

**MONIQUE ALVES FRANCO DE MORAES
FREITAS**

**AVALIAÇÃO DE PROPRIEDADES MECÂNICAS
DE AÇOS VIA MACROINDENTAÇÃO
INSTRUMENTADA E INTELIGÊNCIA ARTIFICIAL**



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA**

2018

MONIQUE ALVES FRANCO DE MORAES FREITAS

**AVALIAÇÃO DE PROPRIEDADES MECÂNICAS DE AÇOS VIA
MACROINDENTAÇÃO INSTRUMENTADA E INTELIGÊNCIA
ARTIFICIAL**

Tese apresentada ao Programa de Pós-graduação em Engenharia Mecânica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de **DOCTORA EM ENGENHARIA MECÂNICA**.

Área de Concentração: Materiais e Processos de Fabricação

Orientador: Prof. Dr.-Ing. Sinésio Domingues Franco.

Co-orientador: Prof. Dr. Alcimar Barbosa Soares

**UBERLÂNDIA - MG
2018**

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

F866a
2018 Freitas, Monique Alves Franco de Moraes, 1989-
Avaliação de propriedades mecânicas de aços via macroindentação
instrumentada e inteligência artificial / Monique Alves Franco de Moraes
Freitas. - 2018.
210 f. : il.

Orientador: Sinésio Domingues Franco.
Coorientador: Alcimar Barbosa Soares.
Tese (Doutorado) - Universidade Federal de Uberlândia, Programa
de Pós-Graduação em Engenharia Mecânica.
Disponível em: <http://dx.doi.org/10.14393/ufu.te.2018.752>
Inclui bibliografia.

1. Engenharia mecânica - Teses. 2. Materiais - Propriedades
mecânicas - Teses. 3. Aprendizado do computador - Teses. I. Franco,
Sinésio Domingues, 1962-. II. Soares, Alcimar Barbosa, 1965- III.
Universidade Federal de Uberlândia. Programa de Pós-Graduação em
Engenharia Mecânica. IV. Título.

CDU: 621



ALUNA: Monique Alves Franco de Moraes Freitas

NÚMERO DE MATRÍCULA: 11323EMC008

ÁREA DE CONCENTRAÇÃO: Materiais e Processos de Fabricação

LINHA DE PESQUISA: Tribologia e Materiais

PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA: NÍVEL DOUTORADO

TÍTULO DA TESE:

“Avaliação de Propriedades Mecânicas de Aços via Macroindentação Instrumentada e Inteligência Artificial”

ORIENTADOR: Prof. Dr. Sinésio Domingues Franco

CO-ORIENTADOR: Prof. Dr. Alcimar Barbosa Soares

A Tese foi **APROVADA** em reunião pública, realizada na Sala de Reuniões do Laboratório de Tecnologia em Atrito e Desgaste - Bloco 5F, Campus Santa Mônica, em 27 de fevereiro de 2018, às 13:30 horas, com a seguinte Banca Examinadora:

NOME	ASSINATURA
Prof. Dr. Sinésio Domingues Franco	UFU
Prof. Dr. Louriel Oliveira Vilarinho	UFU
Profa. Dra. Rosenda Valdés Arencibia	UFU
Prof. Dr. Armando Albertazzi Gonçalves Júnior	UFSC
Prof. Dr. Enes Gonçalves Marra	UFG

Uberlândia, 27 de fevereiro de 2018

Dedico este trabalho aos meus pais, Eron e Magda, pelo incentivo e amor incondicional, fazendo-me sentir mais segura para persistir nos meus objetivos, aos meus irmãos, Cristiano e Renan, pela parceria e pelo companheirismo e ao meu marido, Dênis, pela companhia constante.

AGRADECIMENTOS

A Deus por abençoar a minha trajetória, dando-me saúde e sabedoria para seguir em frente;

Ao professor Sinésio Domingues Franco pela oportunidade de realização de mais uma pesquisa no Laboratório de Tecnologia em Atrito e Desgaste (LTAD), no qual fiz também o mestrado. Agradeço-lhe, também, pela compreensão durante todo esse tempo de aprendizado, principalmente, durante a fase em que, paralelamente ao doutorado, eu estive atuando como professora substituta da Faculdade de Engenharia Mecânica (FEMEC) da Universidade Federal de Uberlândia (UFU). Ainda, agradeço-lhe pela confiança e pelo direcionamento fornecido durante este trabalho;

Ao professor Alcimar Barbosa Soares pela co-orientação;

Ao Eng. Dênis Soares de Freitas (LTAD) pelo esclarecimento de dúvidas sobre redes neurais artificiais e algoritmos genéticos;

Ao Eng. Eduardo Ribeiro Nicolosi (PETROBRAS) pelo apoio e compartilhamento dos arquivos dos ensaios de macroindentação instrumentada, realizados no *PropInSitu 2* e utilizados em seu trabalho de mestrado;

Ao Eng. Francisco F. Ramos Neto (PETROBRAS) pelo apoio e acompanhamento deste trabalho;

À Petrobras pelo acompanhamento e apoio financeiro durante o desenvolvimento deste trabalho;

A toda equipe do LTAD pela amizade e parceria;

À UFU e à FEMEC pela oportunidade de concluir o doutorado em um dos melhores programas de pós-graduação do país.

FREITAS, M. A. F. M. **Avaliação de propriedades mecânicas de aços via macroindentação instrumentada e inteligência artificial**. 2018. 210 f. Tese de Doutorado, Universidade Federal de Uberlândia, Uberlândia - MG.

Resumo

Neste trabalho foi desenvolvida uma metodologia para estimar as propriedades mecânicas (dureza Brinell, limite de resistência e limite de escoamento) via ensaios de macroindentação instrumentada. Essa metodologia foi baseada no treinamento de redes neurais artificiais (RNAs) a partir de curvas experimentais de indentações esféricas. Diferentes arquiteturas de RNAs foram implementadas e treinadas através de três algoritmos, a saber: a) algoritmo genético (AG); b) algoritmo híbrido entre AG e método de Levenberg-Marquardt (LM) com regularização bayesiana (RB), denominado AG-LMRB; e c) o método de AG-LMRB, com o acréscimo de uma etapa de verificação de similaridade entre os indivíduos do AG. Os padrões de entrada das RNAs foram obtidos dos ensaios de materiais realizados por Nicolosi (2015) através de um macroindentador portátil, denominado de *PropInSitu 2*. Dentre os resultados obtidos, constatou-se que o algoritmo híbrido AG-LMRB forneceu os melhores resultados, isto é, os menores erros na estimativa das propriedades mecânicas. Tais resultados ocorreram quando esse algoritmo foi aplicado em RNAs compostas por uma camada de entrada de nove variáveis, uma camada oculta com dois neurônios e uma camada de saída com um neurônio. Adicionalmente, foram utilizados determinados valores de parâmetros de desempenho do AG, tais como a quantidade de indivíduos da população inicial, o critério de parada, a taxa de *crossover*, a taxa de mutação, dentre outros; e determinadas funções de ativação dos neurônios. As funções de ativação empregadas nos neurônios ocultos e no neurônio de saída foram, respectivamente, sigmoide e linear. A metodologia desenvolvida foi eficiente na determinação das propriedades mecânicas, já que os melhores resultados obtidos forneceram erros pequenos em relação aos métodos tradicionais. Considerando o nível de confiança de 95 %, os erros para a estimativa da dureza Brinell resultaram na faixa de ± 3 %, para a estimativa do limite de resistência, na faixa de ± 6 % e para a estimativa do limite de escoamento, na faixa de ± 8 %.

Palavras-chave: Avaliação de propriedades mecânicas; métodos de aprendizado de máquina; RNA; treinamento supervisionado; macroindentação instrumentada.

FREITAS, M. A. F. M. **Evaluation of mechanical properties of steels using instrumented macroindentation and artificial intelligence**. 2018. 210 f. Thesis of Doctorate, Universidade Federal de Uberlândia, Uberlândia - MG.

Abstract

In this work, a methodology was developed to estimate the mechanical properties (Brinell hardness, ultimate tensile strength and yield strength) using instrumented macroindentation tests. This methodology was based on the training of artificial neural networks (ANNs) from experimental curves of spherical indentations. Different ANNs architectures were implemented and trained with three algorithms, namely: a) genetic algorithm (GA); b) hybrid algorithm between GA and Levenberg-Marquardt (LM) method with Bayesian regularization (BR), named GA-LMBR; and c) the GA-LMBR method, with the addition of a similarity verification step among GA individuals. The input patterns of the ANNs were obtained from the materials tests performed by Nicolosi (2015) through a portable macroindentator called PropInSitu 2. Among the results obtained, it was verified that the hybrid algorithm GA-LMBR provided the best results, i.e., it resulted in the smallest errors in the estimation of the mechanical properties. These results were achieved when the GA-LMBR method was applied to an ANN composed of a nine-variable input layer, a hidden layer with two neurons and an output layer with one neuron. In addition, certain values of GA performance parameters, such as the number of individuals of the initial population, stopping criterion, crossover rate, mutation rate, among others; and certain neuron activation functions were used. The activation functions employed in the hidden neurons and the output neuron were, respectively, sigmoid and linear. The methodology developed was efficient in determining the mechanical properties, since the best results provided small errors compared to the traditional methods. Considering 95 % confidence level, the errors for the Brinell hardness estimation were in the range of ± 3 %, for the ultimate tensile strength estimation, in the range of ± 6 % and for the yield strength estimation, in the range of ± 8 %.

Keywords: *Evaluation of mechanical properties; machine learning methods; ANN; supervised training; instrumented macroindentation.*

LISTA DE FIGURAS

Figura 1.1 - Ensaio de macroindentação instrumentada de um aço carbono com 10 ciclos de carregamento/descarregamento, força máxima de 1200 N e penetrador com diâmetro de 1,5 mm	1
Figura 2.1 - Curva característica do ensaio de macroindentação instrumentada, adaptada de (HAGGAG, 1993)	6
Figura 2.2 - Perfil típico da região indentada após o ciclo de carregamento/descarregamento, adaptada de (HAGGAG, 1993)	7
Figura 2.3 - ProplnSitu 2: a) equipamento montado em uma base fixa para ensaios em laboratório; b) detalhe mostrando a localização da célula de carga, LVDT e penetrador (FRANCO <i>et al.</i> , 2007)	8
Figura 2.4 - Representação de um neurônio artificial, adaptado de (HAYKIN, 2001)	21
Figura 2.5 - Arquitetura de uma rede MLP com duas camadas ocultas, adaptado de (HAYKIN, 2009)	24
Figura 2.6 - Sequência de ações durante o treinamento de uma RNA (SANTANA, 2012; LOUZADA, 2013)	25
Figura 2.7 - Somatório dos erros quadráticos em função das iterações durante o treinamento. O ponto "a" indicia o ponto de parada antecipada do treinamento e o ponto "b" corresponde ao fim do treinamento caso ele continuasse, adaptado de (HAGAN <i>et al.</i> , 2014)	30
Figura 2.8 - Operações básicas de um AG (FREITAS, 2014)	32
Figura 3.1 - Etapas executadas para o desenvolvimento do programa de cálculo das propriedades mecânicas	42
Figura 3.2 - Amostra do material "B" ensaiada com força máxima de 85 N e penetrador com diâmetro de 0,4 mm (NICOLOSI, 2015)	46
Figura 3.3 - Material "C" ensaiado com força máxima de 662 N e penetrador com diâmetro de 1,5 mm (NICOLOSI, 2015)	47
Figura 3.4 - Perfis de dureza Vickers (HV10) ao longo da espessura das amostras a) do aço "B" e b) do aço "C". Os intervalos de 95 % de confiança para o valor da média estão indicados pelas barras verticais. Também estão indicadas a espessura média, medida com um paquímetro digital e a dureza média (HV10med) para cada amostra, com os respectivos intervalos de confiança (95 %) (NICOLOSI, 2015)	48

Figura 3.5 - Organização dos materiais de “A” a “G”. Exemplo de organização do material “A”	52
Figura 3.6 - Organização dos materiais API 5L X65, L80, P110 e ABNT 8550. Exemplo de organização do material L80	53
Figura 3.7 - Características das curvas dos ensaios de macroindentação instrumentada – Exemplo com o primeiro ensaio do aço “D” com a seguinte configuração de ensaio: força máxima de 1200 N e penetrador com diâmetro de 1,5 mm	55
Figura 3.8 - Identificação dos aços do subconjunto de treinamento em regiões definidas através da análise do limite de resistência medido desses aços em função da Entrada 1	56
Figura 3.9 - Identificação dos aços do subconjunto de treinamento em regiões definidas através da análise do limite de escoamento medido desses aços em função da Entrada 1	57
Figura 3.10 - Identificação dos aços do subconjunto de treinamento em regiões definidas através da análise da dureza Brinell medida desses aços em função da Entrada 1	58
Figura 3.11 - Identificação dos aços do subconjunto de treinamento em regiões através da análise do limite de resistência medido desses aços em função da Entrada 2	59
Figura 3.12 - Identificação dos aços do subconjunto de treinamento em regiões através da análise do limite de escoamento medido desses aços em função da Entrada 3	60
Figura 3.13 - Identificação dos aços do subconjunto de treinamento em regiões através da análise do limite de resistência medido desses aços em função da Entrada 4	61
Figura 3.14 - Identificação dos aços do subconjunto de treinamento em regiões através da análise do limite de escoamento medido desses aços em função da Entrada 8	63
Figura 3.15 - Arquitetura de RNAE com três neurônios, uma camada de entrada com nove variáveis, uma camada intermediária e uma saída para estimar determinada propriedade mecânica. Total de 21 pesos	68
Figura 3.16 - Arquitetura de RNAE com três neurônios, uma camada de entrada com quatro variáveis, uma camada intermediária e uma saída para estimar determinada propriedade mecânica. Total de 11 pesos	68
Figura 3.17 - Arquitetura de RNAE com quatro neurônios, uma camada de entrada com nove variáveis, uma camada intermediária e uma saída para estimar determinada propriedade mecânica. Total de 31 pesos	68
Figura 3.18 - Função de ativação sigmoide empregada nos neurônios ocultos	69
Figura 3.19 - Representação binária de 32 bits de cada peso do indivíduo do AG de acordo com a IEEE <i>Standard</i> 754	71
Figura 3.20 - Representação de cada indivíduo da população do AG quando se	71

considera o treinamento de uma RNAE com arquitetura igual à mostrada na Fig. 3.15	
Figura 3.21 - Exemplo de <i>crossover</i> uniforme nos pais quando se considera o treinamento de uma RNA com arquitetura igual à mostrada na Fig. 3.16	75
Figura 3.22 - Resultado do <i>crossover</i> uniforme nos pais da Fig. 3.21	76
Figura 3.23 - Algoritmo de treinamento da RNAE: AG-LMRB	78
Figura 3.24 - Algoritmo de treinamento da RNAE: AG-LMRB*, com verificação de similaridade entre os indivíduos da população de interesse	80
Figura 3.25 - Algoritmo de treinamento da RNAE: AG	81
Figura 3.26 - Algoritmo de obtenção das propriedades mecânicas para a RNAE treinada. Exemplo para a obtenção de uma dada propriedade mecânica do aço A, considerando a arquitetura de RNAE da Fig. 3.15	87
Figura 4.1 - Melhor resultado do treinamento da RNAE para estimar a dureza Brinell – Treinamento a partir da execução da configuração 8 (Tab. 4.1) e do método AG-LMRB para treinar uma RNAE de 9 entradas e 3 neurônios	92
Figura 4.2 - Teste da melhor RNAE para estimar a dureza Brinell, utilizando todos os materiais para verificação dos erros obtidos em cada configuração de ensaio	95
Figura 4.3 - Resultado do teste da melhor RNAE para estimar a dureza Brinell, utilizando apenas os materiais “A” a “G”, que tiveram ensaios realizados com todos os penetradores	96
Figura 4.4 - Melhor resultado do treinamento da RNAE para estimar o limite de resistência - Treinamento a partir da execução da configuração 7 (Tab. 4.4)	100
Figura 4.5 - Teste da melhor RNAE para estimar o limite de resistência, utilizando todos os materiais para verificação dos erros obtidos em cada configuração de ensaio	102
Figura 4.6 - Resultado do teste da melhor RNAE para estimar o limite de resistência, utilizando apenas os materiais “A” a “G”, que tiveram ensaios realizados com todos os penetradores	103
Figura 4.7 - Melhor resultado do treinamento da RNAE para estimar o limite de escoamento – Treinamento realizado a partir da execução da configuração 5 (Tab. 4.7)	106
Figura 4.8 - Teste da melhor RNAE para o limite de escoamento, utilizando todos os materiais para verificação dos erros obtidos em cada configuração de ensaio	109
Figura 4.9 - Resultado do teste da melhor RNAE para o limite de escoamento, utilizando apenas os materiais “A” a “G”, que tiveram ensaios realizados com todos os penetradores	109

LISTA DE TABELAS

Tabela 2.1 - Valores da literatura estimados para α_m conforme o tipo de material a ser indentado	12
Tabela 2.1 - Valores da literatura estimados para β_m conforme o tipo de material a ser indentado	13
Tabela 2.2 - Comparação entre diferentes algoritmos de otimização (YU; Wilamowski, 2011)	38
Tabela 3.1 - Composições químicas dos aços “A” a “G” (% em peso) (NICOLSI, 2015)	43
Tabela 3.2 - Composição química dos aços API 5L X65, L80, P110 (NICOLSI, 2015) e ABNT 8550 (DA SILVA, 2008) (% em peso)	44
Tabela 3.3 - Parâmetros específicos dos ensaios de macroindentação instrumentada realizados nos onze aços através do <i>PropInSitu 2</i> (NICOLSI, 2015)	45
Tabela 3.4 - Valores médios das propriedades mecânicas de tração e de dureza dos aços de “A” a “G”. Limites de escoamento e de resistência informados pelo fabricante dos tubos. Dureza Brinell obtida a partir da conversão da dureza Vickers (HV10), a qual foi medida para determinar os perfis de dureza ao longo da espessura das amostras (NICOLSI, 2015)	45
Tabela 3.5 - Propriedades mecânicas dos corpos de prova do aço API 5L X65 obtidas via ensaio de tração e dureza (NICOLSI, 2015)	50
Tabela 3.6 - Propriedades mecânicas dos corpos de prova do aço L80 obtidas via ensaio de tração e dureza (NICOLSI, 2015)	50
Tabela 3.7 - Propriedades mecânicas dos corpos de prova do aço P110 obtidas via ensaio de tração e dureza (NICOLSI, 2015)	51
Tabela 3.8 - Propriedades mecânicas dos quatro trechos das barras do aço ABNT 8550, submetido ao tratamento térmico de têmpera e revenimento, obtidas via ensaio de tração e de dureza (NICOLSI, 2015)	51
Tabela 3.9 - Faixa de propriedades mecânicas abrangidas pelos subconjuntos de treinamento e validação	52
Tabela 3.10 - Nove entradas das RNAEs	54
Tabela 3.11 - Coeficientes de ponderação de cada variável de entrada e associados às respectivas PCs	65

Tabela 3.12 - Variância das PCs	65
Tabela 3.13 - Variância explicada das PCs	66
Tabela 3.14 - Coeficientes de ponderação de cada variável de entrada e associados às últimas PCs	66
Tabela 3.15 - Coeficientes de ponderação de cada variável de entrada e associados às três primeiras PCs	67
Tabela 3.16 - Limites máximos das propriedades mecânicas implementados para alterar a restrição de 0 a 1 das saídas dos neurônios da última camada	70
Tabela 3.17 - Posição dos pesos binários e decimais (após a conversão) no vetor representativo dos indivíduos, considerando a arquitetura de RNA da Fig. 3.15	72
Tabela 3.18 - Conjunto de diferentes configurações de treinamento das RNAEs executadas para estimar a dureza Brinell	82
Tabela 3.19 - Conjunto de diferentes configurações de treinamento das RNAEs executadas para estimar o limite de resistência	84
Tabela 3.20 - Conjunto de diferentes configurações de treinamento das RNAEs executadas para estimar o limite de escoamento	85
Tabela 4.1 - Resultados dos treinamentos de RNAEs para estimar a dureza Brinell	89
Tabela 4.2 - Resultado do treinamento da RNAE a partir da configuração 8 (Tab. 4.1) e do método de treinamento AG-LMRB*	93
Tabela 4.3 - Melhor arquitetura da RNA e valores ótimos dos pesos para estimar a dureza Brinell de novos materiais	94
Tabela 4.4 - Resultados dos treinamentos de RNAEs para estimar o limite de resistência	98
Tabela 4.5 - Resultado do treinamento da RNAE a partir da configuração 7 (Tab. 4.4) e do método de treinamento AG-LMRB*	100
Tabela 4.6 - Melhor arquitetura da RNA e valores ótimos dos pesos para essa arquitetura para estimar o limite de resistência de novos materiais	101
Tabela 4.7 - Resultados dos treinamentos de RNAEs para estimar o limite de escoamento	105
Tabela 4.8 - Resultado do treinamento da RNAE a partir da configuração 5 (Tab. 4.7) e do método de treinamento AG-LMRB*	107
Tabela 4.9 - Melhor arquitetura da RNA e valores ótimos dos pesos para essa arquitetura para estimar o limite de escoamento de novos materiais	108

Tabela 4.10 - Resultados obtidos com este trabalho e com o trabalho de Nicolosi (2015), para a estimativa das propriedades mecânicas. Erros percentuais relativos entre os valores obtidos pelas metodologias analisadas e os valores obtidos pelos ensaios convencionais de tração e dureza 111

LISTA DE SÍMBOLOS E SIGLAS

Símbolos latinos:

A	Parâmetro de inclinação da função sigmoide
A	Parâmetro de teste do material
a_{jk}	Autovetor ou coeficiente de ponderação da variável x_k , considerando a j-ésima PC
b_j	Bit com índice j, sendo j = 0 a 31
b_m	<i>Offset</i> de escoamento
b_k	<i>Bias</i> associado ao neurônio k
C	Complacência total medida
C_a	Complacência da amostra
C_e	Complacência do equipamento
CC	Curvatura da indentação
D	Vetor de saída desejado
D	Diâmetro da esfera do penetrador
d	Vetor de saída desejado
d_f	Diâmetro final da impressão
d_p	Diâmetro plástico de indentação
d_t	Diâmetro total de indentação
E	Número de Euler
eD	Expoente em binário convertido para decimal
E	Somatório dos erros quadráticos
e	Vetor de erro
$e_{p,m}$	Erro de treinamento na saída m da RNA, quando aplicado o padrão p
E_a	Módulo de elasticidade do material da amostra
E_d	Somatório dos quadrados dos erros
E_i	Módulo de elasticidade do material do penetrador
E_R	Módulo de elasticidade reduzido do material
E_w	Somatório dos quadrados dos pesos
$Erro_{máx}$	Erro máximo

$Erro_{config}$	Erro de determinada configuração de ensaio
$ Erro_{médio} $	Módulo da média dos erros das configurações de ensaio para todos os materiais de determinado subconjunto
$f(u)$	Função de ativação
F	Força de indentação
$F_{máx}$	Força máxima de indentação
F_{obj}	Função objetivo
g_i	Elementos do vetor gradiente de erro
h	Profundidade de indentação
H	Matriz Hessiana
h_e	Profundidade elástica de indentação
$h_{máx}$	Profundidade máxima de indentação
h_p	Profundidade plástica de indentação
h_t	Profundidade total de indentação
$h_{tmáx}$	Profundidade total máxima de indentação
I	Matriz identidade
l_n	n-ésimo valor, antes da normalização, de uma dada variável de entrada, mediante apresentação do n-ésimo padrão de entrada
$l_{máx}$	Valor máximo, antes da normalização, de uma dada variável de entrada, mediante apresentação de todos os padrões de entrada
$l_{mín}$	Valor mínimo, antes da normalização, de uma dada variável de entrada, mediante apresentação de todos os padrões de entrada
J	Matriz Jacobiana
K	Coeficiente de resistência
M	Número total de saídas da RNA
m	Coeficiente de Meyer
n	Expoente de encruamento
n_{ciclos}	Número de ciclos
o	Vetor de saída atual
P	Número de padrões de entrada da RNA
$Propriedade_{MédiaConfig}$	Média das propriedades mecânicas obtidas via apresentação das características individuais de cada ensaio à RNAE
$Propriedade_{Medida}$	Propriedade mecânica medida (média) do material ensaiado
s	Desvio padrão da média
S	Rigidez do contato
u	Combinação linear das entradas do neurônio

xc_i	Valores dos dados após a centralização
x_i	i-ésimas variáveis originais
x_n	Entrada do neurônio
x_k	Variável original pertencente ao conjunto de dados reduzidos via PCA
X_n	n-ésimo valor normalizado de uma dada variável de entrada, mediante apresentação do n-ésimo padrão de entrada
W	Número de parâmetros da RNA
W_P	Energia de deformação plástica
W_T	Energia de deformação total
w	Peso sináptico
y_k	Saída do neurônio k

Símbolos gregos:

\bar{x}	Média amostral da variável x_i
μ	Coefficiente de combinação
ν_a	Coefficiente de Poisson do material da amostra
ν_i	Coefficiente de Poisson do material do penetrador
τ	Tensão de indentação
δ	Parâmetro que depende do estágio de desenvolvimento da zona plástica sob o penetrador e de τ
δ_{max}	Valor máximo de δ
σ_e	Límite de escoamento do material
σ_r	Límite de ruptura do material
σ_v	Tensão verdadeira
ε_v	Deformação plástica verdadeira
ϕ	Parâmetro utilizado no modelo de Haggag correlacionando ε_v , E_a e σ_v
ρ	Constante de aprendizado do método BP
α	Hiperparâmetro do método de LMRB
α_m	Fator de restrição que depende da sensibilidade à taxa de deformação do material; usado para calcular o parâmetro δ (Modelo de Haggag)

β	Hiperparâmetro do método de LMRB
β_m	Coeficiente de deformação do material; usado para calcular o limite de escoamento através do modelo de Haggag
γ	Parâmetro do método de LMRB

Siglas e abreviaturas:

AG	Algoritmo genético
BP	<i>Backpropagation</i>
GC	Gradiente conjugado
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
IEI	Indentação esférico instrumentada
ISO	<i>International Organization for Standardization</i>
LM	Levenberg-Marquardt
LMRB	Levenberg-Marquardt com regularização bayesiana
LTAD	Laboratório de Tecnologia em Atrito e Desgaste
LVDT	<i>Linear Variable Differential Transformer</i>
MLP	<i>Multilayer Perceptron</i>
PC	<i>Principal Component</i>
PCA	<i>Principal Component Analysis</i>
RNA	Rede neural artificial
RNAE	Rede neural artificial evolutiva
RS	Recozimento simulado
SSM	<i>Stress-Strain Microprobe</i>

SUMÁRIO

CAPÍTULO I – INTRODUÇÃO	1
1.1. Objetivos	4
1.2. Estrutura do trabalho	4
CAPÍTULO II – REVISÃO BIBLIOGRÁFICA	5
2.1. Aspectos gerais sobre ensaios de macroindentação instrumentada	5
2.2. Modelos de Haggag e de Ahn e Kwon para determinação das propriedades mecânicas via ensaios de macroindentação instrumentada	8
2.2.1. Modelo de Haggag	9
2.2.2. Análise crítica dos modelos de Haggag e de Ahn e Kwon	14
2.3. Revisão da literatura sobre as metodologias para a determinação das propriedades mecânicas baseadas em métodos de aprendizado de máquina	15
2.3.1. Métodos de treinamento de RNAs	17
2.4. Redes Neurais Artificiais (RNAs)	20
2.4.1. Neurônio Artificial	21
2.4.2. Funções de ativação	22
2.4.3. Arquitetura da RNA	23
2.4.4. Aprendizado ou Treinamento da RNA	24
2.4.5. Pré-processamento dos dados de treinamento de uma RNA	25
2.4.6. Definição da quantidade de neurônios	28
2.4.7. Inicialização dos pesos e bias	29
2.4.8. Critério de parada do treinamento de uma RNA	29
2.4.9. Generalização da RNA	29
2.5. Algoritmos Genéticos (AGs)	31
2.6. Método de Levenberg-Marquardt (LM) com Regularização Bayesiana (RB) – LMRB	34
CAPÍTULO III – METODOLOGIA	41
3.1. Definição do banco de dados para treinamento, validação e teste das RNAEs	43
3.2. Organização dos arquivos do banco de dados em pastas específicas	52
3.3. Definição das entradas e saída das RNAEs	53

3.3.1. Escolha das variáveis de entrada das RNAEs	53
3.3.2. Escolha da saída das RNAEs	64
3.3.3. Normalização das variáveis de entrada das RNAEs	64
3.3.4. Redução da quantidade de variáveis de entrada através da PCA	64
3.4. Definição das arquiteturas a serem avaliadas para as RNAEs	67
3.5. Definição da função de ativação dos neurônios das RNAEs	69
3.6. Definição dos parâmetros de desempenho do AG	70
3.6.1. Representação do indivíduo	71
3.6.2. Definição da quantidade de indivíduos da população inicial	73
3.6.3. Definição da função de avaliação/objetivo	73
3.6.4. Definição do critério de parada	74
3.6.5. Definição dos valores iniciais para os pesos pertencentes aos indivíduos da população	74
3.6.6. Definição da quantidade de filhos a serem formados pelo crossover	74
3.6.7. Definição do método de seleção dos pais para o crossover	74
3.6.8. Definição do método de crossover para a geração dos filhos	75
3.6.9. Definição da quantidade de filhos que passaram pelo processo de mutação	76
3.6.10. Definição da quantidade de pesos que tiveram os bits alterados em cada filho selecionado para a mutação	76
3.6.11. Definição da quantidade de bits a serem alterados em cada peso pertencente ao filho selecionado para a mutação	76
3.6.12. Definição do método de mutação	76
3.6.13. Definição do método de reinserção dos indivíduos, que consistiu na seleção dos melhores indivíduos para a próxima geração	77
3.7. Fluxograma de treinamento das RNAEs	77

3.8. Definição de diferentes configurações de treinamento das RNAEs	81
3.9. Seleção da melhor configuração de treinamento das RNAEs para cada propriedade mecânica	86
3.10. Algoritmo de obtenção das propriedades mecânicas a partir das RNAEs treinadas	86
CAPÍTULO IV – RESULTADOS E DISCUSSÕES	88
4.1. Resultados dos treinamentos das RNAEs para estimar a dureza Brinell	88
4.2. Resultados dos treinamentos das RNAEs para estimar o limite de resistência	97
4.3. Resultados dos treinamentos das RNAEs para estimar o limite de escoamento	103
4.4. Comparação entre os resultados obtidos com este trabalho, a partir da utilização dos pesos ajustados das melhores RNAEs, e os obtidos com outros trabalhos da literatura	110
CAPÍTULO V – CONCLUSÕES	115
CAPÍTULO VI – TRABALHOS FUTUROS	117
REFERÊNCIAS BIBLIOGRÁFICAS	119
ANEXOS E APÊNDICES	131
Anexo I – Gráficos dos ensaios de macroindentação instrumentada	131
Anexo II – Dimensões das amostras dos aços empregados nos ensaios	168
Apêndice I – Valores das variáveis de entrada das RNAEs, antes e depois de normalizadas	171
Apêndice II – Gráficos dos erros de treinamento e validação em função da geração do AG para estimar a dureza Brinell	188
Apêndice III – Gráficos dos erros de treinamento e validação em função da geração do AG para estimar o limite de resistência	198
Apêndice IV – Gráficos dos erros de treinamento e validação em função da geração do AG para estimar o limite de escoamento	205

CAPÍTULO I

INTRODUÇÃO

A determinação das propriedades mecânicas é importante para a escolha do material a ser empregado em determinada estrutura e, também, para a verificação da vida útil remanescente de estruturas, durante a execução de manutenções.

Tradicionalmente, para se avaliar a integridade de estruturas faz-se necessária a estimativa de suas propriedades mecânicas. Para tal, são empregados ensaios destrutivos, tais como: ensaios de tração, tenacidade à fratura, impacto e fadiga. Esses ensaios são realizados em corpos de prova de grandes dimensões, usinados a partir de amostras retiradas da estrutura a ser analisada, o que leva, necessariamente, a parada do equipamento.

Como alternativa, as propriedades mecânicas também podem ser estimadas através de ensaios de macroindentação instrumentada. Para a execução desses ensaios não é necessário retirar qualquer tipo de amostra da estrutura a ser analisada. Conseqüentemente, não há comprometimento da integridade dessa estrutura e nem interrupção da operação. Segundo Nicolosi (2015), isso é muito relevante na indústria de óleo e gás, já que a parada de equipamentos/sistemas envolve enormes custos operacionais e lucro cessante.

Na literatura, existem alguns modelos para a determinação das propriedades mecânicas a partir dessa técnica da macroindentação instrumentada.

Os métodos analíticos mais utilizados para a avaliação dessas propriedades via macroindentação instrumentada foram propostos por Haggag (HAGGAG; NANSTAD; BRASKI, 1989) e por Ahn e Kwon (AHN; KWON, 2001). Ambos os modelos empregam um penetrador esférico que é forçado contra uma amostra enquanto a força e a profundidade de indentaç o s o monitoradas. Um ensaio de indentaç o t pico para estimar as propriedades mec nicas utilizando esses m todos   mostrado na Fig. 1.1. Durante o ensaio de indentaç o, s o realizados v rios ciclos de carregamento e descarregamento parciais.

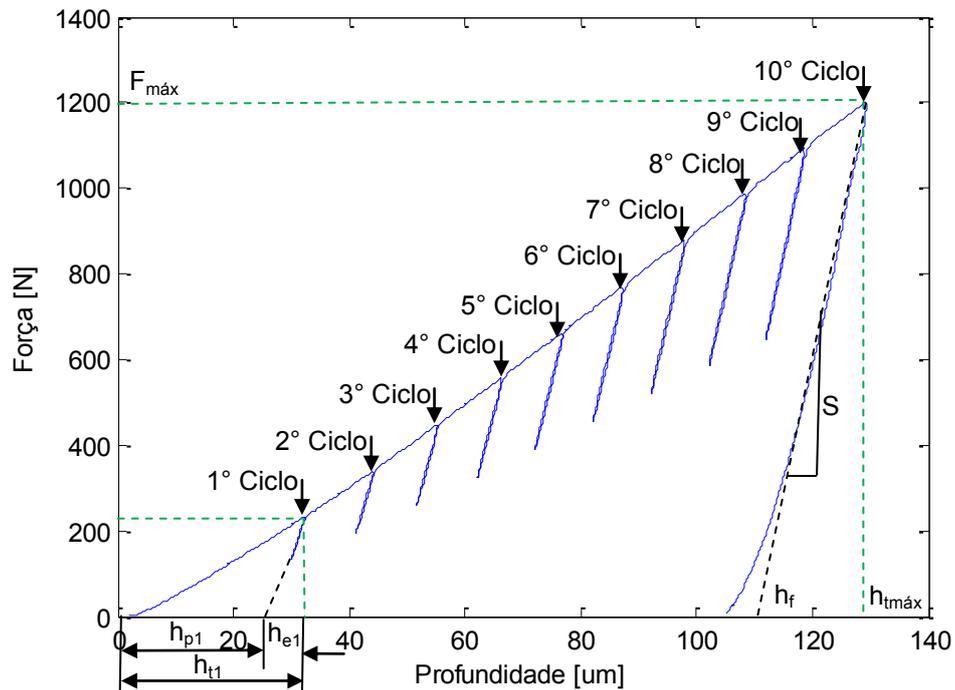


Figura 1.1 – Ensaio de macroindentação instrumentada de um aço carbono com 10 ciclos de carregamento/descarregamento, força máxima de 1200 N e penetrador com diâmetro de 1,5 mm

Onde: h_{pn} é a profundidade plástica de indentação do n -ésimo ciclo de carregamento/descarregamento, h_f é a profundidade plástica final, h_{en} é a profundidade elástica de indentação do n -ésimo ciclo de carregamento/descarregamento, h_{tn} é a profundidade total de indentação do n -ésimo ciclo de carregamento/descarregamento, $h_{tmáx}$ é a profundidade total máxima de indentação, $F_{máx}$ é a força máxima do ensaio de indentação e S é a rigidez do contato.

O modelo proposto por Haggag utiliza parâmetros de cálculo empíricos, como $\beta_m = 0,2285$ e $\alpha_m = 1,200$, permitindo a estimativa dos limites de escoamento e de resistência de aços carbono em diferentes condições termomecânicas. No entanto, este modelo pode precisar de ajustes ao testar aços temperados e revenidos de alta resistência (NICOLSI, 2015). Nestes aços, podem ocorrer erros significativos durante a estimativa das propriedades mecânicas. Outro ponto a considerar é que existem indícios de que os parâmetros β_m e α_m também dependem do diâmetro do penetrador e da carga máxima utilizada nos ensaios (NICOLSI, 2015). O uso do modelo Ahn e Kwon também pode não fornecer resultados satisfatórios ao estimar as propriedades mecânicas dos aços de alta resistência.

Apesar das limitações mencionadas acima, metodologias alternativas para calcular os limites de escoamento e de resistência por meio do modelo de Haggag ou de correlações utilizando a dureza determinada pelos ensaios de indentação podem levar a erros inferiores a 10 % (NICOLSI, 2015).

Por sua vez, o método 3 na norma ISO / TR 29381 (ISO, 2008) sugere o uso de redes neurais artificiais (RNAs). Esse método é uma alternativa para a determinação das propriedades mecânicas dos materiais.

RNAs têm sido empregadas para obter propriedades mecânicas a partir de curvas de nano e macroindentação (MULIANA *et al.*, 2002; THO *et al.*, 2004; SWADDIWUDHIPONG *et al.*, 2006; SWADDIWUDHIPONG; HARSONO; ZISHUN, 2008; HAJ-ALI *et al.*, 2008; HARSONO; SWADDIWUDHIPONG; LIU, 2009; KRUGLOV; MISHULINA; BAKIROV, 2012).

Alguns desses autores treinaram as RNAs a partir de curvas de indentação geradas pela análise de elementos finitos (MULIANA *et al.*, 2002; THO *et al.*, 2004; SWADDIWUDHIPONG *et al.*, 2006; SWADDIWUDHIPONG; HARSONO; ZISHUN, 2008; HAJ-ALI *et al.*, 2008; HARSONO; SWADDIWUDHIPONG; LIU, 2009; KRUGLOV; MISHULINA; BAKIROV, 2012; LI *et al.*, 2016; ARBABI *et al.*, 2016), utilizando penetradores de ponta cônica (com ângulos de 30° a 70°) ou Berkovich (MULIANA *et al.*, 2002; THO *et al.*, 2004; SWADDIWUDHIPONG *et al.*, 2006; SWADDIWUDHIPONG; HARSONO; ZISHUN, 2008; HAJ-ALI *et al.*, 2008; HARSONO; SWADDIWUDHIPONG; LIU, 2009).

É altamente desejável que essas RNAs sejam treinadas por meio de ensaios experimentais de indentação instrumentada, pois é difícil reproduzir todas as características dos materiais, tais como heterogeneidades, rugosidade superficial, tensões residuais, atrito entre o penetrador e o material ensaiado (VENKATESH *et al.*, 2000) pela análise de elementos finitos. Além disso, as curvas de indentação dependem do equipamento de ensaio, incluindo sua complacência, o aperto e a fixação de dispositivos da amostra, a agudeza da ponta do penetrador, a exatidão dos sistemas de medição de força (F) e profundidade de indentação (h) (VENKATESH *et al.*, 2000).

Assim, este trabalho tem como objetivo desenvolver uma metodologia, empregando RNAs e curvas experimentais de macroindentação esférica instrumentada para obter propriedades mecânicas, com exatidão similar ou melhor que a encontrada da literatura (HAGGAG; NANSTAD; BRASKI, 1989; AHN; KWON, 2001; NICOLSI, 2015), para aços carbono com limite de resistência variando cerca de 450 a 1000 MPa.

1.1. Objetivos

O objetivo geral deste trabalho é definir uma metodologia, empregando RNAs, para determinar as propriedades mecânicas (dureza Brinell, limite de resistência e limite de escoamento) a partir de curvas experimentais de ensaios de macroindentação esférica instrumentada.

Para atingir esse objetivo, os seguintes objetivos específicos foram traçados:

- Definir as arquiteturas das RNAs e os métodos de treinamento;
- Definir as configurações de treinamento das RNAs;
- Desenvolver um programa computacional para treinar RNAs;
- Realizar os treinamentos das RNAs;
- Obter os erros da estimativa de cada propriedade mecânica;
- Testar as melhores RNAs, depois de treinadas e validadas.

1.2. Estrutura do trabalho

Os assuntos pertinentes a esta tese estão organizados com a seguinte estrutura:

- No Capítulo II é apresentada uma revisão bibliográfica sobre as metodologias para a determinação de propriedades mecânicas;
- No Capítulo III é apresentada a metodologia empregada neste trabalho;
- No Capítulo IV são apresentados os resultados e as discussões;
- No Capítulo V estão resumidas as principais conclusões;
- No Capítulo VI são apresentadas sugestões para trabalhos futuros;
- Por fim, são apresentados as referências bibliográficas citadas neste trabalho, os anexos e apêndices com as informações adicionais e complementares sobre tópicos discutidos ao longo da tese.

CAPÍTULO II

REVISÃO BIBLIOGRÁFICA

2.1. Aspectos gerais sobre ensaios de macroindentação instrumentada

Os ensaios de macroindentação instrumentada, nos quais se tem a monitoração da força aplicada sobre a superfície analisada em função da profundidade de indentação, apresentam-se como uma alternativa rápida e eficaz para a obtenção de propriedades mecânicas de tração. Embora deixem uma impressão permanente na peça, esses são considerados ensaios semi destrutivos quando realizados em superfícies de dutos, haja vista que a profundidade máxima de indentação não ultrapassa 300 μm (RAMOS NETO *et al.*, 2004). Um ensaio de indentação é caracterizado como um ensaio de macroindentação quando ele é realizado utilizando forças compressivas entre 2 N e 30 kN (ISO, 2002).

A macroindentação instrumentada é um ensaio baseado em múltiplas indentações em um mesmo local de penetração, com ciclos de carregamento/descarregamento. Desta forma, com o monitoramento constante da carga (F) e da profundidade de indentação (h) determina-se uma curva característica do ensaio F x h (Fig. 2.1). A partir de correlações entre essa curva e equações semi empíricas, estimam-se diversas propriedades mecânicas, tais como: limite de escoamento, limite de resistência, dureza, curva tensão x deformação, coeficiente de resistência, coeficiente e expoente de encruamento e tenacidade à fratura (HAGGAG; NANSTAD; BRASKI, 1989; AHN; KWON, 2001; RAMOS NETO; FRANCO, 2002).

Na Figura 2.1 tem-se que h_p é a profundidade plástica de indentação, h_e é a profundidade elástica de indentação e h_t é a profundidade total de indentação, correspondente à força de indentação do respectivo ciclo.

A exatidão dos valores obtidos para as propriedades mecânicas, além de depender das incertezas associadas à calibração dos sensores empregados na instrumentação do equipamento de ensaio, à resolução do sistema de aquisição de dados, ao modelamento

matemático de cálculo dessas propriedades e à dimensão do penetrador, depende, também, da correção da complacência desse equipamento de ensaio.

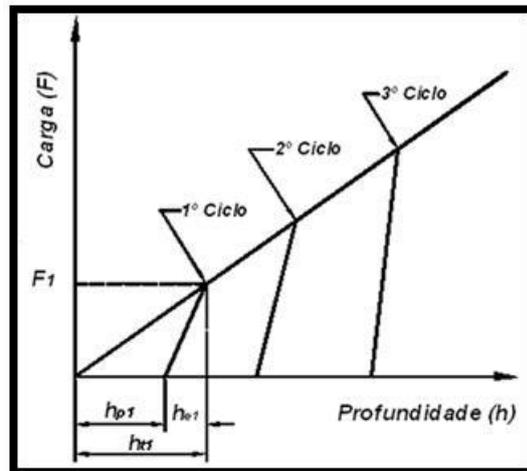


Figura 2.1 – Curva característica do ensaio de macroindentação instrumentada, adaptada de (HAGGAG, 1993)

A complacência do equipamento nada mais é do que a deformação elástica da estrutura de aplicação de força e do penetrador, mediante carregamento do sistema.

A complacência do equipamento (C_e) somada à complacência da amostra (C_a) resulta na complacência total medida (C), conforme Eq. (2.1) (OLIVER; PHARR, 1992).

$$C = C_e + C_a \quad (2.1)$$

Na Figura 2.1, a inclinação da curva de descarregamento na carga máxima aplicada no ensaio (associada ao início do descarregamento do último ciclo de carregamento/descarregamento) representa a rigidez do contato S , conforme Eq. (2.2). Portanto, a complacência da amostra C_a durante o contato elástico é designada pela Eq. (2.3), sendo equivalente ao inverso da rigidez do contato (OLIVER; PHARR, 1992).

$$S = \frac{dF}{dh} = \frac{2}{\sqrt{\pi}} E_R \sqrt{A} \quad (2.2)$$

$$C_a = \frac{1}{S} \quad (2.3)$$

Na Equação (2.2), E_R representa o módulo de elasticidade reduzido do material, obtido por meio da Eq. (2.4), e A é a área de contato da indentação (OLIVER; PHARR, 1992).

$$\frac{1}{E_R} = \frac{(1 - \nu_a^2)}{E_a} + \frac{(1 - \nu_i^2)}{E_i} \quad (2.4)$$

Onde E_a e ν_a são, respectivamente, o módulo de elasticidade e o coeficiente de Poisson do material da amostra e E_i e ν_i correspondem, respectivamente, ao módulo de elasticidade e ao coeficiente de Poisson do material do penetrador (OLIVER; PHARR, 1992).

A compensação da complacência do equipamento é utilizada em ensaios de micro e nanoindentação, nos quais as profundidades de indentação são muito pequenas e, conseqüentemente, a complacência do equipamento, se não conhecida e compensada, influencia muito nos resultados.

Embora nos ensaios de macroindentação a profundidade de indentação seja maior, comparativamente às dos ensaios anteriormente mencionados, a complacência deve ser considerada, pois a deformação elástica do equipamento pode ser relevante nos resultados, dependendo do material e das dimensões do equipamento. Conforme Oliver e Pharr (1992), no caso de indentações de grande dimensão, realizadas em materiais com elevado módulo de elasticidade, uma parte significativa da complacência total corresponde à complacência do equipamento.

Na Figura 2.2, é representado o perfil típico do ciclo de carregamento/descarregamento da região indentada.

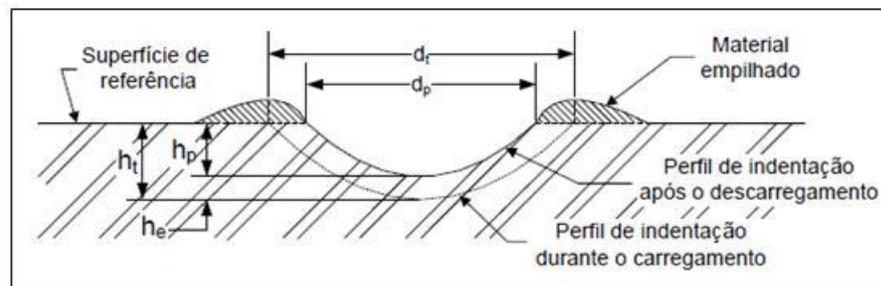


Figura 2.2 - Perfil típico da região indentada após o ciclo de carregamento/descarregamento, adaptada de (HAGGAG, 1993)

Na Figura 2.2, d_p representa o diâmetro plástico de indentação; d_t é o diâmetro total de indentação.

Na seção seguinte, serão apresentados, em detalhes, os modelos analíticos mais utilizados para a avaliação de propriedades mecânicas de tração de materiais metálicos após a realização de ensaios de macroindentação instrumentada usando penetradores esféricos, que são os modelos de Haggag (HAGGAG; NANSTAD; BRASKI, 1989) e de Ahn e Kwon (AHN; KWON, 2001).

2.2. Modelos de Haggag e de Ahn e Kwon para determinação das propriedades mecânicas via ensaios de macroindentação instrumentada

O modelo de Haggag é baseado em relações semi empíricas e parâmetros de cálculo (constantes) empíricos que dependem da classe de material a ser ensaiada e não considera efeito da deformação da superfície causada pelo penetrador (*pile up / sink in*) (MATHEW *et al.*, 1999) e ainda não há uma norma que regule o uso desse modelo (SOUSA, 2011).

O modelo de Ahn e Kwon, diferentemente do de Haggag, utiliza parâmetros de contato, considerando os efeitos de *pile up / sink in* em torno do penetrador, para avaliar as propriedades mecânicas de tração e não utiliza parâmetros de cálculo dependentes do material ensaiado. Este modelo serviu de base para a elaboração da norma ISO/TR 29381 (2008).

Ambos os modelos já foram implementadas no *PropInSitu 2*, Fig. 2.3, um macroindentador portátil desenvolvido pela equipe do Laboratório de Tecnologia em Atrito e Desgaste (LTAD), através da utilização do *software* Labview® (FRANCO *et al.*, 2007). A seguir, o modelo de Haggag, por ser mais difundido na literatura, é apresentado com mais detalhes.

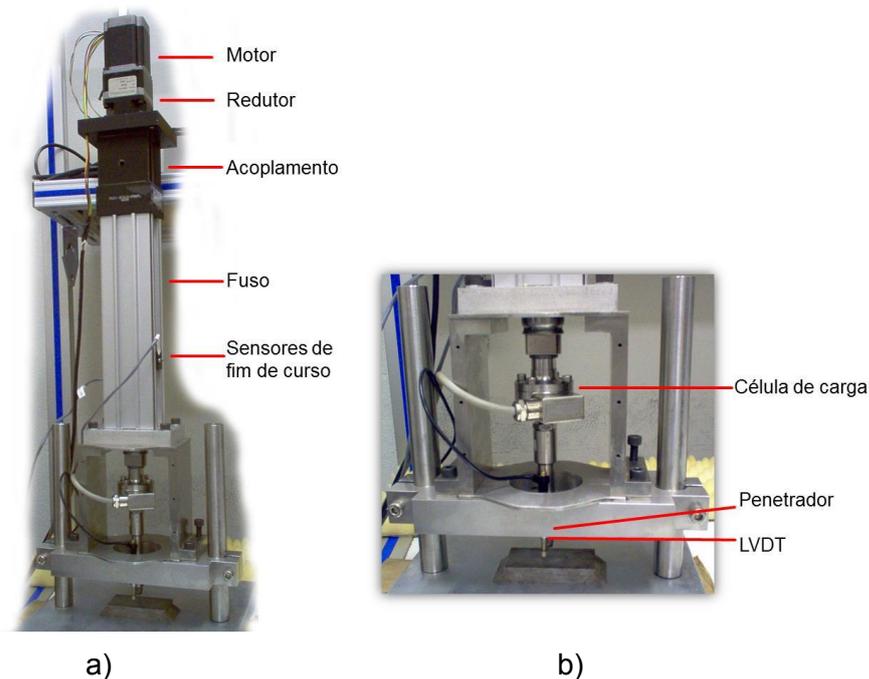


Figura 2.3 – PropInSitu 2: a) equipamento montado em uma base fixa para ensaios em laboratório; b) detalhe mostrando a localização da célula de carga, LVDT e penetrador (FRANCO *et al.*, 2007)

2.2.1. Modelo de Haggag

O grupo de pesquisadores liderados por M. Fahmy Haggag (HAGGAG *et al.*, 1989; MURTY *et al.*, 1998), do Oak Ridge National Laboratory, desenvolveu um método de indentação esférica instrumentada (IEI) para determinação da curva tensão x deformação. Seu sistema Stress-Strain Microprobe (SSM) é capaz de determinar a deformação de tração e propriedades de fratura baseados em IEI. Uma série de equações foram propostas para relacionar os dados de indentação com os parâmetros da curva tensão x deformação. As análises da IEI são baseadas principalmente em teorias de elasticidade e plasticidade e algumas correlações empíricas, tal como descrito a seguir.

A correlação entre dureza e deformação durante a indentação esférica com os testes de tração uniaxial foi, primeiramente, abordada por Tabor (1951). Seus cálculos/explicações foram baseados em três premissas importantes:

- (i) Curvas monotônicas tensão x deformação plástica verdadeiras, obtidas dos ensaios de tração e compressão uniaxial são razoavelmente semelhantes;
- (ii) A deformação da indentação correlaciona-se com a deformação plástica verdadeira em ensaios de tração;
- (iii) A dureza ou pressão média de indentação correlaciona-se com a tensão verdadeira em ensaios de tração.

Estas premissas são bem estabelecidas para vários materiais (HAGGAG, 1993). Nota-se que para a primeira premissa, as curvas de tensão *versus* deformação (de engenharia) correlacionam-se somente até o limite de resistência, desde que não haja mudança na área de seção transversal do corpo de prova (estricção).

Na técnica de macroindentação instrumentada, quando da utilização de penetradores esféricos, um carregamento seguido de subcarregamentos parciais permite que a profundidade de indentação h_p associada com a deformação plástica seja estimada. O diâmetro plástico d_p pode ser determinado a partir de h_p se não há ocorrência pronunciada de material acumulado ou deslocado entorno da indentação (MOK, 1996).

Nos múltiplos ciclos do ensaio de macroindentação instrumentada ocorrem processos consecutivos de encruamento, tanto do material anteriormente deformado, quanto do material sem deformação. Conseqüentemente, a análise do limite de escoamento é realizada tomando-se ocorrências simultâneas de escoamento e encruamento do material sob condições de compressão multiaxial. Se, por um lado o volume de material deformado aumenta com o incremento da profundidade devido à geometria da esfera, por outro, o material apresenta encruamento e dificulta este avanço. Por esta razão, os ensaios macroindentação instrumentada não apresentam duas fases: linear elástica, seguida de uma não linear com encruamento do material. Portanto, os gráficos $F \times h$ (Força *versus* Profundidade) normalmente apresentam-se como porções que podem ser aproximadas por polinômios de primeiro grau, como mostrado na Fig. 2.1. A partir destas curvas determinam-se os valores da força máxima ($F_{máx}$) e das profundidades plástica (h_p), elástica (h_e) e máxima ($h_{máx}$) de cada ciclo (CALLEGARI *et al.*, 2006).

