.A. 2000.
- BURBA, Leandro de Toledo. **Estudo numérico do efeito da Tensão de Triaxialidade em aço aplicado à indústria naval**. Dissertação (Mestrado) – Universidade de Brasília, Faculdade de Tecnologia, Departamento de Engenharia Mecânica. 2018.
- CAO, Ke; YUE, Zhen-ming; ZHAO, Xiao-di; QI, Jiashuo; GAO, Jun. (2019). **Hybrid inverse parameter identification of fully coupled ductile damage model for steel sheet DP600 with two different algorithms: Trust Region and Genetic Algorithms**. Journal of Materials Engineering and Performance, (2019) 28:3149-3156.
- CHAPARRO, B.M., THUILLIER, S.; MENEZES, L.F.; MANACH, P.Y.; FERNANDES, J.V. (2008). **Material parameters identification: Gradient-based, genetic and hybrid optimization algorithms**. Computational Materials Science, Vol. 44, p. 339-346
- CHAPRA, Steven C.; CANALE, Raymond P. (2008). **Métodos Numéricos para Engenharia**. Tradução técnica Helena Castro. São Paulo: McGraw-Hill, 2008.
- CHASTAND, V.; TEZENAS, A.; CADORET, Y.; QUAEGBEUR, P.; MAIA, W.; CHARKALUK, E. (2016). **Fatigue characterization of Titanium Ti-6Al-4V samples produced by Additive Manufacturing**. Procedia Structural Integrity 2, 3168–3176.
- CHEN, Dong; LI, Yazhi; YANG, Xuan; JIANG WEI, Guan, Lingxiao (2021). **Efficient parameters identification of modified GTN model of ductile fracture using machine learning**. Engineering Fracture Mechanics 245 (2021) 107535.
- CHEN, Y.; PENG, X.; KONG, L.; DONG, G.; REMANI, A.; LEACH, R. (2021). **Defect inspection technologies for additive manufacturing**. International Journal of Extreme Manufacturing, 3(2). <https://doi.org/10.1088/2631-7990/ABE0D0>
- CHIAVERINIV. **Aços e Ferros Fundidos**. ABM, 6ª ed., São Paulo, 1988.
- CHIAVERINIV. **Tecnologia Mecânica: Materiais de Construção Mecânica**; Volume III. McGraw-Hill, 2ª ed., São Paulo, 1979.
- CHOI, Yun Young; KIM, Seongyoon; KIM, Soowhan; CHOI, Jung-il (2020). **Multiple parameter identification using genetic algorithm in vanadium redox flow batteries**. Journal of Power Sources 450 (2020) 227684
- DIETER, George E. (1984) **Metalurgia Mecânica**. Rio de Janeiro: Editora Guanabara Dois. 1984
- DO, Huy Q.; ARAGÓN, Alejandro M.; SCHOTT, Dingena L. (2017). **Automated discrete element method calibration using genetic and optimization algorithms**. Powders & Grains – EPJ Web of Conferences 140, 15011
- DONG, Xiaoma; CHEN Lifei (2022). **Identification of 3D Elastic-Plastic Model for Tunnel Engineering Based on Improved Genetic Algorithm**. Hindawi - Mathematical Problems in Engineering. Volume 2022, Article ID 8305175.

- FELCHAR, Cauê; DA SILVA, Iara da Cunha R. (2018). **Arrefecimento Simulado para encontrar raízes de funções otimizado por Algoritmo Genético**. Revista Eletrônica de Iniciação Científica em Computação, v.16. n. 2. 2018.
- FERNÁNDEZ, J. R.; LÓPEZ-CAMPOS, J. A.; SEGADE, A.; VILÁN, J. A. (2020). **CMMSE 2017 – a numerical method based on Genetic Algorithms for the characterization of viscoelastic materials**. International Journal of Computer Mathematics, 2020, vol. 97, nº. 1-2, 292-311.
- FERRARESI, Dino (1977). **Usinagem dos metais**. São Paulo: Editora Blücher. 1977
- FOGE, J. C. **Introduction to stochastic search and optimization**. Hoboken, New Jersey: John Wiley and Sons, 2003.
- FOGEL, L. J; OWENS, A. J.; WALSH, M. J. **Artificial intelligence through simulated evolution**. New York: John Wiley and Sons, 1966.
- FRANÇA, José Alexandre de; MORAIS FRANÇA, Maria Bernadete de; KOYAMA, Marcela Hitomi; SILVA, Tiago Polizer da (2009). **Uma implementação do algoritmo de Levenberg-Marquardt dividido para aplicações em visão computacional**. Semina: Ciências Exatas e Tecnológicas, Londrina, v. 30, n. 1, p. 51-62, jan./jun. 2009
- FRONIUS (2023). **CMT**. Endereço Eletrônico: [https://www3.fronius.com/cps/rde/xbcr/SID16FC0973-6DEFEAF4/fronius\\_brasil/CMT\\_cold\\_metal\\_transfer\\_pt.pdf](https://www3.fronius.com/cps/rde/xbcr/SID16FC0973-6DEFEAF4/fronius_brasil/CMT_cold_metal_transfer_pt.pdf). Último Acesso: 10/05/2023
- GARCIA, Amauri; SPIM, Jaime Alvares; SANTOS, Carlos Alexandre dos (1999). **Ensaio dos Materiais**. Rio de Janeiro: Editora LTC. 1999
- GOLDBERG, D. E. **Genetic algorithms in search, optimization and machine learning**. New York: Addison-Wesley Publishing, 1989.
- GOMES-RUGGIERO, Márcia Aparecida. **Modificações globalmente convergentes para o método das assíntotas móveis e solução dos subproblemas via regiões de confiança**. Tese (Doutorado) – Universidade Estadual de Campinas (UNICAMP), Instituto de Matemática, Estatística e Computação Científica. 2010.
- GORDON, J.V., HARLOW, D.G. (2019). **Statistical modeling of wire and arc additive manufactured stainless steel 304: microstructure and fatigue**. International Journal of Reliability, Quality and Safety Engineering 26, 1950016.
- GOUVÊA, Érica Josiane Coelho. **Métodos convergentes de otimização global baseados no vetor q-Gradiente**. Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2016.
- GROOVER, Mikell P. (2014) **Introdução aos processos de fabricação**. Tradução e revisão técnica André Ribeiro de Oliveira. Rio de Janeiro: LTC, 2014.
- GURSON, A.L. (1977). **Continuum Theory of Ductile Rupture by Void Nucleation and Growth: Part 1—Yield Criteria and Flow Rules for Porous Ductile Media**. Journal of Engineering Materials and Technology, 99, 2-15. <https://doi.org/10.1115/1.3443401>
- HADEN, C.V., ZENG, G., CARTER, F.M., RUHL, C., KRICK, B.A., HARLOW, D.G. (2017). **Wire and arc additive manufactured steel: tensile and wear properties**. Additive Manufacturing 16, 115–123.

- HAN, Xiao; CHAO, Yuexing; ZHANG, Wei; CHAO Yuezhen; WU, Chengwei (2019). **Study on the effect of post curing on the mode II fracture energy of structural adhesive using a parameter identification approach.** *International Journal of Adhesion na Adhesives* 95 (2019) 102398.
- HAUSER, T., REISCH, R.T., BREESE, P.P., NALAM, Y., JOSHI, K.S., BELA, K., KAMPS, T., VOLPP, J., KAPLAN, A.F.H. (2021). **Oxidation in wire arc additive manufacturing of aluminium alloys.** *Additive Manufacturing* 41, 101958.
- HERBERT, G.; BUCHANAN, C.; GARDNER, L.; KYVELOU, P. (2020). **Testing and initial verification of the world's first metal 3D printed bridge.** Article in *Journal of Constructional Steel Research*. <https://doi.org/10.1016/j.jcsr.2020.106233>
- HERGLI, Khaoula; MAROUANI, Haykel; ZIDI, Mondher (2018). **Numerical determination of Jiles-Atherton hysteresis parameters: Magnetic behavior under mechanical deformation.** *Physica B* 549 (2018) 74 – 81.
- HOLLAND, J. H. **Adaptation in natural and artificial systems.** Cambridge: MIT Press, 1992.
- HOSSEINI, V.A., HÖGSTRÖM, M., HURTIG, K., BERMEJO, M.A.V., STRIDH, L., KARLSSON, L. (2019). **Wire-arc additive manufacturing of a duplex stainless steel: thermal cycle analysis and microstructure characterization.** *Welding in the World* 63, 975–987.