A tensão e a deformação verdadeiras podem ser resolvidas a partir das Eq. (2.5) e (2.6), respectivamente. Todas essas equações são interdependentes, o que requer que a solução seja obtida de forma iterativa por meios computacionais.

A máxima deformação que pode ser medida através IEI é 20 %, quando $d_p = D$ (MURTY; MATHEW, 2004). Usando a equação de Hertz (HAGGAG; NANSTAD; BRASKI, 1989), a profundidade plástica h_p pode ser estimada a partir do descarregamento da amostra e, então, convertido em diâmetro plástico da indentação d_p , usando a Eq. (2.7). A teoria de Hertz para contato normal elástico entre dois sólidos é usada na análise da deformação que ocorre no início do teste de indentação (TIMOSHENKO; GOODIER, 1970).

$$\varepsilon_v = 0,2 \cdot \frac{d_p}{D} \tag{2.5}$$

$$\sigma_v = \frac{4 \cdot F}{\pi \cdot d_p^2 \delta} \quad (2.6)$$

Onde: F é a força de indentação; D é o diâmetro da esfera; ε_v é a deformação plástica verdadeira; σ_v é a tensão verdadeira e δ é o parâmetro que depende do estágio de desenvolvimento da zona plástica sob o penetrador e da tensão de indentação (τ), Eq. (2.8).

O cálculo de d_p é dado pela Eq. (2.7).

$$d_p = \sqrt[3]{2,735 \cdot F \cdot D \cdot \left(\frac{1}{E_a} + \frac{1}{E_i} \right) \cdot \left(\frac{h_p^2 + 0,25 \cdot d_p^2}{h_p^2 + 0,25 \cdot d_p^2 - h_p \cdot D} \right)} \quad (2.7)$$

O valor de δ pode ser obtido da Eq. (2.8).

$$\delta = \begin{cases} 1,12: & \phi \leq 1 \\ 1,12 + \tau \cdot \ln \phi: & 1 < \phi \leq 27 \\ \delta_{m\acute{a}x}: & \phi > 27 \end{cases} \quad (2.8)$$

Os valores de ϕ , $\delta_{m\acute{a}x}$ e τ são obtidos a partir das Eq. (2.9), (2.10) e (2.11).

$$\phi = \frac{\varepsilon_v \cdot E_a}{0,43 \cdot \sigma_v} \quad (2.9)$$

$$\delta_{m\acute{a}x} = 2,87 \cdot \alpha_m \quad (2.10)$$

$$\tau = \frac{\delta_{m\acute{a}x} - 1,12}{\ln(27)} \quad (2.11)$$

Onde: α_m é um fator de restrição.

A constante α_m é uma das constantes do método de Haggag e que deve ser adequadamente definida para que resulte em valores corretos das propriedades mecânicas. Segundo Haggag (2009), esta constante depende do tipo/classe do material a ser ensaiado e, conforme Kania, Russell e Gao (2003), esta constante depende, também, do diâmetro do penetrador esférico. Haggag *et al.* (1990), Kania, Russell e Gao (2003), afirmaram que esta

constante também depende da sensibilidade à taxa de deformação do material da amostra indentada. Ainda pode-se dizer que esta constante está relacionada com a determinação do limite de resistência.

Na Tabela 2.1 constam informações a respeito dos valores atribuídos para α_m , conforme o tipo de material a ser ensaiado via macroindentação.

Tabela 2.1 – Valores da literatura estimados para α_m conforme o tipo de material a ser indentado

Material	α_m
Vários aços estruturais	$0,90 < \alpha_m < 1,25$, dependendo da sensibilidade à taxa de deformação (MURTY <i>et al.</i> , 1998)
Desconhecido	1,10 (HAGGAG, 2009)

A faixa de escoamento plástico da curva de tensão verdadeira σ_v versus deformação plástica verdadeira ε_v pode ser representada por uma função de potência, Eq. (2.12).

$$\sigma_v = K \cdot \varepsilon_v^n \quad (2.12)$$

Onde: K e n são o coeficiente de resistência e o expoente de encruamento, respectivamente; σ_v é a tensão verdadeira, Eq. (2.6) e ε_v é a deformação plástica verdadeira, Eq. (2.5).

Os dados calculados das Eqs. (2.5) e (2.6) são ajustados à Eq. (2.12) através de uma regressão, onde se obtém os valores do expoente de encruamento n e do coeficiente de resistência K . Logo, o limite de ruptura (σ_r - de engenharia) é calculado a partir da Eq. (2.13).

$$\sigma_r = K \cdot \left(\frac{n}{e} \right)^n \quad (2.13)$$

Onde: e é o número de Euler = 2,7182...

Para cada ciclo do ensaio de indentação, a profundidade total h_t é medida enquanto a carga é aplicada e, usando a relação de área projetada do penetrador esférico, o diâmetro total d_t pode ser calculado Eq. (2.14).

$$d_t = 2 \cdot \sqrt{(h_t \cdot D - h_t^2)} \quad (2.14)$$

Os pontos de todos os ciclos de carregamento até $d_t/D = 1,0$ são ajustados por uma regressão linear através da seguinte relação, dada pela Eq. (2.15).

$$\frac{F}{d_t^2} = A \cdot \left(\frac{d_t}{D} \right)^{m-2} \quad (2.15)$$

Onde: m é o coeficiente de Meyer e A é o parâmetro de teste do material.

Os valores de A e m são obtidos a partir da regressão dos dados de d_t/D versus F/d_t^2 e o parâmetro de teste do material pode então ser usado para calcular o limite de escoamento σ_e do material, usando a Eq. (2.16).

$$\sigma_e = \beta_m \cdot A \quad (2.16)$$

Onde: β_m é o coeficiente de deformação.

Além de α_m , conforme citado anteriormente, β_m é outra constante que deve ser determinada e inserida no modelo para a determinação das propriedades mecânicas. Esta constante também é dependente do tipo de material e está relacionada com o limite de escoamento, conforme Eq. (2.16) (HAGGAG, 2009). Segundo Haggag (2009), Kania, Russell e Gao (2003), esta constante depende, ainda, do diâmetro do penetrador esférico.

Na Tabela 2.2, estão expressos os valores que podem ser atribuídos a β_m de acordo com o tipo de material a ser indentado.

Tabela 2.2 - Valores da literatura estimados para β_m conforme o tipo de material a ser indentado

Material	β_m
Todos aços-carbono	0,2285 (HAGGAG <i>et al.</i> , 1990; DAS <i>et al.</i> , 2006)
Aços inoxidáveis	0,1910 (HAGGAG <i>et al.</i> , 1990)
Desconhecido	0,2000 (HAGGAG, 2009)

Haggag (2009) apresentou, também, outros valores para as constantes α_m e β_m . No trabalho de Nicolosi (2015) há uma extensa revisão bibliográfica sobre os valores de α_m e β_m adotados na literatura.

Alguns trabalhos (BYUN *et al.*, 1997; HAGGAG, 1993 e 1999; KANIA; RUSSELL; GAO, 2004; KULKARNI *et al.*, 2013; BARBADIKAR *et al.*, 2014 e 2015) sugerem uma

generalização da Eq. (2.16), através da introdução de mais um termo, b_m , denominado de “*offset* de escoamento”, de acordo com a Eq. (2.17).

$$\sigma_e = \beta_m \cdot A + b_m \quad (2.17)$$

Barbadikar *et al.* (2015) propõem o uso do parâmetro b_m como forma de corrigir o erro no cálculo do limite de escoamento devido à presença do *pile-up*. Kulkarni *et al.* (2013) sugerem que o parâmetro β_m na Eq. (2.17) é constante para uma determinada classe de material, mas que b_m pode variar, por exemplo, em função da textura do material, já que os autores encontraram diferenças no valor de b_m ao avaliarem corpos de prova removidos das direções longitudinal e circunferencial de tubos de Zr-2,5%Nb.

Conforme apresentado no trabalho de Nicolosi (2015) não há consenso na literatura quanto aos valores dos parâmetros de cálculo (α_m , β_m e b_m) que devem ser usados, ainda que dentro de uma mesma classe de material, como, por exemplo, em aços-carbono.

A dureza Brinell HB também pode ser determinada a partir do ensaio de indentação instrumentada com penetrador esférico. O cálculo é feito usando a carga máxima $F_{m\acute{a}x}$ (em kgf), o diâmetro final da impressão d_f (em mm) e o diâmetro da esfera D (em mm), usando a Eq. (2.18) (proveniente do ensaio de dureza Brinell padronizado - ASTM E10, 2012).

$$HB = \frac{2 \cdot F_{m\acute{a}x}}{(\pi \cdot D \cdot (D - (D^2 - d_f^2)^{0,5}))} \quad (2.18)$$

2.2.2. Análise crítica dos modelos de Haggag e de Ahn e Kwon

O modelo proposto por Haggag utiliza parâmetros de cálculo empíricos, como $\beta_m = 0,2285$ e $\alpha_m = 1,200$, permitindo a estimativa dos limites de escoamento e de resistência de aços carbono em diferentes condições termomecânicas. No entanto, este modelo pode precisar de ajustes ao testar aços temperados e revenidos de alta resistência (NICOLOSI, 2015). Nestes aços, podem ocorrer erros significativos durante a estimativa das propriedades mecânicas. Outro ponto a considerar é que existem indícios de que os parâmetros β_m e α_m também dependem do diâmetro do penetrador e da carga máxima utilizada nos ensaios (NICOLOSI, 2015). O uso do modelo Ahn e Kwon também pode não fornecer resultados satisfatórios ao estimar as propriedades mecânicas dos aços de alta resistência.

Apesar das limitações mencionadas acima, metodologias alternativas para calcular os limites de escoamento e de resistência através do modelo de Haggag ou de correlações

utilizando a dureza determinada pelos ensaios de indentação podem levar a erros inferiores a 10 % (NICOLOSI, 2015).

Por sua vez, o método 3 na norma ISO / TR 29381 (2008) sugere o uso de redes neurais artificiais (RNAs). Esse método é uma alternativa para a determinação das propriedades mecânicas dos materiais.

Vale lembrar que essa norma descreve três métodos para calcular as propriedades mecânicas de tração de materiais metálicos utilizando ensaios de indentação instrumentada. Esses métodos são:

- Método 1: Tensão e deformação representativas (Modelo de Ahn e Kwon);
- Método 2: Análise inversa usando modelos de elementos finitos;
- Método 3: Utilização de redes neurais.

2.3. Revisão da Literatura sobre as metodologias para a determinação das propriedades mecânicas baseadas em métodos de aprendizado de máquina

A área de aprendizado de máquina é um ramo de estudo da Inteligência Artificial, relacionada ao projeto e desenvolvimento de algoritmos e técnicas capazes de permitirem o aprendizado computacional. O foco de aprendizado de máquina está na extração de conhecimento de grandes massas de dados de maneira automática, utilizando, para tanto, métodos computacionais e estatísticos. O espectro de aplicações das técnicas de aprendizado de máquina é bastante extenso, incluindo, por exemplo, processamento de linguagem natural, reconhecimento de padrões, diagnóstico, detecção de fraudes, reconhecimento de escrita e de fala, análise de investimentos, visão computacional, robótica e bioinformática (TAVARES; LOPES; LIMA, 2007).

Essas técnicas de aprendizado de máquina estão divididas em dois grandes grupos, a saber: métodos determinísticos e métodos estocásticos. Alguns dos métodos determinísticos são: máxima descida, método de Newton, método quase-Newton, gradiente conjugado (GC), método de Levenberg-Marquardt (LM), método Simplex. Exemplos de métodos estocásticos são: recozimento simulado (RS), algoritmos genéticos (AGs), busca tabu, otimização extrema, otimização por colônia de formigas, otimização por enxame de partículas, redes neurais artificiais (RNAs). Ainda existem os métodos híbridos, os quais combinam a estratégia de busca global dos métodos estocásticos com busca local dos métodos determinísticos, como por exemplo: AGPlex (AG + Simplex), RSPlex (RS + Simplex), AGGC (AG + Gradiente Conjugado) (CAMPOS VELHO, 2008).

Conforme Swaddiwudhipong; Harsono; Zishun (2008), esses métodos de aprendizado de máquina, tais como a RNA, estão ganhando popularidade no campo da

engenharia devido à sua capacidade de imitar o método de cálculo adotado pelo cérebro humano. Eles não necessitam de modelos matemáticos complicados como os necessários nos métodos convencionais.

Em virtude disso, modelos de RNAs têm sido amplamente aplicados para resolver análise reversa envolvendo funções complicadas como as de ensaios de indentação de um dado material. Essa análise reversa consiste em, a partir das curvas desses ensaios, obter as propriedades mecânicas do material ensaiado. Assim, esses modelos foram utilizados para obter as propriedades mecânicas dos materiais a partir de curvas de nano e macroindentação por vários pesquisadores (MULIANA *et al.*, 2002; THO *et al.*, 2004; SWADDIWUDHIPONG *et al.*, 2006; SWADDIWUDHIPONG; HARSONO; ZISHUN, 2008; HAJ-ALI *et al.*, 2008; HARSONO; SWADDIWUDHIPONG; LIU, 2009; KRUGLOV; MISHULINA; BAKIROV, 2012).

Alguns desses autores treinaram as RNAs a partir de curvas de indentação geradas pela análise de elementos finitos (MULIANA *et al.*, 2002; THO *et al.*, 2004; SWADDIWUDHIPONG *et al.*, 2006; SWADDIWUDHIPONG; HARSONO; ZISHUN, 2008; HAJ-ALI *et al.*, 2008; HARSONO; SWADDIWUDHIPONG; LIU, 2009; KRUGLOV; MISHULINA; BAKIROV, 2012; LI *et al.*, 2016; ARBABI *et al.*, 2016), utilizando penetradores de ponta cônica (com ângulos de 30° a 70°) ou Berkovich (MULIANA *et al.*, 2002; THO *et al.*, 2004; SWADDIWUDHIPONG *et al.*, 2006; SWADDIWUDHIPONG; HARSONO; ZISHUN, 2008; HAJ-ALI *et al.*, 2008; HARSONO; SWADDIWUDHIPONG; LIU, 2009).

É altamente desejável que essas RNAs sejam treinadas através de ensaios experimentais de indentação instrumentada, pois é difícil reproduzir todas as características dos materiais, tais como heterogeneidades, rugosidade superficial, tensões residuais, atrito entre o penetrador e o material ensaiado (VENKATESH *et al.*, 2000) pela análise de elementos finitos. Além disso, as curvas de indentação dependem do equipamento de ensaio, incluindo sua complacência, o aperto e a fixação de dispositivos da amostra, a agudeza da ponta do penetrador, a exatidão dos sistemas de medição de força (F) e profundidade de indentação (h) (VENKATESH *et al.*, 2000).

Segundo Giannakopoulos e Suresh (1999) três variáveis podem ser diretamente extraídas de uma curva de indentação de ensaios com penetradores de ponta aguda (i.e. Vickers, Berkovich ou cônica), tais como CC (curvatura da parcela de carregamento da curva F x h), S (rigidez do contato) e W_p/W_T (razão entre a energia de deformação plástica e a energia de deformação total).

Baseado nisso, Dao *et al.* (2001) propuseram uma análise reversa para estimar as propriedades mecânicas (limite de escoamento, limite de resistência e dureza) a partir da curva F x h do ensaio de indentação com penetrador com ponta aguda. Eles utilizaram como

entradas da RNA essas três variáveis mencionadas anteriormente e, após o treinamento, notaram que as propriedades plásticas dos materiais obtidas a partir dos ensaios de indentação instrumentada são muito sensíveis a pequenas variações na curva $F \times h$, similar ao que foi destacado por Venkatesh *et al.* (2000).

Swaddiwudhipong; Harsono; Zishun (2008) desenvolveram uma RNA e uma máquina de vetor de suporte (MVS) para estimar as propriedades mecânicas (limite de escoamento, módulo de Young e expoente de encruamento) a partir de curvas simuladas de indentação de materiais elasto-plásticos com a utilização de penetradores de ponta cônica. Os autores utilizaram as seguintes características das curvas $F \times h$ como entradas da RNA: CC e W_p/W_T . As entradas dos algoritmos foram perturbadas simultaneamente e, posteriormente, eles concluíram que a previsão das propriedades mecânicas foi mais exata quando se utilizou o modelo de RNA, comparativamente ao modelo de MVS.

Harsono; Swaddiwudhipong; Liu (2009) propuseram um modelo de RNA para extrair propriedades mecânicas de materiais com base em um banco de dados obtido com simulações de indentações esférica e Berkovich no *software* Abaqus. O modelo proposto pôde prever com exatidão as propriedades elastoplásticas (módulo de Young, limite de escoamento e expoente de encruamento) de um novo conjunto de materiais que não foram incluídos no treinamento nem na validação. Esses autores usaram o algoritmo *backpropagation* (BP) para treinar a rede utilizando a *toolbox* do Matlab V.6.5.

Eles utilizaram como entradas da RNA as seguintes características obtidas das curvas $F \times h$ de ensaios de indentação esférica: $F_{m\acute{a}x}/h^2_{m\acute{a}x}$ e W_p/W_T . Já para os ensaios com penetrador Berkovich, as entradas foram: CC e W_p/W_T .

2.3.1. Métodos de treinamento de RNAs

Em relação ao método escolhido para treinar a RNA, comumente utiliza-se o método BP.

O método BP funciona medindo o erro de saída, calculando o gradiente desse erro e ajustando os pesos (e *biases*) da RNA na direção do gradiente descendente. Ou seja, o BP é um algoritmo de busca local do gradiente descendente (ALBA; CHICANO, 2004).

Segundo Yao (1999), métodos de treinamento baseados em gradientes, como o BP, são sensíveis aos mínimos locais da função erro. E esses mínimos locais podem estar localizados longe da solução almejada (MONTANA E DAVIS, 1989). Outra desvantagem do BP é que para calcular um gradiente, é necessário diferenciar uma dada função. Assim, o BP não pode lidar com funções descontínuas, o que restringe seu uso nesses casos (MONTANA E DAVIS, 1989).

Diferentemente do método BP, os AGs são bons para explorar um grande e complexo espaço de busca para encontrar valores próximos ao ótimo global (MONTANA E DAVIS, 1989).

Neste contexto, por exemplo, a utilização de AGs juntamente com RNAs constitui parte da classe de redes neurais evolutivas (RNAEs). Os AGs podem ser utilizados para diferentes tarefas, como a execução do treinamento dos pesos, definição da arquitetura da rede, busca por parâmetros dos algoritmos de aprendizado, busca por inicializações dos pesos das conexões, dentre outras. As RNAEs possuem a capacidade de se adaptarem ao ambiente onde são empregadas, bem como às mudanças que podem ocorrer nesse ambiente. Isso acontece pela existência de duas formas de adaptação, a evolução originada dos AGs e o processo de aprendizado pela atualização dos pesos das RNAs, fazendo com que sua adaptação seja mais efetiva e eficiente (YAO, 1999).

Esta combinação de RNA com AG possibilitou a adoção de novas alternativas para a o algoritmo de aprendizagem, motivando o desenvolvimento de muitos trabalhos (ALBA; CHICANO, 2004; ZHOU; YIN; HU, 2009; INTACHOT; BOONJING; INTAKOSUM, 2016; KANUMURI *et al.*, 2017).

Karak; Chatterjee; Bandopadhyay (2015), com o objetivo de estimar as propriedades físicas e mecânicas (obtidas a partir da nanoindentação) de determinadas ligas ferríticas, desenvolveram uma RNA de três camadas. Para treiná-la eles empregaram o AG. Os resultados mostraram que o AG forneceu o melhor desempenho em relação ao modelo tradicional de RNA treinado por BP. Para cada uma das propriedades físicas e mecânicas (porosidade, densidade, dureza, módulo de Young, resistência à compressão) foi desenvolvida uma RNA possuindo uma camada de entrada com dois nós (temperatura e % em peso de Cr), uma camada oculta e uma camada de saída com um neurônio de saída.

Segundo Almeida (2007), as metodologias que seguem a abordagem evolucionária, tal como o AG, tendem a fazer uma busca extensa por redes quase-ótimas para um dado problema. Trabalhos recentes da literatura comprovam a sua eficácia, porém um ponto negativo da abordagem evolucionária é o alto tempo necessário para que bons resultados sejam obtidos. Conforme Yao (1999), os algoritmos de busca global são normalmente caros computacionalmente.

Como alternativa, existe a abordagem não-evolucionária que procura acelerar essa busca por meio da otimização propriamente dita e não tanto da busca como acontece na abordagem evolucionária (ALMEIDA, 2007).

Dessa forma, existem vários trabalhos que mesclam as abordagens evolucionária (busca global) e não-evolucionária (busca local), resultando em sistemas híbridos para

realizar o treinamento de RNAs na tentativa de combinar as melhores características de diferentes algoritmos (IRANI; NASIMI, 2011; ALBA; CHICANO, 2004).

Portanto, um sistema híbrido de aprendizagem consiste em adicionar a um método de busca global um método de mínimo local ou vice-versa. A hibridização pode envolver dois ou mais métodos de otimização distintos. Segundo Alba e Chicano (2004), um algoritmo adicionado pode ser utilizado para melhorar os resultados de um outro algoritmo separadamente ou ele pode ser utilizado como um operador de um outro algoritmo.

Não se restringindo à implementação das RNAEs, Alba e Chicano (2004) estudaram vários algoritmos para treinar RNAs, a saber: BP, Levenberg-Marquardt (LM), AG, algoritmo híbrido entre AG e BP (AG-BP) e um algoritmo híbrido entre AG e LM (AG-LM). Em ambos os algoritmos híbridos, os métodos de mínimos locais (BP e LM) foram utilizados como um operador de mutação do método de busca global AG. Dentre os cinco algoritmos, que foram implementados para classificar problemas de saúde (diagnóstico de câncer de mama, diabetes e doenças cardíacas), o algoritmo híbrido AG-LM foi o que em geral apresentou melhores resultados (menores erros).

Hagan e Menhaj (1994), por sua vez, estudaram a aplicação do algoritmo de LM para treinar uma RNA e verificaram que ele é mais eficiente em relação a outros algoritmos (gradiente conjugado e taxa de aprendizado variável) quando a rede contém não mais que algumas centenas de pesos. Em contrapartida, o LM requer maior esforço computacional para cada iteração. Outra observação feita pelos autores foi que, em muitos casos, o algoritmo LM convergiu, enquanto que os outros dois algoritmos não conseguiram convergir.

Soundararajan *et al.* (2017) implementaram uma RNA, através da *Neural Network Toolbox* do Matlab[®], para obter as propriedades mecânicas de uma liga de alumínio (dureza, limite de resistência e limite de escoamento). Para treiná-la, também utilizaram o método de LM, com o qual obtiveram ótimos resultados. A RNA tinha três camadas, a saber: uma camada de entrada, uma camada oculta e uma camada de saída com três neurônios, cada um responsável por emitir uma das propriedades.

Karimirad; Chauhan; Shirinzadeh (2014) propuseram um modelo em RNA, cujo treinamento foi feito com o algoritmo de LM devido à sua rápida convergência e exatidão. E no sentido de aprimorar a generalização da rede e prevenir o *overfitting*, o método de regularização bayesiana foi empregado. Os resultados do treinamento mostraram que houve 97 % de correlação entre o resultado obtido pela RNA e o resultado real.

Pandya; Dennis; Russell (2017) desenvolveram um modelo de RNA *feed-forward* de múltiplas camadas empregando, também, o algoritmo de treinamento de LM com regularização bayesiana (LMRB). Esse modelo teve como objetivo estimar a taxa de erosão

e, como resultado, reduziu o erro acumulativo para menos que 10 %, comparativamente ao erro de mais de 40 % do modelo de erosão da Baker Hughes.

Cintra (2003) desenvolveu uma RNA para o controle de teor de minério em frentes de lavra a partir de observações geológicas e geotécnicas. Essa rede foi treinada com o algoritmo de LM acoplado com regularização bayesiana. Obteve-se, assim, um índice de acertos de 80 % na predição de teores de cobre em bancadas simuladas.

Diante do anteriormente exposto, pode-se notar que o método de LMRB tem sido empregado para treinar RNA em muitos trabalhos da literatura, obtendo resultados satisfatórios (CINTRA, 2003; TAKAHASHI, 2006; MIRIKITANI; NIKOLAEV, 2010; KARIMIRAD; CHAUHAN; SHIRINZADEH, 2014; PANDYA; DENNIS; RUSSELL, 2017).

Todavia, em muitos desses trabalhos não houve a aplicação desse método na estimativa das propriedades mecânicas via macroindentação instrumentada (CINTRA, 2003; MIRIKITANI; NIKOLAEV, 2010; KARIMIRAD; CHAUHAN; SHIRINZADEH, 2014; PANDYA; DENNIS; RUSSELL, 2017).

Também, o método de treinamento híbrido entre AG e LM (AG-LM) (ALBA; CHICANO, 2004) forneceu resultados muito satisfatórios em uma aplicação na qual o objetivo do treinamento não foi de estimar propriedades mecânicas.

Em decorrência disso, surgiu a necessidade de se investigar a utilização do algoritmo híbrido AG-LMRB no treinamento de RNAs para estimar propriedades mecânicas via ensaios de macroindentação instrumentada. A escolha da hibridização entre AG e LMRB é consequência dos resultados satisfatórios decorrentes da aplicação do método LMRB e do método híbrido AG-LM, em outras aplicações, conforme mencionado anteriormente.

2.4. Redes Neurais Artificiais (RNAs)

As RNAs são sistemas paralelos distribuídos e constituídos de unidades de processamento simples, denominadas neurônios ou unidades de processamento, que têm a propensão natural para armazenar conhecimento experimental adquirido pelo processo de aprendizagem e torná-lo disponível para o uso. Tal conhecimento é armazenado através das forças de conexão entre os neurônios, conhecidas como pesos sinápticos (HAYKIN, 2001).

Segundo Haykin (2001), as RNAs têm duas capacidades de processamento de informação, a aprendizagem e a generalização, o que torna possível a resolução de problemas complexos.

O procedimento utilizado para realizar tal processo de aprendizagem (ou treinamento) é denominado de algoritmo de aprendizagem (ou treinamento), cuja função é

modificar os pesos sinápticos da rede de uma forma ordenada, através da apresentação de diversos padrões de entrada, para alcançar um objetivo de projeto desejado (minimizar o erro). Já a generalização se refere ao fato de a RNA produzir saídas adequadas para as entradas que não estavam presentes durante o treinamento (HAYKIN, 2001).

Os pesos, incluindo o *bias*, são os parâmetros que são estimados por uma RNA durante o seu treinamento. Quando não há mais alterações significativas nesses pesos, conclui-se que a rede está treinada. Após o treinamento seus valores são fixados, permanecendo constantes (LOUZADA, 2013).

O uso de RNAs oferece as seguintes propriedades úteis e capacidades: não-linearidade, mapeamento de entrada-saída através da aprendizagem, adaptabilidade, tolerância a falhas (HAYKIN, 2001).

2.4.1. Neurônio Artificial

McCulloch e Pitts (1943) introduziram o modelo do neurônio artificial, a partir do modelamento matemático de um neurônio biológico. Em 1949, Hebb desenvolveu o primeiro método de treinamento de RNAs. A partir daí, foram desenvolvidos outros trabalhos que apresentaram RNAs com diferentes arquiteturas e técnicas de treinamento (ROSENBLATT, 1958; WIDROW; HOFF, 1960; RUMELHART; HINTON; WILLIAMS, 1986).

O neurônio biológico serve como inspiração para o modelo do neurônio artificial conforme a Fig. 2.4. O neurônio artificial apresenta três elementos básicos: um conjunto de sinapses; um somador; e uma função de ativação. Ainda, o neurônio artificial apresenta um conjunto de entradas, simulando os dendritos e uma saída, simulando o axônio.

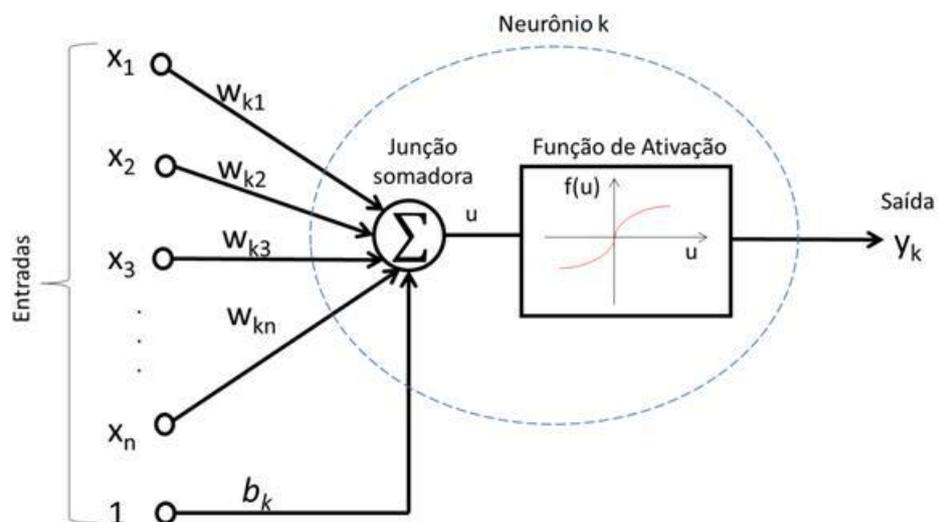


Figura 2.4 – Representação de um neurônio artificial, adaptado de (HAYKIN, 2001)

Onde:

- x_1 a x_n são as entradas do neurônio k , obtidas do conjunto de dados de treinamento. A entrada 1 é fixa, correspondente à entrada do *bias*;
- w_{k1} a w_{kn} são os pesos sinápticos associados ao neurônio k , cada um referente a uma dada entrada, que varia de 1 a n . Ao contrário de uma sinapse do cérebro, o peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos bem como positivos (HAYKIN, 2001);
- b_k é o *bias*, um termo de polarização do neurônio, que pode ser tratado como um peso sináptico, cuja entrada é sempre igual a 1. Ele tem o efeito de aumentar ou diminuir a influência do valor da combinação linear das entradas (entrada da função de ativação), dependendo se ele é positivo ou negativo, respectivamente (HAYKIN, 2001);
- \sum refere-se à junção somadora, que realiza uma combinação linear (u) das entradas do neurônio, ou seja, realiza a soma dos sinais de entrada, ponderados pelos respectivos pesos sinápticos, conforme Eq. (2.19);

$$u = \sum_{i=1}^n (x_i w_{ki}) + b_k \quad (2.19)$$

- y_k é a saída do neurônio k , obtida pela aplicação de uma função de ativação ($f(u)$) sobre a combinação linear (u).

A função de ativação restringe a amplitude da saída do neurônio k . Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo fechado $[0, 1]$ ou $[-1, 1]$ (HAYKIN, 2001). Também, é importante ressaltar que essa função de ativação, dependendo da função que ela representa, pode introduzir não-linearidade ao neurônio (LOUZADA, 2013).

Matematicamente, o neurônio k pode ser descrito pelas Eqs. (2.19) e (2.20).

$$y_k = f(u) = F \left(\sum_{i=1}^n (x_i w_{ki}) + b_k \right) \quad (2.20)$$

2.4.2. Funções de ativação

Existem diversos tipos de funções de ativação, sendo que as mais populares são as funções: limiar (ou degrau), linear por partes, sigmoide e tangente hiperbólica (HAYKIN, 2001).

A função sigmoide, Eq. (2.21), é a função mais utilizada na construção de RNAs, cujo gráfico tem forma de s. Ela é definida como uma função crescente com balanceamento adequado entre o comportamento linear e não linear e assume um intervalo de variação entre 0 e 1 (HAYKIN, 2001).

$$F(u) = \frac{1}{1 + e^{-au}} \quad (2.21)$$

Onde: “a” é o parâmetro de inclinação da função sigmoide. No limite, quando o parâmetro de inclinação se aproxima do infinito, a função sigmoide se torna simplesmente uma função de limiar. Enquanto que a função de limiar assume o valor de 0 ou 1, uma função sigmoide assume um intervalo contínuo de valores entre 0 e 1. Também, a função sigmoide é diferenciável, enquanto que a função de limiar não o é (HAYKIN, 2001).

Como mencionado por Haykin (2001), a função mais utilizada é a sigmoide. Vários autores empregaram essa função (ALTINKOK; KOKER, 2004; SANTANA, 2012; TOSUN; ÖZLER, 2002; ASILTÜRK; ÇUNKAS, 2011; TOPÇU; SARIDEMIR, 2008; SINGH; SINGH; SINGH, 2001; HAJ-ALI *et al.*, 2008).

E, em muitos trabalhos da literatura, os autores utilizaram a função sigmoide nos neurônios das camadas ocultas e função linear nos neurônios da camada de saída (HARSONO; SWADDIWUDHIPONG; LIU, 2009; IRANI E NASIMI, 2011; BATISTA, 2012; KARIMIRAD; CHAUHAN; SHIRINZADEH, 2014; ATRIAN *et al.*, 2016).

2.4.3. Arquitetura da RNA

A maneira pela qual os neurônios de uma rede neural estão estruturados define a arquitetura da rede. Em geral, identificam-se três classes de arquiteturas de rede fundamentalmente diferentes: redes alimentadas diretamente com camada única; redes alimentadas diretamente com múltiplas camadas (*Multilayer Feedforward Networks*) e redes recorrentes (HAYKIN, 2009). *Multilayer Feedforward Networks* também é conhecida como *Perceptron* de múltiplas camadas (*Multilayer Perceptron – MLP*).

Redes alimentadas diretamente com múltiplas camadas, Fig. 2.5, possuem uma ou mais camadas ocultas (ou intermediárias), que são camadas de neurônios que se situam entre as camadas de entrada e saída. As camadas ocultas aumentam a habilidade da rede de extrair estatísticas de ordem elevada das entradas. E as saídas dessas camadas serão as entradas das camadas subseqüentes, propagando-se os sinais até a camada de saída da rede (HAYKIN, 2009).

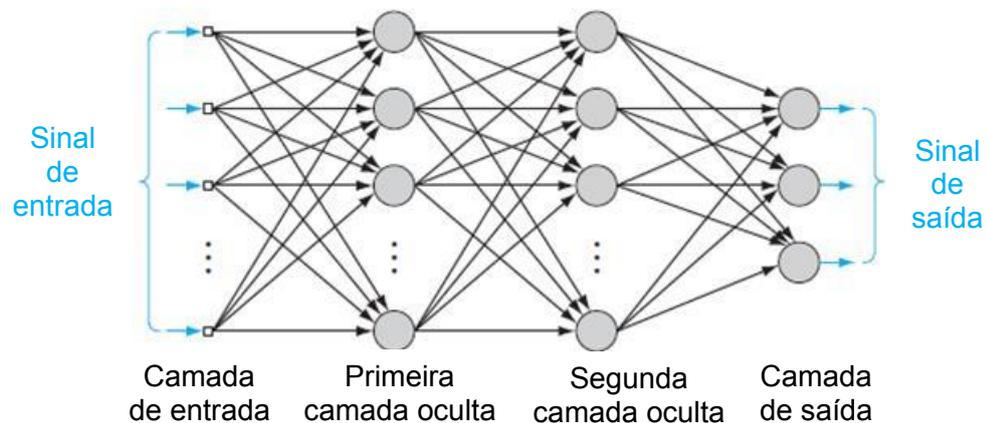


Figura 2.5 – Arquitetura de uma rede MLP com duas camadas ocultas, adaptado de (HAYKIN, 2009)

2.4.4. Aprendizado ou Treinamento da RNA

A forma de aprendizado também diferencia as RNAs, a qual pode ser de dois tipos: não supervisionada ou supervisionada (BISHOP, 1995).

O aprendizado supervisionado é aquele em que, para cada padrão de entrada apresentado à RNA, se conhece o valor da saída desejado. Já no aprendizado não supervisionado, é inexistente um valor de saída desejado e, assim, a saída da RNA não pode ser comparada com a saída desejada, de tal forma que os pesos sinápticos possam ser ajustados para minimizar o erro. Logo, este tipo de aprendizado é caracterizado pela busca de alguma correlação nos dados de entrada (BISHOP, 1995).

Por padrão, o treinamento de uma MLP é do tipo supervisionado por meio de algoritmo BP, que tem a função de encontrar as derivadas da função de erro com relação aos pesos e *bias* da RNA. A função de erro calcula a diferença entre a saída fornecida pela RNA e a saída desejada em relação a um determinado padrão de entrada (BISHOP, 1995).

Basicamente, o treinamento de uma MLP busca minimizar uma função de erro e maximizar a capacidade de generalização da rede. Para a maioria das MLP, a função objetivo é o erro quadrático médio (HAGAN *et al.*, 2014).

O treinamento de uma MLP pode ser descrito, resumidamente, pelos passos abaixo, Fig. 2.6 (SANTANA, 2012; LOUZADA, 2013).

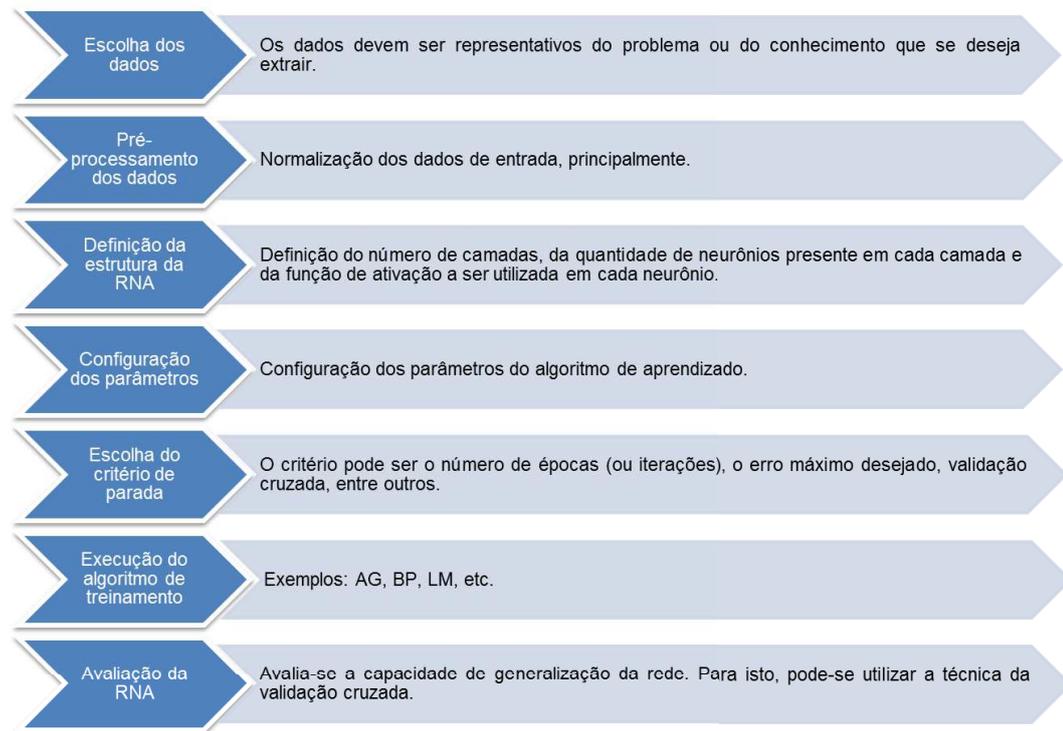


Figura 2.6 - Sequência de ações durante o treinamento de uma RNA (SANTANA, 2012; LOUZADA, 2013)

2.4.5. Pré-processamento dos dados de treinamento de uma RNA

A normalização dos dados antes que os mesmos sejam fornecidos à rede é uma etapa de pré-processamento muito importante, principalmente para um caso em que os dados de entrada são formados por diferentes variáveis, as quais possuem ordens de grandeza distintas. Dessa forma, os dados de entrada com ordem de grandeza superior acabam por mascarar o restante. Outra justificativa para normalizar os dados vem do fato de que os neurônios da RNA transmitirem sinais que variam de -1 a +1 (LOUZADA, 2013) ou de 0 a 1, dependendo da limitação imposta na saída de cada neurônio por sua respectiva função de ativação.

Também, é importante salientar que os limites máximo e mínimo adotados para a normalização dos dados, devem ser um pouco maiores (em módulo) que os valores máximo e mínimo desses mesmos dados. Pois, nem sempre é possível se trabalhar com informações que sejam completamente representativas do problema analisado. Dessa forma, ao se estabelecer uma margem de segurança em relação aos valores máximo e mínimo dos dados, evita-se que a RNA se confunda com valores fora da curva de normalização, provocados por dados de valor inferior ou superior aos apresentados para seu treinamento (LOUZADA, 2013).

Os dados de entrada, em muitos trabalhos, foram normalizados para o intervalo positivo entre 0 e 1 (SINGH; SINGH; SINGH, 2001; ZHOU; YIN; HU, 2009; SILVA; SCHIMIDT, 2016; SOUNDARARAJAN *et al.*, 2017), conforme Eq. (2.22) (ZHOU; YIN; HU, 2009; SILVA; SCHIMIDT, 2016).

$$X_n = \frac{I_n - I_{\min}}{I_{\max} - I_{\min}} \quad (2.22)$$

Onde:

- X_n é o n-ésimo valor normalizado de uma dada variável de entrada, mediante apresentação do n-ésimo padrão de entrada;
- I_n é o n-ésimo valor, antes da normalização, de uma dada variável de entrada, mediante apresentação do n-ésimo padrão de entrada;
- I_{\max} é o valor máximo, antes da normalização, de uma dada variável de entrada, mediante apresentação de todos os padrões de entrada;
- I_{\min} é o valor mínimo, antes da normalização, de uma dada variável de entrada, mediante apresentação de todos os padrões de entrada.

A redução das variáveis de entrada de uma RNA também é um tipo de pré-processamento dos dados e ela pode ser realizada através do método conhecido como Análise de Componentes Principais ou *Principal Component Analysis* (PCA).

A ideia central da PCA é reduzir a dimensão de um conjunto de dados com um grande número de variáveis inter-relacionadas, mantendo o máximo possível a variância presente no conjunto de dados. Isso é conseguido através da transformação desse conjunto para um novo conjunto de variáveis, que são as componentes principais (PCs – *Principal Components*), que não são correlacionadas e que são ordenadas de tal forma que as primeiras representam a maior parte da variância presente em todas as variáveis originais (JOLLIFFE, 2002). Essas PCs passam a ser as novas entradas da RNA.

Cada PC obtida quando os dados são reduzidos é escrita como uma combinação linear desses dados, conforme Eq. (2.23) (JOLLIFFE, 1973).

$$PC_j = a_{j1}x_1 + a_{j2}x_2 + a_{j3}x_3 + \dots + a_{jk}x_k \quad (2.23)$$

Onde a_{jk} é o autovetor ou coeficiente de ponderação da variável x_k e PC_j é a j-ésima PC do novo conjunto de dados.

Uma vantagem das PCs sobre as variáveis originais é que estas podem guardar correlações entre si, enquanto aquelas são ortogonais entre si, de forma que cada PC traz

uma informação estatística diferente (TAKAHASHI, 2006). A redução dimensional do conjunto de dados através das PCs também é útil para diminuir o número de parâmetros a serem ajustados (pesos sinápticos e *bias*) pela RNA durante o aprendizado (MORAIS, 2011).

A desvantagem da utilização da PCA é que essa técnica apenas considera relações lineares entre os componentes do vetor de entrada. Ao reduzir a dimensão utilizando uma transformação linear, podem-se perder algumas informações não lineares. Uma vez que o principal objetivo da utilização de RNAs é adquirir o poder de suas capacidades de mapeamento não linear, deve-se ter cuidado ao empregar as PCs para reduzir a dimensão das entradas antes de aplicá-las à RNA (HAGAN *et al.*, 2014).

Um dos passos para realizar a PCA consiste na centralização dos dados em torno da média (média igual a zero), Eq. (2.24) (MORAIS, 2011).

$$xc_i = \frac{x_i - \bar{x}}{s} \quad (2.24)$$

Onde: xc_i são os valores dos dados após a centralização, x_i são os i -ésimos dados, sendo $i = 1, 2, \dots, n$ (número total de dados), \bar{x} é a média amostral da variável x_i e s é o desvio padrão amostral da variável x_i .

Para Jolliffe (1972), o número de variáveis originais mantidas após a PCA é igual ao número de autovalores maiores que 0,7, sendo este o melhor critério para a decisão sobre quantas variáveis rejeitar e, conseqüentemente, quantas variáveis manter e quais PCs são as mais significativas. Alternativamente, o número de variáveis mantidas é igual ao número de PCs necessárias para explicar uma porcentagem superior a 80 % da variância total dos dados.

Entre os métodos de descarte de variáveis que utilizam as PCs estão: B1, B2, B3 e B4 (JOLLIFFE, 1972). Os métodos B1, B2 e B3 correspondem a um procedimento no qual o descarte ocorre através da análise das últimas PCs, as quais também são descartadas. Nos métodos B1 e B2, as variáveis associadas com cada uma dessas PCs são excluídas e as variáveis remanescentes são mantidas. Uma variável associada é aquela que tem o maior valor absoluto do coeficiente de uma dada PC.

O método B1 iterativamente repete a PCA em cada subconjunto restante de variáveis até que todos os autovalores sejam maiores que um dado valor (normalmente 0,7), enquanto que o método B2 realiza uma única PCA. No método B3, para cada uma das variáveis originais, calcula-se a soma dos quadrados dos coeficientes da variável nos

últimos PCs e as variáveis rejeitadas são aquelas para as quais essa soma é a maior (JOLLIFFE, 1972).

Já o método B4 corresponde a um procedimento que descarta variáveis através da análise das primeiras PCs, as quais são mantidas. Dessa forma, cada variável associada a cada uma dessas CP é mantida e as outras variáveis remanescentes são descartadas (JOLLIFFE, 1972).

Jolliffe (1972) realizou comparações utilizando dados simulados entre os métodos B2 e B4, que utilizam PCs, e com vários outros métodos de seleção de subconjuntos que não utilizam PCs. Os resultados mostraram que os métodos B2 e B4 reteram ou mantiveram os melhores subconjuntos com mais frequência do que os outros métodos considerados. Mas em contrapartida, os métodos B2 e B4 também selecionaram os subconjuntos ruins, ao invés de selecionar subconjuntos bons ou moderados. O método B4 foi o mais extremo nesse contexto, pois selecionou os subconjuntos “melhores” e “ruins” mais frequentemente do que qualquer outro método e selecionou os subconjuntos “moderados” ou “bons” menos frequentemente (JOLLIFFE, 2002).

Ainda, Cadima e Jolliffe (1995) alertam que o mecanismo de seleção desses métodos anteriormente apresentados pode ser não confiável porque depende apenas dos coeficientes das PCs. Assim, ele negligencia não apenas o desvio padrão dos valores das variáveis, que também determina a importância de cada variável na combinação linear, mas também os padrões de correlações entre essas variáveis.

Em virtude do anteriormente exposto, constata-se que a técnica PCA aplicada no pré-processamento dos dados para o treinamento de uma RNA deve ser analisada com cautela, já que, dependendo do problema em análise, ela pode ser vantajosa, aprimorando as capacidades de previsão da RNA (SILVA; SCHIMIDT, 2016; BALAS; KOÇ; TÜR, 2010; MORAIS, 2011) ou não (SILVA; ALMEIDA e YAMAKAMI, 2012).

2.4.6. Definição da quantidade de neurônios

Para controlar a complexidade do modelo de uma RNA pode-se, como uma primeira abordagem, variar o número de parâmetros da rede, como alterar a quantidade de neurônios escondidos ou ocultos. (BISHOP, 1995).

Segundo Santana (2012), a definição do tamanho da rede, bem como sua arquitetura, muitas vezes é realizada a partir de um processo de tentativa e erro ou com base em conhecimentos empíricos e, conseqüentemente, a escolha de uma boa estrutura pode consumir muito tempo.

Ainda, conforme Powar e Date (2015), o aumento desnecessário dos neurônios ocultos ajusta erroneamente (*overfit*) os dados e produz resultados inexatos.

2.4.7. Inicialização dos pesos e bias

Uma boa escolha para os valores iniciais dos pesos sinápticos da rede pode ser de grande valia para que um projeto seja bem-sucedido. Para isso, devem-se evitar os extremos. Por exemplo, quando são atribuídos valores iniciais grandes aos pesos sinápticos, é muito provável que os neurônios da rede sejam levados à saturação, o que pode reduzir a velocidade do processo de aprendizagem (HAYKIN, 2009).

2.4.8. Critério de parada do treinamento de uma RNA

Para a maioria das aplicações de RNA, o erro de treinamento nunca converge identicamente para zero. Por esta razão, é necessário estabelecer um critério para decidir quando parar o treinamento. Esse critério pode ser parar o treinamento quando o erro atinge um limite especificado. Todavia, é normalmente difícil saber qual é o nível aceitável de erro. O critério mais simples, então, é parar o treinamento depois de alcançado um número fixo de iterações. E, mesmo assim, é difícil saber quantas iterações serão necessárias. Em virtude disso, o número máximo de iterações é normalmente definido razoavelmente alto. Se os pesos não tiverem convergido depois de atingido o número máximo de iterações, o treinamento pode ser reiniciado usando os pesos finais da primeira execução como condições iniciais para a próxima execução do treinamento (HAGAN *et al.*, 2014).

2.4.9. Generalização da RNA

O objetivo do treinamento de uma RNA não é aprender uma representação exata dos próprios dados de treinamento, mas sim construir um modelo estatístico do processo que gera os dados. Ou seja, o importante é saber se a rede é capaz de exibir uma boa generalização, isto é, fazer boas previsões para novas entradas (BISHOP, 1995).

Visto isso, para que a RNA não reconheça somente os padrões do conjunto de treinamento, um procedimento de validação é executado. Essa validação, ou validação cruzada é realizada conforme descrito a seguir.

Inicialmente, divide-se o conjunto dos dados de entrada em três subconjuntos, quais sejam: subconjunto de treinamento, subconjunto de validação e subconjunto de teste. Normalmente, o subconjunto de treinamento representa um valor em torno de 70 % de todos os dados, enquanto que o percentual dos subconjuntos de validação e teste estão por volta de 20 % e 10 %, respectivamente (LOUZADA, 2013). Hagan *et al.* (2014) dividiram os dados de forma similar: 70 % para o treinamento, 15 % para validação e 15 % para teste. No trabalho de Karimirad; Chauhan; Shirinzadeh (2014), os dados foram divididos da seguinte forma: 60 % para treinamento, 20 % para validação e 20 % para teste.

O treinamento da RNA é iniciado apresentando todos os padrões do conjunto de treinamento. O conjunto de validação também é apresentado e o erro de validação é monitorado durante o processo de treinamento. Quando o erro no conjunto de validação aumenta para várias iterações, os pesos que produziram o erro mínimo no conjunto de validação são usados como pesos finais da rede treinada (HAGAN *et al.*, 2014).

No ponto de mínimo da curva de validação é correto afirmar que, apesar de a rede melhorar o seu desempenho com os dados do conjunto de treinamento, ela começa a perder poder de generalização. Nessa condição, a rede está atendo-se somente aos padrões de treinamento e não mais conseguindo representar outros padrões. Esse fenômeno é conhecido como super treinamento ou *overfitting* (LOUZADA, 2013).

Na Figura 2.7, o ponto “a” indica o ponto de parada antecipada do treinamento (*early stopping*) e o ponto “b” corresponde ao fim do treinamento, caso ele continue. Entre os pontos “a” e “b” houve um aumento do erro de validação, indicando o *overfitting* da RNA. Isso significa que houve um super treinamento da rede, ou seja, especialização da rede nos dados de treinamento e perda da capacidade de generalização.

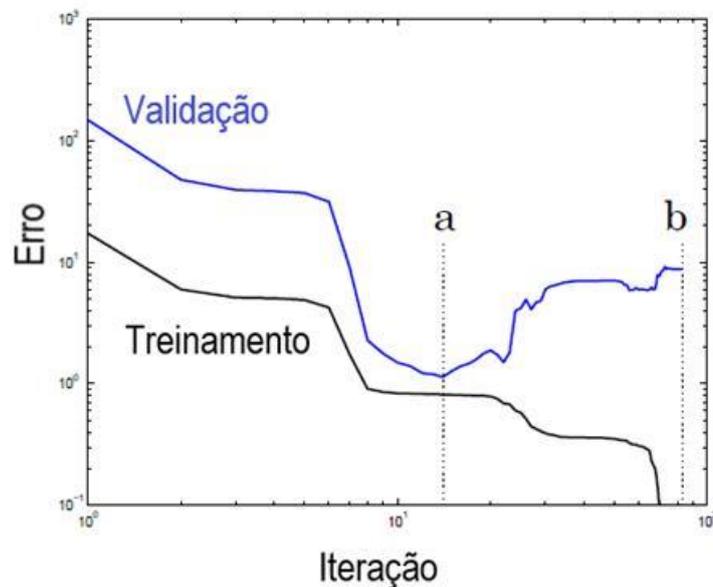


Figura 2.7 - Somatório dos erros quadráticos em função das iterações durante o treinamento. O ponto "a" indicia o ponto de parada antecipada do treinamento e o ponto "b" corresponde ao fim do treinamento caso ele continuasse, adaptado de (HAGAN *et al.*, 2014)

No intuito de se obter uma melhor generalização, é viável que a RNA apresente uma resposta suave, que acontece quando não há crescimento abrupto do erro de validação. Esta é uma das motivações para se empregar as técnicas de regularização, as quais são destinadas a encorajar mapeamentos de rede suaves (BISHOP, 1995).

Em relação ao subconjunto de teste, ele é importante porque permite verificar a resposta direta da RNA treinada em relação a um novo padrão de entrada, até então desconhecido por essa rede. Assim, o teste dessa rede é uma das formas de se analisar, também, a capacidade da mesma em generalizar o conhecimento adquirido no processo de treinamento.