- JAFARI, D.; VANEKER, T.H.J.; GIBSON, I. (2021). **Wire and arc additive manufacturing: Opportunities and challenges to control the quality and accuracy of manufactured parts.** *Mater Des* 202, 109471
- JIANG, W.; LI, Y.; SU, J (2016). **Modified GTN model for a broad range of stress states and application to ductile fracture.** *European Journal of Mechanics - A/Solids* 2016;57: 132–48.
- JIN, Yin-Fu; WU, Ze-Xiang; YIN, Zhen-Yu; SHEN, Jack Shuilong (2017). **Estimation of critical state-related formula in advanced constitutive modeling of granular material.** *Acta Geotechnica* (2017) 12:1329-1351.
- KIM, F. H.; MOYLAN, S. P. (2018). **Literature Review of Metal Additive Manufacturing Defects.** <https://doi.org/10.6028/NIST.AMS.100-16>
- KLEINERMANN, J. P.; PONTHOT, J. P. (2003) **Parameter identification and shape/process optimization in metal forming simulation.** *J. Mater. Process. Technol.*, vol. 139, no. 1-3 SPEC, pp. 521–526, 2003, doi: 10.1016/S0924-0136(03)00530-2.
- KUMAR, V.; MANDAL, A.; DAS, A.K.; KUMAR, S. (2021). **Parametric study and characterization of wire arc additive manufactured steel structures.** *International Journal of Advanced Manufacturing Technology* 115, 1723–1733.
- LACERDA, E. G. M.; CARVALHO, A. C. P. L. F. de. **Introdução aos algoritmos genéticos.** In: CONGRESSO NACIONAL DA SOCIEDADE BRASILEIRA DE COMPUTAÇÃO, 19, 1999, Rio de Janeiro. **Proceedings...** Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, 1999. v. 2, p. 51 – 126.
- LEE, Woei-Shyan; SU, Tzay-Tian. (1999). **Mechanical properties and microstructural features of AISI 4340 high-strength alloy steel under quenched and tempered conditions.** *Journal of Materials Processing Technology*, Taiwan, v. 87, p. 198-206, 1999.



- LEVENBERG, K. (1944). **A method for the solution of of certain non-linear problems is least squares**. Quarterly of Applied Math, Providence, v. 2, p. 164-168, 1944.
- LEWANDOWSKI, J. J.; SEIFI, M. (2016). **Metal Additive Manufacturing: A Review of Mechanical Properties**. Annual Review of Materials Research, 46, 151–186. <https://doi.org/10.1146/ANNUREV-MATSCI-070115-032024>
- LINDEN, Ricardo (2012). **Algoritmos Genéticos**. Rio de Janeiro: Editora Ciência Moderna. 2012.
- LMFIT (2023). **LMFIT: Non-Linear Least-Squares Minimization and Curve-Fitting for Python**. Endereço eletrônico: <https://lmfit.github.io/lmfit-py/intro.html>. Último acesso: 20/03/2023.
- LOTFOLAHPOUR, Amirreza; SOLTANI, Nasser; GANJIANI, Mehdi; BAHARLOUEI, Davoud (2018). **Parameters identification and validation of plastic-damage model of 304 stainless steel by small Punch test at ambient temperature**. Engineering Fracture Mechanics 200 (2018) 64-74.
- LUBLINER, J. **Plasticity Theory**. Dover Publications. 2008.
- MALCHER, L., SILVA, C. P.; SILVA, G. P.; SANTOS, M. C., ZIBEROV, M. (2023) **Gurson porous material in additive manufacturing: hybrid methodology for mechanical characterization**. Journal of Advanced Manufacturing Technology. 2023.
- MAROUANI, H.; HERGLI, K.; DHAHRI, H.; FOUAD, Y. (2019). **Implementation and Identification of Preisach Parameters: Comparison between Genetic Algorithm, Particle Swarm Optimization and Levenberg-Marquardt Algorithm**. Arabian Journal for Science and Engineering (2019) 44:6941-6949.
- MARQUARDT, D. W. (1963) **An algorithm for least-squares estimation of nonlinear parameters**. Journal of the Society for industrial and Applied Mathematics, Philadelphia, v. 11, n.2, p. 431-441, 1963.