2.5. Algoritmos Genéticos (AGs)

O AG baseia-se na teoria da evolução de Darwin (SALGADO *et al.*, 2007). Em virtude disso, o AG busca a solução ótima global de um problema através da submissão de uma população de indivíduos a um processo de evolução, por vários ciclos ou gerações. Esses indivíduos são os candidatos a soluções desse problema e a evolução dos mesmos acontece pelos principais operadores genéticos, quais sejam: seleção, reprodução e mutação. Esses indivíduos são representados por cromossomos, cada um associado a uma aptidão (desempenho de cada indivíduo na solução do problema), o que irá definir o mecanismo de seleção (FREITAS, 2014).

Em relação aos métodos de otimização clássicos, os AGs diferenciam-se em quatro pontos principais (DE OLIVEIRA, 2011):

- Operam em um espaço de soluções codificadas e não no espaço de busca diretamente;
- Operam em um conjunto (população) de pontos e não a partir de um ponto isolado;
- Necessitam somente de informação sobre o valor da função objetivo para cada membro da população e não requerem derivadas ou qualquer outro tipo de conhecimento;
- Usam regras de transição probabilísticas, e não determinísticas.

Na Figura 2.8 está representada a sequência das operações básicas de um AG (FREITAS, 2014).

A etapa inicial do AG é a criação da população inicial, que consiste em definir a quantidade e a representação dos indivíduos. O tamanho populacional mínimo é o menor valor no qual o AG converge para o ótimo (DE OLIVEIRA, 2011) ou próximo ao ótimo. Cada indivíduo da população é um candidato potencial à solução do problema e pode ser representado, por exemplo, das seguintes formas: binária, real e inteira. Uma vez definida a representação, os indivíduos são gerados aleatoriamente.

O cálculo da aptidão é feito pela função de avaliação ou função objetivo (ou desempenho), que pode ser uma função de máximo ou de mínimo. Assim, a aptidão está

relacionada com o resultado obtido quando o indivíduo é testado nessa função. Essa função indicará o quanto cada indivíduo da população está próximo da melhor solução para o problema, sendo esse procedimento realizado para todos os indivíduos (FREITAS, 2014).

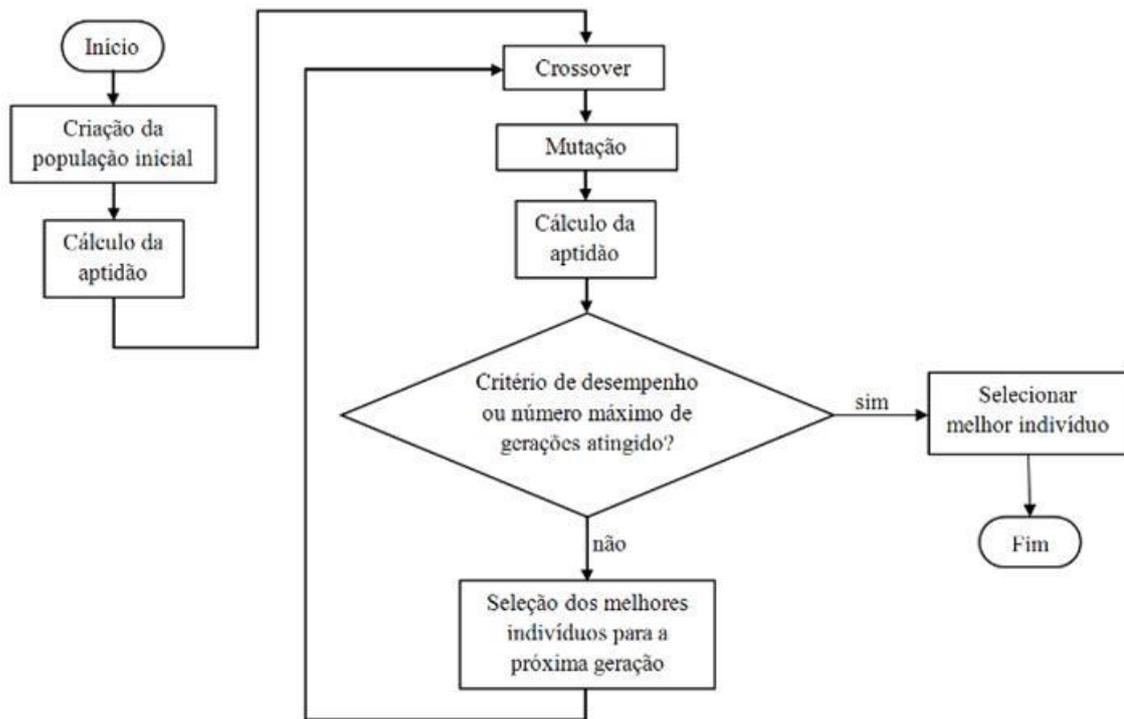


Figura 2.8 - Operações básicas de um AG (FREITAS, 2014)

O AG é composto por uma sequência de gerações ou iterações, sendo que a cada uma dessas gerações são executados os seguintes procedimentos evolutivos na população: seleção dos indivíduos (pais) para a reprodução através da taxa de *crossover* (recombinação); reprodução dos pais gerando os filhos; mutação dos filhos através da taxa de mutação; e seleção dos indivíduos para a próxima geração, também conhecida como reinserção da população.

A seleção dos pais para a reprodução ou *crossover* consiste em selecionar, de acordo com um determinado método, pares de indivíduos da população. Cada par de pais troca material genético, gerando um par de novos indivíduos, que são os filhos e, assim, transmitindo suas características genéticas para a próxima geração. Dentre os métodos existentes, são listados: *ranking*, torneio e truncamento (DE OLIVEIRA, 2011).

A diferença entre os métodos de seleção é denominada de pressão seletiva. Quanto maior a chance de os indivíduos com maior aptidão serem sorteados, maior é a pressão seletiva. Quanto maior a pressão seletiva, menor será o número de gerações necessárias

para se chegar à solução, porém maior será o risco de convergência prematura, ou seja, maior é o risco de o AG convergir para um mínimo local (DE OLIVEIRA, 2011; FREITAS, 2014).

Dentre os tipos de *crossover* existentes, quando se trata de um indivíduo com representação binária, podem-se citar: *crossover* simples, *crossover* múltiplo e *crossover* uniforme (DE OLIVEIRA, 2011).

Em relação à mutação, tem-se que, para um indivíduo com representação binária (LIMA, 2008; KARAK; CHATTERJEE; BANDOPADHYAY, 2015), altera-se um ou mais bits do cromossomo, modificando-os pelo seu complemento binário. E a taxa de mutação pode ser dada por bit ou por indivíduo. A mutação visa introduzir e manter a diversidade genética na população através de modificações aleatórias em um ou mais genes de alguns filhos selecionados.

Quanto à seleção dos indivíduos para a próxima geração, são listados alguns métodos, a saber: reinserção pura, reinserção uniforme, reinserção ordenada e elitismo (DE OLIVEIRA, 2011).

Os parâmetros de desempenho de um AG são as variáveis que devem ser definidas para a sua construção, tais como: representação do indivíduo, quantidade de indivíduos da população total, quantidade de indivíduos selecionados a cada geração, métodos de seleção para a próxima geração e para o *crossover*, tipos de *crossover* e de mutação, número de filhos por geração e quantidade de filhos que sofrerão mutação (FREITAS, 2014).

Esses parâmetros devem ser analisados através de testes de forma a encontrar a melhor configuração para o AG de acordo com o problema a ser resolvido, evitando convergência prematura, que resulta no risco de não encontrar respostas satisfatórias, ou, por outro lado, esforço computacional desnecessário (FREITAS, 2014). Bento e Kagan (2008), por exemplo, analisaram diferentes combinações de operadores e parâmetros do AG para a aplicação na minimização de perdas elétricas em redes de distribuição.

Por fim, as principais vantagens dos AGs são: técnica de busca global, viabiliza a otimização de problemas mal estruturados e dispensa a formulação matemática precisa do problema. Esta técnica é robusta e aplicável a uma grande diversidade de problemas e, para muitos deles, é capaz de encontrar soluções sub-ótimas, inclusive ótimas, em um tempo razoável. Em contrapartida, as principais desvantagens dos AGs são: dificuldade para se achar o ótimo global exato, requerem um grande número de avaliações das funções de aptidão e suas restrições e numerosas possibilidades de configurações podendo complicar a resolução (FREITAS, 2014).

2.6. Método de Levenberg-Marquadt (LM) com regularização bayesiana (RB) - LMRB

O algoritmo de LM combina o método de descida mais íngreme (ou gradiente descendente) e o algoritmo de Gauss-Newton. Ele tem a vantagem de possuir a velocidade do algoritmo de Gauss-Newton e a estabilidade do método de descida mais íngreme. Ele é também mais robusto do que o algoritmo de Gauss-Newton, porque, em muitos casos, pode convergir bem, mesmo que a superfície do erro seja muito mais complexa do que a situação quadrática (YU; WILAMOWSKI, 2011).

Embora o algoritmo de LM tenda a ser um pouco mais lento que o algoritmo de Gauss-Newton (em situação de convergência), ele converge muito mais rapidamente do que o método de descida mais íngreme (YU; WILAMOWSKI, 2011). Isso acontece porque o algoritmo LM foi desenvolvido como uma abordagem que usa informação de segunda ordem para aumentar a velocidade de treinamento, sem a necessidade de computar diretamente a matriz Hessiana, que contém as derivadas de segunda ordem (ALMEIDA, 2007).

A idéia básica do algoritmo LM é que ele realiza um processo de treinamento combinado: em torno da área com curvatura complexa, o algoritmo LM muda para o algoritmo de descida mais íngreme, até que a curvatura local seja adequada para fazer uma aproximação quadrática; então, aproximadamente, torna-se o algoritmo de Gauss-Newton, que pode acelerar significativamente a convergência (YU; WILAMOWSKI, 2011).

A seguir são apresentados, brevemente, os métodos de Newton, Gauss-Newton e LM, empregados para atualizar os pesos da RNA.

O método de Newton necessita do cálculo das derivadas da função erro em relação aos pesos para a obtenção da matriz Hessiana, podendo esse cálculo ser muito complicado. A fim de simplificar o processo de cálculo, a matriz Jacobiana \mathbf{J} foi introduzida através do método de Gauss-Newton, conforme Eq. (2.25) (YU; WILAMOWSKI, 2011).

$$\mathbf{J} = \begin{bmatrix} \frac{\partial e_{1,1}}{\partial w_1} & \frac{\partial e_{1,1}}{\partial w_2} & \dots & \frac{\partial e_{1,1}}{\partial w_N} \\ \frac{\partial e_{1,2}}{\partial w_1} & \frac{\partial e_{1,2}}{\partial w_2} & \dots & \frac{\partial e_{1,2}}{\partial w_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{1,M}}{\partial w_1} & \frac{\partial e_{1,M}}{\partial w_2} & \dots & \frac{\partial e_{1,M}}{\partial w_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{P,1}}{\partial w_1} & \frac{\partial e_{P,1}}{\partial w_2} & \dots & \frac{\partial e_{P,1}}{\partial w_N} \\ \frac{\partial e_{P,2}}{\partial w_1} & \frac{\partial e_{P,2}}{\partial w_2} & \dots & \frac{\partial e_{P,2}}{\partial w_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{P,M}}{\partial w_1} & \frac{\partial e_{P,M}}{\partial w_2} & \dots & \frac{\partial e_{P,M}}{\partial w_N} \end{bmatrix} \quad (2.25)$$

Onde:

- M é o número total de saídas da RNA;
- P é o número de padrões de entrada da RNA;
- w_N é o N -ésimo peso da rede, sendo N o número total de pesos;
- $e_{p,m}$ é o erro de treinamento na saída m ($m=1$ a M) da RNA, quando aplicado o padrão p ($p=1$ a P);
- $\frac{\partial e_{p,m}}{\partial w_N}$ é a derivada primeira do erro de treinamento na saída.

Nesses métodos considera-se que a função objetivo que se deseja minimizar é o somatório dos erros quadráticos (E), conforme Eq. (2.26) (YU; WILAMOWSKI, 2011).

$$E(\mathbf{x}, \mathbf{w}) = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{p,m}^2 \quad (2.26)$$

Onde:

- \mathbf{x} é o vetor de entrada;
- \mathbf{w} é o vetor de pesos;
- $e_{p,m}$ é obtido pela Eq. (2.27)

$$e_{p,m} = d_{p,m} - o_{p,m} \quad (2.27)$$

Onde:

- \mathbf{d} é o vetor de saída desejado;
- \mathbf{o} é o vetor de saída atual.

Os elementos do vetor gradiente de erro g_i são calculados pela Eq. (2.28) (YU; WILAMOWSKI, 2011).

$$g_i = \frac{\partial E}{\partial w_i} = \sum_{p=1}^P \sum_{m=1}^M \left(\frac{\partial e_{p,m}}{\partial w_i} e_{p,m} \right) \quad (2.28)$$

A relação entre o vetor gradiente de erro e a matriz Jacobiana \mathbf{J} é dada pela Eq. (2.29), após combinar as Eqs. (2.25) e (2.28) (YU; WILAMOWSKI, 2011).

$$\mathbf{g} = \mathbf{J}^T \mathbf{e} \quad (2.29)$$

Onde o vetor de erro é dado pela Eq. (2.30) (YU; WILAMOWSKI, 2011).

$$\mathbf{e} = \begin{bmatrix} e_{1,1} \\ e_{1,2} \\ \dots \\ e_{1,M} \\ \dots \\ e_{P,1} \\ e_{P,2} \\ \dots \\ e_{P,M} \end{bmatrix} \quad (2.30)$$

A relação entre a matriz Hessiana \mathbf{H} e a matriz Jacobiana \mathbf{J} é escrita pela Eq. (2.31) (YU; WILAMOWSKI, 2011).

$$\mathbf{H} \approx \mathbf{J}^T \mathbf{J} \quad (2.31)$$

O algoritmo de Gauss-Newton é escrito conforme a Eq. (2.32) (YU; WILAMOWSKI, 2011).

$$\mathbf{w}_{k+1} = \mathbf{w}_k - (\mathbf{J}_k^T \mathbf{J}_k)^{-1} \mathbf{J}_k^T \mathbf{e}_k \quad (2.32)$$

Mesmo o algoritmo de Gauss-Newton tendo a vantagem, em relação ao método de Newton, de não precisar do cálculo das derivadas de segunda ordem da função objetivo de erro, ele ainda permanece com o mesmo problema de convergência do algoritmo de Newton. Matematicamente, o problema está associado ao fato de a matriz $\mathbf{J}^T \mathbf{J}$ não ser invertível em alguns casos (YU; WILAMOWSKI, 2011).

Visto isso, para se certificar de que a matriz Hessiana aproximada $\mathbf{J}^T \mathbf{J}$ é invertível, ou não singular, o algoritmo de LM introduz outra aproximação à matriz de Hessiana, dada pela Eq. (2.33) (YU; WILAMOWSKI, 2011).

$$\mathbf{H} \approx \mathbf{J}^T \mathbf{J} + \mu \mathbf{I} \quad (2.33)$$

Onde:

- μ é o coeficiente de combinação e é sempre positivo;
- \mathbf{I} é a matriz identidade.

Da Equação (2.33), pode-se notar que os elementos na diagonal principal da matriz Hessiana aproximada serão maiores do que zero. Portanto, com essa aproximação, pode-se ter certeza de que a matriz \mathbf{H} é sempre invertível (YU; WILAMOWSKI, 2011).

Em virtude dessa aproximação da matriz Hessiana, o algoritmo de LM é descrito combinando as Eqs. (2.32) e (2.33), resultando na Eq. (2.34) (YU; WILAMOWSKI, 2011)

$$w_{k+1} = w_k - (J_k^T J_k + \mu I)^{-1} J_k^T e_k \quad (2.34)$$

O algoritmo LM alterna entre os dois algoritmos anteriormente citados durante o processo de treinamento, ou seja, o algoritmo de descida mais íngreme (ou *backpropagation*) e o algoritmo de Gauss-Newton. Quando o coeficiente de combinação μ é muito pequeno (quase zero), a Eq. (2.34) se aproxima da Eq. (2.32) e o algoritmo Gauss-Newton é usado. Quando o coeficiente de combinação μ é muito grande, a Eq. (2.34) se aproxima da Eq. (2.35), que atualiza os pesos segundo o método BP, e o método de descida mais íngreme é usado (YU; WILAMOWSKI, 2011).

$$w_{k+1} = w_k - \rho g_k \quad (2.35)$$

Onde ρ é a constante de aprendizado.

A definição inicial do parâmetro μ é de fundamental importância para um bom desempenho do algoritmo LM, pois é partindo desse valor inicial que o algoritmo inicia a busca por um ótimo local (ALMEIDA, 2007). Suratgar; Tavakoli; Hoseinabadi (2005), no intuito de reduzir as oscilações e aumentar a velocidade de convergência do processo de treinamento, modificaram o método de LM através da criação de uma fórmula para μ (Eq. (2.36)), que até então era um número constante. O parâmetro μ não pode ser maior que 10^{10} (KAYRI, 2016).

$$\mu = 0,01 e^T e \quad (2.36)$$

Onde a matriz $e^T e$ nada mais é do que a soma dos erros quadráticos do treinamento da RNA.

Segundo Almeida e Ludermir (2006), o bom desempenho do algoritmo LM, além da forma de atualização dos pesos, é fruto da união de uma boa escolha do parâmetro μ (que pode ser visto também como a taxa de aprendizagem para o algoritmo LM) e do tamanho da rede. Esse algoritmo consegue treinar de forma muito rápida redes de tamanho moderado, até com cem pesos a serem ajustados.

A Tabela 2.3 representa a comparação entre esses diferentes algoritmos: BP, Newton, Gauss-Newton e LM (YU; WILAMOWSKI, 2011).

Tabela 2.3 – Comparação entre diferentes algoritmos de otimização (YU; WILAMOWSKI, 2011)

Algoritmos	Regras de atualização dos pesos	Convergência	Complexidade computacional
BP	$w_{k+1} = w_k - \alpha g_k$	Estável, lenta	Gradiente do erro
Newton	$w_{k+1} = w_k - (H_k)^{-1} g_k$	Instável, rápida	Gradiente do erro e matriz Hessiana
Gauss-Newton	$w_{k+1} = w_k - (J_k^T J_k)^{-1} J_k^T e_k$	Instável, rápida	Matriz Jacobiana
LM	$w_{k+1} = w_k - (J_k^T J_k + \mu I)^{-1} J_k^T e_k$	Estável, rápida	Matriz Jacobiana

Nota-se da Tabela 2.3 que o algoritmo LM apresenta as melhores características de convergência e complexidade computacional, dentre os métodos analisados. Para otimizar esse algoritmo, pode-se inserir a regularização bayesiana.

Regularização é uma denominação genérica para métodos envolvendo a modificação da função de desempenho das RNAs, que normalmente é a soma dos quadrados dos erros de treinamento, objetivando a melhoria de sua capacidade de generalização (CINTRA, 2003).

E, dentro do contexto de RNAs, os métodos bayesianos oferecem uma série de características importantes, pois permitem que os valores dos coeficientes de regularização sejam selecionados usando apenas os dados de treinamento, sem a necessidade de usar separadamente dados de treinamento e validação (BISHOP, 1995).

Portanto, a regularização bayesiana é implementada no algoritmo de LM para minimizar uma combinação linear de erros e pesos quadráticos, Eq. (2.37). Esta implementação é uma das abordagens para superar o problema do *overfitting*. Assim, reduz-se também a necessidade de se testar um número diferente de neurônios escondidos para um problema (PANDYA; DENNIS; RUSSELL, 2017). Com a regularização, qualquer rede modestamente grande deve ser capaz de representar suficientemente a verdadeira função (FORESEE; HAGAN, 1997).

Vale salientar que, tipicamente, a função objetivo é $F = E_d$. Todavia, a regularização considera um termo adicional, conforme Eq. (2.37) (FORESEE; HAGAN, 1997).

$$F = \beta E_d + \alpha E_w \quad (2.37)$$

Onde:

- E_d é o somatório dos quadrados dos erros, conforme Eq. (2.26);
- E_w é o somatório dos quadrados dos pesos;
- α e β são os hiperparâmetros que serão otimizados para minimizar a função objetivo. Segundo Bishop (1995), eles têm essa denominação de hiperparâmetros, pois controlam a distribuição de outros parâmetros (pesos e *bias*).

O principal problema com a implementação da regularização está na definição dos valores corretos para os parâmetros α e β da função objetivo (FORESEE; HAGAN, 1997).

Os procedimentos para a implementação do algoritmo LM para o treinamento de uma RNA estão descritos no trabalho de Yu e Wilamowski (2011). Com a inserção da regularização bayesiana no método de LM (LMRB), esses procedimentos são adaptados, conforme descrito a seguir (MACKAY, 1992; FORESEE; HAGAN, 1997; POLAND, 2001; SOUZA, 2009; YU; WILAMOWSKI, 2011; PANDYA; DENNIS; RUSSELL, 2017).

1. Inicializar os pesos da RNA;
2. Calcular a matriz Jacobiana. Esta matriz pode ser calculada conforme está descrito em Yu e Wilamowski (2011);
3. Calcular o gradiente do erro, conforme a Eq. (2.28);
4. Aproximar a matriz Hessiana, conforme a Eq. (2.33);
5. Inicializar α e β , por exemplo, $\alpha=0$ e $\beta=1$ (FORESEE; HAGAN, 1997);
6. Calcular a função objetivo, conforme a Eq. (2.37);
7. Atualizar os pesos conforme a Eq. (2.34);
8. Recalcular a função objetivo (Eq. (2.37)) utilizando os pesos atualizados;
9. Comparar o valor da função objetivo atualizada em relação ao valor da função objetivo calculada inicialmente;
 - a. Se o valor da função objetivo atualizada tiver diminuído, aceitar os novos pesos e diminuir o coeficiente μ pelo fator γ ($\mu = \mu/\gamma$);
 - b. Se o valor da função objetivo atualizada tiver aumentado, descartar os novos pesos e manter os anteriores e também aumentar o μ pelo fator γ ($\mu = \mu\gamma$);
10. Atualizar os hiperparâmetros bayesianos utilizando as seguintes fórmulas, Eqs. (2.38) a (2.40).

$$\gamma = W - (\alpha \text{tr}(\mathbf{H}^{-1})) \quad (2.38)$$

Onde W é o número de parâmetros da RNA (pesos e *bias*) e tr é o traço da inversa da matriz Hessiana (traço de uma matriz quadrada é a soma dos elementos da diagonal principal dessa matriz). Esse hiperparâmetro γ pode variar de 0 a W (MACKAY, 1992).

$$\beta = (N - \gamma)/(2E_d) \quad (2.39)$$

Onde N é o número de entradas-padrão do conjunto de treinamento (MACKAY, 1992).

$$\alpha = W/(2E_w + \text{tr}(\mathbf{H}^{-1})) \quad (2.40)$$

CAPÍTULO III

METODOLOGIA

A metodologia adotada no presente trabalho é apresentada na Fig. 3.1. Ela visou o desenvolvimento de um programa computacional para treinar RNAs e, assim, estimar as propriedades mecânicas a partir de curvas de ensaios de macroindentação instrumentada. Neste trabalho foram utilizados materiais cujos ensaios foram realizados através do *PropInSitu 2* por Nicolosi (2015).

As propriedades mecânicas avaliadas neste programa foram: dureza Brinell, limite de resistência e limite de escoamento. Para cada uma delas foi desenvolvida uma RNAE (RNA evolutiva), cujo treinamento supervisionado foi realizado considerando diferentes arquiteturas de RNAE, parâmetros de desempenho do AG e algoritmos de treinamento.

Cada RNAE foi treinada com três algoritmos diferentes, que foram:

- AG-LMRB, algoritmo híbrido composto pelos métodos AG e LMRB;
- AG-LMRB*, algoritmo híbrido composto pelos métodos AG e LMRB, o qual se diferencia do algoritmo AG-LMRB por realizar uma operação a mais que é a de verificar a similaridade entre os indivíduos da população do AG;
- AG.

O programa de cálculo das propriedades mecânicas foi desenvolvido em um computador com plataforma Windows 7 de 64 bits, dois processadores Intel® Xeon® E5-2620 de 2,40 GHz e memória RAM de 32 GB, utilizando o *software* Matlab®. Ao invés de utilizar a *Toolbox NN* desse *software* para desenvolver um modelo de RNA, neste trabalho o código da RNAE, bem como o código dos algoritmos de treinamento, foram elaborados manualmente por assim permitir maior flexibilidade de programação.

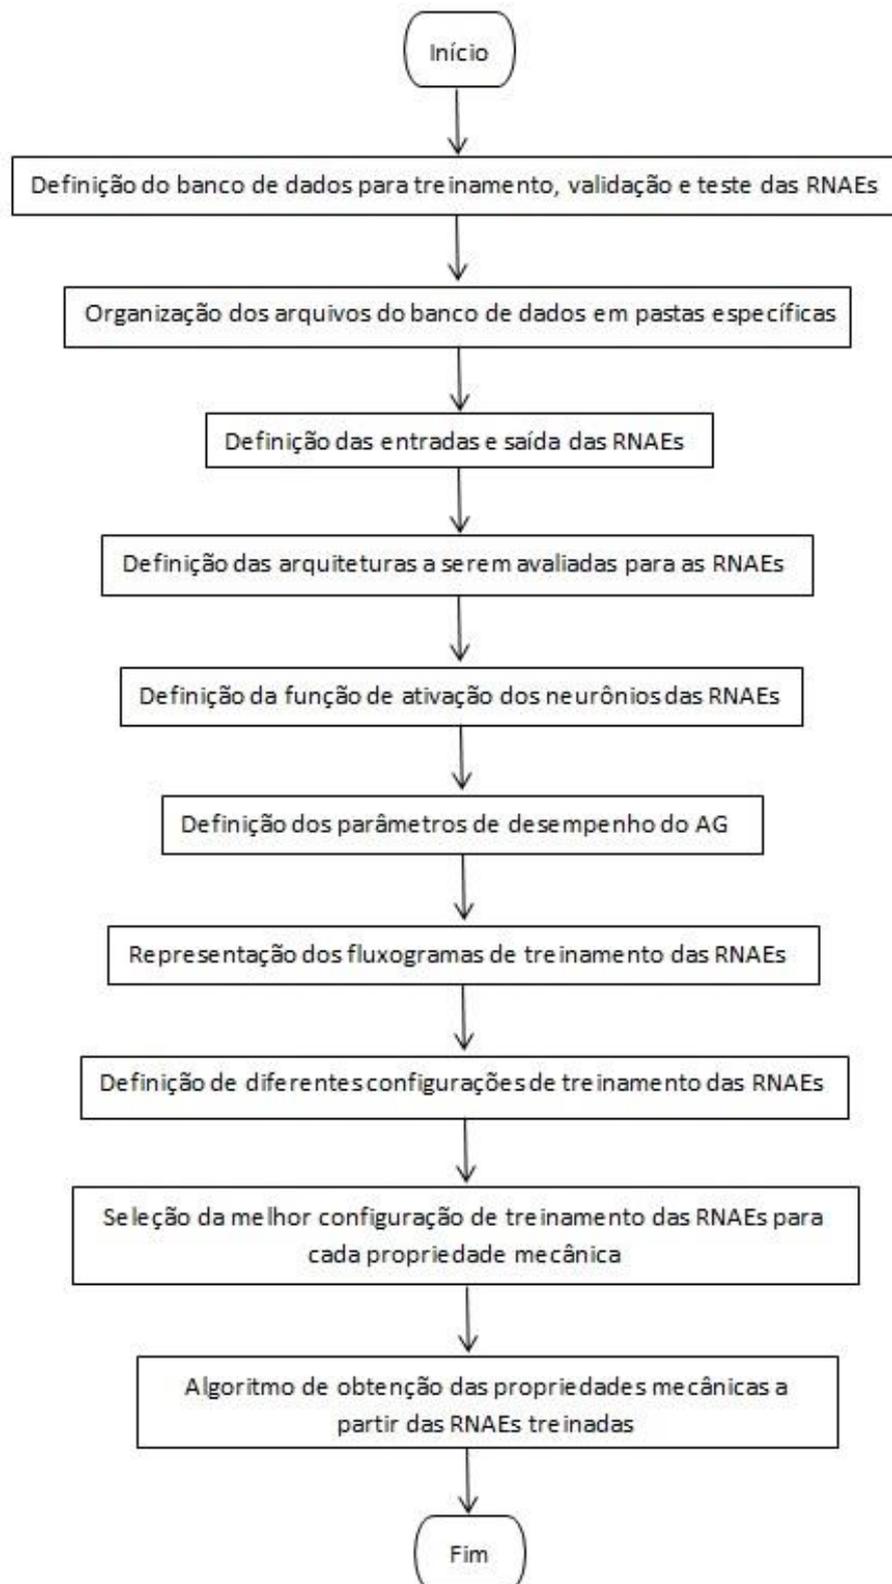


Figura 3.1 – Etapas executadas para o desenvolvimento do programa de cálculo das propriedades mecânicas

3.1. Definição do banco de dados para treinamento, validação e teste das RNAEs

O banco de dados para treinamento, validação e teste das RNAEs foi composto por ensaios de macroindentação de onze aços, realizados por Nicolosi (2015) em um macroindentador portátil (*PropInSitu 2*) do LTAD com a utilização de apenas 1 LVDT para medição de profundidade.

Dentre esses onze aços, sete deles foram denominados “A” a “G”, e os outros quatro foram os seguintes: API 5L X65, L 80, P110 e ABNT 8550, cujas composições químicas são mostradas nas Tabs. 3.1 e 3.2. Os gráficos das curvas dos ensaios de macroindentação desses aços estão no Anexo I. Como se pode observar, nem todos os materiais são bem comportados e nem todos são homogêneos. Pois, as curvas F x h dos ensaios de macroindentação de alguns materiais não estão total ou aproximadamente sobrepostas, considerando as mesmas condições de ensaio.

Tabela 3.1 – Composições químicas dos aços “A” a “G” (% em peso) (NICOLOSI, 2015)

Aço	C	S	P	Mn	Si	Cu	Cr	Mo	Al	V	Ti, Ni	Nb, W
A	0,205	0,019	0,012	0,828	0,274	0,180	0,117	0,027	0,028	0,001	Ti - 0,019 Ni - 0,088	Nb - 0,003 W - 0,006
B	0,194	0,015	0,011	1,596	0,228	-	0,165	0,035	0,002	0,002	Ti - 0,001 Ni - 0,020	-
C	0,079	0,012	0,014	1,513	0,295	-	0,059	0,074	0,024	0,040	Ti - 0,002	Nb - 0,031 W - 0,018
D	0,268	0,010	0,013	1,088	0,240	-	0,346	0,030	0,026	0,004	Ti - 0,030 Ni - 0,007	Nb - 0,006 W - 0,017
E	0,004	-	0,021	0,477	0,324	0,060	11,900	2,056	0,005	0,047	Ti - 0,157 Ni - 6,670	Nb - 0,024 W - 0,155
F	0,335	0,017	0,015	0,445	0,329	0,014	0,943	0,865	0,027	0,053	Ti - 0,017 Ni - 0,020	Nb - 0,033 W - 0,023
G	0,375	0,011	0,016	0,376	0,375	0,044	0,999	1,300	0,024	0,068	Ti - 0,004 Ni - 0,017	Nb - 0,085 W - 0,029

Dois penetradores esféricos de WC-Co, com diâmetros de 1,5 mm e 1,0 mm, e um penetrador esferocônico de diamante, com diâmetro da ponta de 400 µm, foram utilizados nos ensaios. Os certificados de calibração desses penetradores são apresentados no Anexo I do trabalho de Nicolosi (2015), nos quais estão detalhadas as tolerâncias dimensionais.

Tabela 3.2 – Composição química dos aços API 5L X65, L80, P110 (NICOLSI, 2015) e ABNT 8550 (DA SILVA, 2008) (% em peso)

Aço	C	S	P	Mn	Si	Cr	Mo	Al	V	Ti, Ni	Nb	Co, Cu
API 5L X65	0,084	0,011	0,011	1,472	0,254	0,041	0,048	0,026	0,038	Ti 0,002	0,025	Co 0,008
L80	0,266	0,015	0,010	1,077	0,231	0,307	0,055	0,022	0,003	Ti 0,022	0,001	Co 0,006
P110	0,248	0,007	0,010	1,053	0,225	0,326	0,052	0,023	0,003	Ti 0,027	-	Co 0,003
ABNT 8550	0,320	0,031	0,011	0,740	0,280	1,710	0,170	1,060	0,020	Ni 0,940	0,010	Cu 0,230

Os seguintes parâmetros foram mantidos constantes em todos os ensaios (NICOLSI, 2015):

- Número de ciclos de indentação: 10;
- Porcentagem de descarregamento em cada ciclo: 40 %.

Os seguintes valores para os módulos de elasticidade, introduzidos no programa de cálculo para determinação das propriedades mecânicas dos aços analisados, foram (NICOLSI, 2015):

- Módulo de elasticidade do material das amostras (aço): 210 GPa;
- Módulo de elasticidade do material dos penetradores de WC-Co: 645 GPa;
- Módulo de elasticidade do material do penetrador de diamante: 1140 GPa.

Além dos parâmetros gerais dos ensaios, mencionados anteriormente, outros parâmetros, agora específicos, são mostrados na Tab. 3.3.

Cada uma das amostras dos aços de “A” a “G” foram retiradas dos tubos desses aços por corte mecânico, para realização dos ensaios de macroindentação instrumentada ao longo da espessura da parede dos mesmos. Essas amostras foram disponibilizadas diretamente pelo fabricante dos tubos, que também informou os limites de escoamento e de resistência à tração desses materiais, Tab. 3.4. Como as dimensões das amostras foram reduzidas (Anexo II), não foi possível efetuar a remoção de corpos de prova para realização de ensaios de tração convencionais, com o objetivo de se confirmar as propriedades mecânicas fornecidas pelo fabricante e, portanto, estas foram assumidas como corretas (NICOLSI, 2015).

Tabela 3.3 – Parâmetros específicos dos ensaios de macroindentação instrumentada realizados nos onze aços através do *PropInSitu 2* (NICOLOSI, 2015)

Material	Diâmetro do penetrador [mm]	Força Máxima de Indentação [N]	Quantidade de ensaios de macroindentação
"A" a "G"	0,4	85	10
	1,0	294	5
		533	5
		800	5
	1,5	662	5
		1200	5
		1800	5
API 5L X65 e L80	1,5	662	5 para cada corpo de prova (CP1 a CP4)
		1800	
P110 e ABNT 8550	1,5	1200	

Tabela 3.4 – Valores médios das propriedades mecânicas de tração e de dureza dos aços de "A" a "G". Limites de escoamento e de resistência informados pelo fabricante dos tubos. Dureza Brinell obtida a partir da conversão da dureza Vickers (HV10), a qual foi medida para determinar os perfis de dureza ao longo da espessura das amostras (NICOLOSI, 2015)

Material	Limite de escoamento [MPa]	Limite de resistência [MPa]	Dureza Brinell [HBW]
A	300	463	128
B	462	567	170
C	473	545	177
D	586	699	207
E	736	823	254
F	779	874	252
G	896	954	283

Ainda conforme informações repassadas pelo fabricante, os corpos de prova de tração, usados nos ensaios para determinação das propriedades mecânicas de tração (limites de escoamento e de resistência) dos aços de "A" a "G", Tab. 3.4, foram removidos da direção longitudinal e do meio da parede dos mesmos tubos (NICOLOSI, 2015). E a medição de dureza foi realizada por Nicolosi (2015).

Vale ressaltar que, dentre os materiais “A” a “G”, apenas os aços “B” e “C” (Anexo 1 e Figs. 3.2 e 3.3) apresentam gradiente de propriedades mecânicas ao longo da espessura das amostras (Fig. 3.4) e isso se reflete no distanciamento significativo entre as curvas obtidas nos ensaios de macroindentação instrumentada, para ensaios de uma mesma configuração (NICOLSI, 2015). Cada configuração de ensaio para um determinado material é dada pela combinação entre força máxima aplicada e diâmetro do penetrador empregado.

Na Figura 3.2 está disposto o gráfico com todos os ensaios realizados na amostra do material “B”, submetida à seguinte configuração de ensaio: força máxima de 85 N e penetrador com 0,4 mm de diâmetro. Na Figura 3.3 está representado o gráfico com os ensaios executados na amostra “C” a partir da aplicação de 662 N de força máxima e de um penetrador com 1,5 mm de diâmetro.

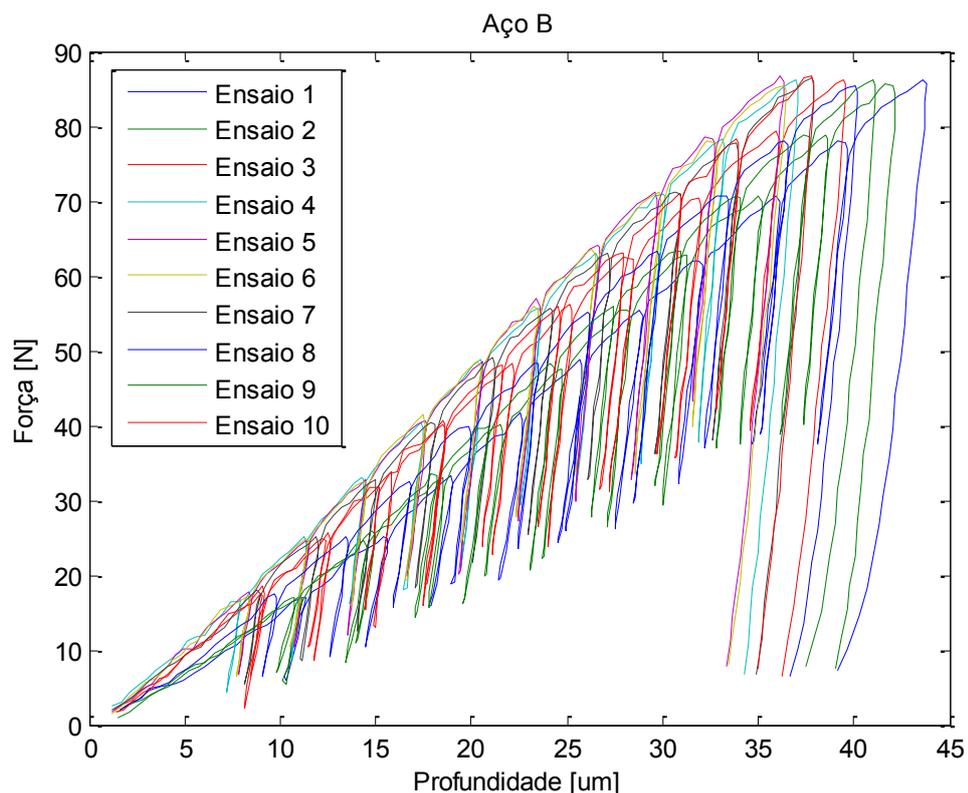


Figura 3.2 – Amostra do material “B” ensaiada com força máxima de 85 N e penetrador com diâmetro de 0,4 mm (NICOLSI, 2015)

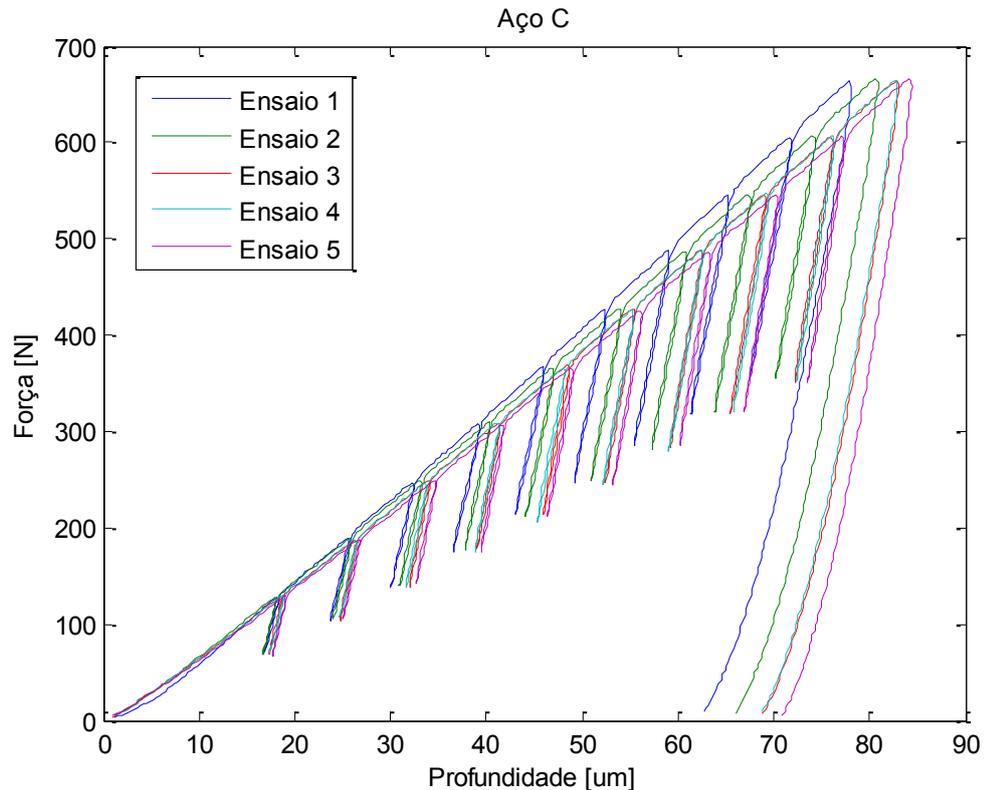
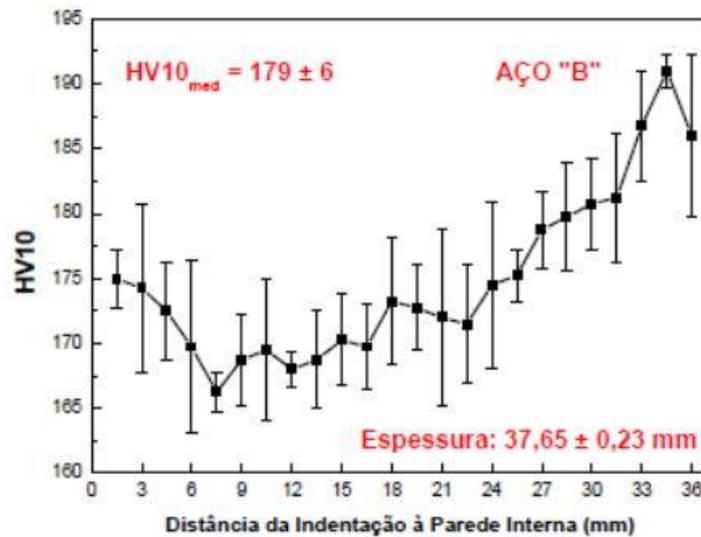


Figura 3.3 - Material “C” ensaiado com força máxima de 662 N e penetrador com diâmetro de 1,5 mm (NICOLSI, 2015)

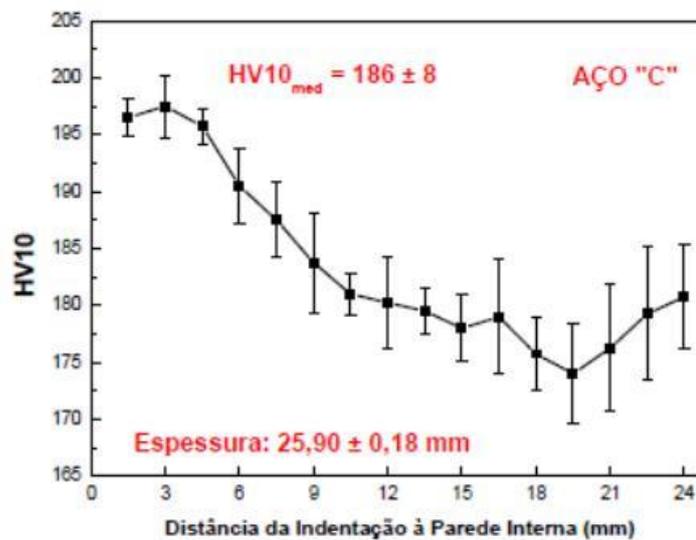
Os perfis de dureza Vickers (HV10) ao longo da espessura das amostras dos aços “B” e “C” são mostrados na Fig. 3.4.

Em relação aos tubos dos aços API 5L X65, L80 e P110, os respectivos corpos de prova de tração com seção retangular foram removidos dos mesmos na direção longitudinal e o mais próximo possível da região central da parede (Anexo II). E nas regiões dos corpos de prova nas quais houve o contato com as garras da máquina de tração foram realizados os ensaios de dureza e de macroindentação instrumentada (NICOLSI, 2015).

Para o aço ABNT 8550, os corpos de prova de tração com seção circular foram removidos das barras desse aço, após o tratamento térmico de têmpera e revenimento e da avaliação da dureza e da microestrutura usando as amostras retiradas das extremidades das barras ao final de cada etapa do tratamento (Anexo II). Assim, garantiu-se que os corpos de prova de tração foram removidos de barras nas quais o tratamento foi corretamente executado (NICOLSI, 2015).



a)



b)

Figura 3.4 – Perfis de dureza Vickers (HV10) ao longo da espessura das amostras a) do aço "B" e b) do aço "C". Os intervalos de 95 % de confiança para o valor da média estão indicados pelas barras verticais. Também estão indicadas a espessura média, medida com um paquímetro digital e a dureza média ($HV10_{med}$) para cada amostra, com os respectivos intervalos de confiança (95 %) (NICOLSI, 2015)

Para que a comparação entre propriedades mecânicas calculadas a partir de ensaios de macroindentação instrumentada com aquelas determinadas via ensaios de tração fosse possível, os ensaios de macroindentação instrumentada foram realizados nos próprios corpos de prova dos aços API 5L X65, L80 e P110 usados nos ensaios de tração, antes da realização destes, nas regiões indicadas onde há o contato com as garras da máquina de

tração (Anexo II), as quais tiveram as superfícies lixadas (1200 *mesh*). Ensaios de dureza Vickers (HV10) também foram realizados nestas regiões. Caso os ensaios de macroindentação instrumentada e de dureza fossem realizados em outras amostras retiradas dos tubos, ao invés de diretamente nos corpos de prova de tração, correr-se-ia o risco de se avaliar e comparar regiões com diferentes propriedades mecânicas, já que os tubos podem apresentar gradiente de propriedades ao longo da espessura e do comprimento (NICOLOSI, 2015).

Diferentemente dos aços API 5L X65, L80 e P110, para os quais foram usados corpos de prova de seção retangular, no caso do aço ABNT 8550, como os corpos de prova de tração foram cilíndricos, não foi possível realizar os ensaios de macroindentação diretamente nos mesmos. Por isso, trechos das barras usadas na confecção dos corpos de prova de tração foram fresados, nas partes superior e inferior, com a remoção de 4 mm de material, para realização dos ensaios de macroindentação (Anexo II). Os parâmetros de usinagem foram escolhidos visando minimizar ao máximo possível qualquer efeito de encruamento próximo à superfície. As superfícies obtidas após a etapa de fresamento foram retificadas, visando garantir o paralelismo entre faces, e uma delas, a usada nos ensaios de macroindentação e dureza, foi lixada (1200 *mesh*) (NICOLOSI, 2015).

Vale salientar que, além dos aços “B” e “C”, o tubo do qual foram extraídas as amostras do aço API 5L X65 também possuía gradiente de dureza significativo ao longo da espessura. No entanto, espera-se que os resultados nesse aço API 5L X65 não sejam influenciados por esse gradiente, já que os ensaios de macroindentação foram realizados em corpos de prova de tração extraídos o mais próximo possível da região central da parede.

Nas Tabelas 3.5 a 3.8 estão dispostas as propriedades mecânicas dos aços API 5L X65, L80, P110 e ABNT 8550.

Diante da breve descrição dos aços, cujos ensaios compõem o banco de dados, totalizando 400 ensaios, foram selecionados três subconjuntos: treinamento, validação e teste (LOUZADA, 2013; HAGAN *et al.*, 2014; KARIMIRAD; CHAUHAN; SHIRINZADEH, 2014). Essa divisão em subconjuntos, embora não necessária quando se emprega a regularização bayesiana (BISHOP, 1995), foi feita para analisar a generalização da rede e identificar a geração a partir da qual a rede tende a apresentar o *overfitting*.

O subconjunto de treinamento foi composto por um total de 260 ensaios, representando 65 % dos ensaios do banco de dados, e que foram executados nos seguintes aços: “A”, “D”, “E”, “F”, “G”, API 5L X65, ABNT 8550, Tab. 3.9. A escolha desses materiais foi baseada na premissa de que o treinamento de uma RNA deve abranger a maior faixa possível das

propriedades mecânicas dentro das possibilidades existentes no banco de dados, para que seja representativo do problema em questão.

Tabela 3.5 – Propriedades mecânicas dos corpos de prova do aço API 5L X65 obtidas via ensaio de tração e dureza (NICOLSI, 2015)

Corpo de prova	Limite de escoamento [MPa]	Limite de resistência [MPa]	Dureza Brinell** [HBW]±IC (95 %)
CP1	493	581	174±4
CP2	436	530	167±3
CP3	473	557	178±3
CP4	490	576	178±3
Média±IC (95 %)*	473±42	561±37	174±2

* Intervalo de confiança de 95 % para o valor da média

** A dureza Brinell foi obtida a partir da dureza Vickers (HV10), determinada em ensaio no durômetro, através de conversão conforme a norma ISO 18265 (ISO, 2013).

Tabela 3.6 – Propriedades mecânicas dos corpos de prova do aço L80 obtidas via ensaio de tração e dureza (NICOLSI, 2015)

Corpo de prova	Limite de escoamento [MPa]	Limite de resistência [MPa]	Dureza Brinell** [HBW]±IC (95 %)
CP1	526	643	200±3
CP2	488	573	192±7
CP3	535	643	188±3
CP4	508	624	195±6
Média±IC (95 %)*	514±33	621±52	194±3

* Intervalo de confiança de 95 % para o valor da média

** A dureza Brinell foi obtida a partir da dureza Vickers (HV10), determinada em ensaio no durômetro, através de conversão conforme a norma ISO 18265 (ISO, 2013).

Já o subconjunto de validação foi composto por um total de 60 ensaios, representando 15 % dos ensaios do banco de dados, e que foram executados nos seguintes aços: L-80 e P-110, Tab. 3.9. Esses materiais não estavam presentes durante o treinamento e, assim, podem ser utilizados para analisar a generalização da rede (HAYKIN, 2001) e também apresentam propriedades mecânicas que estão dentro da faixa de propriedades abrangida pelo subconjunto de treinamento.

Tabela 3.7 – Propriedades mecânicas dos corpos de prova do aço P110 obtidas via ensaio de tração e dureza (NICOLSI, 2015)

Corpo de prova	Limite de escoamento [MPa]	Limite de resistência [MPa]	Dureza Brinell** [HBW]±IC (95 %)
CP1	867	938	277±5
CP2	862	936	270±5
CP3	845	916	278±8
CP4	856	925	268±12
Média±IC (95 %)*	857±15	929±16	273±4

* Intervalo de confiança de 95 % para o valor da média

** A dureza Brinell foi obtida a partir da dureza Vickers (HV10), determinada em ensaio no durômetro, através de conversão conforme a norma ISO 18265 (ISO, 2013).

Tabela 3.8 – Propriedades mecânicas dos quatro trechos das barras do aço ABNT 8550, submetido ao tratamento térmico de têmpera e revenimento, obtidas via ensaio de tração e de dureza (NICOLSI, 2015)

Corpo de prova	Limite de escoamento [MPa]	Limite de resistência [MPa]	Dureza Brinell** [HBW]±IC (95 %)
CP1	819	949	289±4
CP2	807	938	288±4
CP3	820	949	291±4
CP4	830	959	288±4
Média±IC (95 %)*	819±15	949±14	289±1

* Intervalo de confiança de 95 % para o valor da média

** A dureza Brinell foi obtida a partir da dureza Vickers (HV10), determinada em ensaio no durômetro, através de conversão conforme a norma ISO 18265 (ISO, 2013).

Nota-se que os materiais “B” e “C”, por possuírem gradiente significativo de propriedades mecânicas ao longo da espessura, não foram inclusos no subconjunto de treinamento nem no de validação. Diante da pouca quantidade de ensaios disponíveis no banco de dados, os materiais “B” e “C” foram inclusos no subconjunto de teste, representando, com 80 ensaios, 20 % do conjunto total de ensaios. Adicionalmente, foram testados também todos os outros materiais, incluindo os empregados no treinamento e na validação. Isso permitiu verificar o comportamento direto da RNA para cada configuração isolada de cada material.

Tabela 3.9 – Faixa de propriedades mecânicas abrangidas pelos subconjuntos de treinamento e validação

Subconjuntos	Materiais	Faixa de dureza Brinell [HBW]	Faixa de limite de resistência [MPa]	Faixa de limite de escoamento [MPa]
Treinamento	A, D, E, F, G, API 5L X65, ABNT 8550	128 a 291	463 a 959	300 a 896
Validação	L-80, P-110	188 a 278	573 a 938	488 a 867

3.2. Organização dos arquivos do banco de dados em pastas específicas

Os arquivos do banco de dados foram organizados em pastas específicas, com o intuito de facilitar a importação dos mesmos pelo programa computacional desenvolvido para estimar as propriedades mecânicas.

Para cada aço de “A” a “G”, foram definidas pastas para cada conjunto de ensaios realizados com um determinado penetrador (Fig. 3.5). Dentro de cada pasta de um dado penetrador, os arquivos foram organizados de acordo com a carga máxima do ensaio. Também foi inserida uma pasta, denominada “PROPRIEDADES MEDIDAS”, a qual possuía um arquivo “.txt” com as três propriedades medidas experimentalmente do material analisado (dureza Brinell [HBW], limites de resistência [MPa] e escoamento [MPa]). Essas propriedades foram utilizadas como valores de referência para as saídas das RNAEs.



Figura 3.5 – Organização dos materiais de “A” a “G”. Exemplo de organização do material “A”.

Ainda dentro de cada pasta com determinada força máxima, Fig. 3.5, foram inseridos os ensaios efetivamente realizados e uma pasta denominada “DADOS DO ENSAIO”, que

contém os valores do: módulo de elasticidade do material da amostra (E_a [GPa]) e do penetrador (E_i [GPa]); número de ciclos de carregamento e descarregamento; diâmetro do penetrador ([mm]); força máxima ([N]); descarregamento parcial.

Em relação aos materiais API 5L X65, L80, P110 e ABNT 8550, a organização dos dados foi conforme a Fig. 3.6.

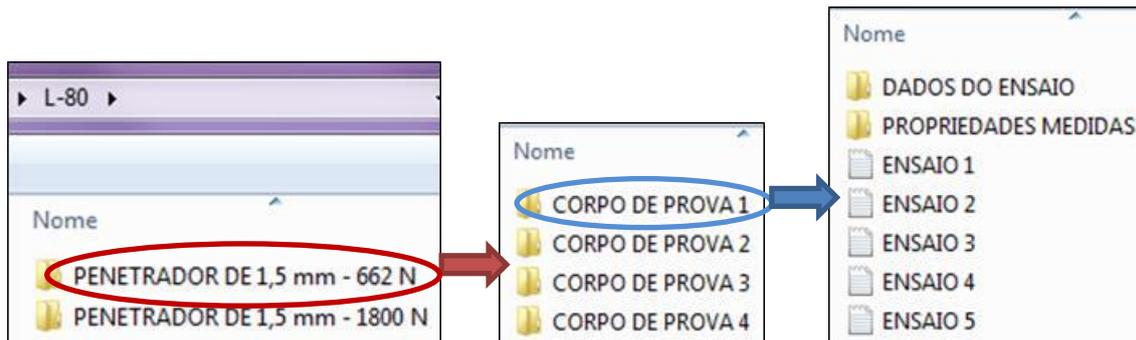


Figura 3.6 – Organização dos materiais API 5L X65, L80, P110 e ABNT 8550. Exemplo de organização do material L80

3.3. Definição das entradas e saída das RNAEs

3.3.1. Escolha das variáveis de entrada das RNAEs

Inicialmente, foram extraídas oito características das curvas dos ensaios de macroindentação instrumentada, que juntamente com a entrada correspondente ao *bias*, formaram as nove variáveis de entrada que compuseram a camada de entrada das RNAEs, Tab. 3.10.

Essas entradas são brevemente apresentadas e justificadas a seguir. Nessa etapa, foi avaliado o comportamento das entradas calculadas a partir dos ensaios do subconjunto de treinamento. Cada ensaio, cujas características foram adquiridas para compor as nove entradas das RNAEs, representa uma linha com nove colunas da matriz total dos ensaios do subconjunto de treinamento (260 linhas e 9 colunas).

Tabela 3.10 – Nove entradas das RNAEs

Entradas das RNAEs	Relação matemática ou constante
Entrada 1	$\frac{F_{m\acute{a}x}}{h_{tm\acute{a}x}D} [Pa]$
Entrada 2	$\frac{\sum_{i=1}^M (F_i/h_i - F_{m\acute{a}x}/h_{tm\acute{a}x})}{n_{ciclos}} \left[\frac{N}{m} \right]$
Entrada 3	$S = \frac{dF}{dh} \left[\frac{N}{m} \right]$
Entrada 4	CA [adimensional]
Entrada 5	$E_i [Pa]$
Entrada 6	$D [m]$
Entrada 7	DP [adimensional]
Entrada 8	$\frac{W_P}{W_T}$ [adimensional]
Entrada 9	1 [entrada correspondente ao bias]

Onde: $F_{m\acute{a}x}$ [N] é a máxima força de indentação aplicada, $h_{tm\acute{a}x}$ [m] é a profundidade máxima de indentação, D [m] é o diâmetro do penetrador, F_i [N] é a i -ésima força de indentação, h_i [m] é a i -ésima profundidade de indentação, n_{ciclos} é a quantidade de ciclos de carregamento/descarregamento, S é a rigidez do contato, CA é o coeficiente angular da reta que ajusta os coeficientes lineares das curvas de descarregamento de cada ciclo de indentação, em função da força que inicia cada ciclo [adimensional], E_i é o módulo de elasticidade do material do penetrador [Pa], DP é o descarregamento parcial [adimensional], W_P [J] é a energia de deformação plástica e W_T [J] é a energia de deformação total.

a) Entrada 1

A Entrada 1 foi definida como a relação entre o coeficiente angular da curva de carregamento ($F_{m\acute{a}x}/h_{tm\acute{a}x}$) e o diâmetro do penetrador (D) (Fig. 3.7), todos já com as unidades convertidas para o SI (INMETRO, 2012), Eq. (3.1).

$$Entrada\ 1 = \frac{F_{m\acute{a}x}}{h_{tm\acute{a}x}D} [Pa] \quad (3.1)$$

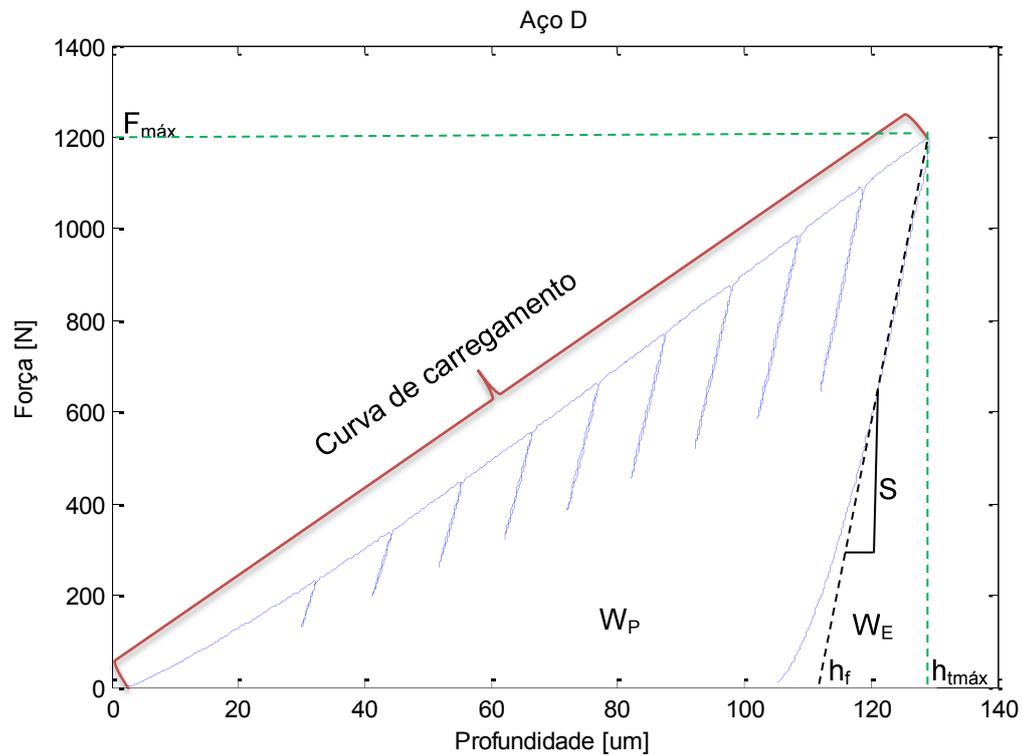


Figura 3.7 – Características das curvas dos ensaios de macroindentação instrumentada – Exemplo com o primeiro ensaio do aço “D” com a seguinte configuração de ensaio: força máxima de 1200 N e penetrador com diâmetro de 1,5 mm (NICOLOSI, 2015)

A curva de carregamento, Fig. 3.7, considerando as indentações esféricas empregadas neste trabalho, foi aproximada por uma reta e sua inclinação (coeficiente angular) foi utilizada para a análise da Entrada 1 (Eq. (3.1)).

A Entrada 1 (Eq. (3.1)) foi assim definida, porque constatou-se, por tentativa, que os valores atribuídos a essa relação matemática foram muitos próximos entre si (Figs. 3.8, 3.9 e 3.10), quando consideradas configurações de ensaio diferentes para um mesmo material. Dessa forma, essa relação mostrou-se importante para classificar os materiais.

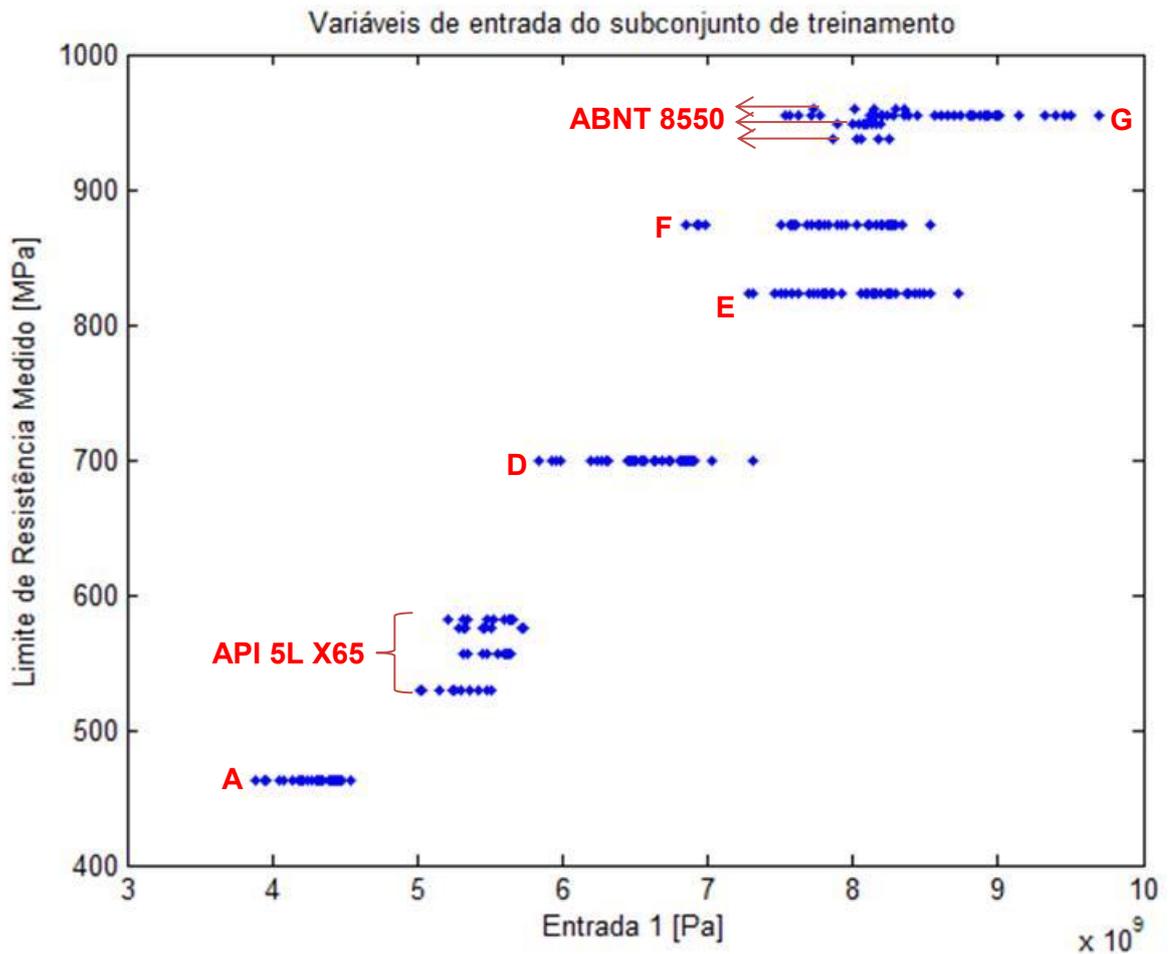


Figura 3.8 – Identificação dos aços do subconjunto de treinamento em regiões definidas através da análise do limite de resistência medido desses aços em função da Entrada 1

A partir das Figuras 3.8, 3.9 e 3.10, observa-se que as propriedades mecânicas medidas, limite de resistência, limite de escoamento e dureza Brinell, respectivamente, tiveram o mesmo comportamento em função da Entrada 1, já que esta entrada só depende dos parâmetros da curva e do diâmetro do penetrador.

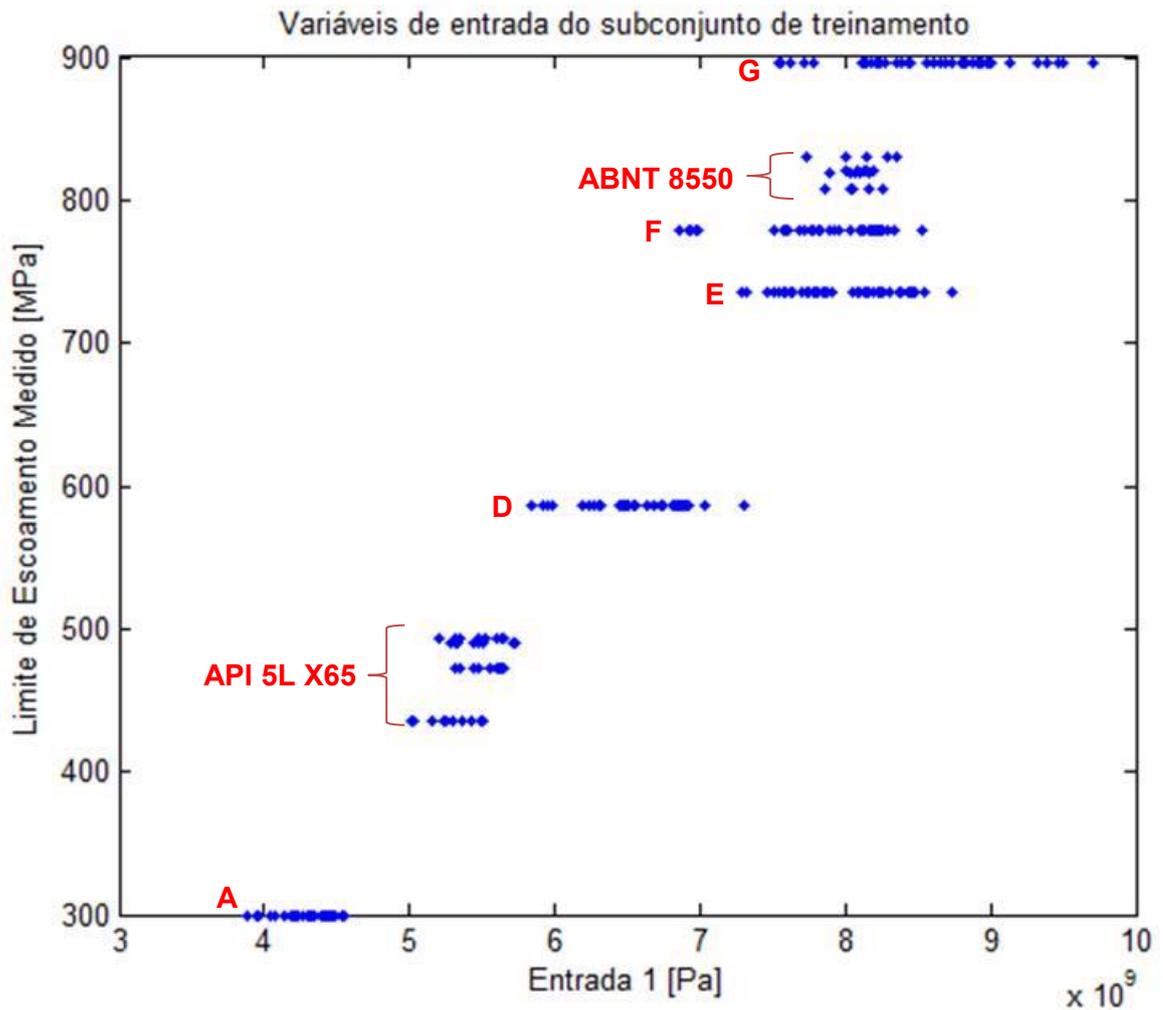


Figura 3.9 - Identificação dos aços do subconjunto de treinamento em regiões definidas através da análise do limite de escoamento medido desses aços em função da Entrada 1

Esse comportamento permitiu verificar que os aços do subconjunto de treinamento ocuparam regiões bem definidas nos gráficos, onde cada linha representou um desses aços. Portanto, a Entrada1 foi uma boa escolha para compor uma das entradas das RNAEs, já que ela tende a classificar os materiais.

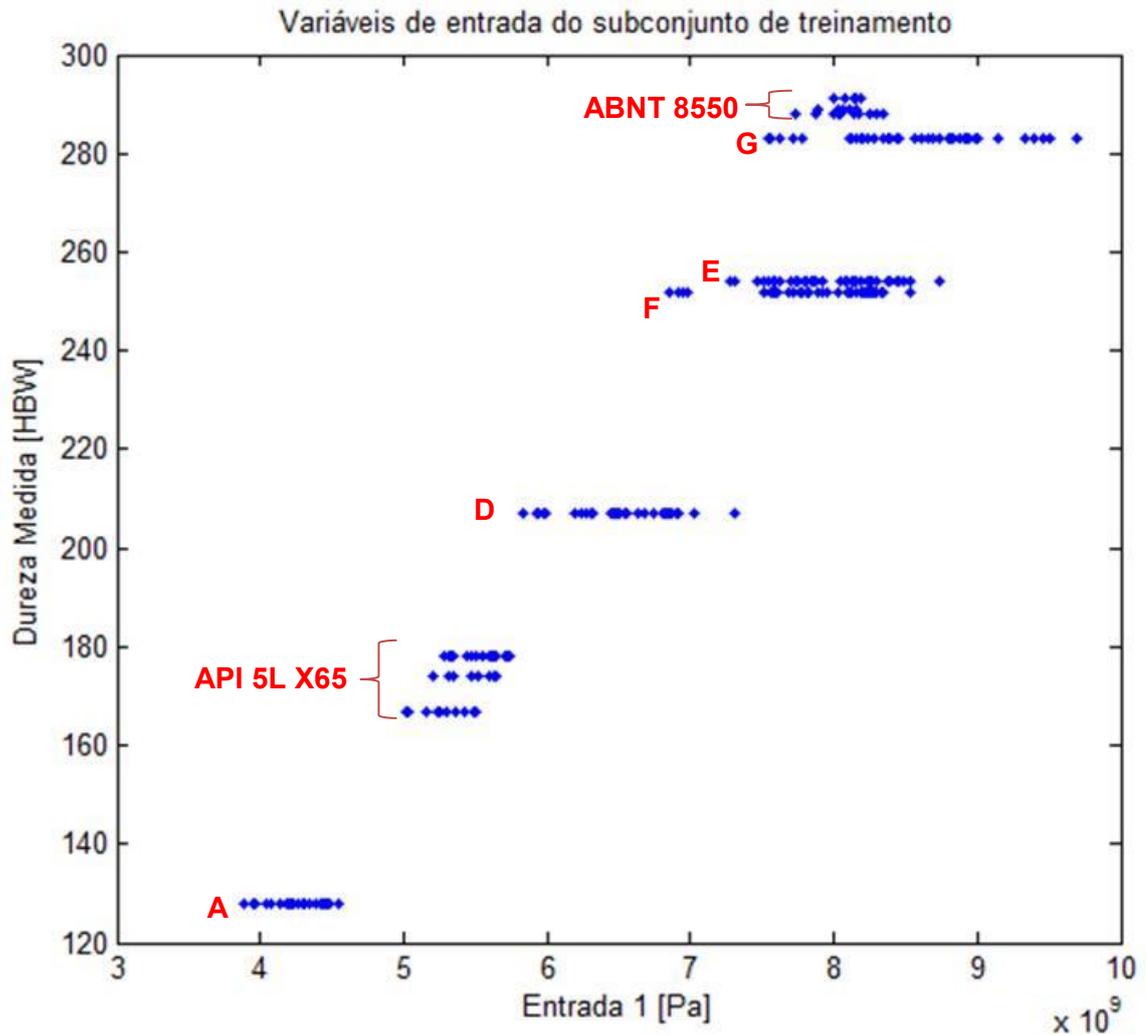


Figura 3.10 - Identificação dos aços do subconjunto de treinamento em regiões definidas através da análise da dureza Brinell medida desses aços em função da Entrada 1

b) Entrada 2

A Entrada 2 foi definida como sendo o somatório da diferença entre os coeficientes angulares pontual e da curva de carregamento em relação à quantidade de ciclos, Eq. (3.2).

A quantidade total de pontos medidos durante cada ensaio é dada por M e a quantidade de ciclos de carregamento/descarregamento, n_{ciclos} , foi igual a 10 em todos os ensaios analisados.

Essa Entrada 2 quantifica se há uma “barriga” (distorção da curva de carregamento) para cima, caso o somatório seja positivo, ou uma “barriga” para baixo, caso o somatório seja negativo.

$$Entrada\ 2 = \frac{\sum_{i=1}^M \left(\frac{F_i}{h_i} - \frac{F_{m\acute{a}x}}{h_{tm\acute{a}x}} \right)}{n_{ciclos}} \left[\frac{N}{m} \right] \quad (3.2)$$

A análise dessa Entrada 2 também foi feita através do gráfico de cada propriedade mecânica medida em função dessa entrada. Como todos os gráficos apresentaram o mesmo comportamento, foi mostrado aqui apenas a Fig. 3.11 como exemplo. Verificou-se que os aços do subconjunto de treinamento apresentaram regiões não tão bem definidas como em relação à Entrada 1, pois alguns pontos ficaram dispersos para cada aço.

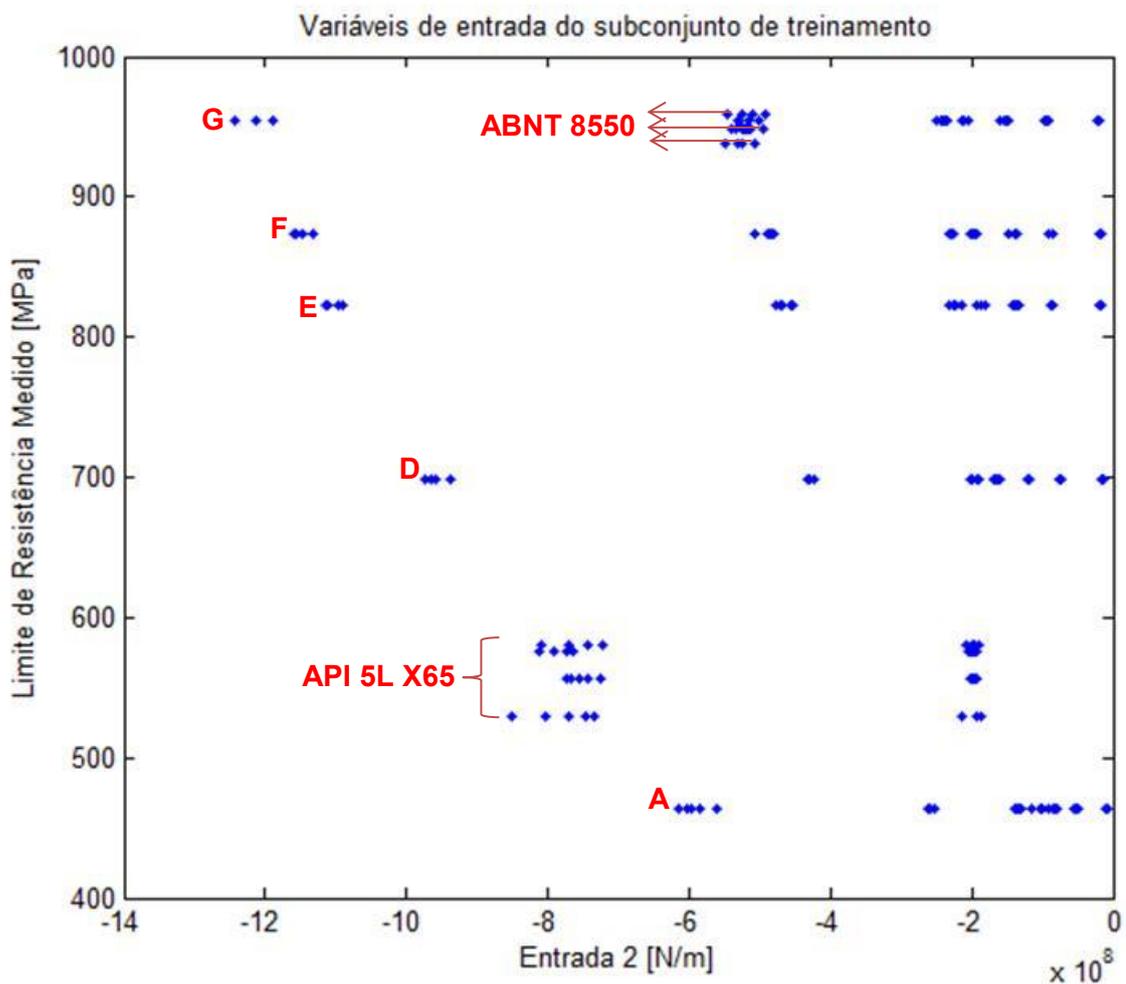


Figura 3.11 - Identificação dos aços do subconjunto de treinamento em regiões através da análise do limite de resistência medido desses aços em função da Entrada 2

c) Entrada 3

A Entrada 3 foi definida como a rigidez do contato (S) [N/m], a qual foi igual ao coeficiente angular da reta associada ao início do descarregamento até 60 % da força máxima (já que o descarregamento foi de 40 % em todos os ensaios) do último ciclo de carregamento/descarregamento, Fig. 3.7. Essa Entrada 3 é uma característica importante do material ensaiado (GIANNAKOPOULOS; SURESH, 1999; DAO *et al.*, 2001).

A análise dessa Entrada 3 também foi realizada similarmente às outras entradas. Na Figura 3.12 nota-se que os valores da Entrada 3 que caracterizam cada aço estão menos dispersos em relação à Fig. 3.11. Portanto, a Entrada 3 classifica melhor os materiais em relação à Entrada 2.

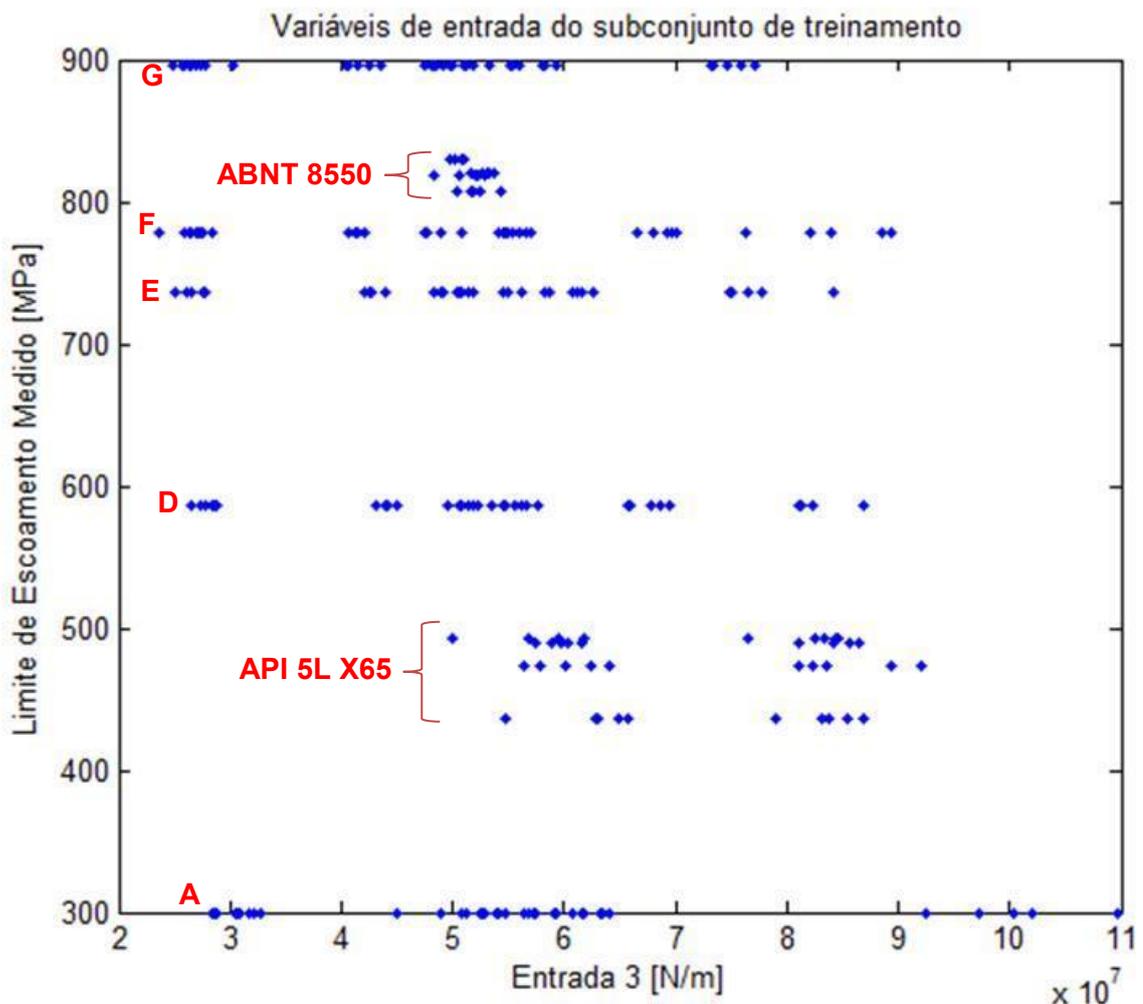


Figura 3.12 - Identificação dos aços do subconjunto de treinamento em regiões através da análise do limite de escoamento medido desses aços em função da Entrada 3

d) Entrada 4

A Entrada 4 foi definida como sendo o coeficiente angular da reta que ajusta os coeficientes lineares das curvas de descarregamento de cada ciclo de indentação, em função da força que inicia cada ciclo. Essa entrada é, portanto, adimensional.

Na Figura 3.13, a classificação dos materiais de acordo com a Entrada 4 foi melhor que em relação à Entrada 3, apresentando menos dispersão entre os valores da Entrada 4 para cada material.

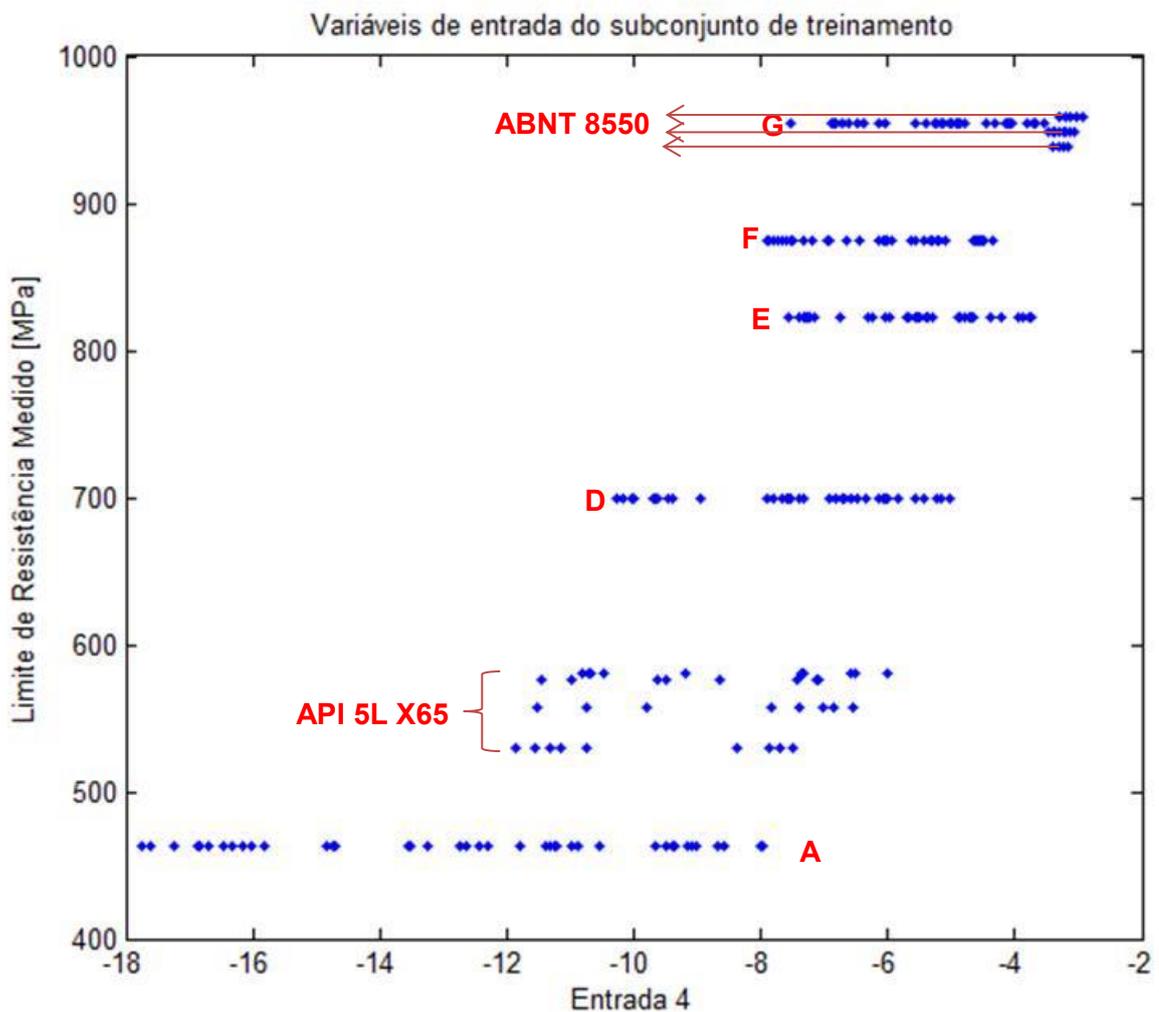


Figura 3.13 - Identificação dos aços do subconjunto de treinamento em regiões através da análise do limite de resistência medido desses aços em função da Entrada 4

e) Entrada 5

A Entrada 5 foi definida como sendo o módulo de elasticidade do material do penetrador, expresso em [Pa].

f) Entrada 6

A Entrada 6 foi definida como sendo o diâmetro do penetrador, expresso em [m].

g) Entrada 7

A Entrada 7 foi definida como sendo o valor do descarregamento parcial (adimensional).

h) Entrada 8

A Entrada 8 foi definida como sendo a relação entre a energia de deformação plástica (W_p) e a energia de deformação total (W_T), Fig. 3.7 e Eq. (3.3).

A energia de deformação total (W_T) foi equivalente à área total abaixo da curva de carregamento até a profundidade máxima ($h_{tm\acute{a}x}$). A energia de deformação plástica (W_P) dependeu do calculo da energia de deformação elástica (W_E), Eq. (3.4), que foi tomada como sendo equivalente à área abaixo da curva de descarregamento entre as profundidades h_f e $h_{tm\acute{a}x}$, Fig. 3.7. A Entrada 8, portanto, é um número adimensional.

Essa entrada também foi utilizada por Dao *et al.* (2001), Swaddiwudhipong; Harsono; Zishun (2008) e Harsono; Swaddiwudhipong; Liu (2009). Dentre esses autores, que propuseram um modelo de RNA para extrair propriedades mecânicas de materiais com base indentações, apenas Harsono; Swaddiwudhipong; Liu (2009) realizaram indentações esféricas. Já, os outros realizaram indentações utilizando penetradores de ponta aguda.

$$Entrada\ 8 = \frac{W_P}{W_T} \quad (3.3)$$

$$W_P = W_T - W_E \quad (3.4)$$

Na Figura 3.14, os aços do subconjunto de treinamento foram classificados em regiões, cuja dispersão entre os pontos correspondentes a cada elemento do vetor Entrada 8 é pequena. Visto isso, a Entrada 8, assim como a Entrada 1, é uma entrada muito importante para as RNAEs, pois seu potencial classificatório de materiais é relevante.

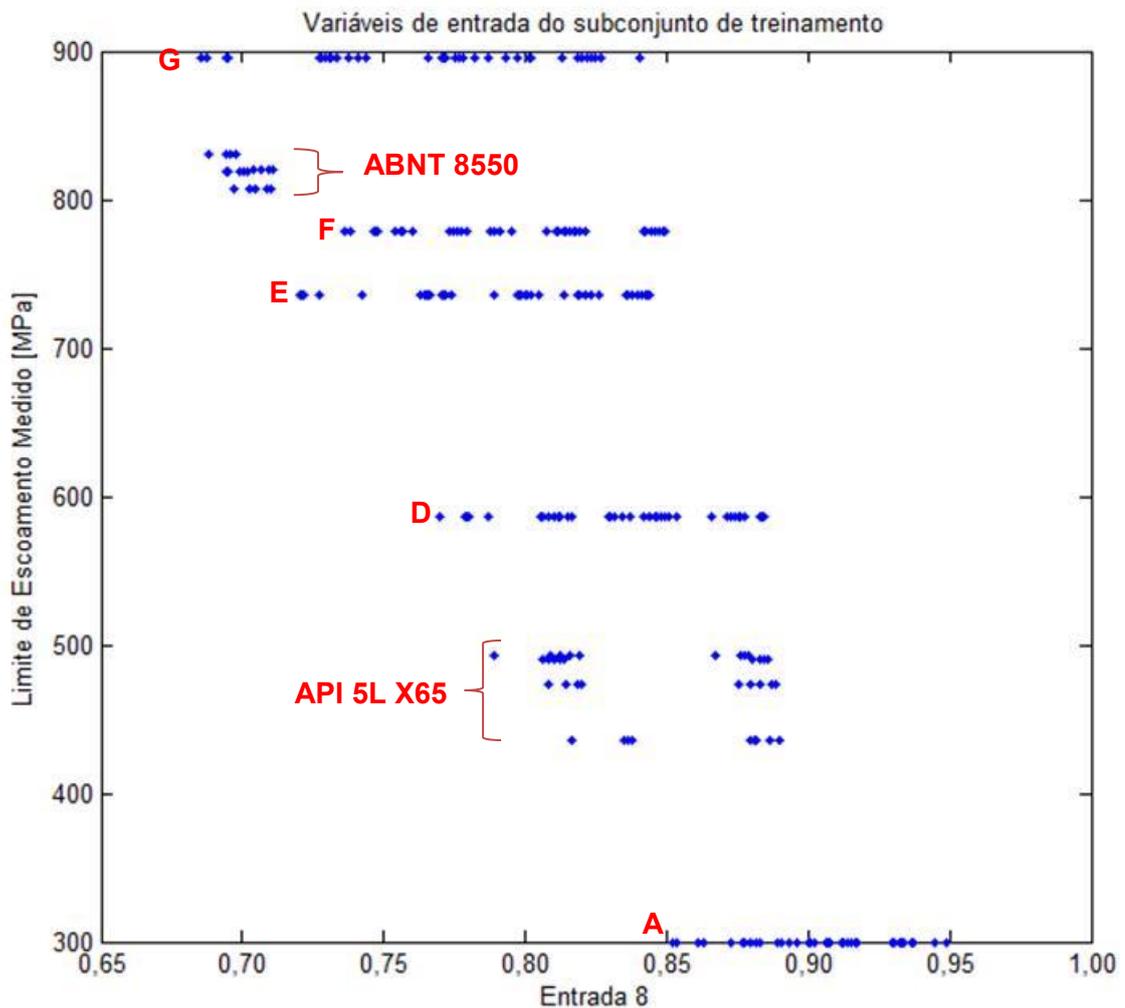


Figura 3.14 - Identificação dos aços do subconjunto de treinamento em regiões através da análise do limite de escoamento medido desses aços em função da Entrada 8

i) Entrada 9

A Entrada 9 foi feita igual a 1 (entrada correspondente ao *bias*).

Dentre as Entradas de 1 a 8, nota-se que as Entradas 1 e 8 são as que melhor classificam os materiais, enquanto que as outras entradas são mais sensíveis aos parâmetros de interesse coletados das curvas $F \times h$ e, assim, as propriedades mecânicas estimadas também o serão. Essa característica das Entradas 2 a 7 é importante também, porque força a RNAE a lidar com a não-linearidade dos materiais a ela apresentados.

3.3.2. Escolha da saída das RNAEs

Em relação à camada de saída das RNAEs, ela foi composta de apenas um neurônio, cuja saída representava o valor estimado da propriedade mecânica para a qual o treinamento da RNAE estava acontecendo.

3.3.3. Normalização das variáveis de entrada das RNAEs

As entradas das RNAEs, tanto as correspondentes aos ensaios do subconjunto de treinamento quanto às do subconjunto de validação foram normalizadas entre 0 e 1, conforme a Eq. (2.22). Pois, elas possuem ordens de grandeza diferentes e os neurônios das RNAEs transmitem sinais que variam entre 0 e 1, que é o intervalo a partir do qual a função de ativação limita os sinais. As entradas 6 a 9 não foram normalizadas, porque os valores delas já estão compreendidos entre 0 e 1.

Antes das variáveis de entrada serem submetidas à normalização (Entradas 1 a 5), foram obtidos os valores mínimo e máximo de cada uma delas, considerando todos os ensaios do subconjunto de treinamento e validação.

Os limites máximo e mínimo de cada variável, de acordo com o qual as variáveis foram normalizadas posteriormente, foram definidos com valores 20 % maiores e 20 % menores que os valores máximo e mínimo observados, respectivamente.

Isso se justifica pelo fato de que a normalização dos dados deve deixar uma margem (tanto inferior quanto superior), visto que nem sempre é possível se trabalhar com informações que sejam completamente representativas do problema analisado. Dessa forma, ao se estabelecer essa margem de segurança, evita-se que a RNA se confunda com valores fora da curva de normalização, provocados por dados de valor inferior ou superior aos apresentados para seu treinamento (LOUZADA, 2013).

A normalização das entradas está expressa no Apêndice I.

3.3.4. Redução da quantidade de variáveis de entrada através da PCA

Neste trabalho também foi empregado o método PCA para a redução da quantidade das variáveis de entrada (Entradas 1 a 8), cujo objetivo foi verificar quais entradas estavam correlacionadas e poder, então, remover algumas delas e manter outras. A forma de descarte dessas variáveis foi realizada, ora empregando o método B2 da PCA, ora o método B4 da PCA (JOLLIFFE, 2002). Vale salientar que foi analisada a correlação entre todas as variáveis de entrada, exceto a entrada correspondente ao *bias* (Entrada 9).

Através da PCA, a dimensão dessas variáveis de entrada foi reduzida e um novo conjunto de variáveis foi criado, que foram as PCs, que não são correlacionadas, e que foram ordenadas de tal forma que as primeiras representaram a maior parte da variância

presente em todas as variáveis originais (JOLLIFFE, 2002). Cada PC foi obtida como uma combinação linear dessas variáveis, conforme Eq. (2.23). Essas PCs passaram a ser as novas entradas das RNAEs.

Inicialmente, os dados correspondentes às variáveis de entrada (Entradas 1 a 8), considerando os ensaios do subconjunto de treinamento, foram centralizados em torno da média (média igual a zero), conforme Eq. (2.24). Em seguida, esses valores centralizados foram submetidos à PCA, através da utilização da função “pca” do Matlab®. Essa função permite fazer a PCA dos dados e emitir os resultados, tais como: coeficientes de ponderação, autovalores ou variâncias das PCs, variâncias explicadas das PCs, *score*, etc., conforme apresentado nas Tabs. 3.11 a 3.13.

Tabela 3.11 – Coeficientes de ponderação de cada variável de entrada e associados às respectivas PCs

Entrada	PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8
1	-0,00322	0,55452	-0,46537	-0,46172	-0,08279	0,27967	0,42152	0,00000
2	-0,41454	0,12548	0,69149	-0,25518	0,15011	0,49634	0,01584	0,00000
3	0,44586	-0,31830	-0,21026	-0,30303	0,16556	0,55516	-0,47775	0,00000
4	0,24162	0,54377	0,11209	-0,02568	0,67892	-0,30127	-0,28464	0,00000
5	-0,48117	0,04892	-0,42769	0,56286	0,34565	0,36969	-0,10105	0,00000
6	0,51976	-0,09348	0,19983	0,37806	0,25739	0,27577	0,62925	0,00000
7	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	1,00000
8	-0,26327	-0,51830	-0,16016	-0,41166	0,54457	-0,25248	0,32655	0,00000

Tabela 3.12 - Variância das PCs

Componente Principal	Variância
PC1	3,35937
PC2	2,56852
PC3	0,73974
PC4	0,20678
PC5	0,06385
PC6	0,05545
PC7	0,00630
PC8	0,00000

A partir da Tabela 3.12, constatou-se, baseado em Jolliffe (1972), que as três primeiras PCs foram as mais significativas, porque suas variâncias (autovalores) foram maiores que 0,7 e, conseqüentemente, o número de variáveis originais mantidas após a PCA foi igual a 3.

As três primeiras PCs (PC1, PC2 e PC3) explicam, conforme a Tab. 3.13, respectivamente, 47,99 %, 36,69 % e 10,57 % da variância total dos dados, o que representou aproximadamente uma variância acumulada de 95,25 % da variância total dos dados.

Tabela 3.13 – Variância explicada das PCs

Componente Principal	Variância explicada [%]
PC1	47,99096
PC2	36,69313
PC3	10,56773
PC4	2,95396
PC5	0,91212
PC6	0,79217
PC7	0,08993
PC8	0,00000

Posteriormente, foram aplicados os métodos de descarte de variáveis, B2 ou B4 (JOLLIFFE, 1972). O método B2 corresponde a um procedimento no qual o descarte ocorre através da análise das últimas PCs, aquelas que também serão descartadas. Visto isso, a Tabela 3.11 foi reescrita apenas com as últimas PCs (PC4 a PC8), conforme Tab. 3.14.

Tabela 3.14 – Coeficientes de ponderação de cada variável de entrada e associados às últimas PCs

Entrada	PC4	PC5	PC6	PC7	PC8
1	-0,46172	-0,08279	0,27967	0,42152	0,00000
2	-0,25518	0,15011	0,49634	0,01584	0,00000
3	-0,30303	0,16556	0,55516	-0,47775	0,00000
4	-0,02568	0,67892	-0,30127	-0,28464	0,00000
5	0,56286	0,34565	0,36969	-0,10105	0,00000
6	0,37806	0,25739	0,27577	0,62925	0,00000
7	0,00000	0,00000	0,00000	0,00000	1,00000
8	-0,41166	0,54457	-0,25248	0,32655	0,00000

Visto isso, no método B2, o descarte ocorreu nas variáveis associadas a cada uma dessas últimas PCs. Como cada variável associada corresponde àquela que tem o maior valor absoluto do coeficiente de uma dada PC, as variáveis associadas a cada uma das últimas PCs foi evidenciada em vermelho na Tab. 3.14.

Então, as variáveis descartadas foram as Entradas 3 a 7. Conseqüentemente, as variáveis mantidas foram as Entradas 1, 2 e 8. Portanto, as três primeiras PCs passaram a

constituir as entradas das RNAEs e cada uma delas foi modelada como a combinação linear das variáveis de entrada 1, 2 e 8 normalizadas e ponderadas pelos seus respectivos coeficientes.

Já o método B4 corresponde a um procedimento que descarta variáveis por meio da análise das primeiras PCs, aquelas que serão mantidas. Dessa forma, cada variável associada a uma dessas CP foi mantida e as outras variáveis remanescentes foram descartadas (JOLLIFFE, 1972). Visto isso, a Tabela 3.11 foi reescrita apenas com as três primeiras PCs, conforme a Tab. 3.15.

Tabela 3.15 – Coeficientes de ponderação de cada variável de entrada e associados às três primeiras PCs

Entrada	PC1	PC2	PC3
1	-0,00322	0,55452	-0,46537
2	-0,41454	0,12548	0,69149
3	0,44586	-0,31830	-0,21026
4	0,24162	0,54377	0,11209
5	-0,48117	0,04892	-0,42769
6	0,51976	-0,09348	0,19983
7	0,00000	0,00000	0,00000
8	-0,26327	-0,51830	-0,16016

A partir da Tabela 3.15, foi analisada a variável associada a cada uma das PCs e aquelas que apresentavam os maiores valores absolutos dos coeficientes foram mantidas, conforme foi evidenciado em verde na Tab. 3.15.

Dessa forma, as variáveis originais mantidas foram as Entradas 1, 2 e 6, já as outras foram descartadas. Assim, as três primeiras PCs passaram a constituir as entradas das RNAEs e cada uma delas foi modelada como a combinação linear das variáveis de entrada 1, 2 e 6 normalizadas e ponderadas pelos seus respectivos coeficientes.

3.4. Definição das arquiteturas a serem avaliadas para as RNAEs

A definição das arquiteturas das RNAEs foi baseada num processo de tentativa e erro (SANTANA, 2012) e tomando-se como base redes MLP com poucos neurônios, uma vez que geralmente o aumento da quantidade de neurônios ocultos não garante uma boa generalização da RNA (POWAR; DATE, 2015).

Adicionalmente, foi considerada a aplicação de algoritmos que empregaram regularização bayesiana, com o método de LMRB, uma vez que isso reduz a necessidade

de se testar um número diferente de neurônios escondidos para um problema (PANDYA; DENNIS; RUSSELL, 2017).

Diante do exposto, foram propostas três tentativas para definição da melhor arquitetura de RNAE para cada propriedade mecânica. Nas Figuras 3.15 e 3.16, estão representadas as RNAEs MLP com três neurônios no total e na Fig. 3.17 consta uma RNAE MLP com quatro neurônios.

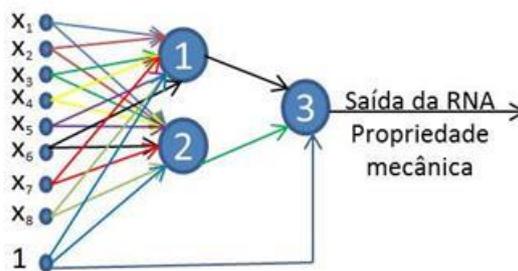


Figura 3.15 – Arquitetura de RNAE com três neurônios, uma camada de entrada com nove variáveis, uma camada intermediária e uma saída para estimar determinada propriedade mecânica. Total de 21 pesos.

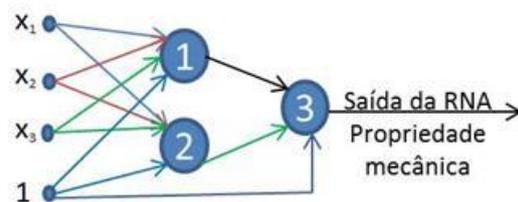


Figura 3.16 - Arquitetura de RNAE com três neurônios, uma camada de entrada com quatro variáveis, uma camada intermediária e uma saída para estimar determinada propriedade mecânica. Total de 11 pesos.

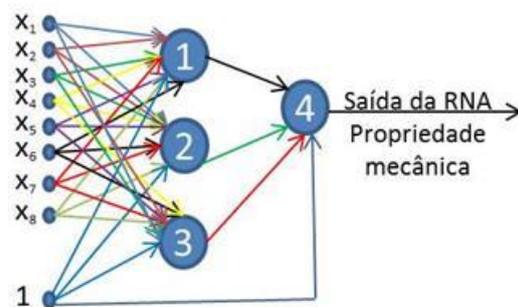


Figura 3.17 - Arquitetura de RNAE com quatro neurônios, uma camada de entrada com nove variáveis, uma camada intermediária e uma saída para estimar determinada propriedade mecânica. Total de 31 pesos

Todas essas redes apresentaram uma camada de entrada com nove (Figs. 3.15 e 3.17) ou quatro variáveis (Fig. 3.16); uma camada oculta com dois (Figs. 3.15 e 3.16) ou três neurônios (Fig. 3.17) e uma camada de saída com um neurônio, cuja saída é a propriedade mecânica estimada pela RNAE.

3.5. Definição da função de ativação dos neurônios das RNAEs

A função de ativação dos neurônios da camada oculta, em todas as arquiteturas de rede adotadas neste trabalho, foi uma função sigmoide, já que, conforme a definição (HAYKIN, 2001), ela é uma função que tanto modela o comportamento não linear, quanto o comportamento linear.

Da Equação (2.21), originou-se a função de ativação sigmoide $F(u)$ empregada neste trabalho, expressa na Fig. 3.18 e pela Eq. (3.5).

$$F(u) = \frac{1}{1 + e^{-u}} \quad (3.5)$$

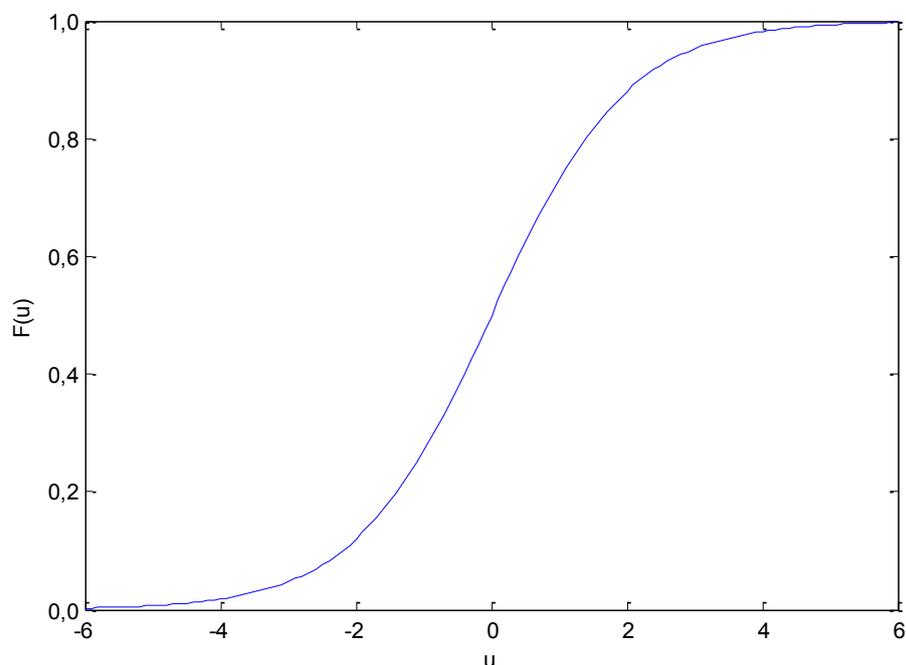


Figura 3.18 – Função de ativação sigmoide empregada nos neurônios ocultos

Já a função de ativação do neurônio da camada de saída foi uma função linear. Devido à saída dessa função ser restringida entre 0 e 1, foi necessário multiplicar a

combinação linear (u) por um limite máximo, Eq. (3.6). Cada propriedade mecânica teve seu respectivo limite máximo, conforme mostrado na Tab. 3.16.

$$f_{linear}(u) = u \cdot LimiteMáximo \quad (3.6)$$

Tabela 3.16 – Limites máximos das propriedades mecânicas implementados para alterar a restrição de 0 a 1 das saídas dos neurônios da última camada

Propriedade mecânica	Limite máximo
Limite de resistência	1200 MPa
Limite de escoamento	1000 MPa
Dureza Brinell	400 HBW

3.6. Definição dos parâmetros de desempenho do AG

Para implementar o AG, foram definidos os seguintes parâmetros de desempenho:

- a) Representação do indivíduo;
- b) Definição da quantidade de indivíduos da população inicial;
- c) Definição da função de avaliação/objetivo;
- d) Definição do critério de parada;
- e) Definição dos valores iniciais para os pesos pertencentes aos indivíduos da população;
- f) Definição da quantidade de filhos a serem formados pelo *crossover*;
- g) Definição do método de seleção dos pais para o *crossover*;
- h) Definição do método de *crossover* para a geração dos filhos;
- i) Definição da quantidade de filhos que passaram pelo processo de mutação;
- j) Definição da quantidade de pesos que tiveram os bits alterados em cada filho selecionado para a mutação;
- k) Definição da quantidade de bits que foram alterados em cada peso pertencente ao filho selecionado para a mutação;
- l) Definição do método de mutação;
- m) Definição do método de reinserção dos indivíduos, que consistiu na seleção dos melhores indivíduos para a próxima geração.