- MARQUES, Mateus de P.; ANGÉLICO, Bruno A.; ABRÃO, Taufik (2014). **Otimização Heurística por Colônia de formigas com aplicações em Sistemas de Comunicações**. Semina: Ciências Exatas e Tecnológicas, Londrina, v. 35, n. 1, p. 63-76. 2014.
- MARTINS, Simone Lima; OCHI, Luiz Satoru; DA SILVA, Geiza Cristina. (2006). **Proposta e avaliação de heurísticas GRASP para o problema da diversidade máxima**. Pesquisa Operacional, v. 26, n. 2, p. 321-360. 2006.
- MCANDREW, A. R.; ROSALES, M. A.; COLEGROVE, P. A.; HÖNNIGE, J. R.; HO, A.; FAYOLLE, R.; EYITAYO, K.; STAN, I.; SUKRONGPANG, P.; CROCHEMORE, A. (2018). **Interpass rolling of ti-6al-4v wire+ arc additively manufactured features for microstructural refinement**. Additive Manufacturing, v. 21, p. 340–349, 2018.
- MEHRPOUYA, M.; DEHGHANGHADIKOLAEI, A.; FOTOVVATI, B.; VOSOOGHNIA, A.; EMAMIAN, S. S.; GISARIO, A. (2019). **The potential of additive manufacturing in the smart factory industrial 4.0: A review**. Applied Sciences (Switzerland), 9(18). <https://doi.org/10.3390/APP9183865>
- MENDES, Raphael de Lima. **Abordagens Evolutivas para Otimização de Redes Neurais Convolucionais baseadas em Algoritmos Genéticos**. Dissertação

(Mestrado) – Universidade Federal de Uberlândia. Pós-graduação em Ciência da Computação. 2021

- MENEZES, Gustavo C.; SILVA, Raphael A. (2020). **Metaheurística GRASP aplicada na resolução de problemas de sequenciamento baseados em Grafo de Conflito**. Revista Eletrônica de Iniciação Científica em Computação, v. 18. n. 4. 2020.
- MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. Springer-Verlag, New York, 1994.
- MUÑOZ-ROJAS, P.A., CARDOSO, E.L., VAZ JR., M. (2010). **Parameter identification of damage models using genetic algorithms**, Experimental Mechanics, v. 50, p. 627-634.
- NEMANI, A.V.; GHAFARI, M.; NASIRI, A. (2020). **On the post-printing heat treatment of a wire arc additively manufactured ER70S part**. Materials 13, 2795.
- NETO, Eduardo de Souza; PERIC, Djordje; OWEN, D.R.J. (2008). **Computational methods for plasticity: theory and applications**. John Wiley & Sons Ltd. ISBN 978-0-470-69452-7. 2008.
- NEWMAN, S. T.; ZHU, Z.; DHOKIA, V.; SHOKRANI, A. (2015). **Process planning for additive and subtractive manufacturing technologies**. CIRP Annals - Manufacturing Technology, 64, 467-470. <https://doi.org/10.1016/j.cirp.2015.04.109>
- NOVELINO, André Luiz Brito (2023). **Fadiga multiaxial em peças fabricadas via manufatura aditiva por deposição a arco via CMT**. Dissertação de Mestrado em Ciências Mecânicas, Faculdade de Tecnologia, Departamento de Engenharia Mecânica, Universidade de Brasília, Brasília, DF. 2023
- PELTERET, Jean-Paul; WALTER, Bastian; STEINMANN, Paul (2018). **Application of metaheuristic algorithms to the identification of nonlinear magneto-viscoelastic constitutive parameters**. Journal of Magnetism and Magnetic Materials 464 (2018) 116-131.
- PETUREAU, L.; DOUMALIN, P.; BREMAND, F. (2019). **Identification of local elastic parameters in heterogeneous materials using a parallelized femu method**. Int. J. of Applied Mechanics and Engineering, 2019, vol. 29, nº. 4, pp. 140-156.
- PONTHOT, J.-P., KLEINERMANN, J.-P. (2006). **A cascade optimization methodology for automatic parameter identification and shape/process optimization in metal forming simulation**. Computer Methods in Applied Mechanics and Engineering, v. 195, p. 5472-5508.
- QIN, Hong (2022). **Estimation and Identification of Nonlinear Parameter of Motion Index Based on Least Squares Algorithm**. Hindawi – Computational Intelligence and Neuroscience, vol. 2022, article ID 7383074, 10 p.
- RAGUVARUN, K.; BALASUBRAMANIAM, K.; RAJAGOPAL, P.; PALANISAMY, S.; NAGARAJAH, R.; HOYE, N.; CURIRI, D.; KAPOOR, A. (2015). **A study of internal structure in components made by additive manufacturing process using 3 D X-ray tomography**. AIP Conf Proc 1650, 146-155.
- RANGAIAH, G. P. **Stochastic global optimization – techniques and applications in chemical engineering**. Singapore: World Scientific Publishing, 2010

- RECHENBERG, I. (Ed.) **Evolutions strategie: optimierung technischer systeme nach prinzipien der biologischen Evolution**. [S.l.]: Frommann-Holzboog, 1973
- RESENDE M. G. C; RIBEIRO C.C. (2005). **GRASP with path-relinking: Recent advances and applications**. In T. Ibaraki, K. Nonobe, and M. Yagiura, editors, *Metaheuristics: Progress as Real Problem Solvers*, pages 29–63. Springer
- RODRIGUES, Jorge; MARTINS, Paulo. **Tecnologia Mecânica: Tecnologia da Deformação Plástica (Fundamentos teóricos)**. Escolar Editora. Lisboa. 2010.
- SANCHES, Fábio Dalmazzo; PEDERIVA, Robson (2008). **Identificação dos Parâmetros de Mancal usando a Equação Matricial de Ljapunov**. V Congresso Nacional de Engenharia Mecânica, Salvador, BA, 2008.
- SANDOVAL, Carolina Fernanda Burbano. (2014) **Modelos Elasto-Plásticos e sua influência no processo de dimensionamento de componentes mecânicos**. Dissertação de Mestrado em Ciências Mecânicas, Faculdade de Tecnologia, Departamento de Engenharia Mecânica, Universidade de Brasília, Brasília, DF. p. 122, 2014.
- SANTOS, R. B. M. dos. **Estudo da resistência mecânica em peças impressas através de manufatura aditiva por deposição a arco via processo gmaw-cmt**. [S.l.]: Projeto de Graduação, Departamento de Engenharia Mecânica, Universidade de Brasília, Brasília, DF. 2022.
- SCOTTI, A.; PONOMAREV, V. **SOLDAGEM MIG/MAG: Melhor entendimento - Melhor desempenho**. Artliber Editora. 2<sup>a</sup>.ed. 2014.
- SEDIGHIANI, K; DIEHL, M.; TRAKA, K.; ROTERS, F.; SIETSMA, J.; RAABE, D. (2020). **An efficient and robust approach to determine material parameters of Crystal plasticity constitutive laws from macro-scale stress-strain curves**. *International Journal of Plasticity* 134 (2020) 102779.
- SILVA, Gabriel de Paiva; BARRETO, Thalia de Souza Menna; de OLIVEIRA, Déborah; ZIVEROV, Maksym. **Uma contribuição sobre os métodos de manufatura aditiva de metais e o desafio da qualidade superficial em suas aplicações**. 12<sup>o</sup> Congresso Brasileiro de Engenharia de Fabricação. Brasília, DF. 2023.
- SIMO, J.C.; HUGHES, T.J.R. **Computational Inelasticity**. Springer. 1998.
- SIMÕES, Fernando M.F. **Introdução à Mecânica dos Meios Contínuos**. IST Press, Portugal, Lisboa. 2017.
- SKRLEC Andrej; KLEMENC Jernej (2020). **Estimating the strain-rate-dependent parameters of the Johnson-Cook Material Model using optimisation algorithms combined with a response surface**. *Mathematics* 2020, 8, 1105.
- SOBRINHO, Paulo de Sousa. **Algoritmos Genéticos Canônico e Elitista: uma abordagem comparativa**. Dissertação (Mestrado em Matemática Aplicada) – Programa de Pós-Graduação em Matemática Aplicada e Estatística (PPGMAE), Universidade Federal do Rio Grande do Norte, Natal, 2014.
- SOLA, A.; NOURI, A. (2019). **Microstructural porosity in additive manufacturing: The formation and detection of pores in metal parts fabricated by powder bed fusion**. *Journal of Advanced Manufacturing and Processing*, 1(3), e10021. <https://doi.org/10.1002/AMP2.10021>

- SOUZA, Fernanda Gonçalves. **Método meta-heurístico de colônia de formigas e sua aplicação na alocação de petróleo**. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Química. São Paulo, 2019.