3.6.1. Representação do indivíduo

Cada indivíduo foi representado pelos pesos da RNAE em treinamento, que são as variáveis que se deseja otimizar. A quantidade de pesos presente em cada indivíduo depende da arquitetura da RNAE considerada (Figs. 3.15, 3.16 ou 3.17).

Cada peso foi codificado por um número binário de 32 bits (IEEE Standard 754 32-bit single precision floating point, Fig. 3.19). O *bias* foi tratado como um peso adicional da rede.

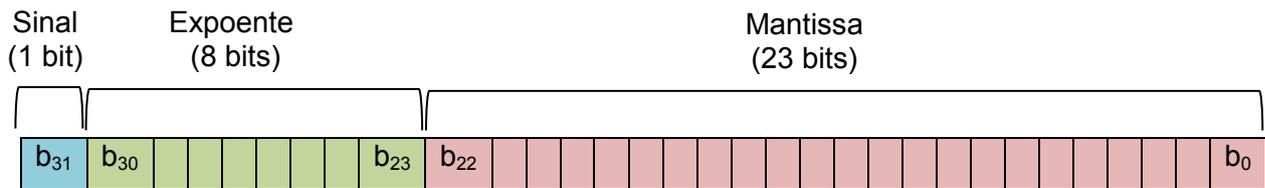


Figura 3.19 – Representação binária de 32 bits de cada peso do indivíduo do AG de acordo com a IEEE Standard 754

Onde: b_j é o bit com índice j , sendo $j = 0$ a 31.

A Equação (3.7) representa a conversão do número binário, representado conforme a Fig. 3.19, em um número decimal. Observa-se que se o bit do sinal for igual 1, o sinal será negativo, caso contrário, ou seja, se o bit de sinal for igual a 0, então o sinal será positivo.

$$ValorDecimal = (-1)^{b_{31}} \left(1 + \sum_{j=1}^{23} b_{23-j} 2^{-j} \right) 2^{(eD-127)} \quad (3.7)$$

Onde: eD é o expoente em binário convertido para decimal, conforme Eq. (3.8).

$$eD = \sum_{j=0}^7 b_{23+j} 2^j \quad (3.8)$$

Na Figura 3.20, por exemplo, o indivíduo apresenta 21 pesos e corresponde à arquitetura da Fig. 3.15.

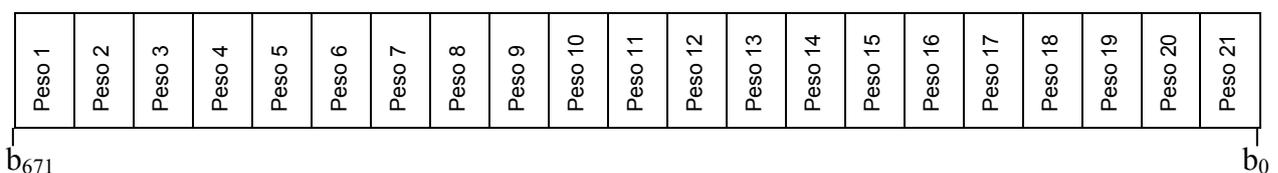
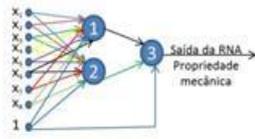


Figura 3.20 - Representação de cada indivíduo da população do AG quando se considera o treinamento de uma RNAE com arquitetura igual à mostrada na Figura 3.15

Esse indivíduo da Fig. 3.20 teve seus pesos ordenados em um vetor e associados às entradas de cada neurônio da arquitetura de rede (Fig. 3.15), conforme a Tab. 3.17. Essa análise foi feita para os indivíduos representativos de cada arquitetura de RNAE considerada neste trabalho.

Tabela 3.17 – Posição dos pesos binários e decimais (após a conversão) no vetor representativo dos indivíduos, considerando a arquitetura de RNA da Fig. 3.15

			
Número do neurônio	Entrada do neurônio	Posição do peso binário no vetor	Posição do peso decimal no vetor
1	X_1	Bit 671 ao bit 640	1
	X_2	Bit 639 ao bit 608	2
	X_3	Bit 607 ao bit 576	3
	X_4	Bit 575 ao bit 544	4
	X_5	Bit 543 ao bit 512	5
	X_6	Bit 511 ao bit 480	6
	X_7	Bit 479 ao bit 448	7
	X_8	Bit 447 ao bit 416	8
	1	Bit 415 ao bit 384	9
2	X_1	Bit 383 ao bit 352	10
	X_2	Bit 351 ao bit 320	11
	X_3	Bit 319 ao bit 288	12
	X_4	Bit 287 ao bit 256	13
	X_5	Bit 255 ao bit 224	14
	X_6	Bit 223 ao bit 192	15
	X_7	Bit 191 ao bit 160	16
	X_8	Bit 159 ao bit 128	17
	1	Bit 127 ao bit 96	18
3	Saída do neurônio 1	Bit 95 ao bit 64	19
	Saída do neurônio 2	Bit 63 ao bit 32	20
	1	Bit 31 ao bit 0	21

3.6.2. Definição da quantidade de indivíduos da população inicial

A população inicial foi formada por 100 indivíduos em todas as configurações de treinamento propostas.

3.6.3. Definição da função de avaliação/objetivo

A função objetivo que se desejou minimizar foi o erro máximo, que consistiu na Eq. (3.9). Esse erro foi calculado para cada indivíduo da população, mediante a apresentação à RNAE de todo o conjunto de ensaios, ora do subconjunto de treinamento ora do subconjunto de validação.

$$F_{obj} = Erro_{m\acute{a}x}[\%] = |Erro_{m\acute{e}dio}| + 2s \quad (3.9)$$

Onde:

- F_{obj} é a função objetivo;
- $Erro_{m\acute{a}x}$ é o erro máximo, expresso em %;
- $|Erro_{m\acute{e}dio}|$ é o módulo da média dos erros das configurações de ensaio (Eq. (3.10)) para todos os materiais de determinado subconjunto, expresso em %;
- s é o desvio padrão da média dos erros das configurações de ensaios ($Erro_{m\acute{e}dio}$), expresso em %.

Conforme a Equação (3.9), o erro associado a cada indivíduo foi definido com uma distribuição normal, sendo igual ao módulo da média dos erros de configuração (Eq. (3.10)), acrescidos de dois desvios padrão da média. Assim, os erros para a estimativa das propriedades mecânicas devem ficar dentro da faixa de $\pm Erro_{m\acute{a}x}$, com um nível de confiança de 95,45 %.

Na Equação (3.10), o erro de cada configuração de ensaio, composta, em geral, por cinco ensaios, foi dado pela diferença relativa da propriedade medida do material ensaiado e a média das propriedades mecânicas obtidas via apresentação das características individuais de cada ensaio à RNAE.

$$Erro_{config}[\%] = \frac{Propriedade_{Medida} - Propriedade_{M\acute{e}diaConfig}}{Propriedade_{Medida}} \cdot 100 \quad (3.10)$$

Onde:

- $Erro_{config}$ é o erro de determinada configuração de ensaio, expresso em %;

- $Propriedade_{MédiaConfig}$ é a média das propriedades mecânicas obtidas via apresentação das características individuais de cada ensaio à RNAE;
- $Propriedade_{Medida}$ é a propriedade mecânica medida (média) do material ensaiado.

O cálculo da média das propriedades mecânicas obtidas pela RNA para um dado material, Eq. (3.9), foi importante, porque a propriedade medida desse material fora obtida do centro da parede dos tubos, sendo equivalente à média da propriedade medida. Ou seja, não se tinha o valor da propriedade medida pontual onde foi realizado cada ensaio.

Por fim, os indivíduos foram ordenados de acordo com a ordem crescente de erro máximo. Portanto, quanto menor era esse erro, melhor classificado era o indivíduo.

Vale salientar que os indivíduos da população original não foram avaliados novamente após a mutação. Apenas foram avaliados os novos indivíduos resultantes do *crossover* e da mutação. Em seguida, tanto os indivíduos originais, quanto os novos indivíduos foram ordenados para o processo de reinserção ordenada.

3.6.4. Definição do critério de parada

O critério de parada para a finalização do AG foi o número máximo de gerações, que foi igual a 100 ou 200.

3.6.5. Definição dos valores iniciais para os pesos pertencentes aos indivíduos da população

No algoritmo de treinamento, os pesos foram inicializados, aleatoriamente, com valores limites pré-determinados, ora dentro do intervalo $[-1 \ 1]$ ora dentro de $[-1,5 \ 1,5]$ ora dentro de $[-3 \ 3]$. Esses limites superior e inferior também foram utilizados para limitar os pesos após a mutação. Pois, a mutação, por permitir a troca de bits, pode resultar em indivíduos cujos pesos possuam valores imprevisíveis. Assim, esses valores podem ser muito grandes, em módulo, o que prejudica a característica de não singularidade da matriz Hessiana, quando aplicado o algoritmo de LMRB.

3.6.6. Definição da quantidade de filhos a serem formados pelo *crossover*

A quantidade total de filhos foi definida como sendo 100 % maior que a quantidade de indivíduos da população inicial.

3.6.7. Definição do método de seleção dos pais para o *crossover*

Os métodos de seleção dos pais para o *crossover* implementados foram:

- *Ranking*: todos os indivíduos foram ordenados de acordo com a aptidão (erro máximo). A probabilidade de um indivíduo ser sorteado dependeu unicamente da sua aptidão. A população foi ordenada com base no menor erro dos indivíduos, de forma que o primeiro indivíduo foi aquele de menor erro e maior aptidão. Desta forma, foi elaborada uma rotina em que os indivíduos que ocupam as primeiras posições tiveram maior quantidade de “token” e, assim, maior probabilidade de serem escolhidos. Vários sorteios entre esses “token” foram realizados e os detentores dos “token” sorteados foram selecionados;
- *Torneio*: A variável “tour” indica o número de indivíduos que foram envolvidos em cada torneio, de forma que, a cada torneio, um sub-grupo de “tour” indivíduos é selecionado da população. Assim, o melhor indivíduo do sub-grupo é selecionado como resultado do torneio. Na programação desenvolvida, o melhor indivíduo é aquele com menor erro associado e o “tour” utilizado foi igual a 3.

3.6.8. Definição do método de *crossover* para a geração dos filhos

O método de *crossover* implementado foi o *crossover* uniforme. Inicialmente, foi sorteada uma máscara do tamanho do indivíduo, Fig. 3.21, a qual indicou qual pai forneceu cada gene do primeiro filho. O segundo filho foi gerado pelo complemento da máscara. A máscara foi gerada aleatoriamente e, enquanto a máscara fosse composta apenas por genes de um único pai, ela era gerada novamente até que fosse composta por genes de ambos os pais.

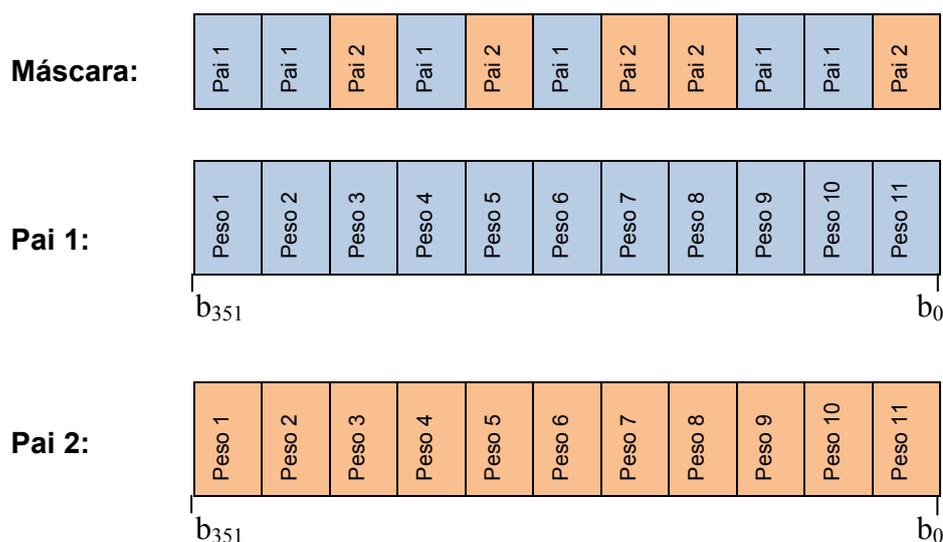


Figura 3.21 – Exemplo de *crossover* uniforme nos pais quando se considera o treinamento de uma RNA com arquitetura igual à mostrada na Fig. 3.16

A Figura 3.21 representa dois pais, associados à arquitetura da Fig. 3.16, e um exemplo de máscara. Nesse exemplo, a máscara permitiu que todos os bits de cada peso de ambos os pais fossem totalmente repassados para os filhos, Fig. 3.22. Mas existiu a possibilidade de a máscara obtida sortear, dentro do conjunto de bits de um determinado peso, apenas alguns bits para compor o primeiro filho.

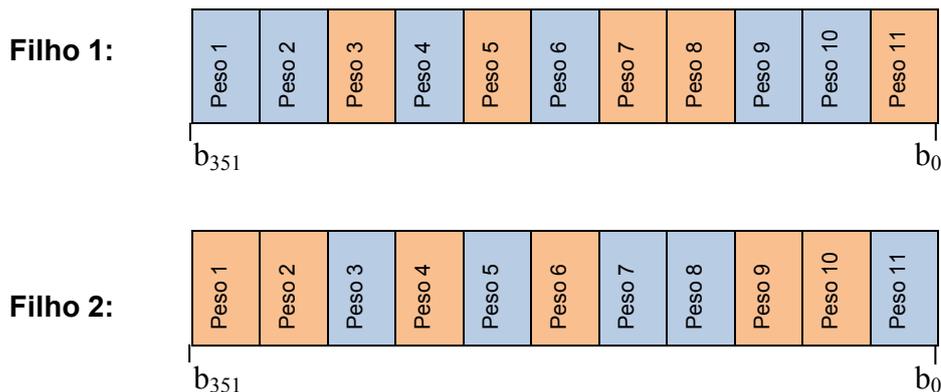


Figura 3.22 – Resultado do *crossover* uniforme nos pais da Fig. 3.21

3.6.9. Definição da quantidade de filhos que passaram pelo processo de mutação

A quantidade de filhos que passaram pelo processo de mutação foi definida em 15 % do total de filhos e, em algumas configurações, foi empregado 30 %.

3.6.10. Definição da quantidade de pesos que tiveram os bits alterados em cada filho selecionado para a mutação

Dentre a quantidade de pesos pertencentes a cada arquitetura de RNA, foram selecionados aleatoriamente aproximadamente 38 % do total de pesos para que essa parcela tivesse os bits alterados pela mutação.

3.6.11. Definição da quantidade de bits a serem alterados em cada peso pertencente ao filho selecionado para a mutação

Nos pesos pertencentes aos filhos selecionados para a mutação, foi definido que apenas dois bits ou quatro bits fossem alterados em cada peso.

3.6.12. Definição do método de mutação

A mutação foi executada a partir das seguintes etapas:

- Seleção aleatória dos indivíduos para a mutação. Uma vez que um indivíduo foi selecionado, ele nunca seria selecionado novamente;

- Seleção aleatória de alguns pesos, dentre cada indivíduo selecionado anteriormente;
- Seleção aleatória dos bits a serem alterados em cada um dos pesos selecionados. Caso qualquer um dos bits sorteados fosse pertencente ao expoente da representação binária do peso em análise, então se sorteava novamente outro bit, até que este não pertencesse ao expoente. Isso foi feito porque se fosse alterado algum bit do expoente, poder-se-ia alterar drasticamente o valor do peso. Assim, preferiu-se realizar as mutações ou no sinal ou na mantissa do peso binário.

3.6.13. Definição do método de reinserção dos indivíduos, que consistiu na seleção dos melhores indivíduos para a próxima geração

Para a seleção dos melhores indivíduos para a próxima geração, foi escolhido o método da reinserção ordenada. Através desse método, os indivíduos da população original e os novos indivíduos gerados após *crossover* e mutação (filhos com e sem mutação) foram ordenados. Em seguida, dentre os indivíduos ordenados, foram selecionados os primeiros melhores indivíduos, cuja quantidade foi igual ao número de indivíduos da população inicial.

3.7. Fluxograma de treinamento das RNAEs

O algoritmo de treinamento AG-LMRB, disposto na Fig. 3.23, emprega os métodos de busca global (AG) e local (LMRB). O método de LMRB, por buscar os mínimos locais, otimizando os pesos dos indivíduos da população na qual foi aplicado (ora na população inicial ora em todos os filhos com e sem mutação), teve o objetivo de auxiliar o AG na busca deste pelo mínimo global.

Para a implementação do método de LMRB, foram adotados os seguintes valores para a inicialização da constante μ e dos hiperparâmetros:

- $\mu = E_d$. Esse valor atribuído a constante μ representou uma modificação em relação ao valor empregado no trabalho de Suratgar; Tavakoli; Hoseinabadi (2005);
- $\beta = 1$ e $\alpha = 0$ (FORESEE; HAGAN, 1997).

E os critérios de parada adotados foram quando:

- O valor da função objetivo (Eq. 2.37) da iteração atual do método fosse menor que o valor dessa função na iteração anterior; e
- $\mu > 10^{10}$ (KAYRI, 2016).

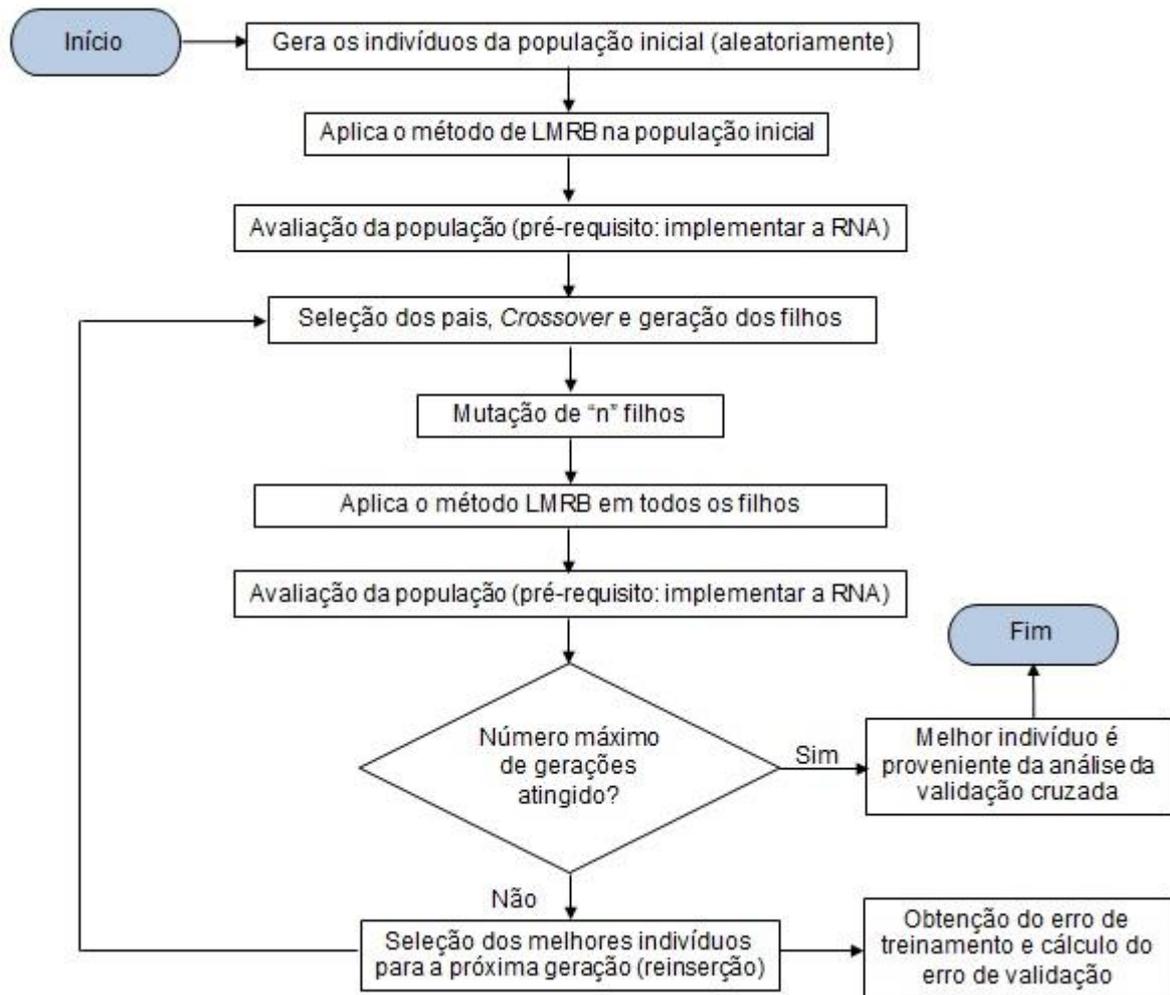


Figura 3.23 - Algoritmo de treinamento da RNAE: AG-LMRB

Como a função objetivo do treinamento foi o erro máximo, Eq. (3.9), diferentemente da função objetivo do método de LMRB, Eq. (2.37), então, durante a minimização da função objetivo do método de LMRB houve uma preocupação em se calcular esse erro antes e depois da otimização dos pesos para cada indivíduo da população do AG em análise.

Caso esse erro, em uma dada iteração do método, fosse menor que o erro obtido antes da otimização por esse método, armazenava-se esse valor de erro e os respectivos pesos atualizados. Esses valores eram então as novas referências para as próximas iterações, até que a função objetivo do método fosse minimizada (Eq. (2.37)).

No fim de cada execução do método, se analisava se cada indivíduo foi ou não otimizado pela minimização da função objetivo do treinamento (Eq. (3.9)). Caso fosse, os valores de erro e pesos atualizados eram obtidos dos respectivos valores armazenados durante as iterações do método de LMRB.

Para a obtenção do erro de treinamento, selecionou-se o erro do primeiro melhor indivíduo da população. Já o erro de validação foi obtido pelo teste da RNAE com o vetor de pesos que compõe esse primeiro melhor indivíduo e a partir da apresentação dos padrões de entrada de validação, que foram as variáveis de entrada normalizadas e obtidas via subconjunto de validação. O erro de validação também foi calculado conforme Eq. (3.9).

O algoritmo de treinamento AG-LMRB* (Fig. 3.24) foi similar ao da Fig. 3.23, com a diferença de acrescentar uma operação que permitiu a verificação de presença de indivíduos repetidos em uma dada população (ora na população inicial ora nos filhos após o método de LMRB). O método de LMRB, nesse caso, teve o intuito de auxiliar a manter a diversidade da população, bem como auxiliar o AG na busca pelo mínimo global.

Essa verificação ocorria da seguinte forma: caso cada i -ésimo peso de um dado indivíduo, relativamente a cada i -ésimo peso de outro indivíduo, fosse menor ou igual a 1 % (limite adotado), concluía-se que esses indivíduos eram similares ou iguais. Assim, o primeiro indivíduo era mantido e o outro era substituído por outro indivíduo gerado aleatoriamente, da mesma forma como fora gerado inicialmente.

Já o algoritmo de treinamento da RNA apresentado na Fig. 3.25, utilizou apenas o AG para treinar a RNA. O objetivo desse algoritmo foi verificar se o AG era suficiente para treinar uma RNA ou se algum dos algoritmos anteriores Fig. 3.23 ou Fig. 3.24, que empregam o método LMRB durante o treinamento, apresentavam resultados mais satisfatórios.

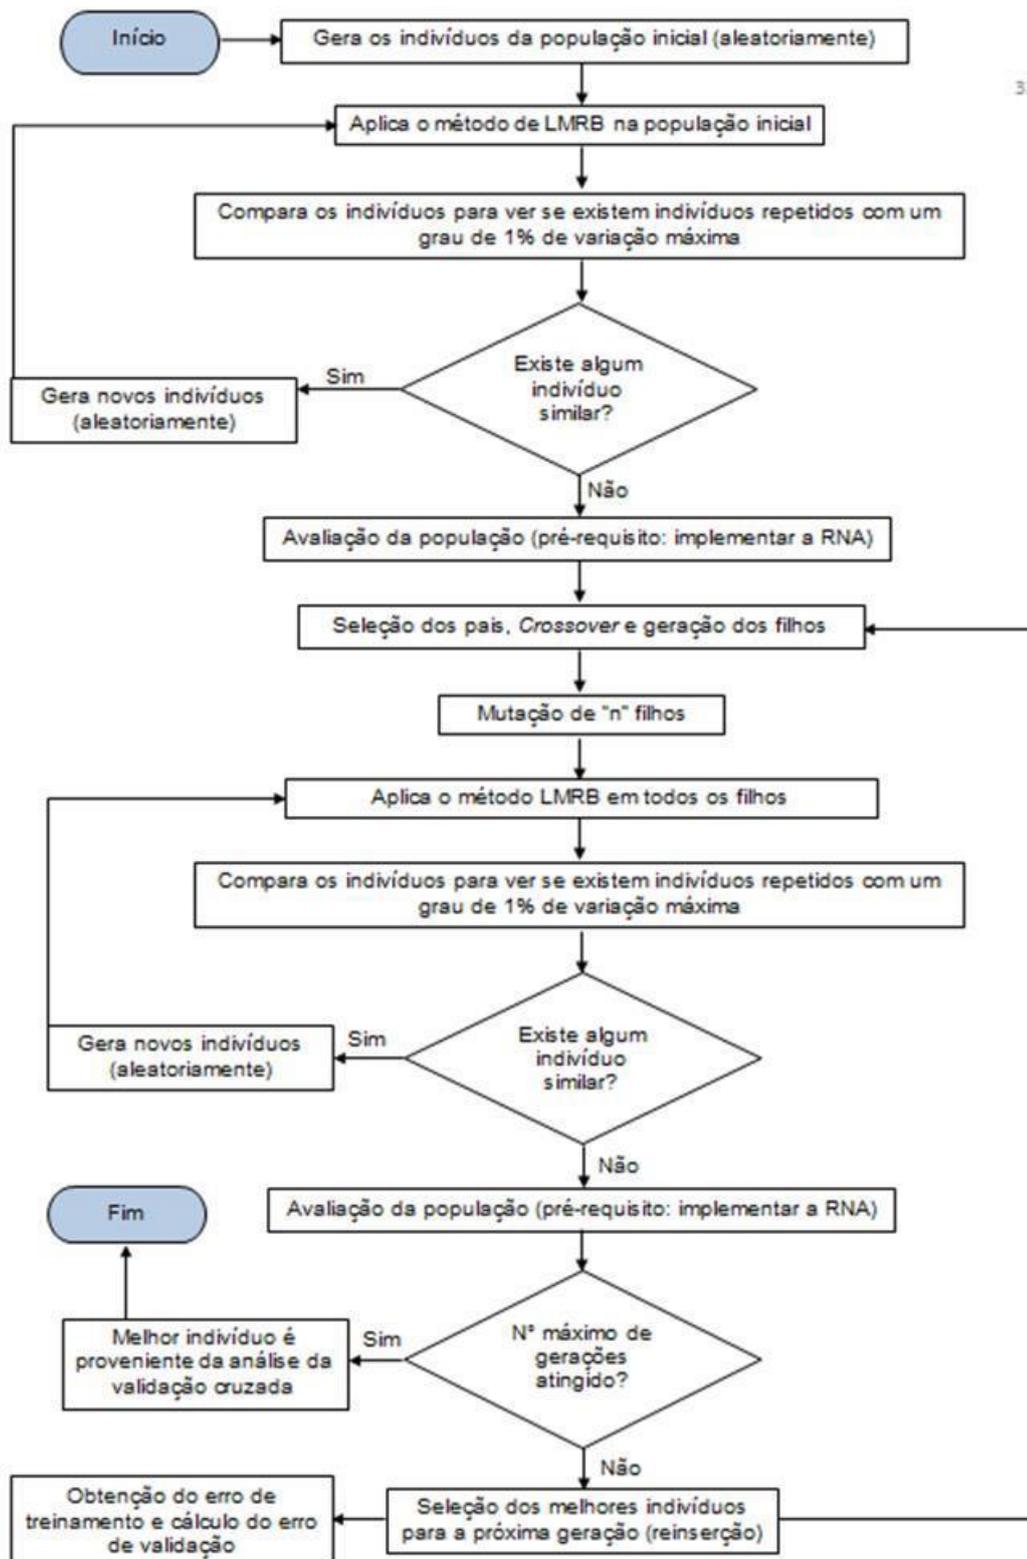


Figura 3.24 - Algoritmo de treinamento da RNAE: AG-LMRB*, com verificação de similaridade entre os indivíduos da população de interesse

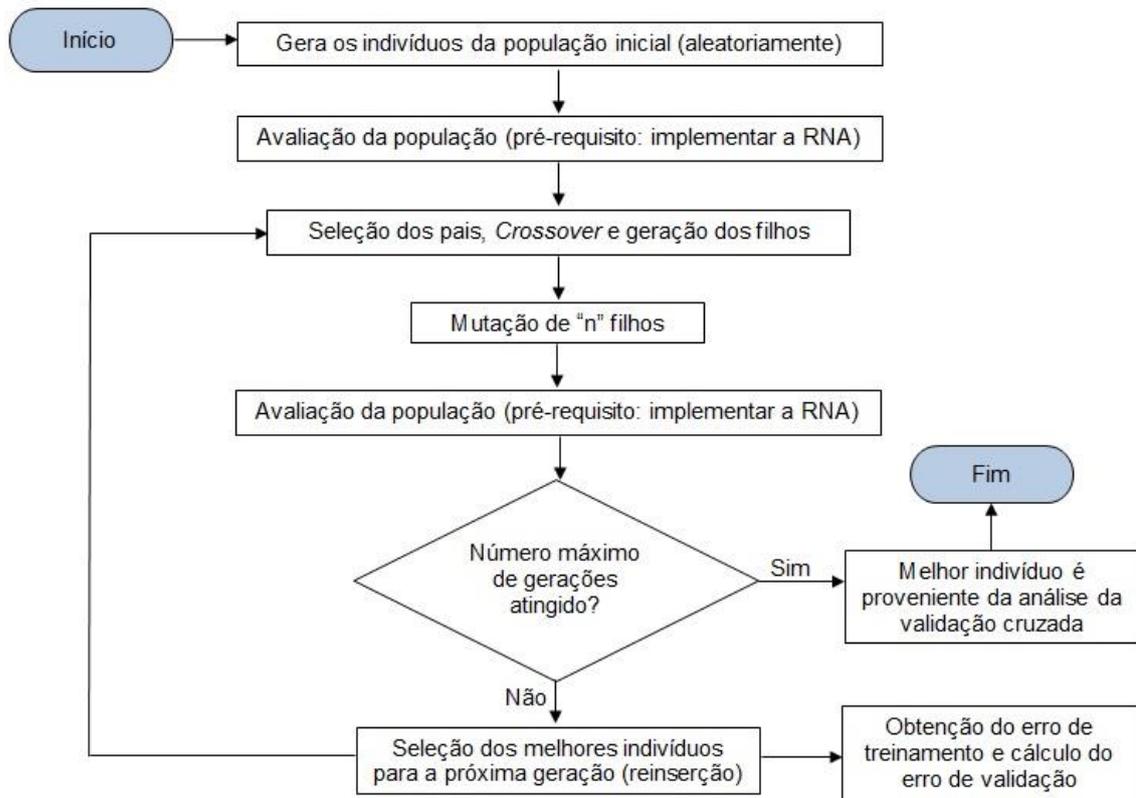


Figura 3.25 – Algoritmo de treinamento da RNAE: AG

3.8. Definição de diferentes configurações de treinamento das RNAEs

No intuito de se obter a melhor configuração de treinamento das RNAEs para cada propriedade mecânica, foi definido um conjunto de diferentes configurações de treinamento que foram executadas conforme as Tabs. 3.18 a 3.20. Essas tabelas estão relacionadas, respectivamente, à estimativa da dureza Brinell e dos limites de resistência e de escoamento. Cada configuração foi definida com uma dada arquitetura de rede e um determinado método de treinamento, bem como com específicos valores para os parâmetros de desempenho do AG.

Para cada uma das configurações executadas, foi obtida a melhor geração, que consiste naquela para a qual ocorreu o ponto de mínimo da curva do erro de validação. Para esse ponto foram, então, coletados os valores dos pesos ótimos, o erro de treinamento e o erro de validação. Cada execução dessas configurações teve o seu tempo calculado durante o treinamento correspondente ao total de gerações.

Apenas os parâmetros de desempenho do AG que não foram comuns para todas as configurações estão expressos nas Tabs. 3.18 a 3.20. Essas configurações foram realizadas empregando o método de treinamento AG ou AG-LMRB.

Tabela 3.18 - Conjunto de diferentes configurações de treinamento das RNAEs executadas para estimar a dureza Brinell

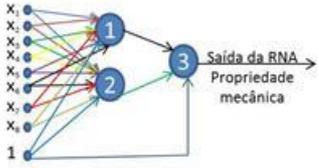
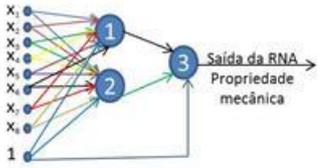
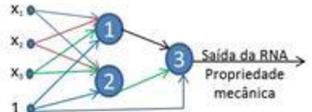
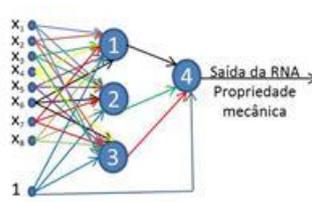
Nº	Arquitetura da RNAE e Método de treinamento	Quantidade de gerações	Taxa de mutação dos filhos	Taxa de mutação dos pesos	Quantidade de bits da mutação	Método de seleção dos pais	Limites dos Pesos
1	 <p>Método de treinamento: AG</p>	100	15 %	38 %	2	Ranking	-1 a 1
2		200	15 %	38 %	2	Ranking	-1 a 1
3		200	15 %	38 %	4	Ranking	-1 a 1
4		100	15 %	38 %	2	Ranking	-1,5 a 1,5
5	 <p>Método de treinamento: AG-LMRB</p>	100	15 %	38 %	2	Ranking	-1 a 1
6		100	15 %	38 %	4	Ranking	-1 a 1
7		100	15 %	38 %	2	Ranking	-1,5 a 1,5
8		100	15 %	38 %	4	Ranking	-1,5 a 1,5
9		100	15 %	38 %	2	Ranking	-3 a 3
10		100	15 %	38 %	4	Ranking	-3 a 3
11		100	15 %	38 %	2	Torneio	-1,5 a 1,5
12		100	30 %	38 %	2	Torneio	-1,5 a 1,5

Tabela 3.18 – Continuação

Nº	Arquitetura da RNAE e Método de treinamento	Método PCA	Taxa de mutação dos pesos	Método de seleção dos pais	Limites dos Pesos
13		B2	36 %	Ranking	-1,5 a 1,5
14	Método de treinamento: AG-LMRB	B4	36 %	Ranking	-1,5 a 1,5
15		-	39 %	Ranking	-1,5 a 1,5
16		-	39 %	Ranking	-1 a 1
17	Método de treinamento: AG-LMRB	-	39 %	Torneio	-1 a 1

As configurações das Tabelas 3.18 a 3.20, em geral, foram definidas aleatoriamente, visando não impor a pressão seletiva. Especificamente para a Tabela 3.18 foi testada uma quantidade maior de configurações, porque se buscou treinar as RNAEs primeiramente para a dureza Brinell e os resultados obtidos ajudaram a definir as configurações das Tabs. 3.19 e 3.20.

As configurações 13 a 17 da Tabela 3.18 foram executadas com os seguintes parâmetros comuns do AG: 100 gerações, taxa de mutação dos filhos de 15 % e quantidade de bits da mutação igual a 2.

Tabela 3.19 - Conjunto de diferentes configurações de treinamento das RNAEs executadas para estimar o limite de resistência

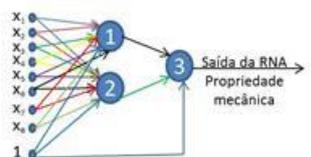
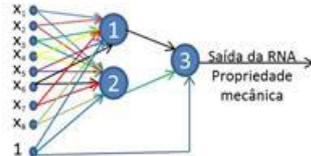
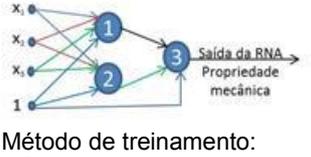
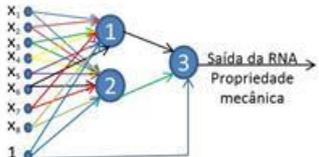
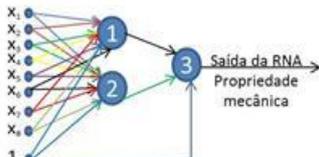
Treinamento de RNAEs para estimar o Limite de resistência								
Nº	Arquitetura da RNAE e Método de treinamento	Método PCA	Quantidade de gerações	Taxa de mutação dos filhos	Taxa de mutação dos pesos	Quantidade de bits da mutação	Método de seleção dos pais	Limites dos Pesos
1		-	100	15 %	38 %	2	Ranking	-1,5 a 1,5
2	Método de treinamento: AG	-	200	15 %	38 %	2	Ranking	-1,5 a 1,5
3		-	100	15 %	38 %	2	Ranking	-1 a 1
4		-	100	15 %	38 %	2	Ranking	-1,5 a 1,5
5		-	100	15 %	38 %	4	Ranking	-1,5 a 1,5
6	Método de treinamento: AG-LMRB	-	100	15 %	38 %	2	Ranking	-3 a 3
7		-	100	15 %	38 %	2	Torneio	-1,5 a 1,5
8		-	100	30 %	38 %	2	Torneio	-1,5 a 1,5
9		B2	100	15 %	36 %	2	Ranking	-1,5 a 1,5
10	Método de treinamento: AG-LMRB	B4	100	15 %	36 %	2	Ranking	-1,5 a 1,5
11		-	100	15 %	39 %	2	Ranking	-1 a 1
12	Método de treinamento: AG-LMRB	-	100	15 %	39 %	2	Ranking	-1,5 a 1,5

Tabela 3.20 - Conjunto de diferentes configurações de treinamento das RNAEs executadas para estimar o limite de escoamento

Treinamento de RNAEs para estimar o Limite de escoamento								
Nº	Arquitetura da RNAE e Método de treinamento	Método PCA	Quantidade de gerações	Taxa de mutação dos filhos	Taxa de mutação dos pesos	Quantidade de bits da mutação	Método de seleção dos pais	Limites dos Pesos
1		-	100	15 %	38 %	2	Ranking	-1,5 a 1,5
2	Método de treinamento: AG	-	200	15 %	38 %	2	Ranking	-1,5 a 1,5
3		-	100	15 %	38 %	4	Ranking	-1,5 a 1,5
4		-	100	15 %	38 %	2	Torneio	-1,5 a 1,5
5	Método de treinamento: AG-LMRB	-	100	30 %	38 %	2	Torneio	-1,5 a 1,5
6		B2	100	15 %	36 %	2	Ranking	-1,5 a 1,5
7	Método de treinamento: AG-LMRB	B4	100	15 %	36 %	2	Ranking	-1,5 a 1,5
8		-	100	15 %	39 %	2	Ranking	-1 a 1
9	Método de treinamento: AG-LMRB	-	100	15 %	39 %	2	Ranking	-1,5 a 1,5

Para o algoritmo de treinamento AG-LMRB*, com verificação de existência de indivíduos repetidos, foi executada apenas a melhor configuração de cada propriedade mecânica obtida através das execuções das configurações das Tabs. 3.18 a 3.20. O objetivo foi verificar se os melhores resultados obtidos poderiam ser ainda melhorados.

3.9. Seleção da melhor configuração de treinamento das RNAEs para cada propriedade mecânica

A seleção da melhor configuração de treinamento das RNAEs para cada propriedade mecânica, dentre as configurações executadas, foi baseada na escolha daquela que resultou em um menor erro de treinamento a partir da análise da validação cruzada (HAGAN *et al.*, 2014). Conseqüentemente, essa configuração representou a melhor combinação entre: arquitetura de rede, parâmetros do AG e algoritmo de treinamento.

Para cada propriedade mecânica, os pesos ótimos correspondentes à RNAE submetida à melhor configuração de treinamento foram utilizados posteriormente para testar as RNAEs e verificar sua capacidade de generalização. Esses mesmos pesos compõem, definitivamente, os pesos (incluindo o *bias*) da RNAE para estimar dada propriedade mecânica.

3.10. Algoritmo de obtenção das propriedades mecânicas a partir das RNAEs treinadas

Como exposto anteriormente, para cada propriedade mecânica analisada, os pesos ótimos correspondentes à RNAE treinada pela melhor configuração foram reinsertados na respectiva RNAE para que ela pudesse estimar determinada propriedade a partir da apresentação do subconjunto de teste (Seção 3.1).

A Figura 3.26 representa o algoritmo de obtenção de uma dada propriedade mecânica (dureza Brinell ou limite de resistência ou limite de escoamento) para sua melhor RNAE treinada. Como exemplo, na Fig. 3.26, foram apresentadas curvas $F \times h$ de ensaios de macroindentação do aço "A" a uma RNAE com arquitetura igual à da Fig. 3.15.

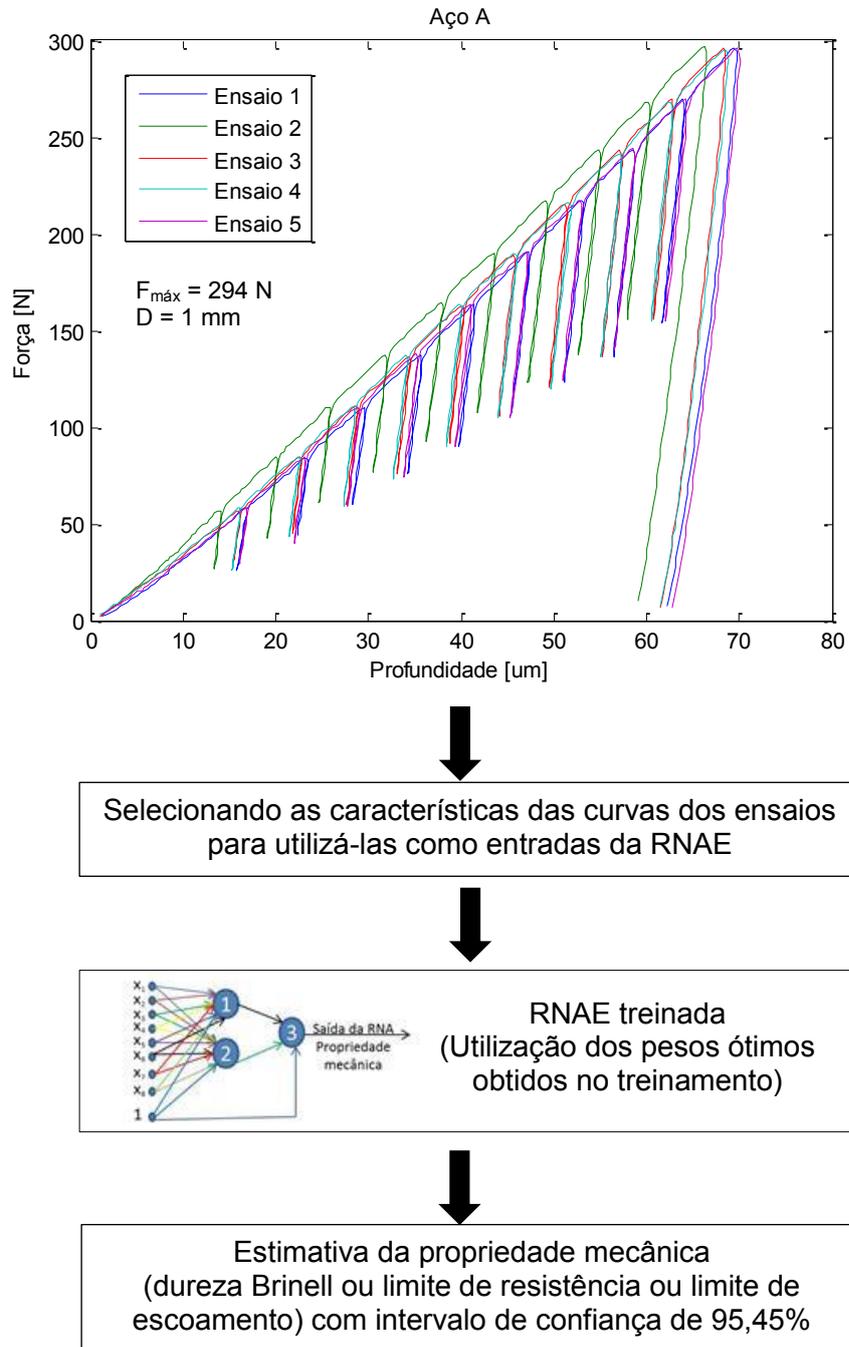


Figura 3.26 – Algoritmo de obtenção das propriedades mecânicas para a RNAE treinada. Exemplo para a obtenção de uma dada propriedade mecânica do aço A, considerando a arquitetura de RNAE da Fig. 3.15

CAPÍTULO IV

RESULTADOS E DISCUSSÕES

Os resultados provenientes das execuções das configurações de treinamento das RNAEs, apresentadas no Capítulo III, são mostrados a seguir.

4.1. Resultados dos treinamentos das RNAEs para estimar a dureza Brinell

Na Tabela 4.1 estão contidos os resultados dos treinamentos de RNAEs através dos algoritmos AG ou AG-LMRB para estimar a dureza Brinell. E no Apêndice II estão representados todos os gráficos com os erros de treinamento e validação obtidos através desses treinamentos.

Observa-se na Tabela 4.1 que o resultado da configuração 2 não foi melhor em relação ao resultado da configuração 1, mesmo aumentando em duas vezes a quantidade de gerações do AG. Isso ocorreu porque o AG é um método probabilístico e, também, ele pode convergir antes de atingir o total de gerações para o qual ele foi programado (Apêndice 2, Fig. AII.2).

Na Tabela 4.1, quando foi aplicado apenas o AG como algoritmo de treinamento da RNAE, o tempo total de execução do mesmo para 100 gerações foi aproximadamente 60 % menor e, em contrapartida, os erros obtidos foram maiores, em relação ao tempo de execução e aos erros resultantes da aplicação do algoritmo de treinamento AG-LMRB para a mesma quantidade de gerações e mesma arquitetura de rede.

Assim, no intuito de comparar os resultados provenientes do treinamento de RNAEs com a mesma arquitetura, através dos algoritmos AG e AG-LMRB, considerando um tempo total de execução similar, as configurações 2 e 3 (Tab. 4.1) foram executadas com o método de treinamento AG (puro) com 200 gerações. Observou-se que as configurações similares, configurações 5 e 6, nas quais foi empregado o método de treinamento AG-LMRB e 100

gerações do AG, após serem executadas, geraram erros menores que os erros dessas configurações 2 e 3.

Tabela 4.1 - Resultados dos treinamentos de RNAEs para estimar a dureza Brinell

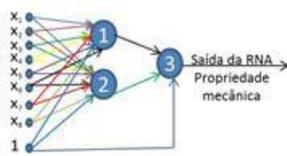
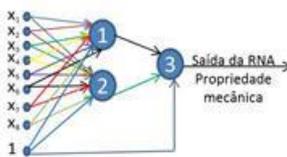
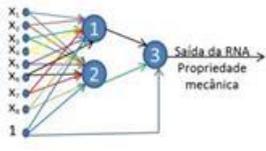
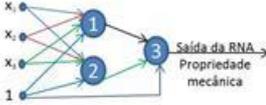
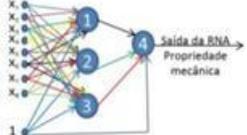
Treinamentos da RNAE para estimar a Dureza Brinell - Método de treinamento: AG											
											
Nº	PCA	Qtde. de gerações	Taxa de mut. dos filhos	Taxa de mut. dos pesos	Qtde de bits da mut.	Método de seleção dos pais	Limites dos Pesos	Melhor geração	Erro Trein. [%] ⁽¹⁾	Erro Valid. [%] ⁽¹⁾	Tempo total de execução [h] ⁽²⁾
1	-	100	15 %	38 %	2	Ranking	-1 a 1	30	10,12	9,88	107
2	-	200	15 %	38 %	2	Ranking	-1 a 1	13	13,53	15,97	246
3	-	200	15 %	38 %	4	Ranking	-1 a 1	77	10,41	14,84	205
4	-	100	15 %	38 %	2	Ranking	-1,5 a 1,5	73	6,66	10,41	96
Treinamentos da RNAE para estimar a Dureza Brinell - Método de treinamento: AG-LMRB											
											
5	-	100	15 %	38 %	2	Ranking	-1 a 1	47	3,81	6,38	261
6	-	100	15 %	38 %	4	Ranking	-1 a 1	26	4,25	5,74	262
7	-	100	15 %	38 %	2	Ranking	-1,5 a 1,5	24	3,50	5,78	280
8	-	100	15 %	38 %	4	Ranking	-1,5 a 1,5	29	3,41	5,82	260
9	-	100	15 %	38 %	2	Ranking	-3 a 3	9	4,78	4,51	259

Tabela 4.1 – Continuação

Treinamentos da RNAE para estimar a Dureza Brinell - Método de treinamento: AG-LMRB											
											
N°	PCA	Qtde. de gerações	Taxa de mut. dos filhos	Taxa de mut. dos pesos	Qtde de bits da mut.	Método de seleção dos pais	Limites dos Pesos	Melhor geração	Erro Trein. [%] ⁽¹⁾	Erro Valid. [%] ⁽¹⁾	Tempo total de execução [h] ⁽²⁾
10	-	100	15 %	38 %	4	Ranking	-3 a 3	16	5,11	5,62	260
11	-	100	15 %	38 %	2	Torneio	-1,5 a 1,5	6	5,47	5,57	220
12	-	100	30 %	38 %	2	Torneio	-1,5 a 1,5	13	3,99	5,51	251
Treinamentos da RNAE para estimar a Dureza Brinell - Método de treinamento: AG-LMRB											
											
13	B2	100	15 %	36 %	2	Ranking	-1,5 a 1,5	17	46,23	36,17	262
14	B4	100	15 %	36 %	2	Ranking	-1,5 a 1,5	14	49,71	39,05	261
Treinamento da RNAE para estimar a Dureza Brinell - Método de treinamento: AG-LMRB											
											
15	-	100	15 %	39 %	2	Ranking	-1,5 a 1,5	33	3,66	5,63	255
16	-	100	15 %	39 %	2	Ranking	-1 a 1	18	4,47	5,20	283
17	-	100	15 %	39 %	2	Torneio	-1 a 1	18	3,60	6,16	282

⁽¹⁾ Os erros de treinamento (Erro Trein.) e validação (Erro Valid.) foram obtidos através da melhor geração do treinamento, aquela na qual houve o menor valor do erro de validação pelo processo da validação cruzada. Todos esses erros foram obtidos com um nível de confiança de 95,45 %.

⁽²⁾ Valor aproximado do tempo total de execução.

Já a execução da configuração 4 da Tab. 4.1 apresentou um erro de treinamento um pouco menor em relação aos erros das configurações 1 a 3, todas executadas através do método de treinamento AG. Todavia, esse erro (6,66 %) ainda foi maior que o erro de treinamento obtido (3,50 %) em uma configuração similar, configuração 7, a qual foi executada a partir do método AG-LMRB. Isso evidenciou que o método de treinamento AG-LMRB foi melhor que o método de treinamento que utiliza o AG puro nas condições dos experimentos.

Em geral, pode-se afirmar que a utilização do AG puro como método de treinamento forneceu resultados não tão bons, com erros de treinamento atingindo até 13,53 %.

Já os resultados obtidos com o treinamento das RNAEs, cuja arquitetura está evidenciada na Tab. 4.1, através do método de treinamento AG-LMRB, foram satisfatórios (configurações 5 a 12 da Tab. 4.1), pois os erros de treinamento foram muito pequenos, com um mínimo de 3,41 % na configuração 8 e um máximo de 5,47 % configuração 11. Portanto, esse método, quando aplicado na RNAE de nove entradas e três neurônios, pode ser considerado adequado para estimar a dureza Brinell.