- SPALL, J.C. (2003). **Introdução à Pesquisa e Otimização Estocástica: Estimativa, Simulação e Controle**. John Wiley & Sons, Inc, Nova York. <https://doi.org/10.1002/0471722138>.
- STAHLSCHMIDT, J. (2010). **Estudos de Identificação de Parâmetros Elasto-Plásticos utilizando Métodos de Otimização**. Dissertação de Mestrado em Ciências e Engenharia de Materiais, Centro de Ciências Tecnológicas, Universidade Federal de Santa Catarina, Joinville, SC. 99p. 2010.
- STAHLSCHMIDT, J; VAZ, M. J.; MUÑOZ-ROJAS, P. A.; CARDOSO, E.L. (2011). **Uma estratégia numérico-experimental para a determinação de parâmetros materiais**. In: 6º. CONGRESSO BRASILEIRO DE ENGENHARIA DE FABRICAÇÃO, 2011, Caxias do Sul, RS. Anais do VI COBEF, 2011
- SURYAKUMAR, S.; KARUNAKARAN, K. P.; BERNARD, A.; CHANDRASEKHAR, U.; RAGHAVENDER, N.; SHARMAN, D. (2011). **Weld bead modeling and process optimization in Hybrid Layered Manufacturing**. Computer-Aided Design, 43(4), 331–344. <https://doi.org/10.1016/J.CAD.2011.01.006>
- TRAJANO, André Nepomuceno. **Estudo do efeito da Tensão de Triaxialidade na Liga AISI 4340 recozida e normalizada**. Dissertação (Mestrado) – Universidade de Brasília, Faculdade de Tecnologia, Departamento de Engenharia Mecânica. 2018.
- WANG, L.; WU, C. S.; GAO, J. Q. (2016). **Suppression of humping bead in high speed GMAW with external magnetic field**. Science and Technology of Welding and Joining, 21(2), 131–139. <https://doi.org/10.1179/1362171815Y.0000000074>
- WANG, Xiaojuan; ZHANG, Guangcai; WANG, Xiaomei; NI PINGHE (2020). **Output-only structural parameter identification with evolutionary algorithms and correlation functions**. Smart Mater. Struct. 29 (2020) 035018.
- WANG, Yuntia; ZENG, Xiangguo; SHENG, Ying; YANG, Xin; WANG, Fang. (2020). **Multi-objective parameter identification and optimization for dislocation-dynamics-based constitutive modeling of Ti-6Al-4V alloy**. Journal of Alloys and Compounds 821 (2020) 153460.
- WINSTON, P. H (1992). **Fundamentos de Inteligência Artificial**. São Paulo. Makron Books. 1992.
- WU, B., PAN, Z., DING, D., CUIURI, D., LI, H., XU, J., NORRISH, J. (2018). **A review of the wire arc additive manufacturing of metals: properties, defects and quality improvement**. J Manuf Process 35, 127–139.
- YIN, Zhen-Yu; JIN, Yin-Fu; SHEN, Shui-Long; HUANG, Hong-Wei (2017). **An efficient optimization method for identifying parameters of soft structured clay by an enhanced genetic algorithm and elastic-viscoplastic model**. Acta Geotechnica (2017) 12:849-867.
- ZHAI, Yue; ZHAO, Ruifeng; LI, Yubai; LI, Yan; MENG, Fandong; WANG, Tienan (2021). **Stochastic inversion method for dynamic constitutive model of rock materials based on improved DREAM**. International Journal of Impact Engineering 147 (2021) 103739.

- ZHANG, X.; LU, Q.; ZHANG, P.; YU, Z.; SHEN, C.; WANG, L.; HUA, X. (2022). **Microstructure and Fatigue Properties of Ti-48Al Alloy Fabricated by the Twin-Wire Plasma Arc Additive Manufacturing**. J Mater Eng Perform 31, 8250–8260.
- ZHOU, Kun; SUN, Xingyue; SHI, Shouwen; SONG, Kai; CHEN Xu. (2021). **Machine learning-based genetic feature identification and fatigue life prediction**. Fatigue Pract Eng Mater Struct. 2021; 44:2524-2537.