Já as configurações 13 e 14 (Tab. 4.1), as quais foram executadas em RNAEs de quatro entradas e três neurônios através do método AG-LMRB, resultaram em erros de treinamento muito elevados, indicando baixa exatidão para a estimativa da dureza Brinell. Esses erros foram, respectivamente, iguais a 46,23 % e 49,71 %, para as configurações 13 (método PCA: B2) e 14 (método PCA: B4).

A aplicação da PCA, nessas configurações, não melhorou a aprendizagem da RNA. Também, Silva; Almeida e Yamakami (2012) aplicaram a técnica PCA no pré-processamento dos dados para o treinamento de uma RNA e verificaram que ela não foi vantajosa para a aprendizagem da rede.

Neste caso, a utilização do método PCA não foi adequada, porque o mecanismo de seleção dos métodos empregados (B2 e B4) pode não ser confiável por depender apenas dos coeficientes das PCs (CADIMA; JOLLIFFE, 1995). Também, ao reduzir a dimensão do vetor de entrada utilizando uma transformação linear (PC), talvez algumas informações não lineares tenham sido perdidas (HAGAN *et al.*, 2014).

As configurações 15 a 17 da Tab. 4.1 foram executadas para os treinamentos de RNAEs de nove entradas e quatro neurônios, através do método AG-LMRB. A execução da configuração 15 resultou num erro de treinamento de 3,66 %, que foi um pouco maior que o erro de 3,50 %, da configuração similar a essa, configuração 7. Da mesma forma, o erro de treinamento de 4,47 % da configuração 16 foi maior que o erro de 3,81 % da configuração 5. Mas, o erro de treinamento de 3,60 % obtido a partir da configuração 17 foi menor que o erro de 5,47 % da configuração 11, que tem um parâmetro diferente da configuração 17.

Esse parâmetro representa os limites adotados para os pesos na inicialização do algoritmo e na restrição após a mutação.

Diante do exposto, percebe-se que a inicialização dos pesos foi um fator importante no desempenho das redes e que o aumento desnecessário dos neurônios ocultos pôde produzir resultados com uma menor exatidão.

Por fim, analisando todos os resultados obtidos na Tab. 4.1, conclui-se que a configuração 8 foi a que proporcionou o melhor resultado. Ou seja, o menor erro de treinamento foi de 3,41 % na estimativa da dureza Brinell, a partir da execução da configuração 8 em uma RNAE de nove entradas e três neurônios, que foi treinada via método AG-LMRB, Fig. 4.1.

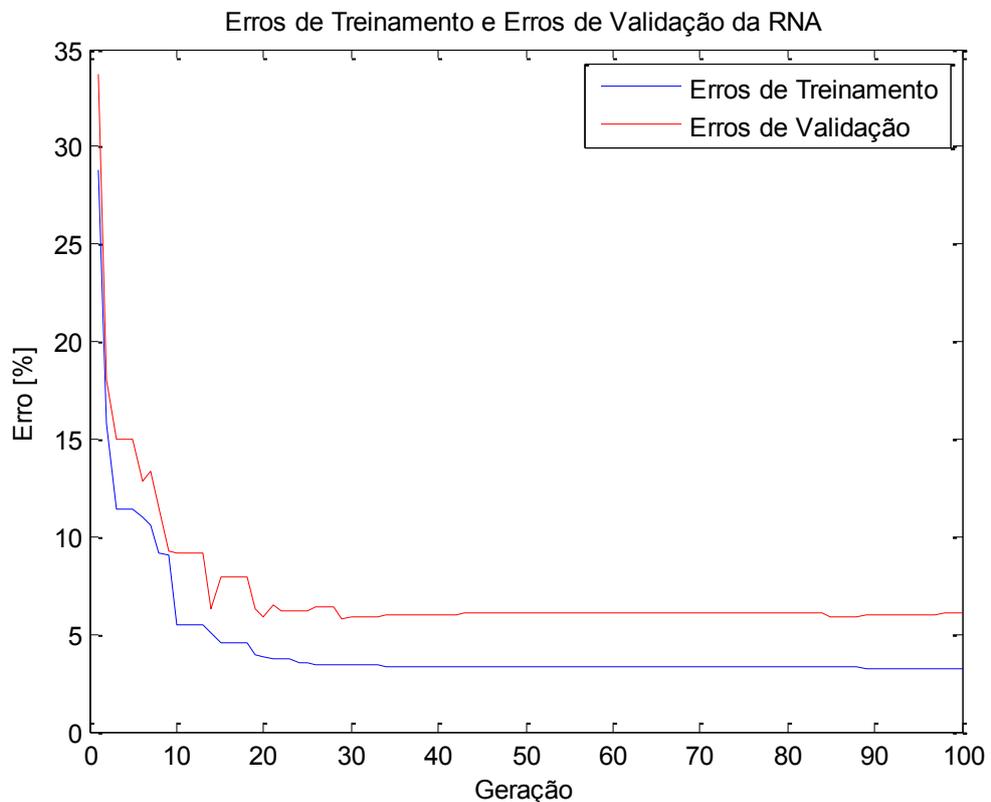
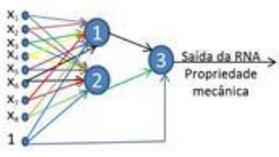


Figura 4.1 – Melhor resultado do treinamento da RNAE para estimar a dureza Brinell – Treinamento realizado a partir da execução da configuração 8 (Tab. 4.1) e do método AG-LMRB para treinar uma RNAE de 9 entradas e 3 neurônios

Posteriormente, foi feita a execução da configuração 8 utilizando a mesma arquitetura de rede, mas empregando o método de treinamento AG-LMRB*, que tem a operação adicional de verificar se existem indivíduos repetidos na população do AG, Tab. 4.2. O erro de treinamento obtido nesse caso foi de 4,42 %, que é maior que o obtido

empregando apenas o método AG-LMRB. Portanto, o método de treinamento AG-LMRB foi o mais adequado.

Tabela 4.2 – Resultado do treinamento da RNAE a partir da configuração 8 (Tab. 4.1) e do método de treinamento AG-LMRB*

Treinamento da RNAE para estimar a Dureza Brinell - Método de treinamento: AG-LMRB*									
									
Qtde. de gerações	Taxa de mut. dos filhos	Taxa de mut. dos pesos	Qtde de bits da mut.	Método de seleção dos pais	Limites dos Pesos	Melhor geração	Erro Trein. [%] ⁽¹⁾	Erro Valid. [%] ⁽¹⁾	Tempo total de execução [h] ⁽²⁾
100	15 %	38 %	4	Ranking	-1,5 a 1,5	17	4,42	5,00	250

⁽¹⁾ Os erros de treinamento (Erro Trein.) e validação (Erro Valid.) foram obtidos através da melhor geração do treinamento, aquela na qual houve o menor valor do erro de validação pelo processo da validação cruzada. Todos esses erros foram obtidos com um nível de confiança de 95,45 %.

⁽²⁾ Valor aproximado do tempo total de execução.

Os pesos (e *bias*) da RNAE, obtidos através da execução da configuração 8, foram considerados os pesos ótimos da RNAE, Tab. 4.3. Eles foram, então, utilizados para testar novos materiais com essa rede. Vale salientar que a limitação dos pesos, durante o treinamento, só ocorreu após a mutação e não após o método de LMRB. Portanto, considerando a configuração 8, os pesos ótimos não ficaram limitados exatamente entre o intervalo [-1,5 1,5], porque houve a atuação do método de LMRB após a mutação.

Os resultados dos testes da RNAE treinada conforme a configuração 8 são mostrados na Fig. 4.2. Nesse caso, o erro associado a cada configuração de ensaio foi o erro relativo entre a propriedade medida experimentalmente e o valor médio das propriedades mecânicas obtidas pela RNAE em cada configuração.

Conforme se observa na Fig. 4.2, há configurações de ensaio, cujos resultados de erros associados ficaram fora dos limites pré-estabelecidos ($\pm 3,41$ %).

Isso ocorreu porque os materiais B e C apresentaram gradiente significativo de propriedade mecânica ao longo da espessura, como mostrado na Fig. 3.4. Assim, a propriedade medida experimentalmente (média) desses materiais não representou bem o perfil de dureza ao longo da espessura desses materiais.

Tabela 4.3 – Melhor arquitetura da RNA e valores ótimos dos pesos para estimar a dureza Brinell de novos materiais

Melhor arquitetura da RNA e pesos ótimos para estimar a dureza Brinell				
Número do neurônio	Entrada do neurônio	Posição do peso binário no vetor	Posição do peso decimal no vetor	Valor real do peso
1	X ₁	Bit 671 ao bit 640	1	-1,3605
	X ₂	Bit 639 ao bit 608	2	0,0632
	X ₃	Bit 607 ao bit 576	3	0,0160
	X ₄	Bit 575 ao bit 544	4	-0,1133
	X ₅	Bit 543 ao bit 512	5	0,0343
	X ₆	Bit 511 ao bit 480	6	-1,1368
	X ₇	Bit 479 ao bit 448	7	-0,2166
	X ₈	Bit 447 ao bit 416	8	1,6605
	1	Bit 415 ao bit 384	9	-0,2557
2	X ₁	Bit 383 ao bit 352	10	-1,5134
	X ₂	Bit 351 ao bit 320	11	0,7306
	X ₃	Bit 319 ao bit 288	12	-0,0373
	X ₄	Bit 287 ao bit 256	13	-0,4297
	X ₅	Bit 255 ao bit 224	14	-1,4045
	X ₆	Bit 223 ao bit 192	15	0,7261
	X ₇	Bit 191 ao bit 160	16	-1,0130
	X ₈	Bit 159 ao bit 128	17	-1,4892
	1	Bit 127 ao bit 96	18	-1,2522
3	Saída do neurônio 1	Bit 95 ao bit 64	19	-1,5777
	Saída do neurônio 2	Bit 63 ao bit 32	20	-1,4202
	1	Bit 31 ao bit 0	21	1,5282

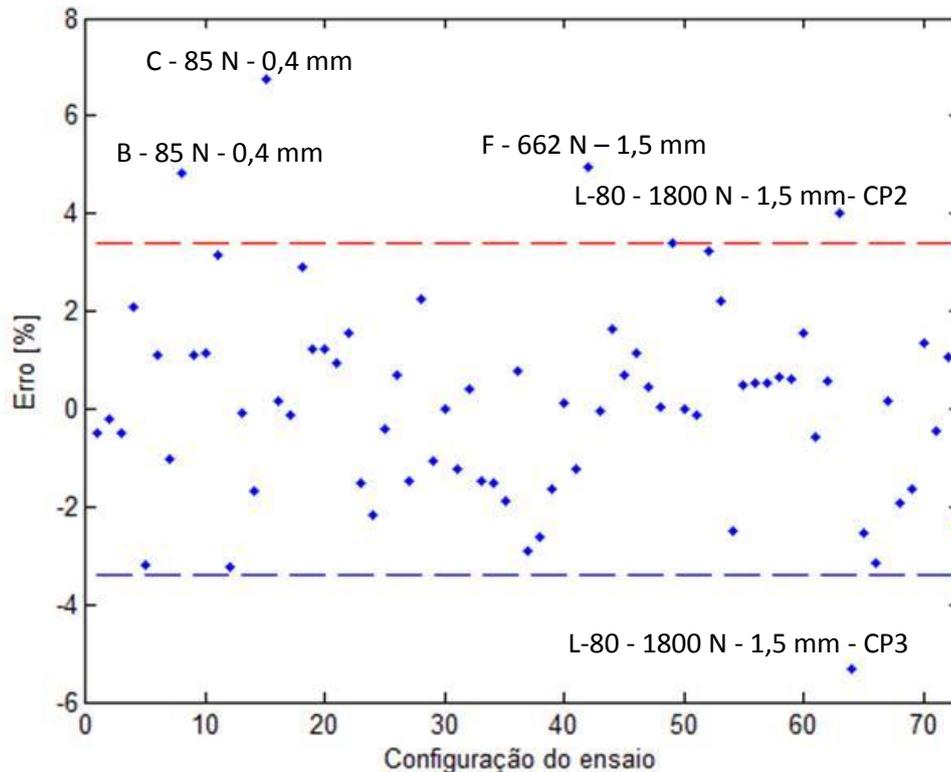


Figura 4.2 – Teste da melhor RNAE para estimar a dureza Brinell, utilizando todos os materiais para verificação dos erros obtidos em cada configuração de ensaio

Além dos materiais B e C, os aços F e L-80 também foram avaliados com erros superiores aos limites máximos do erro da estimativa da dureza Brinell. Isso pode ser justificado devido às curvas $F \times h$ de seus ensaios não terem sido totalmente sobrepostas (Anexo I). Quando as curvas $F \times h$ não são aproximadamente sobrepostas, isso indica que esses materiais apresentam heterogeneidade de propriedades mecânicas, o que faz com que a dureza Brinell estimada experimentalmente (valor médio) também não seja representativa para todos os pontos ensaiados.

O material L-80 também foi empregado no processo de validação da rede. Constatou-se, na Fig. 4.2, que os erros associados à estimativa da dureza Brinell desse material, nas configurações de ensaio que extrapolaram os limites do erro permitido, foram menores, em módulo, que 5,82 %, correspondente ao erro de validação obtido para a configuração 8, com um nível de confiança de 95,45 % (Tab. 4.1).

No gráfico da Figura 4.3, observam-se os erros associados à estimativa da dureza Brinell dos aços de “A” a “G”, a partir da melhor RNAE treinada, em função do diâmetro do penetrador empregado nos ensaios. Apenas foram representados os erros desses aços,

pois estes foram os únicos presentes no banco de dados que tiveram ensaios realizados com todos os penetradores.

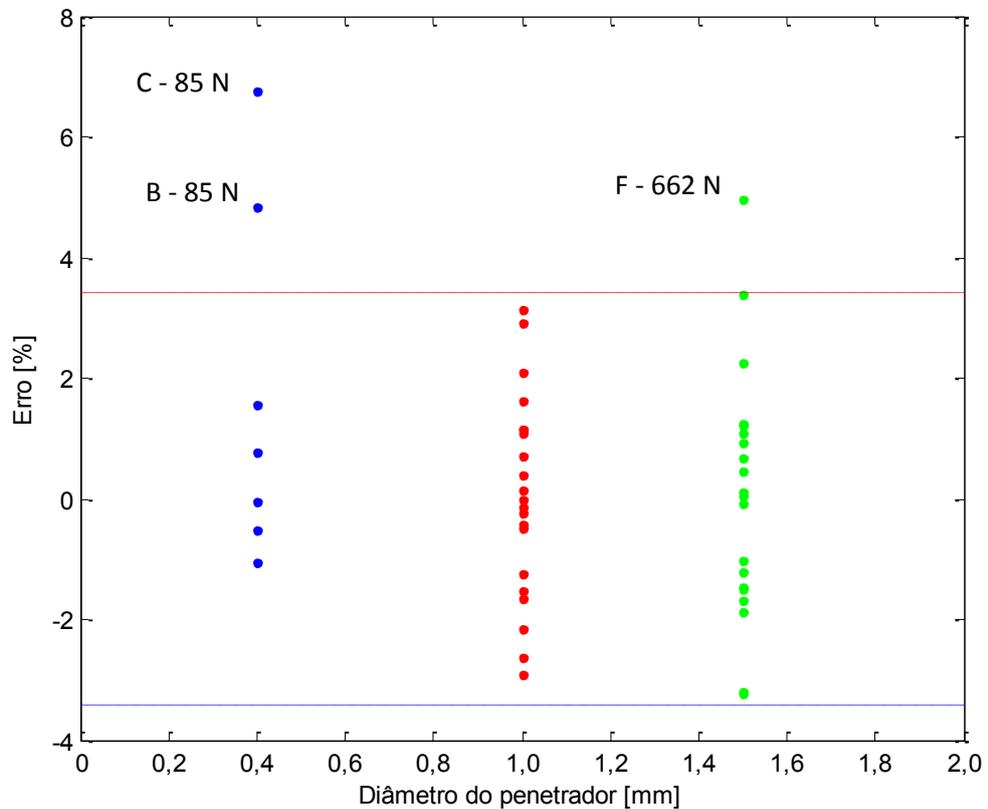


Figura 4.3 – Resultado do teste da melhor RNAE para estimar a dureza Brinell, utilizando apenas os materiais de “A” a “G”, que tiveram ensaios realizados com todos os penetradores

Na Figura 4.3, identifica-se que, para os ensaios realizados com o penetrador de diâmetro igual a 0,4 mm, os erros associados à estimativa da dureza Brinell pela RNAE de todos os aços de “A” a “G”, exceto “B” e “C”, estiveram compreendidos entre -1,06 % e 1,55 %, menor ainda que os limites pré-estabelecidos. E, para os ensaios realizados com penetrador de diâmetro igual a 1,0 mm, os erros da dureza Brinell de todos os materiais, dentre os aços de “A” a “G”, ficaram dentro dos limites. Isso significou que os ensaios realizados com penetradores de diâmetros iguais a 0,4 mm e 1,0 mm foram interpretados com boa exatidão pela RNAE.

4.2. Resultados dos treinamentos das RNAEs para estimar o limite de resistência

Na Tabela 4.4 estão contidos os resultados dos treinamentos de RNAEs através dos algoritmos AG ou AG-LMRB para estimar o limite de resistência. E no Apêndice III estão representados todos os gráficos com os erros de treinamento e validação obtidos através desses treinamentos.

Na Tabela 4.4, os erros de treinamento das RNAEs de nove entradas e três neurônios, treinadas via método AG a partir das configurações 1 e 2, foram maiores que os erros de treinamento de RNAEs com a mesma arquitetura de rede, mas treinadas com o algoritmo AG-LMRB, conforme as configurações 3 a 8. Isso evidencia que este último método de treinamento foi o de melhor desempenho.

Ainda utilizando esse método de treinamento AG-LMRB, as configurações 9 e 10 (Tab. 4.4), aplicadas em RNAEs de quatro entradas e três neurônios, resultaram em erros de treinamento maiores que os erros das configurações 3 a 8 (Tab. 4.4), as quais foram executadas em uma rede de nove entradas e três neurônios. Visto isso, conclui-se que o método PCA aplicado na redução das entradas de nove para quatro não melhorou o desempenho da rede.

Já quando se aumentou o número de neurônios para quatro, mantendo-se as nove entradas e o método de treinamento AG-LMRB, o erro de treinamento da configuração 11 (Tab. 4.4) foi menor que o da configuração 3. Esta configuração 3 diferencia-se da configuração 11 por ter sido executada em uma RNAE de três neurônios. Nesse caso, o aumento da quantidade de neurônios melhorou o desempenho da rede. Todavia, quando se comparam os resultados das configurações 12 e 4, o erro de treinamento foi um pouco maior na configuração 12, que considera quatro neurônios.

Por fim, conclui-se que a configuração 7 (Tab. 4.4) resultou no melhor treinamento das RNAEs para estimar o limite de resistência, garantindo que o erro associado a estimativa dessa propriedade deve estar na faixa de $\pm 6,25\%$, com um nível de confiança de 95,45 %.

Nota-se que essa configuração 7 (Tab. 4.4) foi composta por parâmetros de desempenho do AG diferentes da melhor configuração obtida para a dureza Brinell (configuração 8, Tab. 4.1). Isso ratifica a importância do treinamento de RNAEs isoladamente para cada propriedade mecânica.

Tabela 4.4 - Resultados dos treinamentos de RNAEs para estimar o limite de resistência

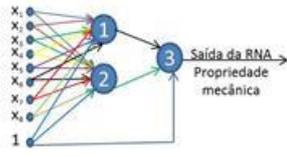
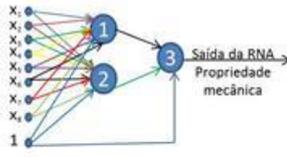
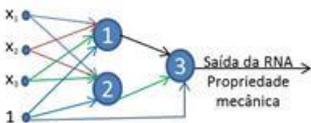
Treinamentos da RNAE para estimar o Limite de resistência - Método de treinamento: AG											
											
N°	PCA	Qtde. de gerações	Taxa de mut. dos filhos	Taxa de mut. dos pesos	Qtde de bits da mut.	Método de seleção dos pais	Limites dos Pesos	Melhor geração	Erro Trein. [%] ⁽¹⁾	Erro Valid. [%] ⁽¹⁾	Tempo total de execução [h] ⁽²⁾
1	-	100	15 %	38 %	2	Ranking	-1,5 a 1,5	45	9,76	11,96	117
2	-	200	15 %	38 %	2	Ranking	-1,5 a 1,5	137	11,24	14,36	204
Treinamentos da RNAE para estimar o Limite de resistência - Método de treinamento: AG-LMRB											
											
3	-	100	15 %	38 %	2	Ranking	-1 a 1	85	7,24	14,13	248
4	-	100	15 %	38 %	2	Ranking	-1,5 a 1,5	60	6,31	10,44	219
5	-	100	15 %	38 %	4	Ranking	-1,5 a 1,5	25	6,56	10,55	253
6	-	100	15 %	38 %	2	Ranking	-3 a 3	8	7,29	7,82	266
7	-	100	15 %	38 %	2	Torneio	-1,5 a 1,5	77	6,25	10,48	222
8	-	100	30 %	38 %	2	Torneio	-1,5 a 1,5	78	6,27	9,64	250

Tabela 4.4 – Continuação

Treinamentos da RNAE para estimar o Limite de resistência - Método de treinamento: AG-LMRB											
											
N°	PCA	Qtde. de gerações	Taxa de mut. dos filhos	Taxa de mut. dos pesos	Qtde de bits da mut.	Método de seleção dos pais	Limites dos Pesos	Melhor geração	Erro Trein. [%] ⁽¹⁾	Erro Valid. [%] ⁽¹⁾	Tempo total de execução [h] ⁽²⁾
9	B2	100	15 %	36 %	2	Ranking	-1,5 a 1,5	17	8,52	13,92	247
10	B4	100	15 %	36 %	2	Ranking	-1,5 a 1,5	54	14,13	21,91	246
Treinamento da RNAE para estimar o Limite de resistência - Método de treinamento: AG-LMRB											
											
11	-	100	15 %	39 %	2	Ranking	-1 a 1	89	6,57	11,84	284
12	-	100	15 %	39 %	2	Ranking	-1,5 a 1,5	29	6,70	11,16	256

⁽¹⁾ Os erros de treinamento (Erro Trein.) e validação (Erro Valid.) foram obtidos através da melhor geração do treinamento, aquela na qual houve o menor valor do erro de validação pelo processo da validação cruzada. Todos esses erros foram obtidos com um nível de confiança de 95,45 %.

⁽²⁾ Valor aproximado do tempo total de execução.

Na Figura 4.4 é mostrado o melhor resultado do treinamento das RNAEs para estimar o limite de resistência, através da execução da configuração 7.

Depois de se obter a melhor configuração de treinamento, foi feita a execução da configuração 7 em uma RNAE com a mesma arquitetura de rede, mas empregando o método de treinamento AG-LMRB*, Tab. 4.5. O erro de treinamento de 6,33 % obtido nesse caso foi um pouco maior do que o obtido empregando apenas o método AG-LMRB sem a verificação de similaridade entre os indivíduos (6,25 %). Portanto, o método de treinamento AG-LMRB foi o mais adequado.

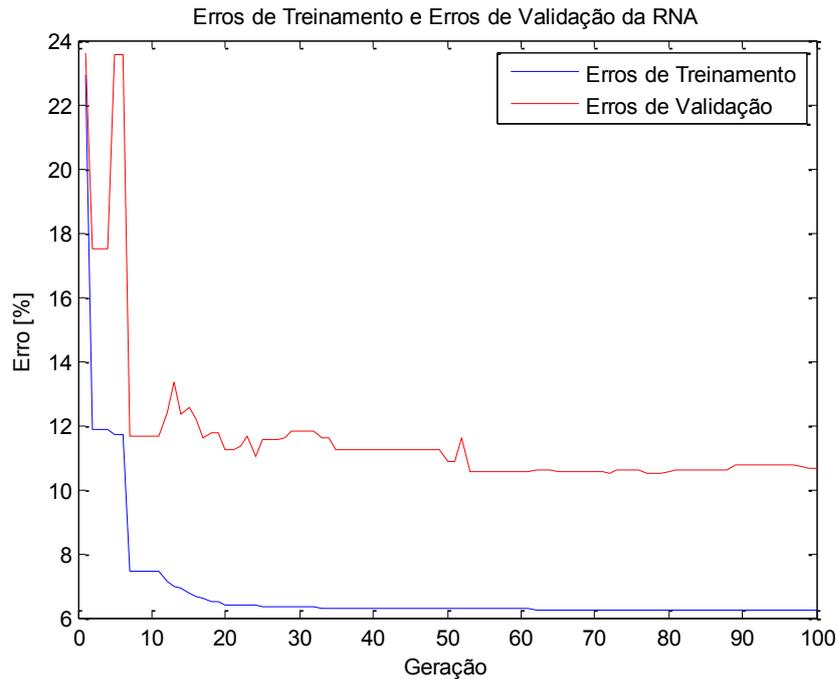


Figura 4.4 – Melhor resultado do treinamento da RNAE para estimar o limite de resistência - Treinamento a partir da execução da configuração 7 (Tab. 4.4)

Tabela 4.5 – Resultado do treinamento da RNAE a partir da configuração 7 (Tab. 4.4) e do método de treinamento AG-LMRB*

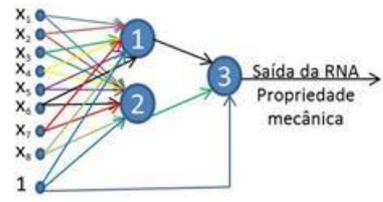
Treinamento da RNAE para estimar o Limite de Resistência - Método de treinamento: AG-LMRB*									
Qtde. de gerações	Taxa de mut. dos filhos	Taxa de mut. dos pesos	Qtde de bits da mut.	Método de seleção dos pais	Limites dos Pesos	Melhor geração	Erro Trein. [%] ⁽¹⁾	Erro Valid. [%] ⁽¹⁾	Tempo total de execução [h] ⁽²⁾
100	15 %	38 %	2	Torneio	-1,5 a 1,5	82	6,33	10,39	251

⁽¹⁾ Os erros de treinamento (Erro Trein.) e validação (Erro Valid.) foram obtidos através da melhor geração do treinamento, aquela na qual houve o menor valor do erro de validação pelo processo da validação cruzada. Todos esses erros foram obtidos com um nível de confiança de 95,45 %.

⁽²⁾ Valor aproximado do tempo total de execução.

Os pesos (e *bias*) da RNAE, obtidos através da execução da configuração 7 (Tab. 4.4), foram considerados os pesos ótimos da RNAE, Tab. 4.6. Eles foram fixos e utilizados para testar novos materiais com essa RNAE.

Tabela 4.6 – Melhor arquitetura da RNA e valores ótimos dos pesos para essa arquitetura para estimar o limite de resistência de novos materiais

Melhor arquitetura da RNA e pesos ótimos para estimar o limite de resistência				
				
Número do neurônio	Entrada do neurônio	Posição do peso binário no vetor	Posição do peso decimal no vetor	Valor real do peso
1	X_1	Bit 671 ao bit 640	1	1,4587
	X_2	Bit 639 ao bit 608	2	-0,3976
	X_3	Bit 607 ao bit 576	3	0,3719
	X_4	Bit 575 ao bit 544	4	0,8180
	X_5	Bit 543 ao bit 512	5	0,1284
	X_6	Bit 511 ao bit 480	6	-0,8095
	X_7	Bit 479 ao bit 448	7	-0,6204
	X_8	Bit 447 ao bit 416	8	-1,5563
	1	Bit 415 ao bit 384	9	-0,2499
2	X_1	Bit 383 ao bit 352	10	1,2730
	X_2	Bit 351 ao bit 320	11	1,1051
	X_3	Bit 319 ao bit 288	12	-0,2749
	X_4	Bit 287 ao bit 256	13	-1,5057
	X_5	Bit 255 ao bit 224	14	0,2322
	X_6	Bit 223 ao bit 192	15	0,5561
	X_7	Bit 191 ao bit 160	16	0,7099
	X_8	Bit 159 ao bit 128	17	-0,5676
	1	Bit 127 ao bit 96	18	0,5325
3	Saída do neurônio 1	Bit 95 ao bit 64	19	1,5454
	Saída do neurônio 2	Bit 63 ao bit 32	20	0,5488
	1	Bit 31 ao bit 0	21	-0,2691

Os resultados dos testes da RNAE, treinada conforme a configuração 7 (Tab. 4.4), estão expressos na Fig. 4.5. Observa-se que há configurações de ensaio, cujos resultados de erros associados ficaram fora dos limites pré-estabelecidos ($\pm 6,25\%$).

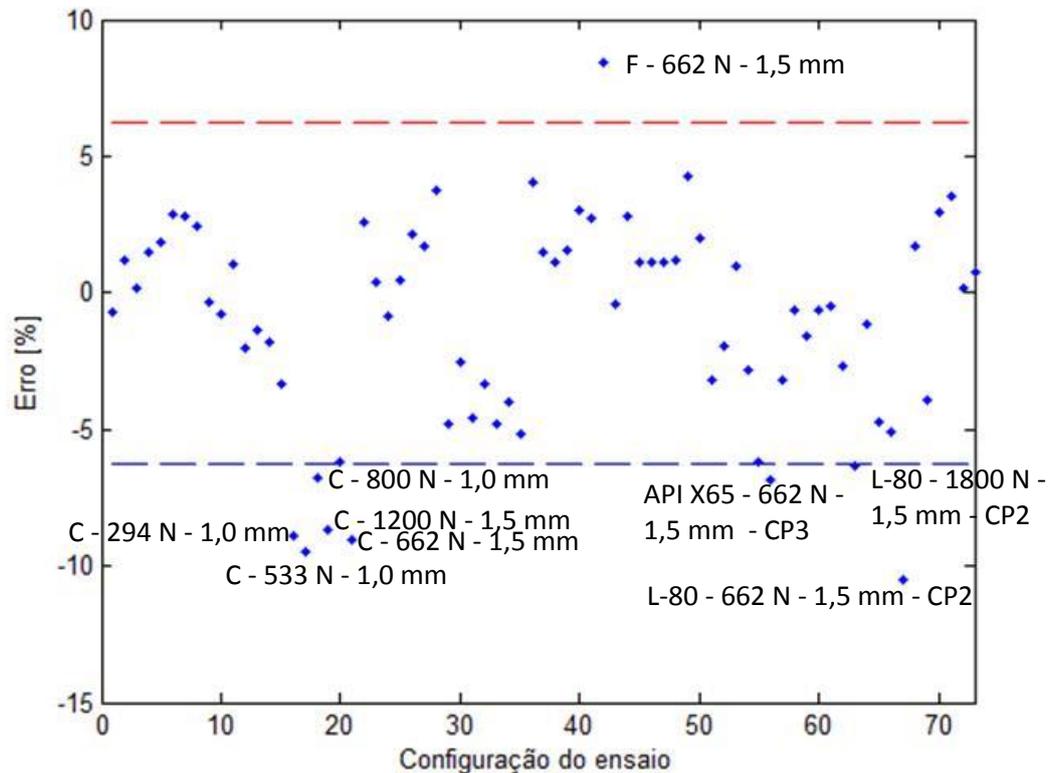


Figura 4.5 - Teste da melhor RNAE para estimar o limite de resistência, utilizando todos os materiais para verificação dos erros obtidos em cada configuração de ensaio

Na Figura 4.5, alguns dos erros associados à estimativa do limite de resistência para o material “C” ficaram localizados fora dos limites, já que o material “C” apresentou gradiente de propriedade mecânica ao longo da espessura e, portanto, o limite de resistência medido experimentalmente adotado para esse material não representou bem cada região ensaiada do material.

Os erros associados às determinadas configurações de ensaio dos materiais F, API X65 e L-80 (Fig. 4.5) foram maiores que os valores da faixa $\pm 6,25\%$, porque as respectivas curvas desses ensaios não foram totalmente sobrepostas (Anexo I). O erro associado à estimativa do limite de resistência do aço L-80, o qual participou do processo de validação, foi igual a 10,48 % em módulo, mesmo valor do erro de validação.

Já na Figura 4.6 é mostrado o resultado do teste da melhor RNAE para estimar o limite de resistência, utilizando apenas os materiais de “A” a “G”, os quais foram os únicos

que tiveram ensaios realizados com todos os penetradores. Sendo assim, identifica-se que para os ensaios de todos esses aços com o penetrador de diâmetro igual a 0,4 mm os erros foram compreendidos entre -4,83 % e 4,01 %, aproximadamente, menor ainda que $\pm 6,25$ %.

Para os ensaios desses materiais, exceto o aço “C”, com o penetrador de diâmetro igual a 1,0 mm, os erros associados à estimativa do limite de resistência ficaram compreendidos entre -4,56 % e 2,77 %, cujo intervalo também está compreendido dentro $\pm 6,25$ % (Fig. 4.6).

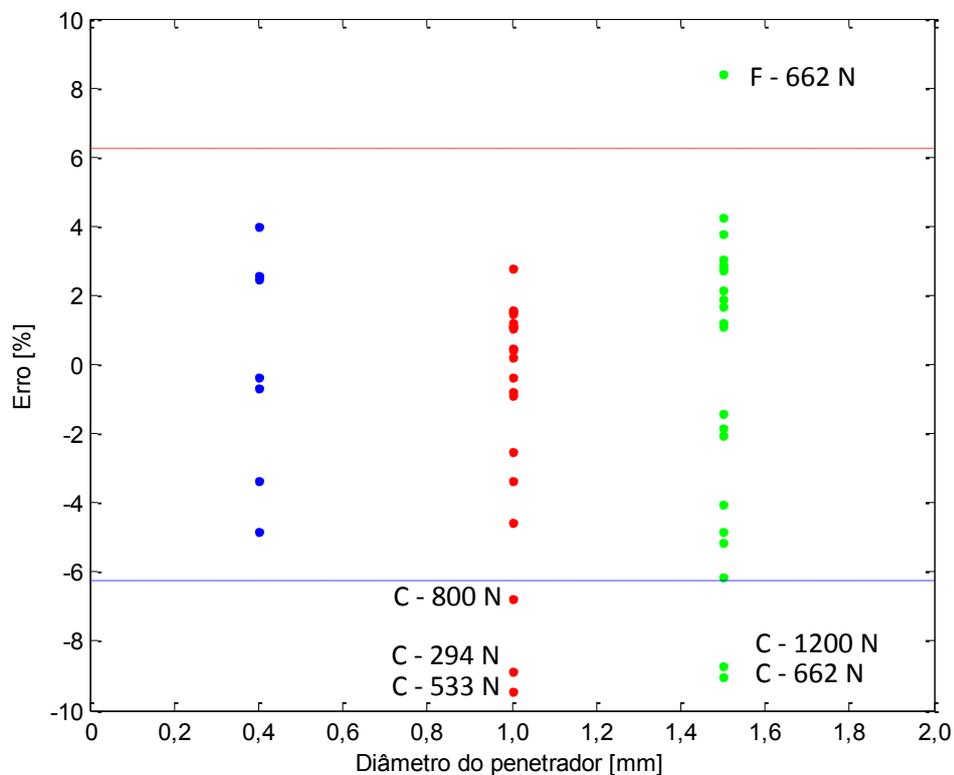


Figura 4.6 - Resultado do teste da melhor RNAE para estimar o limite de resistência, utilizando apenas os materiais “A” a “G”, que tiveram ensaios realizados com todos os penetradores

4.3. Resultados dos treinamentos das RNAEs para estimar o limite de escoamento

Na Tabela 4.7 estão contidos os resultados dos treinamentos de RNAEs através dos algoritmos AG ou AG-LMRB para estimar o limite de escoamento. E no Apêndice IV estão representados todos os gráficos com os erros de treinamento e validação obtidos através desses treinamentos.

Os treinamentos realizados a partir das configurações 1 e 2 (Tab. 4.7) resultaram em erros de treinamento muito elevados e iguais a 23,07 %. Já os resultados provenientes das configurações 3 a 5 (Tab. 4.7) foram mais satisfatórios, cujo menor erro de treinamento foi igual a 8,51 % na configuração 5 e o maior erro foi de 9,59 % na configuração 4. Isso demonstra, que para a mesma arquitetura de rede, com nove entradas e três neurônios, o método de treinamento AG-LMRB teve um melhor desempenho em relação ao AG puro.

As configurações de treinamento 6 e 7 (Tab. 4.7), realizadas em uma RNAE com quatro entradas e três neurônios através do método de treinamento AG-LMRB, resultaram em erros de treinamento iguais a 9,99 % e 22,35 %, respectivamente. Constata-se que o método B2 empregado na redução das entradas pela PCA, na configuração 6, forneceu um resultado mais razoável do que o método B4, na configuração 7. Todavia, ainda não foi o menor erro de treinamento obtido para o limite de escoamento, dentre todas as configurações realizadas.

Já nas configurações 8 e 9 (Tab. 4.7), executadas em uma RNAE com nove entradas e quatro neurônios através do método de treinamento AG-LMRB, aquela que apresentou o menor erro (8,66 %) e o menor tempo de execução foi a configuração 8. Todavia, ainda não foi o menor erro obtido dentre todas as configurações executadas na Tab. 4.7.

Portanto, dentre as configurações de treinamento realizadas, conforme visto na Tab. 4.7, a configuração 5 foi a que forneceu o melhor resultado, cujo erro de treinamento foi o menor e igual a 8,51 %. Essa configuração 5 foi aplicada em uma RNAE de nove entradas e três neurônios, a qual foi treinada a partir do algoritmo AG-LMRB, resultando no gráfico da Fig. 4.7.

Posteriormente, a execução da configuração 5 (Tab. 4.7) foi aplicada novamente no treinamento da mesma RNAE, cuja arquitetura foi composta por nove entradas e três neurônios, mas o método de treinamento foi o AG-LMRB*, Tab. 4.8. O erro de treinamento de 9,04 % obtido nesse caso foi maior que o obtido empregando apenas o método AG-LMRB (8,51 %). Portanto, o método de treinamento AG-LMRB foi o mais adequado.

Os pesos (e *bias*) da RNAE, obtidos através da execução da configuração 5 (Tab. 4.7), foram considerados os pesos ótimos da RNAE, Tab. 4.9. Eles foram fixos e utilizados para testar novos materiais com essa RNAE.

Tabela 4.7 - Resultados dos treinamentos de RNAEs para estimar o limite de escoamento

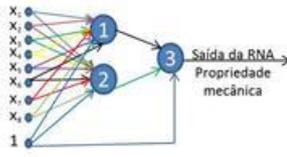
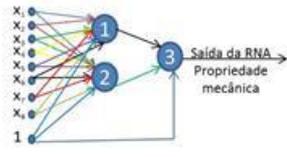
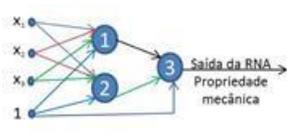
Treinamentos da RNAE para estimar o Limite de escoamento - Método de treinamento: AG											
											
Nº	PCA	Qtde. de gerações	Taxa de mut. dos filhos	Taxa de mut. dos pesos	Qtde de bits da mut.	Método de seleção dos pais	Limites dos Pesos	Melhor geração	Erro Trein. [%] ⁽¹⁾	Erro Valid. [%] ⁽¹⁾	Tempo total de execução [h] ⁽²⁾
1	-	100	15 %	38 %	2	Ranking	-1,5 a 1,5	16	23,07	20,30	116
2	-	200	15 %	38 %	2	Ranking	-1,5 a 1,5	16	23,07	20,30	248
Treinamentos da RNAE para estimar o Limite de escoamento - Método de treinamento: AG-LMRB											
											
3	-	100	15 %	38 %	4	Ranking	-1,5 a 1,5	20	9,09	14,33	249
4	-	100	15 %	38 %	2	Torneio	-1,5 a 1,5	19	9,59	14,00	250
5	-	100	30 %	38 %	2	Torneio	-1,5 a 1,5	14	8,51	16,12	251
Treinamento da RNAE para estimar o Limite de escoamento - Método de treinamento: AG-LMRB											
											
6	B2	100	15 %	36 %	2	Ranking	-1,5 a 1,5	12	9,99	15,08	261
7	B4	100	15 %	36 %	2	Ranking	-1,5 a 1,5	7	22,35	22,14	247

Tabela 4.7 - Continuação

Treinamentos da RNAE para estimar o Limite de escoamento - Método de treinamento: AG-LMRB											
Nº	PCA	Qtde. de gerações	Taxa de mut. dos filhos	Taxa de mut. dos pesos	Qtde de bits da mut.	Método de seleção dos pais	Limites dos Pesos	Melhor geração	Erro Trein. [%] ⁽¹⁾	Erro Valid. [%] ⁽¹⁾	Tempo total de execução [h] ⁽²⁾
8	-	100	15 %	39 %	2	Ranking	-1 a 1	37	8,66	15,26	283
9	-	100	15 %	39 %	2	Ranking	-1,5 a 1,5	3	14,47	15,10	319

⁽¹⁾ Os erros de treinamento (Erro Trein.) e validação (Erro Valid.) foram obtidos através da melhor geração do treinamento, aquela na qual houve o menor valor do erro de validação pelo processo da validação cruzada. Todos esses erros foram obtidos com um nível de confiança de 95,45 %.

⁽²⁾ Valor aproximado do tempo total de execução.

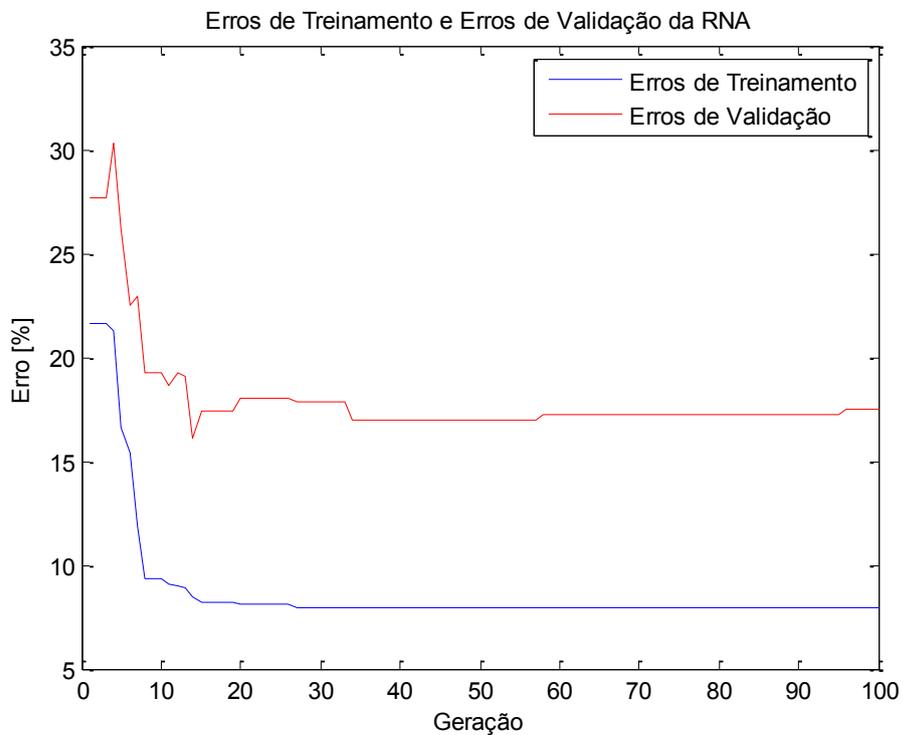
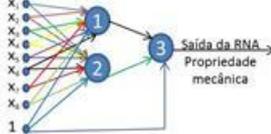


Figura 4.7 – Melhor resultado do treinamento da RNAE para estimar o limite de escoamento – Treinamento realizado a partir da execução da configuração 5 (Tab. 4.7)

Tabela 4.8 – Resultado do treinamento da RNAE a partir da configuração 5 (Tab. 4.7) e do método de treinamento AG-LMRB*

Treinamento da RNAE para estimar o Limite de Escoamento - Método de treinamento: AG-LMRB*									
									
Qtde. de gerações	Taxa de mut. dos filhos	Taxa de mut. dos pesos	Qtde de bits da mut.	Método de seleção dos pais	Limites dos Pesos	Melhor geração	Erro Trein. [%] ⁽¹⁾	Erro Valid. [%] ⁽¹⁾	Tempo total de execução [h] ⁽²⁾
100	30 %	38 %	2	Torneio	-1,5 a 1,5	17	9,04	12,64	251

⁽¹⁾ Os erros de treinamento (Erro Trein.) e validação (Erro Valid.) foram obtidos através da melhor geração do treinamento, aquela na qual houve o menor valor do erro de validação pelo processo da validação cruzada. Todos esses erros foram obtidos com um nível de confiança de 95,45 %.

⁽²⁾ Valor aproximado do tempo total de execução.

Os resultados dos testes da RNAE treinada conforme a configuração 5 (Tab. 4.7) estão expressos na Fig. 4.8. Observa-se que há configurações de ensaio, cujos erros associados ficaram fora dos limites pré-estabelecidos ($\pm 8,51$ %).

Na Figura 4.8, alguns dos erros associados à estimativa do limite de escoamento para o material “B” ficaram localizados fora de $\pm 8,51$ %, já que esse material apresenta gradiente de propriedade mecânica ao longo da espessura (Figs. 3.2 e 3.4). Os erros associados à determinadas configurações de ensaio dos materiais “F”, “G” e L-80 foram maiores que os valores da faixa $\pm 8,51$ %, porque as respectivas curvas desses ensaios não foram totalmente sobrepostas (Anexo I).

Nas configurações de ensaio do material L-80, que fez parte do subconjunto de validação, nas quais os erros ficaram fora da faixa $\pm 8,51$ % (Fig. 4.8), ainda sim apresentaram erros menores que o erro de validação de 16,12 % (Tab. 4.7).

Na Figura 4.9 é mostrado o resultado do teste da melhor RNAE para estimar o limite de escoamento, utilizando apenas os materiais de “A” a “G”, que tiveram ensaios realizados com todos os penetradores. Sendo assim, identifica-se que para os ensaios de todos esses materiais, realizados com o penetrador de diâmetro igual a 1,0 mm, os erros associados à estimativa do limite de escoamento ficaram compreendidos entre -5,89 % e 6,70 %, aproximadamente.

Tabela 4.9 – Melhor arquitetura da RNA e valores ótimos dos pesos para essa arquitetura para estimar o limite de escoamento de novos materiais

Melhor arquitetura da RNA e pesos ótimos para estimar o limite de escoamento				
Número do neurônio	Entrada do neurônio	Posição do peso binário no vetor	Posição do peso decimal no vetor	Valor real do peso
1	X_1	Bit 671 ao bit 640	1	-1,4062
	X_2	Bit 639 ao bit 608	2	0,2393
	X_3	Bit 607 ao bit 576	3	1,2236
	X_4	Bit 575 ao bit 544	4	-0,8666
	X_5	Bit 543 ao bit 512	5	0,1769
	X_6	Bit 511 ao bit 480	6	-0,3882
	X_7	Bit 479 ao bit 448	7	-1,2087
	X_8	Bit 447 ao bit 416	8	1,3199
	1	Bit 415 ao bit 384	9	-0,2654
2	X_1	Bit 383 ao bit 352	10	-1,5580
	X_2	Bit 351 ao bit 320	11	0,0616
	X_3	Bit 319 ao bit 288	12	-0,5712
	X_4	Bit 287 ao bit 256	13	0,3616
	X_5	Bit 255 ao bit 224	14	-0,1120
	X_6	Bit 223 ao bit 192	15	1,1463
	X_7	Bit 191 ao bit 160	16	-0,6611
	X_8	Bit 159 ao bit 128	17	1,1339
	1	Bit 127 ao bit 96	18	-0,6348
3	Saída do neurônio 1	Bit 95 ao bit 64	19	-0,8531
	Saída do neurônio 2	Bit 63 ao bit 32	20	-1,5777
	1	Bit 31 ao bit 0	21	1,5810

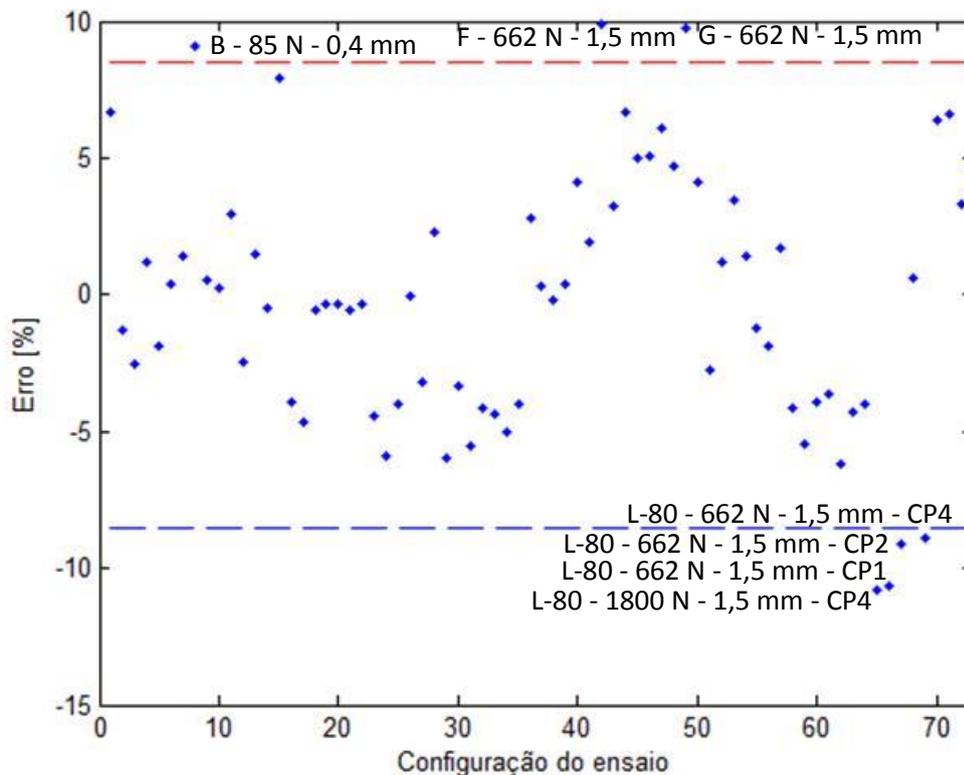


Figura 4.8 - Teste da melhor RNAE para o limite de escoamento, utilizando todos os materiais para verificação dos erros obtidos em cada configuração de ensaio

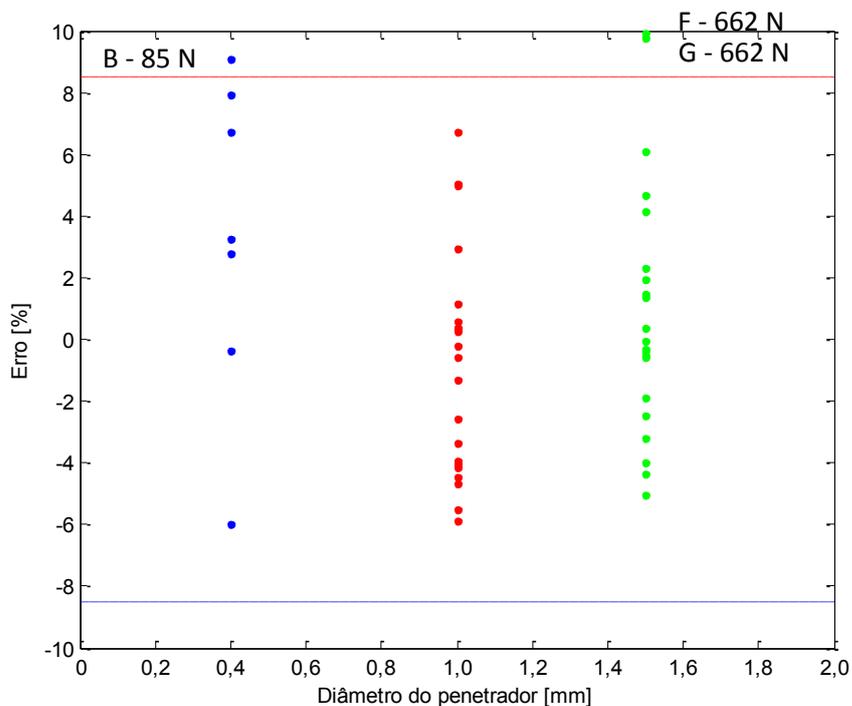


Figura 4.9 - Resultado do teste da melhor RNAE para o limite de escoamento, utilizando apenas os materiais “A” a “G”, que tiveram ensaios realizados com todos os penetradores

4.4. Comparação entre os resultados obtidos com este trabalho, a partir da utilização dos pesos ajustados das melhores RNAEs, e os obtidos com outros trabalhos da literatura

A comparação dos resultados obtidos com este trabalho foi feita em relação ao trabalho de Nicolosi (2015), porque os materiais, as condições de ensaio e o equipamento de teste utilizados foram os mesmos.

Para tanto, nessa comparação, foram empregados os pesos ajustados das melhores RNAEs treinadas, aquelas que forneceram os erros de a) 3,41% na estimativa da dureza Brinell, b) 6,25% na estimativa do limite de resistência e c) 8,51% na estimativa do limite de escoamento. Também foram utilizados os melhores resultados obtidos pelas metodologias desenvolvidas por Nicolosi (2015), que foram baseadas no modelo de Haggag.

Conforme a Tabela 4.10, a metodologia desenvolvida neste trabalho forneceu erros associados à estimativa das propriedades mecânicas, em geral, menores que os obtidos por Nicolosi (2015). Nesse caso, Nicolosi (2015) utilizou a Norma ASTM E10 (2002) para estimar a dureza Brinell e os modelos de Haggag e Ahn e Kwon, com as respectivas constantes indicadas na Tab. 4.10, para estimar os limites de escoamento e resistência.

Na Tabela 4.10, Nicolosi (2015) avaliou os erros associados à estimativa da dureza Brinell e aos limites de escoamento e de resistência, considerando os ensaios dos aços de “A” a “G” com penetradores de diâmetros iguais a 1,0 e 1,5 mm.

Por sua vez, neste trabalho também foram feitas análises dos erros considerando esses mesmos aços de “A” a “G”, ensaiados com penetradores de diâmetros iguais a 1,0 e 1,5 mm (Tab. 4.10).

Nicolosi (2015) estimou os valores da dureza de indentação conforme a recomendação para o ensaio de dureza Brinell padronizado pela norma ASTM E10 (ASTM, 2012) e avaliou os erros percentuais em relação aos valores de dureza Brinell. Tais valores foram determinados a partir da conversão da dureza Vickers (HV10), medida através de um durômetro (Tab. 4.10).

Na maioria dos resultados obtidos por Nicolosi (2015) para a estimativa da dureza, os erros foram inferiores a 12 % (Tab. 4.10), mas foram maiores para o penetrador de diâmetro igual a 1,0 mm. Também houve uma tendência de aumento do erro à medida que a força máxima de indentação aumentou. Para os ensaios com penetrador de diâmetro igual a 1,5 mm e força máxima de 662 N, os erros ficaram abaixo de 5 %.

Já neste trabalho, os erros para a estimativa da dureza Brinell, em todos os resultados analisados para os mesmos aços, ficaram abaixo de 5 % (Fig. 4.3 e Tab. 4.10).

Tabela 4.10 – Resultados obtidos com este trabalho e com o trabalho de Nicolosi (2015), para a estimativa das propriedades mecânicas. Erros percentuais relativos entre os valores obtidos pelas metodologias analisadas e os valores obtidos pelos ensaios convencionais de tração e dureza

Metodologia	Materiais analisados	Dureza Brinell	Limite de escoamento	Limite de resistência
Metodologia desenvolvida neste trabalho	“A” a “G” ⁽¹⁾	<5% ⁽³⁾	<10% ⁽³⁾	<10% ⁽³⁾
	“A” a “G” ⁽⁵⁾	<8% ⁽³⁾	<10% ⁽³⁾	<5% ⁽³⁾
	API 5L X65, L80, P110, ABNT 8550	<6% ⁽³⁾	±12,0%, NC	±6,5%, NC
Norma ASTM E10 (2002) ⁽²⁾ (NICOLOSI, 2015)	“A” a “G” ⁽¹⁾	<12% ⁽⁴⁾	-	
	API 5L X65, L80, P110, ABNT 8550	<10% ⁽³⁾		
Haggag, $\beta_m = 0,2285$ e $\alpha_m = 1,200$ (NICOLOSI, 2015)	“A” a “G” ⁽¹⁾	-	<10% ⁽⁴⁾ para o aço A; >30% ⁽⁴⁾ para o aço G;	<15% ⁽⁴⁾
Ahn e Kwon, $\alpha = 0,14$ e $\psi = 3,00$ (NICOLOSI, 2015)	“A” a “G” ⁽¹⁾	-	>10% ⁽³⁾ , DE 0,2%	<10% ⁽⁴⁾
	“A” a “G” ⁽⁵⁾		<20% ⁽⁴⁾ , DE 1%	
Metodologias desenvolvidas por Nicolosi (2015)	API 5L X65, L80, P110, ABNT 8550	-	±8,0%, NC	±6,5%, NC

⁽¹⁾ Materiais ensaiados com penetradores de diâmetros iguais a 1,0 e 1,5 mm

⁽²⁾ Os valores de dureza Brinell foram determinados a partir da conversão da dureza Vickers (HV10), medida através de um durômetro

⁽³⁾ Para todos os resultados

⁽⁴⁾ Para a maioria dos resultados

⁽⁵⁾ Para penetrador esferocônico de diâmetro igual a 0,4 mm

NC: nível de confiança de 95%

DE: deformação no escoamento

Em relação aos erros associados aos limites de escoamento desses mesmos aços, Nicolosi (2015) obteve erros sempre superiores a 10 % ao aplicar o modelo de Ahn e Kwon e os parâmetros $\alpha = 0,14$ e $\psi = 3,00$, considerando uma deformação no escoamento igual a 0,2 % (Tab. 4.10). Já assumindo a deformação no escoamento de 1 %, Nicolosi (2015), ao aplicar o mesmo modelo, obteve erros abaixo de 20 % na maioria das condições de ensaio (Tab. 4.10) e, em muitos casos, foram inferiores a 10 %.

Nicolosi (2015) também empregou o modelo de Haggag com $\beta_m = 0,2285$ e obteve erros associados ao cálculo de limite de escoamento, na maioria dos casos, abaixo de 10 % para o aço “A” e acima de 30 % para o aço “G” (Tab. 4.10).

Já neste trabalho, os erros para a estimativa do limite de escoamento, em todos os resultados analisados para os mesmos aços, ficaram abaixo de 10 % (Fig. 4.9 e Tab. 4.10).

Em relação à estimativa do limite de resistência, Nicolosi (2015) obteve, na maioria dos resultados, erros inferiores a 10 % ao aplicar o modelo de Ahn e Kwon e os parâmetros $\alpha = 0,14$ e $\psi = 3,00$ (Tab. 4.10). Já ao utilizar o modelo de Haggag com $\alpha_m = 1,200$, Nicolosi (2015) obteve erros abaixo de 15 % na maioria dos casos (Tab. 4.10).

Já neste trabalho, os erros para a estimativa do limite de resistência, em todos os resultados analisados para os mesmos aços, ficaram abaixo de 10 % (Fig. 4.6 e Tab. 4.10).

Para os ensaios dos aços de “A” a “G” com o penetrador esferocônico de diâmetro igual a 0,4 mm, Nicolosi (2015) obteve, na maioria dos casos, erros abaixo de 15 % para o limite de escoamento e erros inferiores a 10 % para o limite de resistência, ao empregar o modelo de Ahn e Kwon com $\alpha = 0,14$ e $\psi = 3,00$, assumindo a deformação no escoamento de 1 % (Tab. 4.10).

Já neste trabalho, os erros para a estimativa do limite de escoamento foram inferiores a 10 % (Fig. 4.9 e Tab. 4.10) e os erros para a estimativa do limite de resistência foram inferiores a 5 % (Fig. 4.6 e Tab. 4.10), em todos os resultados analisados para os mesmos aços ensaiados com penetrador esferocônico.

Nicolosi (2015), para validar as metodologias desenvolvidas em seu trabalho, avaliou os erros obtidos para a estimativa dos limites de escoamento e resistência dos aços API 5L X65, L80, P110 e ABNT 8550. Ele também avaliou os erros obtidos entre a dureza de indentação, calculada conforme a norma ASTM E10 (ASTM, 2012), e a dureza Brinell medida utilizando o durômetro, a partir da conversão da dureza Vickers (HV10).

Nicolosi (2015) obteve erros para o limite de escoamento desses aços na faixa de ± 8 %, com nível de confiança de 95 %, utilizando o modelo de Haggag e valores de β_m e b_m determinados empiricamente (Tab. 4.10).

Já neste trabalho, o erro para a estimativa do limite de escoamento desses mesmos aços esteve dentro da faixa de $\pm 11,9$ %, com nível de confiança de 95 % (Tab. 4.10).

Como se pode observar, o intervalo de confiança obtido neste trabalho para o limite de escoamento foi maior que o obtido por Nicolosi (2015). Isso pode ter acontecido por causa da grande dispersão dos resultados dos ensaios com os aços API 5L X65 e L80. Pois, conforme o Anexo 1 (Figs. A1.50 e A1.58, por exemplo), esses aços apresentaram, em algumas configurações de ensaio, uma diferença significativa na inclinação da curva de carregamento e na profundidade máxima de indentação. As RNAEs são sensíveis a essas diferenças na curva para uma dada configuração de ensaio, tendo dificuldades em classificar materiais que apresentam heterogeneidades significativas.

Vale ressaltar que Nicolosi (2015) utilizou uma relação matemática específica para cada condição de ensaio (força máxima e diâmetro do penetrador). Conseqüentemente, as constantes das relações matemáticas por ele empregadas para estimar as propriedades mecânicas de tração foram específicas para cada configuração de ensaio.

Já neste trabalho, para cada propriedade estimada foi utilizada a mesma RNAE, independente da condição de ensaio. Como Nicolosi (2015) obteve intervalos de confiança menores para o limite de escoamento considerando os aços API 5L X65, L80, P110 e ABNT 8550, isso mostra que uma padronização dos ensaios pode promover resultados mais exatos.

Neste trabalho não foi realizado o treinamento de RNAEs específicas para determinadas condições de ensaio, já que o objetivo foi avaliar a aplicação desse método na condição mais generalizada possível. Porém, acredita-se que o treinamento de RNAEs específicas para cada condição de ensaio pode trazer resultados mais exatos. Essa padronização pode ser realizada em função do diâmetro do penetrador, da força máxima, da profundidade máxima de penetração e até mesmo do número de ciclos do ensaio.

Para aços API 5L X65, L80, P110 e ABNT 8550, Nicolosi (2015) obteve erros para o limite de resistência na faixa de $\pm 6,5\%$, com nível de confiança de 95 % (Tab. 4.10). Esses erros foram obtidos através do modelo de Haggag e valores de " α_m médio" determinados empiricamente. Neste trabalho, o erro obtido na estimativa do limite de resistência também ficou na faixa de $\pm 6,5\%$, com nível de confiança de 95 % (Tab. 4.10).

Assim como na estimativa do limite de escoamento, no caso do limite de resistência Nicolosi (2015) também utilizou um conjunto de constantes do modelo de Haggag diferente para cada condição de ensaio. Como pode ser observado, no caso do limite de resistência, mesmo sendo utilizada a mesma RNAE em todas as condições de ensaio, os erros obtidos foram similares. Isso mostra que a RNAE aplicada em diferentes condições de ensaio é capaz de obter resultados com exatidão muito boa, mesmo em uma situação mais desfavorável.

Para a estimativa da dureza de indentação, Nicolosi (2015) obteve erros menores que 10 % para os aços API 5L X65, L80, P110 e ABNT 8550. Já neste trabalho, os erros foram menores que 6 % considerando todos esses aços (Tab. 4.10). Como pode-se notar, no caso da dureza Brinell, a RNAE também pôde fornecer resultados com boa exatidão.

Já os trabalhos que empregaram RNAs, na maioria dos casos, empregaram penetradores cônicos (THO *et al.*, 2004; SWADDIWUDHIPONG *et al.*, 2006), dificultando a comparação com os resultados deste trabalho, que empregou penetradores esféricos. Adicionalmente, a maioria desses trabalhos (THO *et al.*, 2004; SWADDIWUDHIPONG *et al.*, 2006; KRUGLOV; MISHULINA; BAKIROV, 2012, LI *et al.*, 2016) utilizaram dados simulados em elementos finitos para treinar as RNAs, as quais ficam mais restritas ao conhecimento de materiais com características ideais e que foram submetidos a ensaios também com condições ideais.

CAPÍTULO V

CONCLUSÕES

Com este trabalho foi desenvolvida uma metodologia, empregando RNAs e ensaios experimentais de macroindentação esférica instrumentada, para determinar propriedades mecânicas, com boa exatidão, para aços carbono com limite de resistência variando cerca de 450 a 1000 MPa. Diferentes arquiteturas de RNAs foram implementadas e treinadas, considerando determinados valores dos parâmetros de desempenho do AG e diferentes algoritmos de treinamento, a saber: AG, AG-LMRB e AG-LMRB*. Os resultados obtidos permitiram concluir que:

- a) Para materiais com valores de propriedades dentro da faixa para qual as redes foram treinadas e que foram ensaiados no *PropInSitu 2* com, no mínimo, cinco ensaios para penetradores esféricos de diâmetros iguais a 1,0 e 1,5 mm e, no mínimo, 10 ensaios para penetradores com diâmetros iguais a 0,4 mm:
 - Os erros para a estimativa da dureza Brinell estiveram na faixa de ± 3 %, com o nível de confiança de 95 %;
 - Os erros para a estimativa do limite de resistência estiveram na faixa de ± 6 %, com o nível de confiança de 95 %;
 - Os erros para a estimativa do limite de escoamento estiveram na faixa de ± 8 %, com o nível de confiança de 95 %.
- b) Os menores erros obtidos para a estimativa de cada propriedade mecânica provavelmente não provêm da inexatidão das RNAEs, mas sim devido à heterogeneidade de alguns dos materiais empregados no treinamento das mesmas;
- c) As RNAEs, cujos treinamentos forneceram os menores erros para estimar as propriedades mecânicas, foram capazes de aprender através de um conjunto reduzido de exemplos e depois generalizar o conhecimento adquirido. Ou seja,

forneceram respostas coerentes para materiais desconhecidos, exceto em algumas configurações de ensaio dos materiais que possuíam gradiente de propriedades ao longo da espessura;

- d) A boa generalização das RNAEs que apresentaram os melhores resultados para a estimativa das propriedades mecânicas pôde ser analisada também através da curva dos erros de validação, pois, a partir do ponto de mínimo dessa curva, os erros de validação não cresceram descontroladamente;
- e) Todos os três melhores resultados, cada um específico para a estimativa de uma das propriedades mecânicas, foram obtidos considerando: a mesma arquitetura de rede, o mesmo método de treinamento e diferentes configurações dos parâmetros de desempenho do AG. Conseqüentemente, os valores dos pesos (e *bias*) ótimos foram diferentes para cada RNAE. Isso confirmou a necessidade de treinar as RNAEs especificamente para cada propriedade mecânica;
- f) As melhores RNAEs treinadas foram, nos três casos, RNAEs de nove entradas e três neurônios, treinadas com o algoritmo AG-LMRB. Isso mostrou que o treinamento de uma rede pequena, com apenas três neurônios, através do método AG-LMRB, teve um desempenho satisfatório quando foram considerados, também, os seguintes fatores: as nove variáveis de entrada pré-definidas, os valores dos parâmetros de desempenho do AG adotados e as funções de ativação escolhidas para os neurônios;
- g) O comportamento das RNAEs foi definido pela sua arquitetura, pelas variáveis de entrada selecionadas para compor a camada de entrada, pelos valores dos parâmetros de desempenho do AG, pelos valores atribuídos aos pesos através do processo de aprendizagem adotado e pela resposta de cada neurônio modulada pela função de ativação escolhida.

CAPÍTULO VI

TRABALHOS FUTUROS

Para dar continuidade a este trabalho, sugere-se:

- a) Realizar o treinamento supervisionado das RNAEs que forneceram os melhores resultados neste trabalho, considerando um subconjunto de treinamento com uma variedade maior de materiais. O intuito é de se aumentar a robustez dessas redes. Esses materiais devem ser homogêneos e ensaiados via *PropInSitu 2*;
- b) Refazer o treinamento das RNAEs, utilizando ensaios realizados a partir da nova versão do macroindentador portátil, o *PropInSitu 3*, que ainda não está operacional, pois, provavelmente, a complacência do *PropInSitu 3* será diferente da do *PropInSitu 2*. Assim, neste trabalho, como os parâmetros das curvas obtidas com o *PropInSitu 2* não tinham a complacência compensada, pode ser que os resultados do treinamento, realizados com esse equipamento, não sejam aplicáveis para estimar as propriedades mecânicas via ensaios realizados através do *PropInSitu 3*;
- c) Realizar novos treinamentos supervisionados de RNAEs, que serão dedicadas a estimar propriedades mecânicas de dutos petrolíferos. Dessa forma, as RNAEs serão treinadas a reconhecer apenas as curvas $F \times h$ dos ensaios de materiais realizados na parede externa de dutos. Pois, em campo, o local onde se tem acesso é nesta parede, e não ao longo da espessura;
- d) Realizar o treinamento de RNAEs utilizando arquiteturas de rede e parâmetros de desempenho dos AGs diferentes dos empregados neste trabalho;

- e) Realizar o treinamento de RNAEs para estimar outras propriedades mecânicas, tal como a tenacidade à fratura.

REFERÊNCIAS BIBLIOGRÁFICAS

AHN, J-H.; KWON, D. Derivation of plastic stress-strain relationship from ball indentations: examination of strain definition and pileup effect. **Materials Research Society**, v. 16, n. 11, p. 3170-3178, nov. 2001.

<https://doi.org/10.1557/JMR.2001.0437>

ALBA, E.; CHICANO, JF. Training neural networks with GA hybrid algorithms. In: Proceedings of the Genetic and Evolutionary Computation (GECCO 2004), v. 3102, jun. 2004, Seattle, Washington. p. 852–863.

https://doi.org/10.1007/978-3-540-24854-5_87

ALMEIDA, L. M. **Uma metodologia de busca por redes neurais quase-ótimas**. 2007. 102 f. Dissertação de Mestrado - Universidade Federal de Pernambuco, Recife.

ALMEIDA, L. M.; LUDERMIR, T. B. A hybrid method for searching near-optimal artificial neural networks. In: Sixth International Conference on Hybrid Intelligent Systems (HIS '06), dez. 2006, Rio de Janeiro.

<https://doi.org/10.1109/HIS.2006.264919>

ALTINKOK, N.; KOKER, R. Neural network approach to prediction of bending strength and hardening behaviour of particulate reinforced (Al–Si–Mg)- aluminium matrix composites. **Materials and Design**, v. 25, p. 595–602, 2004.

<https://doi.org/10.1016/j.matdes.2004.02.014>

ARBABI, V.; POURAN, B.; CAMPOLI, G.; WEINANS, H.; ZADPOOR, A. A. Determination of the mechanical and physical properties of cartilage by coupling poroelastic-based finite element models of indentation with artificial neural networks. **Journal of Biomechanics**, v. 49, p. 631–637, 2016.

<https://doi.org/10.1016/j.jbiomech.2015.12.014>

ASILTÜRK, I.; ÇUNKAS, M. Modeling and prediction of surface roughness in turning operations using artificial neural network and multiple regression method. **Expert Systems with Applications**, v. 38, p. 5826–5832, 2011.

ASTM E10. **Standard Test Method for Brinell Hardness of Metallic Materials**. American Society for Testing and Materials, 2012.

ATRIAN, A.; MAJZOBI, G.H.; NOURBAKHS, S.H.; GALEHDARI, S.A.; MASOUDI NEJAD, R. Evaluation of tensile strength of Al7075-SiC nanocomposite compacted by gas gun using spherical indentation test and neural networks. **Advanced Powder Technology**, v. 27, p. 1821–1827, 2016.

BALAS, C. E.; KOÇ, M. L.; TÜR, R. Artificial neural networks based on principal component analysis, fuzzy systems and fuzzy neural networks for preliminary design of rubble mound breakwaters. **Applied Ocean Research**, v. 32, p. 425–433, 2010.

BARBADIKAR, D. R.; BALLAL, A. R.; PESHWE, D. R.; GANESHKUMAR, J.; LAHA, K.; MATHEW, M. D. A Study on the Effect of Tempering Temperature on Tensile Properties of P92 Steel by Automated Ball Indentation Technique. **Procedia Engineering**, v. 86, p. 910-918, 2014.

BARBADIKAR, D. R.; BALLAL, A. R.; PESHWE, D. R.; GANESHKUMAR, J.; LAHA, K.; MATHEW, M. D. Investigation on Mechanical Properties of P92 Steel Using Ball Indentation Technique. **Materials Science & Engineering: A**, v.624, p. 92-101, 2015.

BATISTA, B. C. F. **Soluções de Equações Diferenciais Usando Redes Neurais de Múltiplas camadas com os métodos da Descida mais íngreme e Levenberg-Marquardt**. 2012. 90 f. Dissertação de mestrado - Universidade Federal do Pará, Belém, PA.

BENTO, E. P.; KAGAN, N. Algoritmos genéticos e variantes na solução de problemas de configuração de redes de distribuição. **Revista Controle & Automação**, v.19, n. 3, p. 302-315, 2008.

<https://doi.org/10.1590/S0103-17592008000300006>

BISHOP, C. M. **Neural Networks for Pattern Recognition**. Oxford: Clarendon Press, 1995, 498 p.

BYUN, T. S.; HONG, J. H.; HAGGAG, F. M.; FARRELL, K.; LEE, E. H. Measurement of Through-the-Thickness Variations of Mechanical Properties in SA508 Gr.3 Pressure Vessel Steels Using Ball Indentation Test Technique. **Internatonal Journal of Pressure Vessels and Piping**, 74, p. 231-238, 1997.

[https://doi.org/10.1016/S0308-0161\(97\)00114-2](https://doi.org/10.1016/S0308-0161(97)00114-2)

CADIMA, J.; JOLLIFFE, I.T. Loading and correlations in the interpretation of principal components. **Journal of Applied Statistics**, v. 22, n. 2, p. 203-214, 1995.

<https://doi.org/10.1080/757584614>

CALLEGARI, V. A., FERREIRA, F. M., S. FILHO, B. G., PAES, M. T. P., SOARES, A. B., FRANCO, S. D. Determinação de propriedades mecânicas através de ensaios de macroindentação instrumentada: influência da pressão interna e da topografia superficial em dutos. In: 61º ABM, Rio de Janeiro, 2006.

CAMPOS VELHO, H. F. Mini-Curso. Introdução aos Problemas Inversos: Aplicações em Pesquisa Espacial. Escola de verão em Computação Aplicada. Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 25 p., 2008.

CINTRA, E. C. **Aplicação de redes neurais no controle de teores de cobre e ouro no depósito de Chapada (GO)**. 2003. 170 f. Tese de doutorado – Universidade Estadual Paulista, Instituto de Geociências e Ciências Exatas, Rio Claro – SP.

DA SILVA, F. J. **Erosão, Corrosão, Erosão-Corrosão e Cavitação do ABNT 8550 Nitretado a Plasma**. 2008, 252 p. Tese de Doutorado. Universidade Federal de Uberlândia, Uberlândia, 2008.

DE OLIVEIRA, G. M. B. Material didático da disciplina de Inteligência Artificial. Graduação em Engenharia Mecatrônica da Universidade Federal de Uberlândia. 2011.

DAO, M.; CHOLLACOOP, N.; VAN VLIET, K. J.; VENKATESH, T. A; SURESH, S. Computational modeling of the forward and reverse problems in instrumented sharp indentation. **Acta Materialia**, v. 49, p. 3899–3918, 2001.

[https://doi.org/10.1016/S1359-6454\(01\)00295-6](https://doi.org/10.1016/S1359-6454(01)00295-6)

DAS,G.; GHOSH,S.; BOSE, S. C.; GHOSH, S. Use of ball indentation technique to evaluate room temperature mechanical properties of a gas turbine blade. **Materials Science and Engineering A**, 424, p. 326-332, 2006.

FORESEE, F. D.; HAGAN, M. T. Gauss-Newton Approximation to Bayesian Learning. **IEEE International Conference on Neural Networks**. v. 3, p. 1930 – 1935, 1997.

FRANCO, S. D.; FRANCO, V. L. D. S.; SOARES, A. B.; HWANG, H. F.; BORGES JR. V. S.; RAMOS NETO, F. F.; FORMOSO, C. M. Avaliação de propriedades mecânicas *in situ* através de macroindentação instrumentada – Parte II. Relatório técnico final. Março de 2007.

FREITAS, D. S. **Controle de Força e Rotação de uma Unidade de Reparo por Atrito usando Controlador PID e Inteligência Artificial**. 2014. 191 f. Dissertação de Mestrado – Curso de Engenharia Mecânica, Universidade Federal de Uberlândia, Uberlândia, MG.

GIANNAKOPOULOS, A. E.; SURESH, S. Determination of elastoplastic properties by instrumented sharp indentation. **Scripta Materialia**, v. 40, n. 10, p. 1191–1198, 1999.

[https://doi.org/10.1016/S1359-6462\(99\)00011-1](https://doi.org/10.1016/S1359-6462(99)00011-1)

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt Algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989–993,1994.

<https://doi.org/10.1109/72.329697>

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H.; DE JESÚS, O. **Neural Network Design**, 2ª edição, 2014, 1012 p.

HAGGAG, F. M.; NANSTAD, R. K.; BRASKI, D. N. **Structural Integrity Evaluation Based on an Innovative Field Indentation Microprobe**. *ASME - The American Society of Mechanical Engineers - PVP.* , v. 170, In: Innovative Approaches to Irradiation Damage and Fracture Analysis, p. 101-107, 1989.

HAGGAG, F. M.; WONG, H.; ALEXANDER, D. J.; NANSTAD, R. K. The Use of Field Indentation Microprobe in Measuring Mechanical Properties of Welds. Proceedings of the 2nd International Conference on Trends in Welding Research, Gatlinburg, Tennessee. **Anais...** p.843-849, 1989.

HAGGAG, F. M., NANSTAD, R. K., HUTTON, J. T., THOMAS, D. L., AND SWAIN, R. L., "Use of Automated Ball Indentation to Measure Flow Properties and Estimate Fracture Toughness in Metallic Materials," Applications of Automation Technology to Fatigue and Fracture Testing, ASTM 1092, A. A. Braun, N. E. Ashbaugh, and F. M. Smith, Eds., American Society for Testing and Materials, Philadelphia, 1990, p. 188-208.

<https://doi.org/10.1520/STP25039S>

HAGGAG, F. M., "In-Situ Measurements of Mechanical Properties Using Novel Automated Ball Indentation System," **American Society for Testing and Materials**, Philadelphia, p. 27-44, 1993.

<https://doi.org/10.1520/STP12719S>

HAGGAG, F. M. Non-destructive Determination of Yield Strength and Stress-Strain Curves of In-Services Transmission Pipelines Using Innovative Stress-Strain Microprobe Technology. ATC Report, ATC/DOT/990901. 65 p., 1999.

HAGGAG, F. M. Standard test methods for automated ball indentation (ABI) testing of metallic materials and structures to determine properties and stress-strain curves. **ADVANCED TECHNOLOGY CORPORATION**, OAK RIDGE, TN, USA. 2009.

HAYKIN, S. Nonlinear constitutive models from nanoindentation tests using artificial neural networks. **International Journal of Plasticity**, v. 24, p. 371–396, 2008.

HARSONO, E.; SWADDIWUDHIPONG, S.; LIU, Z. S.; Material characterization based on simulated spherical-Berkovich indentation tests. **Scripta Materialia**, 60, p. 972–975, 2009.

HAYKIN, S. **Redes Neurais - Princípios e Práticas**. , 2. ed. São Paulo: BOOKMAN, 2001.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. Upper Saddle River, New Jersey: Pearson Education Inc., 2009. 906 p.

HEBB, D. O. **The Organization of Behavior**. New York: Wiley, 1949. 335 p.

INMETRO, Sistema internacional de Unidades – SI. Rio de Janeiro, Brasil, 2012. 94 p.

INTHACHOT, M.; BOONJING, V.; INTAKOSUM, S. Artificial Neural Network and Genetic Algorithm Hybrid Intelligence for Predicting Thai Stock Price Index Trend. **Journal Computational Intelligence and Neuroscience**. v. 2016, n. 4. 2016.

IRANI, R.; NASIMI, R. Evolving neural network using real coded genetic algorithm for permeability estimation of the reservoir. **Expert Systems with Applications**, v. 38, p 9862-9866, 2011.

<https://doi.org/10.1016/j.eswa.2011.02.046>

ISO 14577-1. Metallic Materials - Instrumented indentation test for hardness and materials parameters. *International Organization for Standardization*. 2002.

ISO /TR 29381. Metallic materials - Measurement of mechanical properties by an instrumented indentation test - Indentation tensile properties. *International Organization for Standardization*, 2008.

ISO 18265. Metallic Materials – Conversion of Hardness Values. *International Organization for Standardization*, 2013.

JOLLIFFE, I. T. Discarding Variables in a Principal Component Analysis. I: Artificial Data. **Journal of the Royal Statistical Society**. Series C (Applied Statistics), v. 21, n. 2, p. 160-173, 1972.

JOLLIFFE, I. T. Discarding Variables in a Principal Component Analysis. II: Real Data. **Journal of the Royal Statistical Society**. Series C (Applied Statistics), v. 22, n. 1, p. 21-31, 1973.

JOLLIFFE, I. T. **Principal Components Analysis**. 2 ed., Springer, 2002.

KANIA, R.; RUSSELL, A.; GAO, M. Advanced indentation systems for tensile properties evaluation of in-service pipelines. In: Congresso Internacional de Ductos (CIN-005), PUEBLA, nov. 2003.

KANIA, R.; RUSSELL, A.; GAO, M. Advanced Indentation Systems for Tensile Properties Evaluation of In-Service Pipelines. **NACE – Corrosion 2004**, n. 04170, Nova Orleans, USA, 2004.

KANUMURI, L.; PUSHPALATHA, D. V.; NAIDU, A. S. K.; SINGH, S. K. A Hybrid Neural Network - Genetic Algorithm for Prediction of Mechanical Properties of ASS-304 at Elevated Temperatures. **Materials Today: Proceedings**. v. 4, p. 746-751, 2017.

<https://doi.org/10.1016/j.matpr.2017.01.081>

KARAK, S. K.; CHATTERJEE, S.; BANDOPADHYAY, S. Mathematical modelling of the physical and mechanical properties of nano-Y₂O₃ dispersed ferritic alloys using evolutionary algorithm-based neural network. **Powder Technology**, 274, p. 217–226, 2015.

KARIMIRAD, F.; CHAUHAN, S.; SHIRINZADEH, B. Vision-based force measurement using neural networks for biological cell microinjection. **Journal of Biomechanics**, 47, p. 1157–1163, 2014.

<https://doi.org/10.1016/j.jbiomech.2013.12.007>

KAYRI, M. Predictive Abilities of Bayesian Regularization and Levenberg–Marquardt Algorithms in Artificial Neural Networks: A Comparative Empirical Study on Social Data. **Mathematical and Computational Applications**. 21, 20. p. 1 – 11, 2016.

KRUGLOV, I.; MISHULINA, O.; BAKIROV, M. Quantile based decision making rule of the neural networks committee for ill-posed approximation problems. **Neurocomputing**, 96, p. 74–82, 2012.

KULKARNI, R. V.; KRISHNA, K. V. M.; NEOGY, S.; SRIVASTAVA, D.; RAMADASAN, E.; DEY, G. K.; SAIBABA, N.; JHA, S. K.; SHRIWASTAW, R. S.; ANANTHARAMAN, S. Determination of Correlation Parameters for Evaluation of Mechanical Properties by Small Punch Test and Automated Ball Indentation Test for Zr-2,5%Nb Pressure Tube Material. **Nuclear Engineering and Design**, 265, p. 1101-1112, 2013.

LI, Y.; STEVENS, P.; SUN, M.; ZHANG, C.; WANG, W. Improvement of predicting mechanical properties form spherical indentation test. **International Journal of Mechanical Sciences**, 117, p. 182–196, 2016.

LIMA, E. O. **Algoritmo Genético Híbrido aplicado à otimização de funções**. 2008. 73 f. Monografia de graduação. Departamento de Ciência da Computação da Universidade Federal de Lavras. Lavras – Minas Gerais.

LOUZADA, D. R. **Detecção e caracterização de danos estruturais através de sensores a rede de Bragg e Redes Neurais Artificiais**. 2013. 173 f. Tese de doutorado. Programa da Pós-Graduação em Engenharia Mecânica da Pontifícia Universidade Católica (PUC) do Rio de Janeiro (RJ).

MACKAY, D. J. C. Bayesian Interpolation. **Neural Computation**. v. 4. n. 3, p. 415–447, 1992.

<https://doi.org/10.1162/neco.1992.4.3.415>

MATHEW, M. D.; MURTY, K. L.; RAO, K. B. S.; MANNAN, S. L. Ball Indentation Studies on the Effect of Aging on Mechanical Behavior of Alloy 625. **Materials Science and Engineering A**, 264, p. 159-166, 1999.

MCCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. **Bulletin Of Mathematical Biophysics**. v. 5, p. 115-133. 1943.

MOK, C.-H. The dependence of yield stress on strain rate as determined from ball-indentation tests. **Experimental Mechanics**, v. 6, n. 2, p. 87-92, 1966.

MIRIKITANI, D. T.; NIKOLAEV, N. Recursive Bayesian Recurrent Neural Networks for Time-Series Modeling. **IEEE TRANSACTIONS ON NEURAL NETWORKS**, v. 21, n. 2, 2010.

MONTANA, D.J; DAVIS, L. Training feedforward neural networks using genetic algorithms. In: Proceedings of the eleventh international joint conference on artificial intelligence (IJCAI). Morgan Kaufmann, 1989, San Mateo, pp 762–767.

MORAIS, J. T. G. **Análise de componentes principais integrada a redes neurais artificiais para predição de matéria orgânica**. 2011. 67 f. Dissertação de Mestrado. Universidade Federal da Bahia. Escola Politécnica.

MULIANA, A., STEWARD, R., HAJ-ALI, R. M., SAXENA, A. Artificial neural network and finite element modeling of nanoindentation tests. **Metallurgical and Materials Transactions A (Physical Metallurgy and Materials Science)**, p. 1939-1947, 2002.

<https://doi.org/10.1007/s11661-002-0027-3>

MURTY, K. L.; MATHEW, M. D.; MIRAGLIA, P. Q.; SHAH, V. N.; HAGGAG, F. M. Non-destructive Evaluation of Deformation and Fracture Properties of Materials Using Stress-Strain Microprobe. Non-destructive Characterization of Materials in Aging Systems, Materials Research Society, 1998, Penn. **Anais...**

MURTY, K.; MATHEW, M. D. Nondestructive monitoring of structural materials using automated ball indentation (ABI) technique. **Nuclear Engineering and Design**, v. 228, n. 1-3, p. 81-96, 2004.

NICOLOSI, E. R. **Avaliação de Métodos Analíticos para Determinação de Propriedades Mecânicas de Aços Via Ensaio de Macroindentação Instrumentada**. 2015. 308 p. Dissertação de Mestrado, Universidade Federal de Uberlândia, Uberlândia.

OLIVER, W.C., PHARR, G.M. An improved technique for determining hardness and elastic-modulus using load and displacement sensing indentation experiments. **Journal of Materials Research**, v. 7, n. 6, p. 1564-1583, 1992.

<https://doi.org/10.1557/JMR.1992.1564>

PANDYA, D. A.; DENNIS, B. H.; RUSSELL, R. D. A computational fluid dynamics based artificial neural network model to predict solid particle erosion. **Wear**, v. 378-379, p.198–210, 2017.

POLAND, J. On the Robustness of Update Strategies for the Bayesian Hyperparameter α . 4 p. 2001.

POWAR, A., DATE, P. Modeling of microstructure and mechanical properties of heat treated components by using Artificial Neural Network. **Materials Science & Engineering A**, 628, p. 89–97, 2015.

RAMOS NETO, F. F.; FRANCO, S. D. Avaliação de propriedades mecânicas em dutos através de ensaios de macroindentação instrumentada. Anais do V Seminário de Pós-Graduação da Engenharia Mecânica da Universidade Federal de Uberlândia, Uberlândia, 2002. **Anais...** p.1-8. Disponível em: <www.posmec.ufu.br>.

RAMOS NETO, F. F.; S. FILHO, B. G.; PAES, M. T. P.; FRANCO, S. D. Gradientes de propriedades mecânicas em estruturas de condução de petróleo. 14° POSMEC – Simpósio

do Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Uberlândia. 2004.

ROSENBLATT, F. The Perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**. v. 65, p. 386-408. nov. 1958.

<https://doi.org/10.1037/h0042519>

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. In: RUMELHART, D. E.; MCCLELLAND, J. L. *Parallel Data Processing*. Cambridge, MA: The M.I.T. Press, 1986. p. 318-362.

SALGADO, M. F. P.; LISBOA, A. C.; SALDANHA, R. R.; CAMINHAS, W. M.; MENEZES, B. R. Aplicação da computação evolucionária na otimização de confiabilidade de sistemas. In: I Simpósio Brasileiro de Inteligência Computacional, 2007, Florianópolis. *Anais do I SBIC*. Florianópolis, 2007. 6 p.

SANTANA, A. F. **Treinamento de redes neurais artificiais utilizando algoritmos genéticos em plataforma distribuída**. 2012. 120 p. Trabalho de Fim de Curso. Universidade Federal de Lavras, Lavras.

SILVA, R. M.; ALMEIDA, T. A.; YAMAKAMI, A. Análise de desempenho de redes neurais artificiais para classificação automática de *web spam*. **Revista Brasileira de Computação Aplicada**. v.4, n.2, p. 42-57. 2012.

<https://doi.org/10.5335/rbca.2012.2195>

SILVA, S. R.; SCHIMIDT, F. Redução de variáveis de entrada de redes neurais artificiais a partir de dados de análise de componentes principais na modelagem de oxigênio dissolvido. **Química Nova**, v. 39, n. 3, p. 273-278, 2016.

SINGH, V. K.; SINGH, D.; SINGH, T. N. Prediction of strength properties of some schistose rocks from petrographic properties using artificial neural networks. **International Journal of Rock Mechanics & Mining Sciences**, 38, p. 269–284, 2001.

SOUNDARARAJAN, R.; RAMESH, A.; SIVASANKARAN, S.; VIGNESH, M. Modeling and Analysis of Mechanical Properties of Aluminium Alloy (A413) Reinforced with Boron Carbide

(B4C) Processed Through Squeeze Casting Process Using Artificial Neural Network Model and Statistical Technique. **Materials Today: Proceedings**, 4, p. 2008–2030, 2017.

<https://doi.org/10.1016/j.matpr.2017.02.047>

SOUSA, J. V. **Desenvolvimento de um Sistema de Controle e Interfaceamento para um Macroindentador Portátil para Avaliação de Propriedades Mecânicas de Dutos Baseado em Tecnologias DSP e Wireless**. 2011, 137p. Dissertação de Mestrado. Universidade Federal de Uberlândia, Uberlândia, 2011.

SOUZA, C. Neural Network Learning by the Levenberg-Marquardt Algorithm with Bayesian Regularization (Part 2), 2009.

SURATGAR, A. A.; TAVAKOLI, M. B.; HOSEINABADI, A. Modified Levenberg-Marquardt Method for Neural Networks Training. **World Academy of Science, Engineering and Technology**, 6, 2005.

SWADDIWUDHIPONG, S.; HARSONO, E.; ZISHUN, L.; Comparative Study of Reverse Algorithms via Artificial Neural Networks Based on Simulated Indentation Tests. **Tsinghua Science and Technology**, p. 393-399, 2008.

SWADDIWUDHIPONG, S.; HUA, J.; HARSONO, E.; LIU, Z. S.; BRANDON OOI, N. S. Improved algorithm for material characterization by simulated indentation tests. **Modelling and Simulation in Materials Science and Engineering**, p. 1347-1362, 2006.

TABOR, D. **The hardness of Metals**. Oxford: Clarendon Press, 1951.

TAKAHASHI, H. J. **Predição de propriedades mecânicas de aços de alta resistência microligados utilizando técnicas de inteligência computacional**. 2006. 128 f. Dissertação de mestrado. Centro Universitário do Leste de Minas Gerais (unileste MG). Coronel Fabriciano.

TAVARES, L.G.; LOPES, H. S.; LIMA, C.R.E. Estudo comparativo de métodos de aprendizaDO de máquina na detecção de regiões promotoras de genes de Escherichia coli. In: i Simpósio Brasileiro de Inteligência Computacional, 2007, Florianópolis. **Anais do I SBIC**. 5 p.

TIMOSHENKO, S. P.; GOODIER, J. N. **Theory of Elasticity**. 3. ed. McGraw-Hill, 1970.

THO, K. K.; SWADDIWUDHIPONG, S.; LIU, Z. S.; HUA, J. Artificial neural network model for material characterization by indentation. **Modelling and Simulation in Materials Science and Engineering**, p. 1055-1062. 2004.

TOPÇU, İ. B.; SARIDEMIR, M. Prediction of mechanical properties of recycled aggregate concretes containing silica fume using artificial neural networks and fuzzy logic. **Computational Materials Science**, v. 42, p. 74–82, 2008.

TOSUN, N.; ÖZLER, L. A study of tool life in hot machining using artificial neural networks and regression analysis method. **Journal of Materials Processing Technology**, v. 124, p. 99–104, 2002.

WIDROW, B.; HOFF, M. E.. Adaptive switching circuits. In: IRE WESCON CONVENTION RECORD, 1960, New York. Proceedings..., p. 96-104.

VENKATESH, T. A.; VAN VLIET, K. J.; GIANNAKOPOULOS, A. E.; SURESH, S. Determination of elasto-plastic properties by instrumented sharp indentation: guidelines for property extraction. **Scripta Materialia**. v. 42. p. 833–839. 2000.

YAO, X. Evolving Artificial Neural Networks. In: Proceedings of the IEEE, v. 87, n. 9, p. 1423-1447, 1999.

<https://doi.org/10.1109/5.784219>

YU, H; WILAMOWSKI, B. M. Levenberg–Marquardt Training. In: The Industrial Electronics Handbook. CRC Press. 2.ed., v.3.: Intelligent Systems, Capítulo 12, 2011.

<https://doi.org/10.1201/b10604-15>

ZHOU, C-C; YIN, G-F; HU, X-B. Multi-objective optimization of material selection for sustainable products: Artificial neural networks and genetic algorithm approach. **Materials and Design**, v. 30, p. 1209–1215, 2009.

<https://doi.org/10.1016/j.matdes.2008.06.006>

ANEXO I

Os gráficos dos ensaios de macroindentação instrumentada dos materiais de “A” a “G”, API 5L X65, L 80, P110 e ABNT 8550, realizados através do *PropInSitu 2* por Nicolosi (2015), estão representados nas Figs. de AI.1 a AI.73.

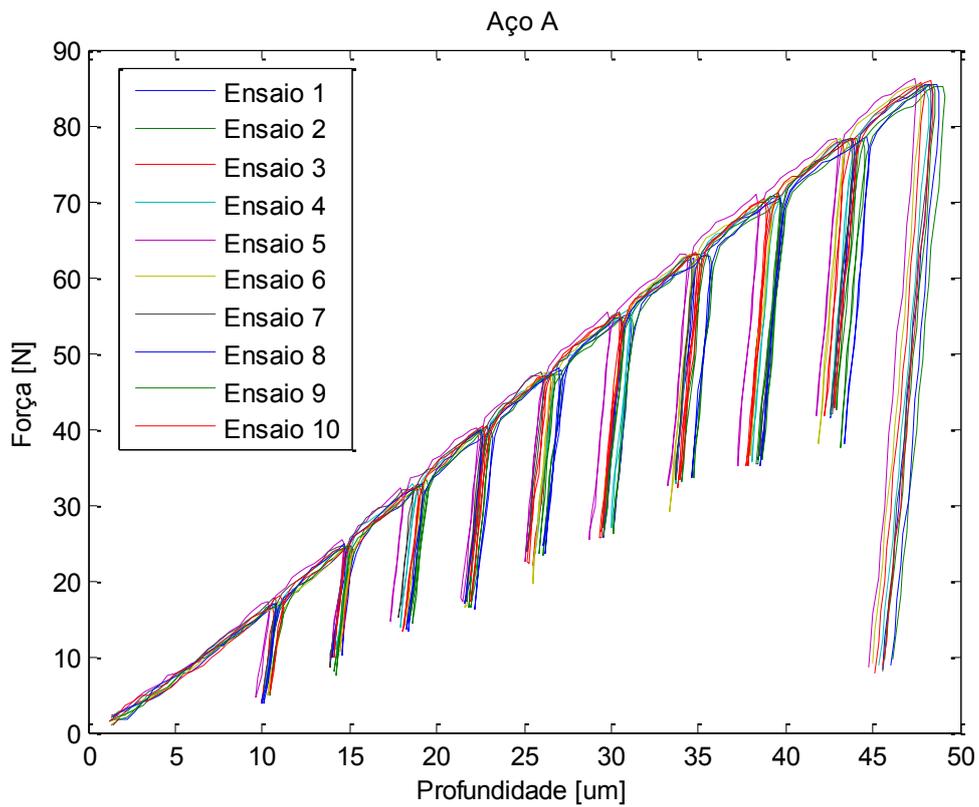


Figura AI.1 – Ensaio de macroindentação instrumentada do Aço “A”, realizado no *PropInSitu 2*, com uma força máxima de 85 N e penetrador esferocônico de diâmetro igual a 0,4 mm (NICOLOSI, 2015)

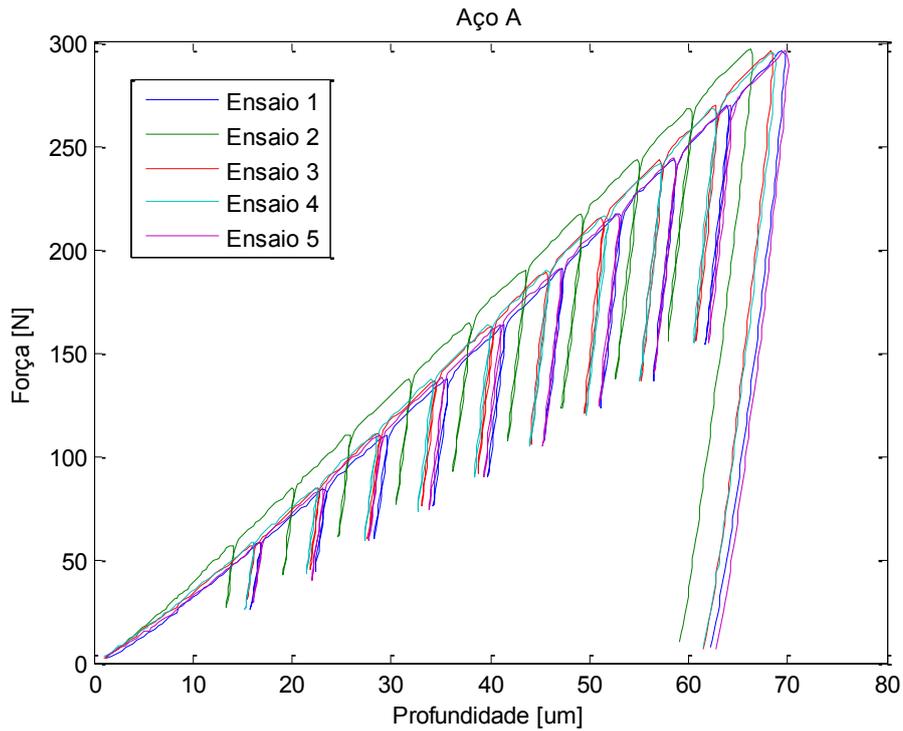


Figura A1.2 - Ensaio de macroindentação instrumentada do Aço "A", realizado no *PropInSitu 2*, com uma força máxima de 294 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

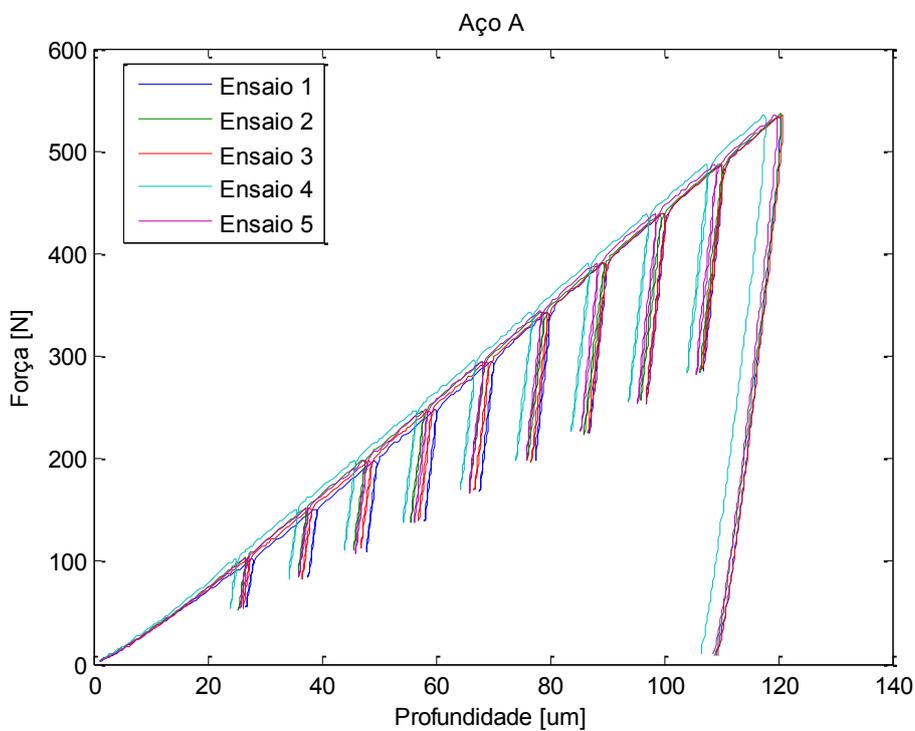


Figura A1.3 - Ensaio de macroindentação instrumentada do Aço "A", realizado no *PropInSitu 2*, com uma força máxima de 533 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

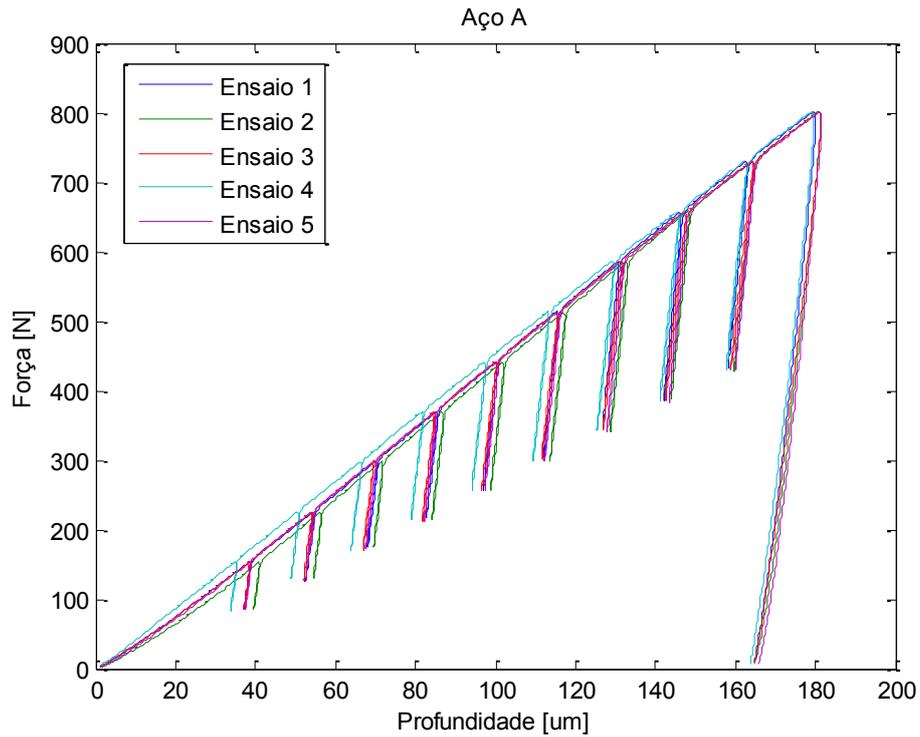


Figura A1.4 - Ensaio de macroindentação instrumentada do Aço “A”, realizado no *PropInSitu 2*, com uma força máxima de 800 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

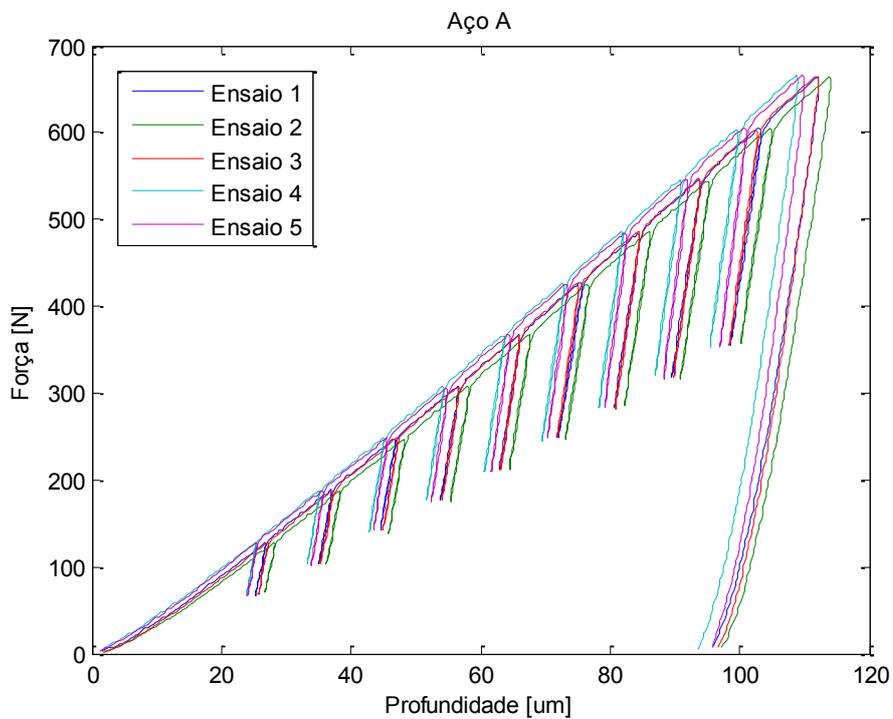


Figura A1.5 - Ensaio de macroindentação instrumentada do Aço “A”, realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

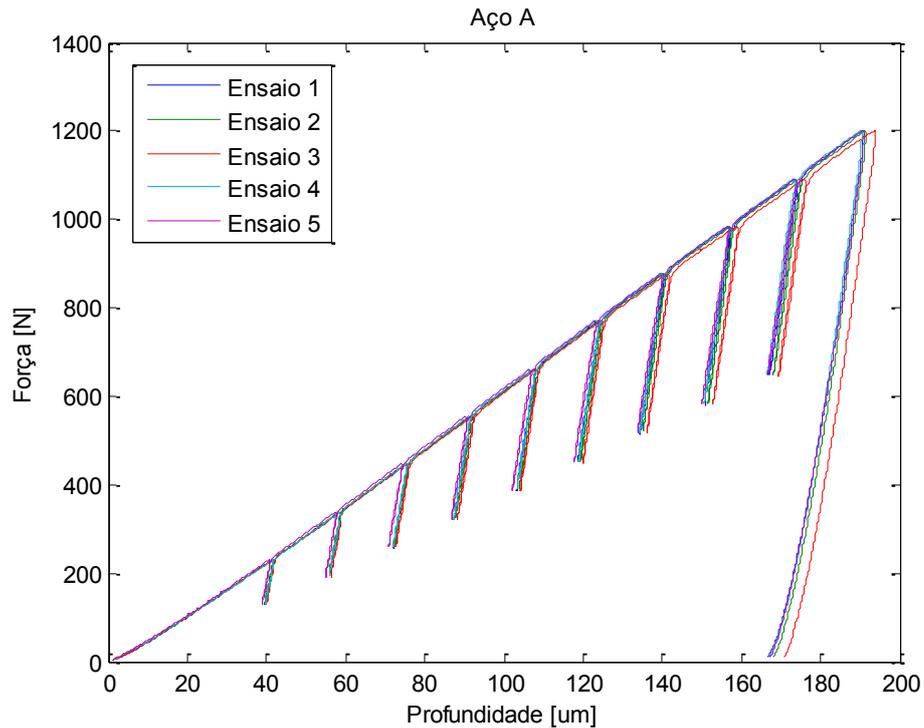


Figura A1.6 - Ensaio de macroindentação instrumentada do Aço “A”, realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

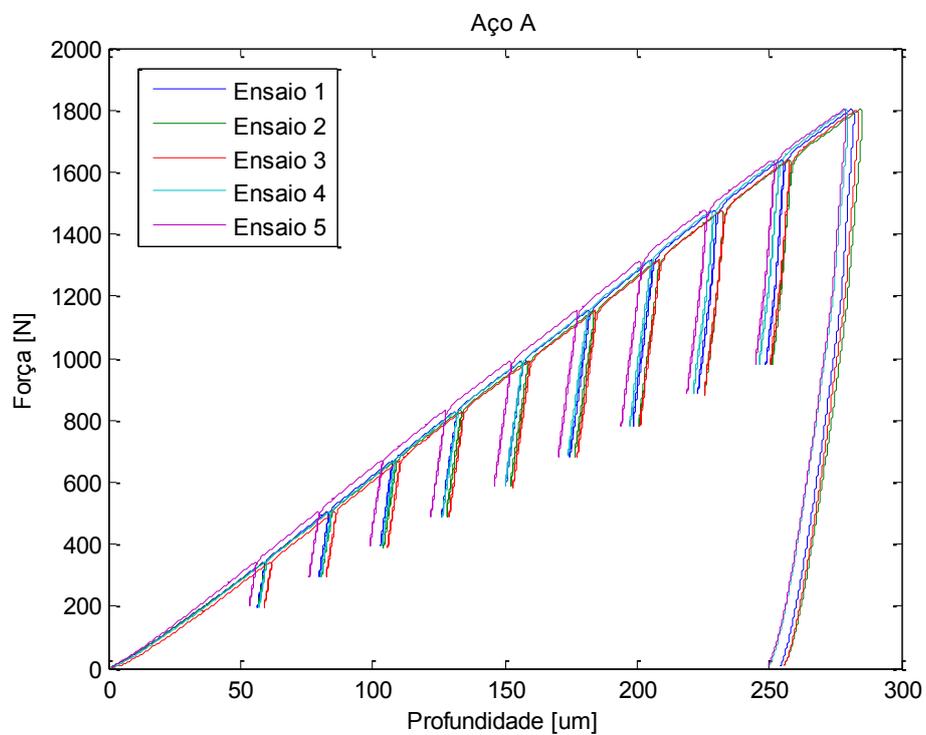


Figura A1.7 - Ensaio de macroindentação instrumentada do Aço “A”, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

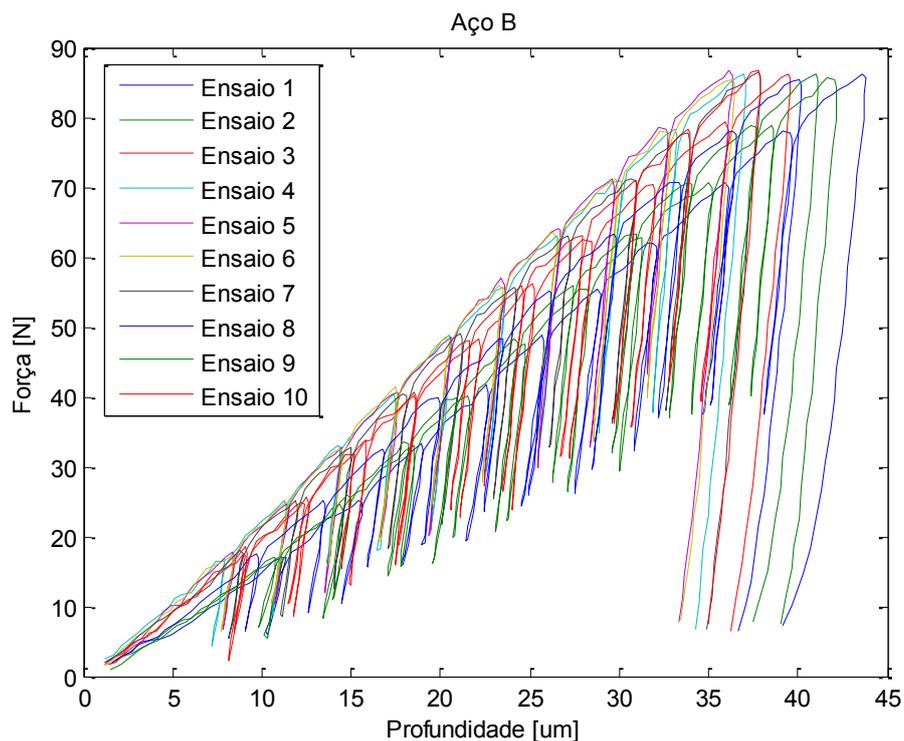


Figura A1.8 – Ensaio de macroindentação instrumentada do Aço “B”, realizado no *PropInSitu 2*, com uma força máxima de 85 N e penetrador esferocônico de diâmetro igual a 0,4 mm (NICOLSI, 2015)

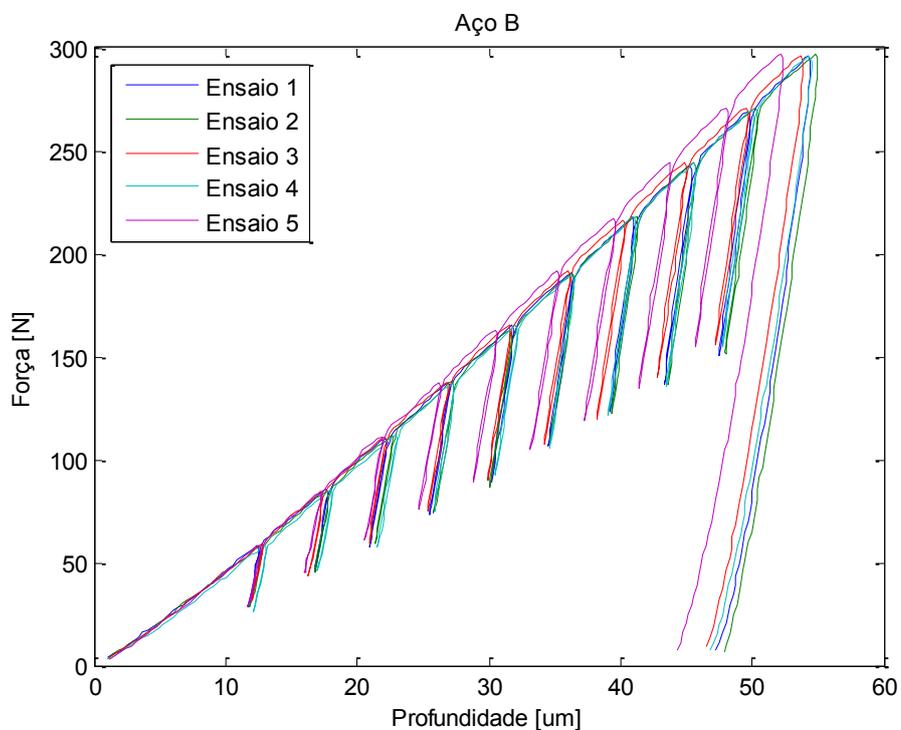


Figura A1.9 - Ensaio de macroindentação instrumentada do Aço “B”, realizado no *PropInSitu 2*, com uma força máxima de 294 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

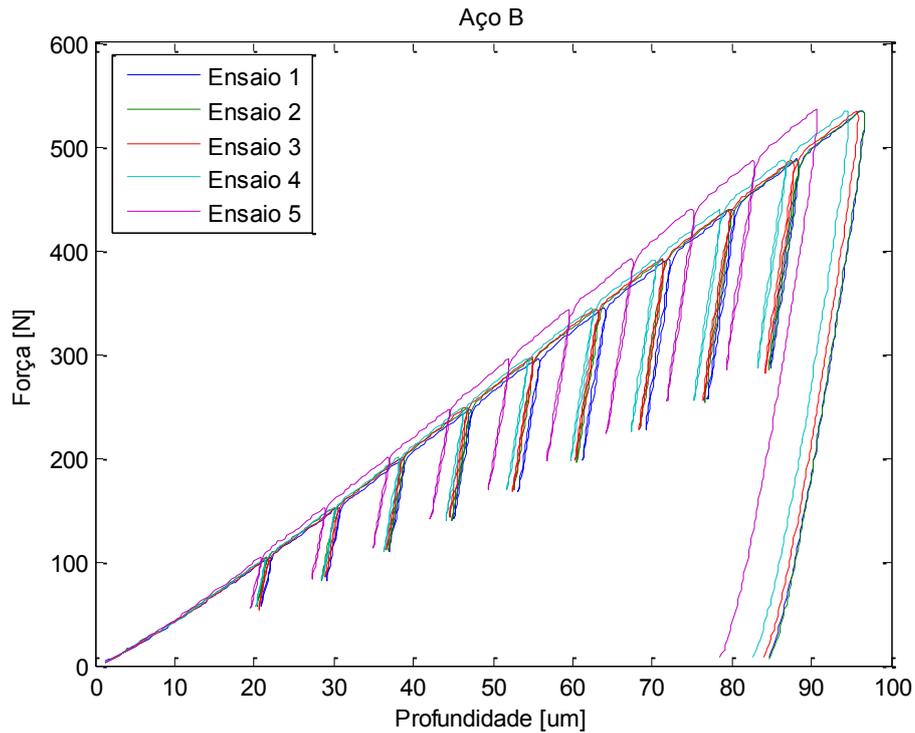


Figura A1.10 - Ensaio de macroindentação instrumentada do Aço “B”, realizado no *PropInSitu 2*, com uma força máxima de 533 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

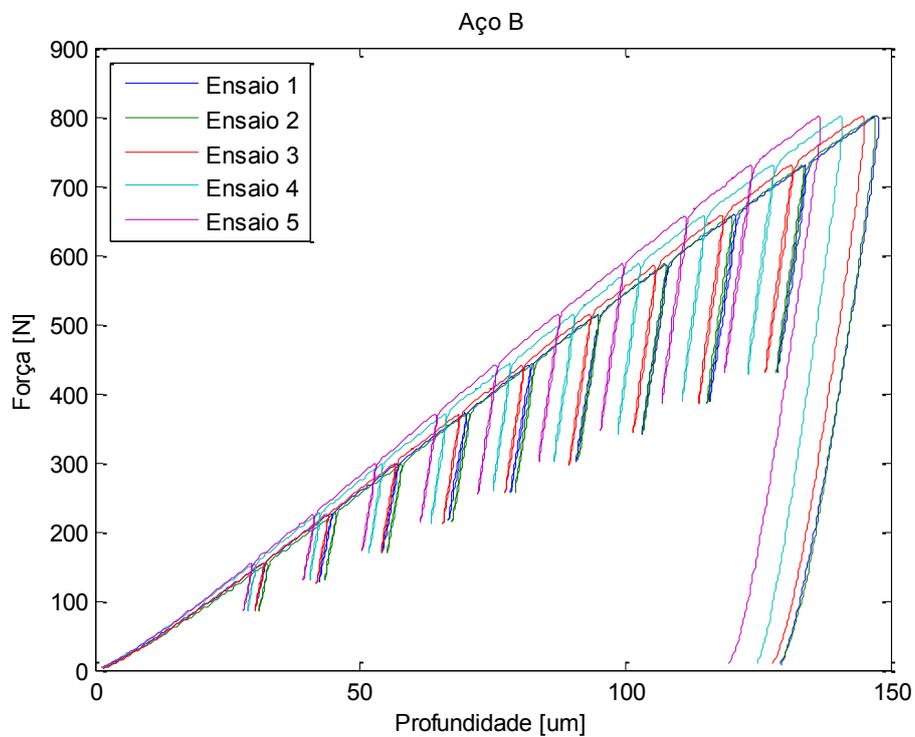


Figura A1.11 - Ensaio de macroindentação instrumentada do Aço “B”, realizado no *PropInSitu 2*, com uma força máxima de 800 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

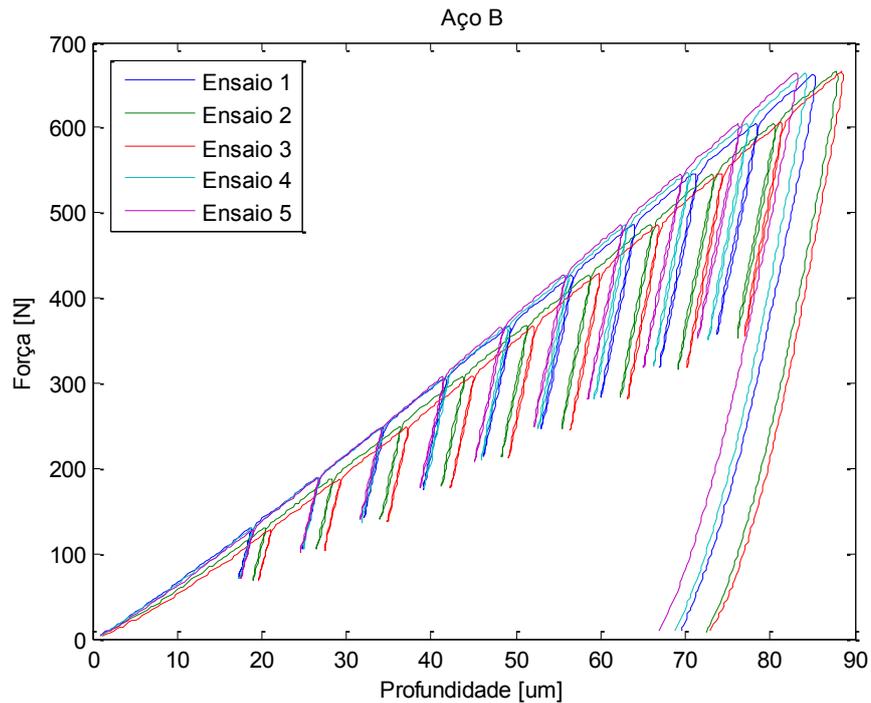


Figura A1.12 - Ensaio de macroindentação instrumentada do Aço "B", realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

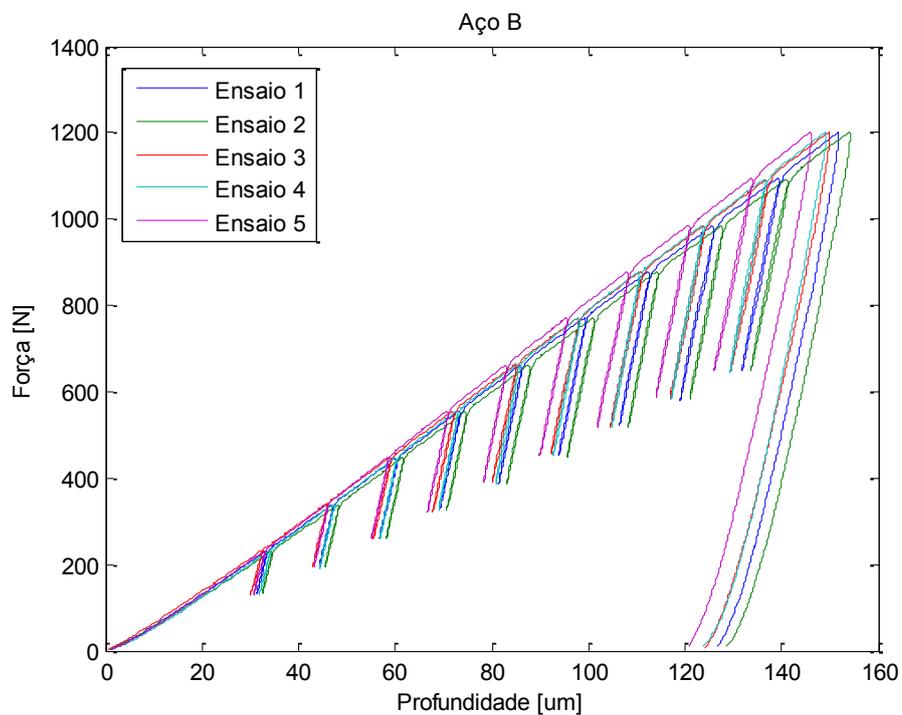


Figura A1.13 - Ensaio de macroindentação instrumentada do Aço "B", realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

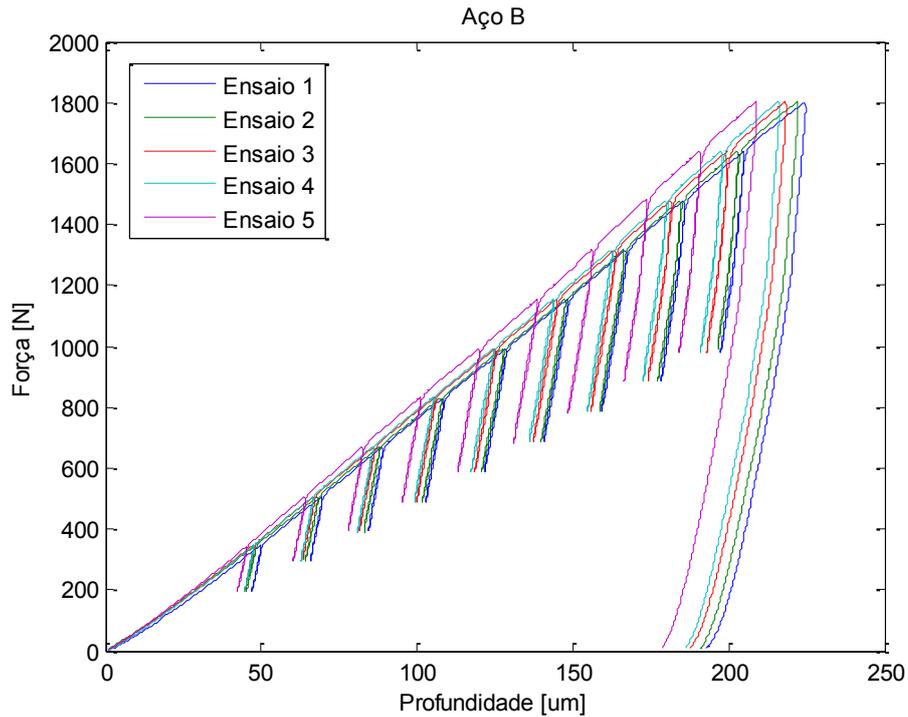


Figura A1.14 - Ensaio de macroindentação instrumentada do Aço “B”, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

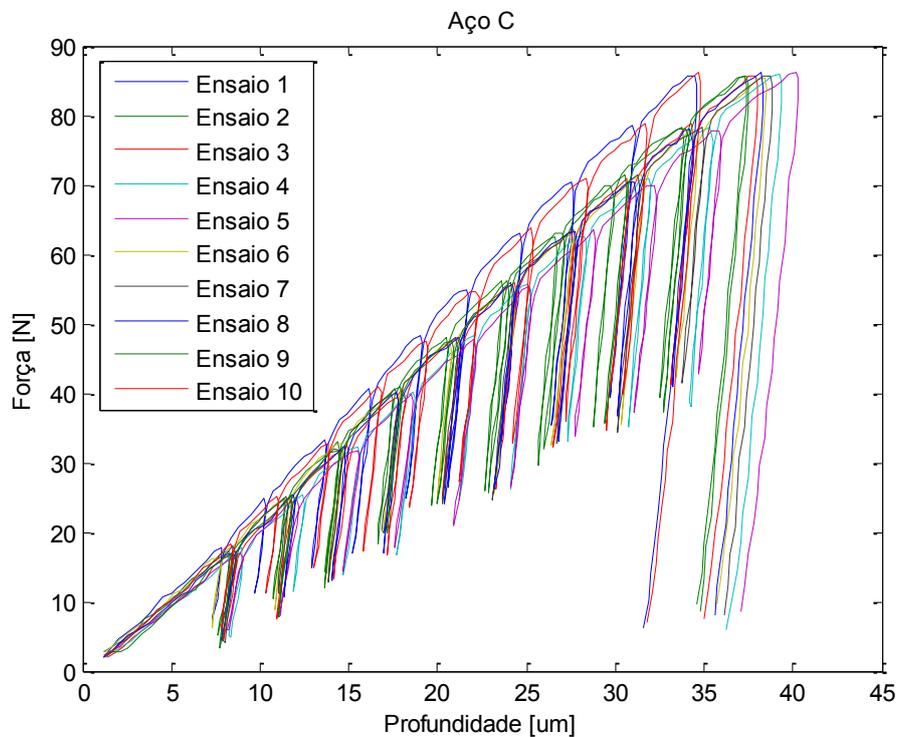


Figura A1.15 – Ensaio de macroindentação instrumentada do Aço “C”, realizado no *PropInSitu 2*, com uma força máxima de 85 N e penetrador esferocônico de diâmetro igual a 0,4 mm (NICOLSI, 2015)

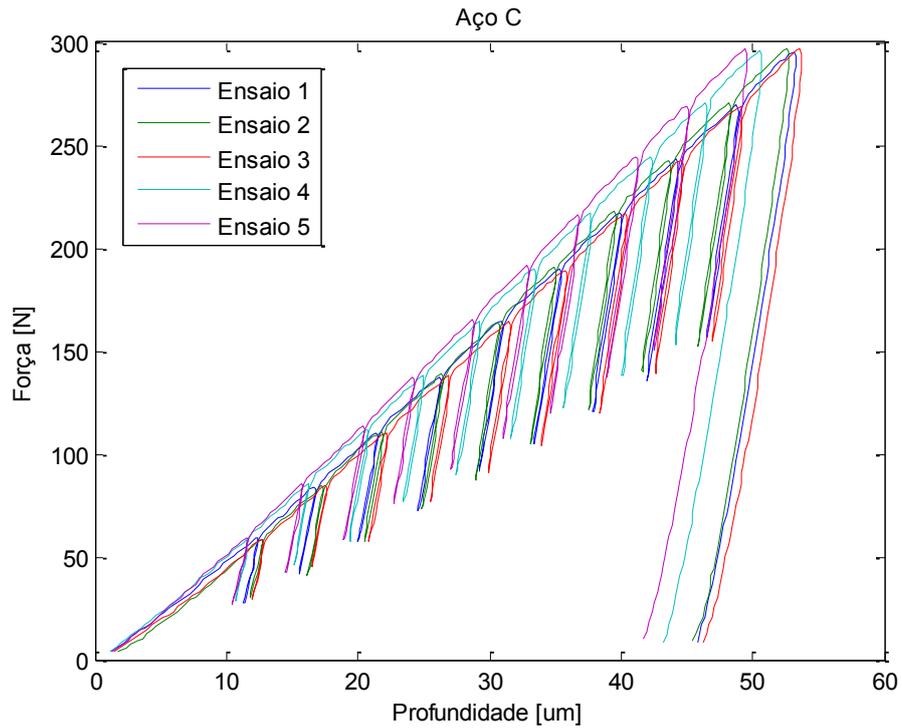


Figura AI.16 - Ensaio de macroindentação instrumentada do Aço "C", realizado no *PropInSitu 2*, com uma força máxima de 294 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

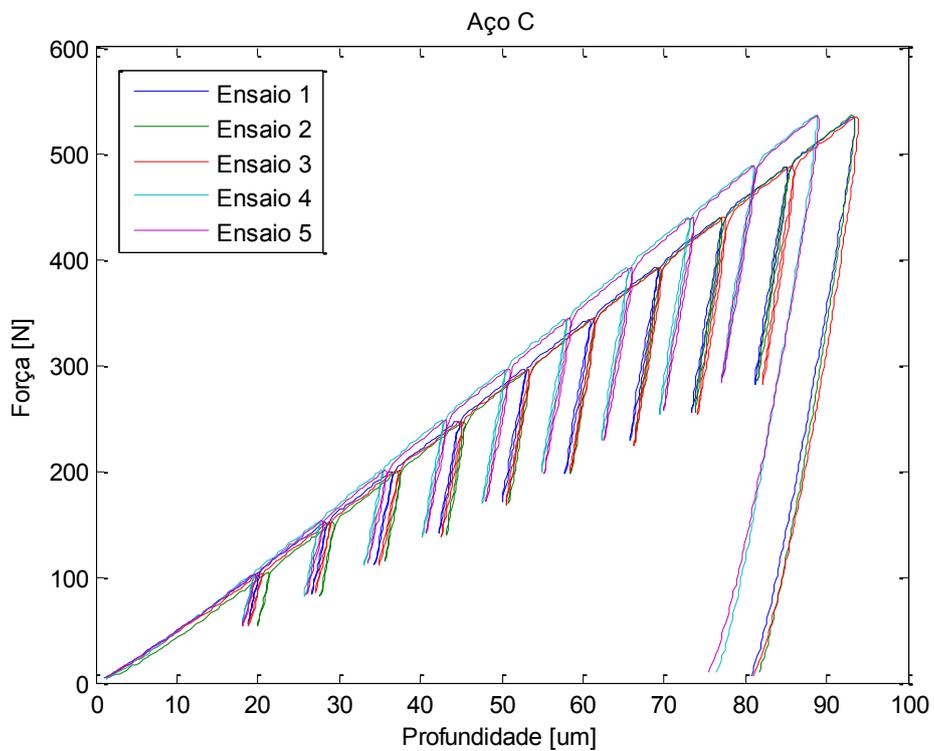


Figura AI.17 - Ensaio de macroindentação instrumentada do Aço "C", realizado no *PropInSitu 2*, com uma força máxima de 533 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

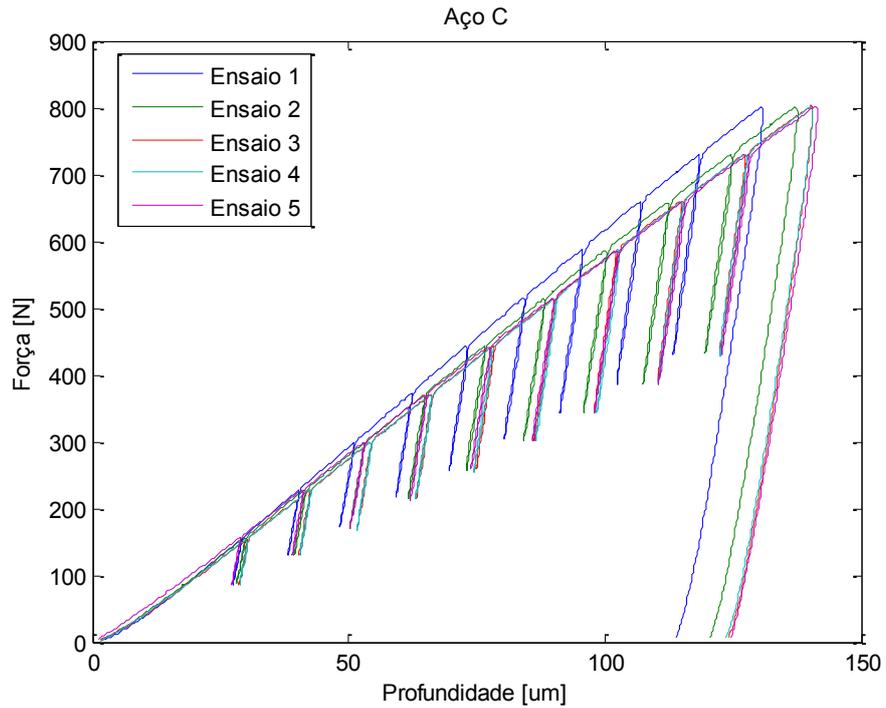


Figura AI.18 - Ensaio de macroindentação instrumentada do Aço "C", realizado no *PropInSitu 2*, com uma força máxima de 800 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

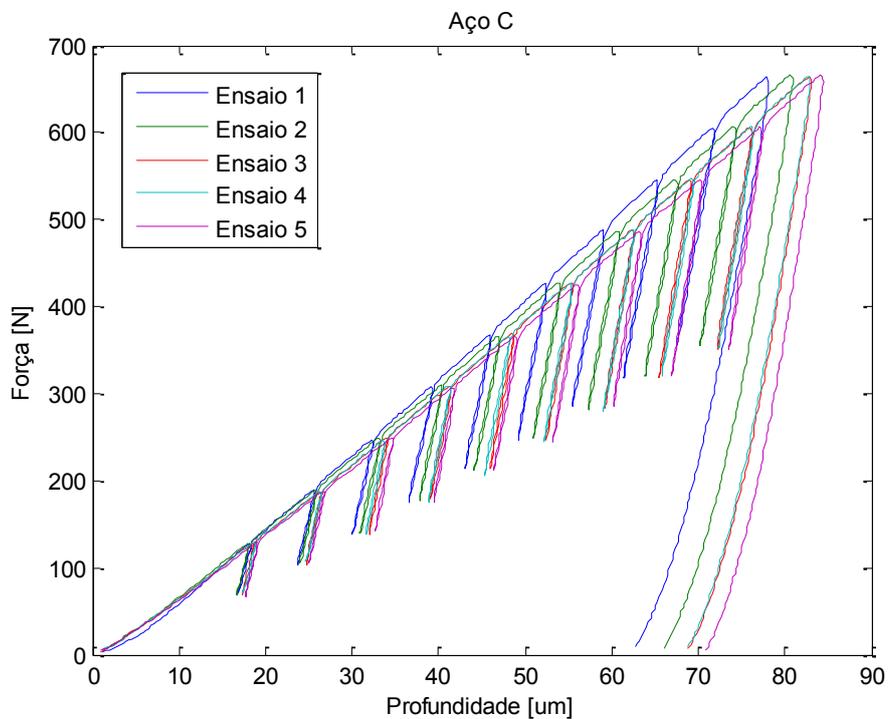


Figura AI.19 - Ensaio de macroindentação instrumentada do Aço "C", realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

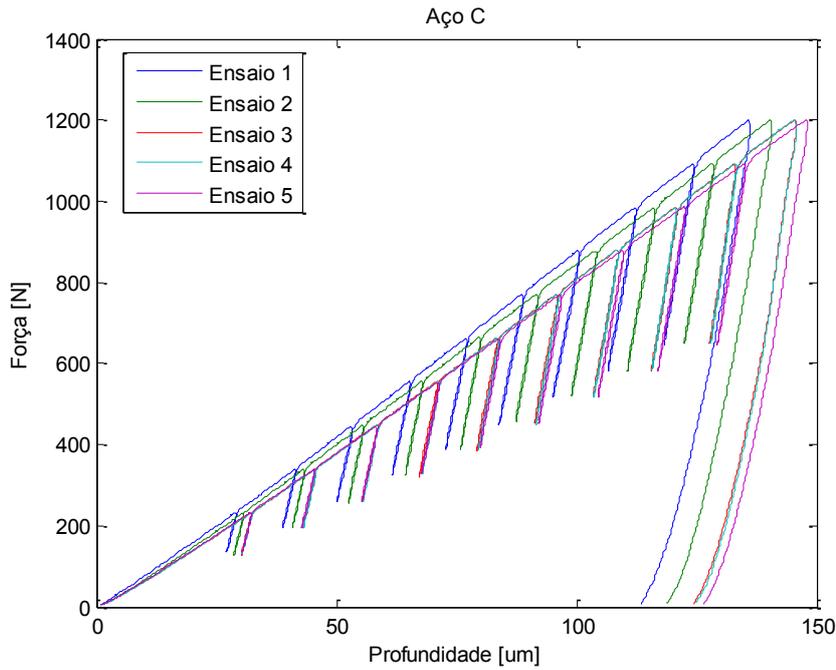


Figura Al.20 - Ensaio de macroindentação instrumentada do Aço "C", realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

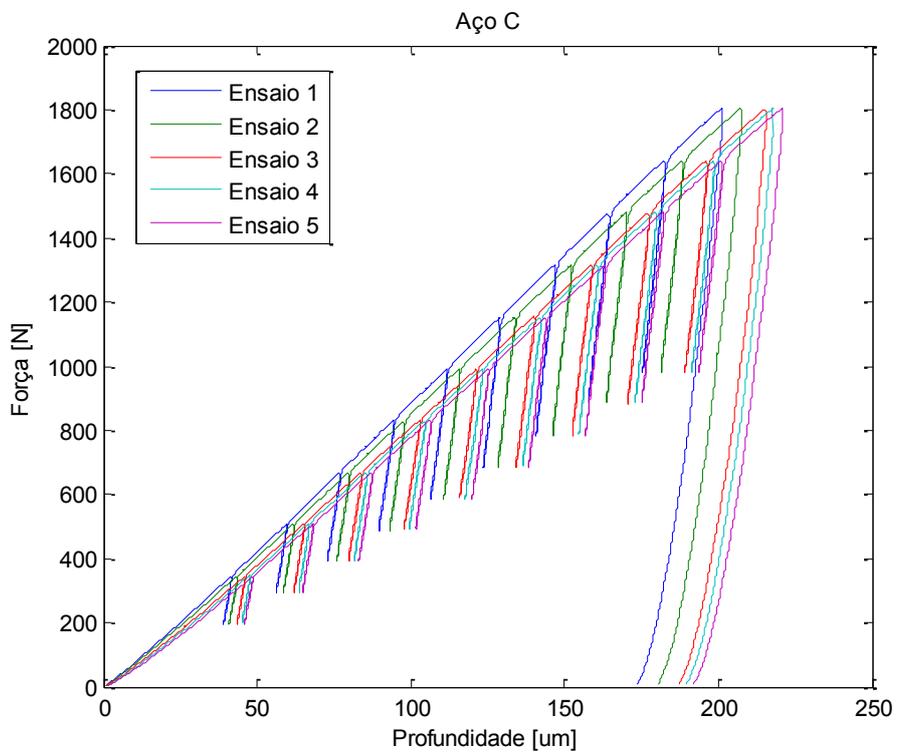


Figura Al.21 - - Ensaio de macroindentação instrumentada do Aço "C", realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

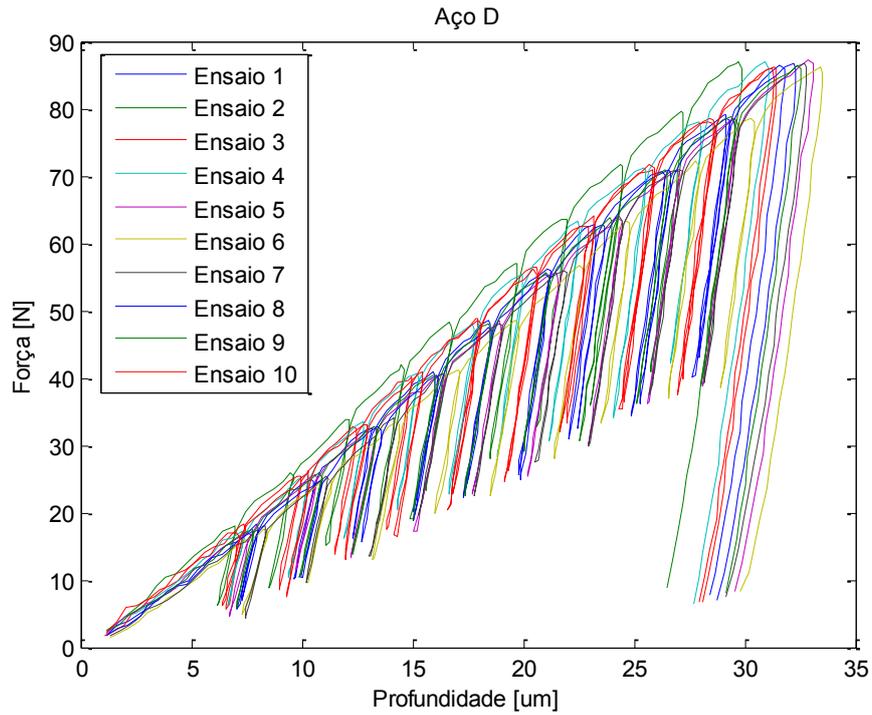


Figura Al.22 - Ensaio de macroindentação instrumentada do Aço “D”, realizado no *PropInSitu 2*, com uma força máxima de 85 N e penetrador esferocônico de diâmetro igual a 0,4 mm (NICOLSI, 2015)

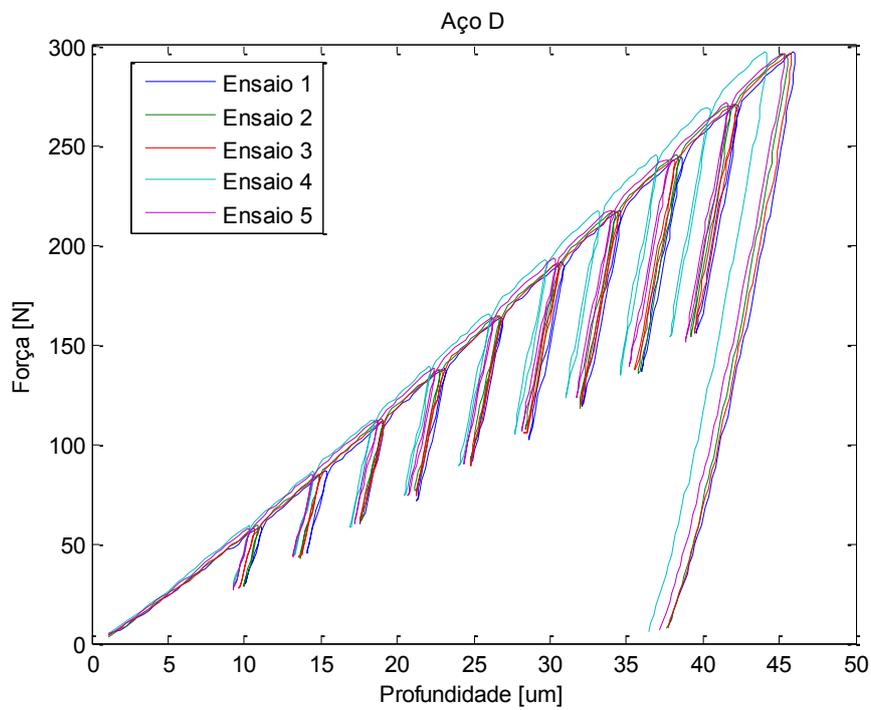


Figura Al.23 - Ensaio de macroindentação instrumentada do Aço “D”, realizado no *PropInSitu 2*, com uma força máxima de 294 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

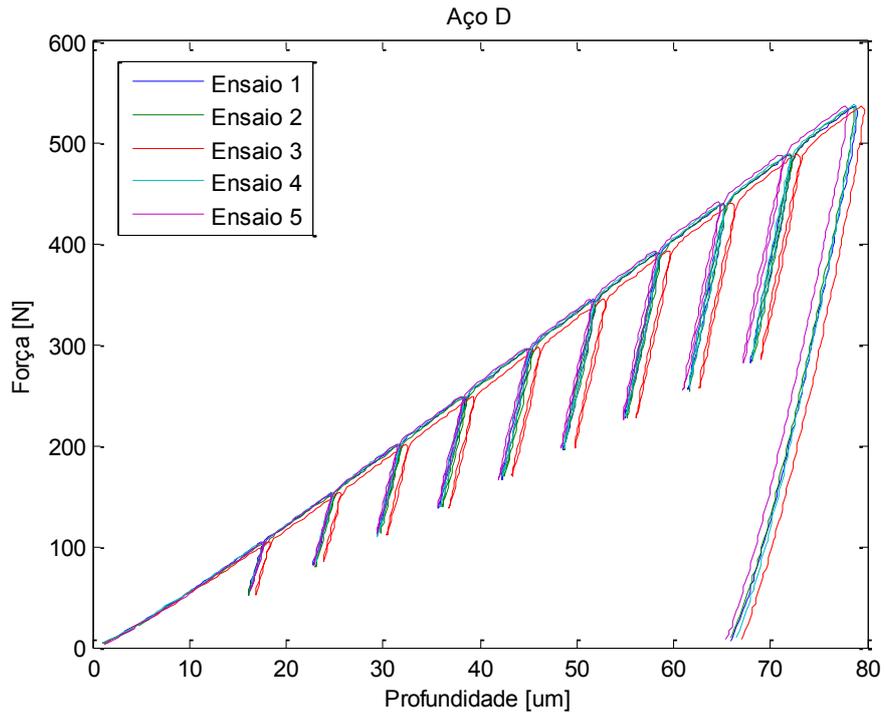


Figura A1.24 - Ensaio de macroindentação instrumentada do Aço "D", realizado no *PropInSitu 2*, com uma força máxima de 533 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

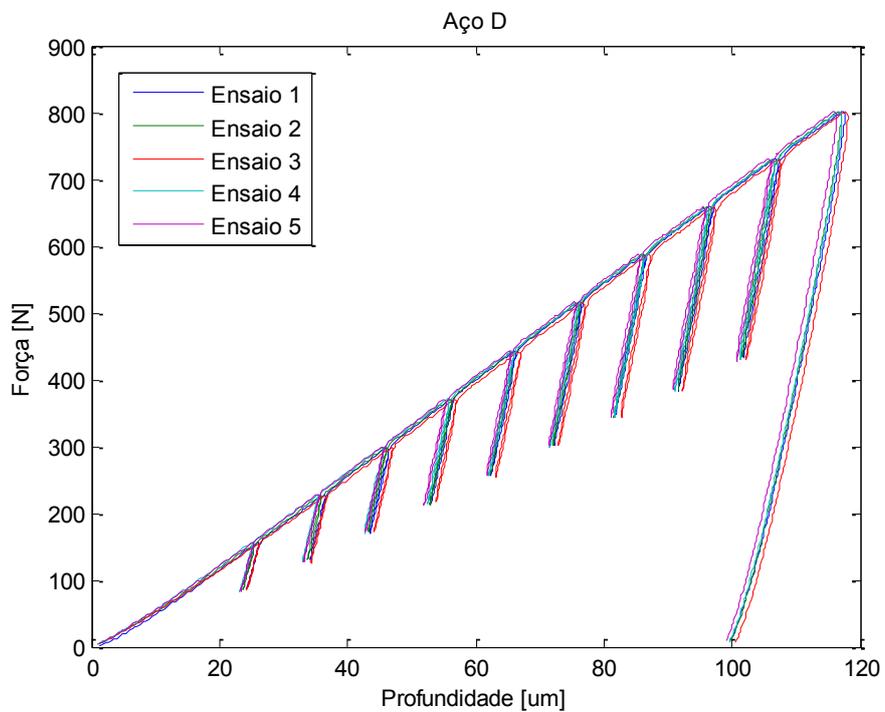


Figura A1.25 - Ensaio de macroindentação instrumentada do Aço "D", realizado no *PropInSitu 2*, com uma força máxima de 800 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

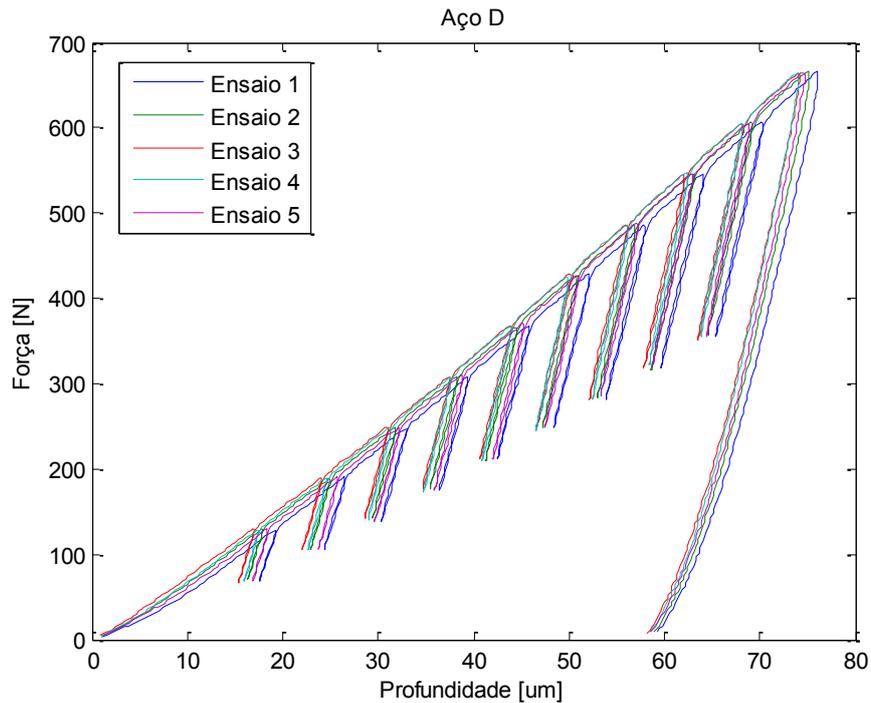


Figura Al.26 - Ensaio de macroindentação instrumentada do Aço "D", realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

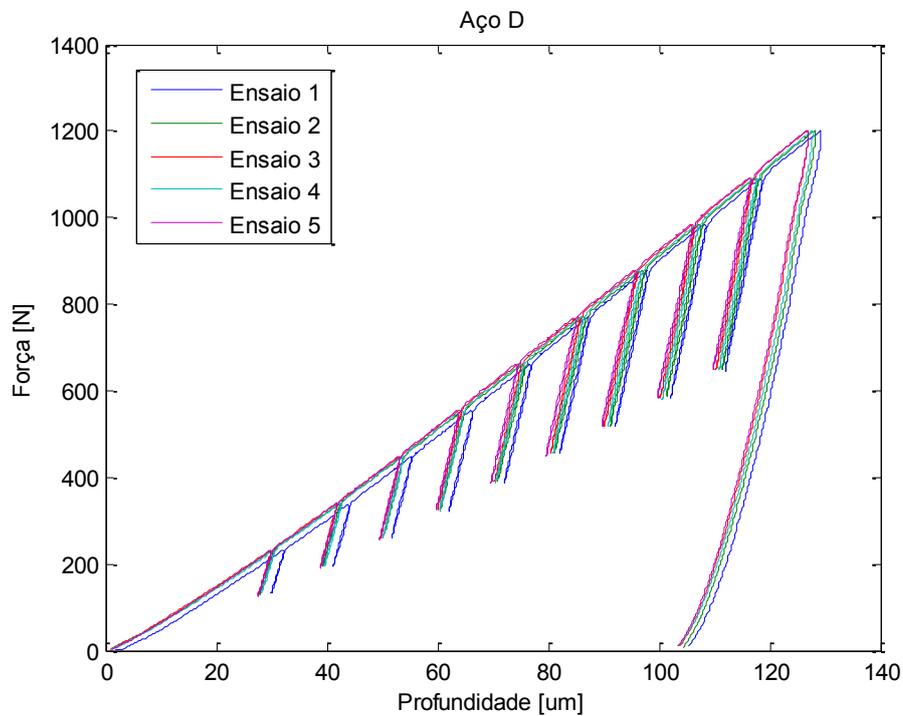


Figura Al.27 - Ensaio de macroindentação instrumentada do Aço "D", realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

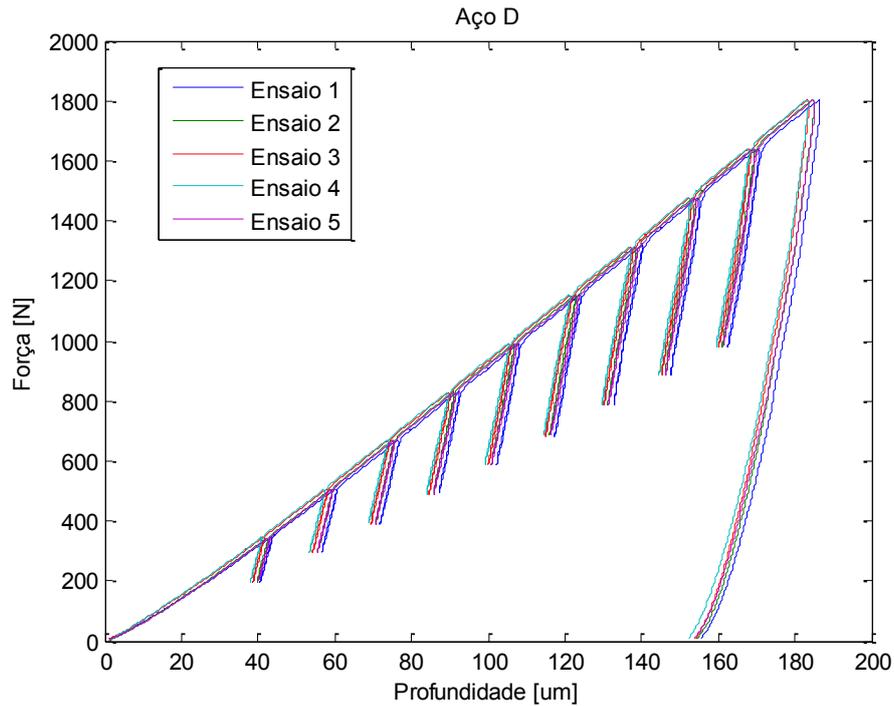


Figura Al.28 - Ensaio de macroindentação instrumentada do Aço “D”, realizado no PropInSitu 2, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

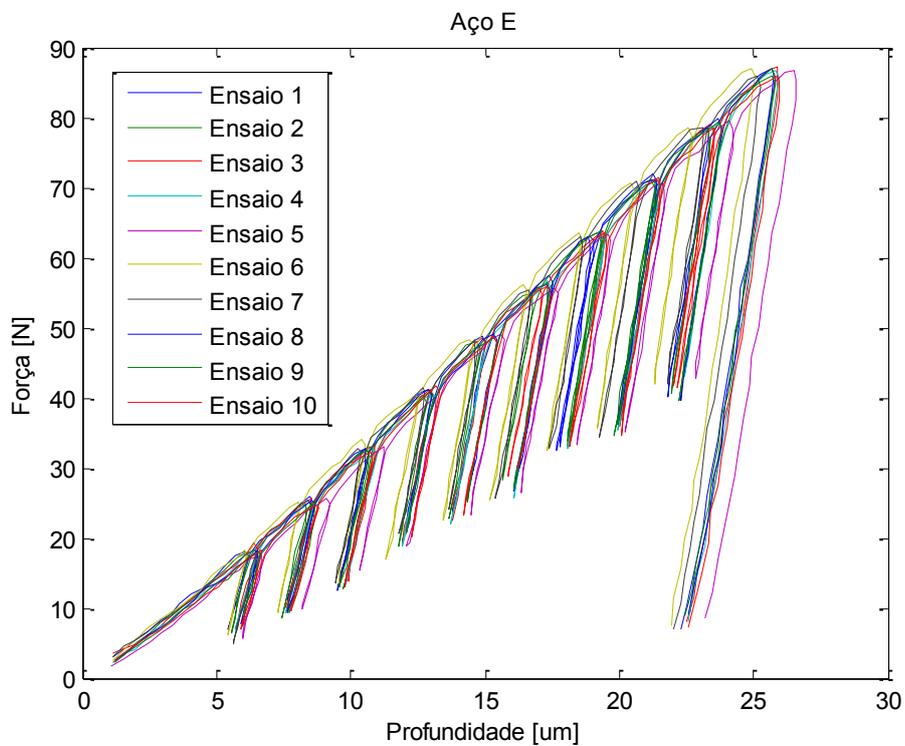


Figura Al.29 - Ensaio de macroindentação instrumentada do Aço “E”, realizado no PropInSitu 2, com uma força máxima de 85 N e penetrador esferocônico de diâmetro igual a 0,4 mm (NICOLSI, 2015)

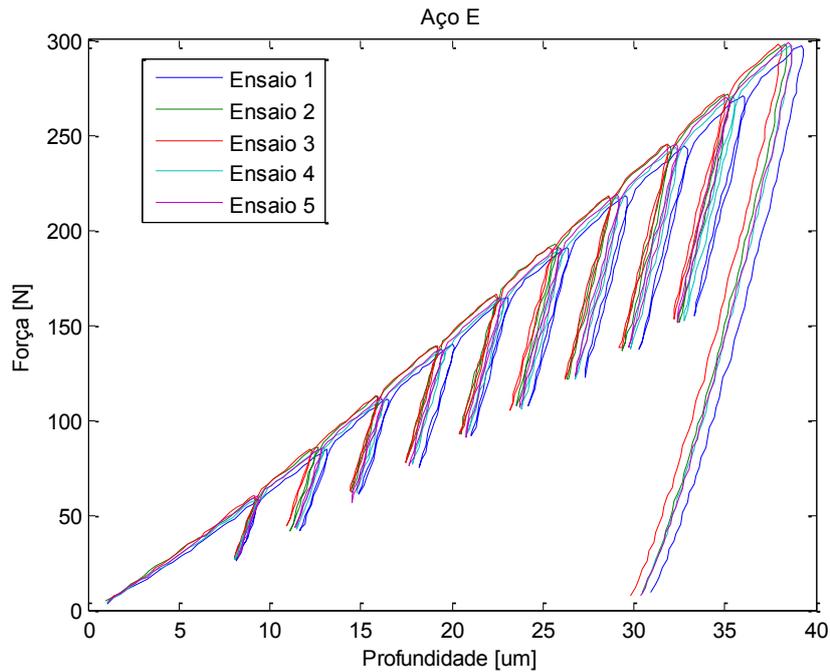


Figura Al.30 - Ensaio de macroindentação instrumentada do Aço “E”, realizado no ProInSitu 2, com uma força máxima de 294 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

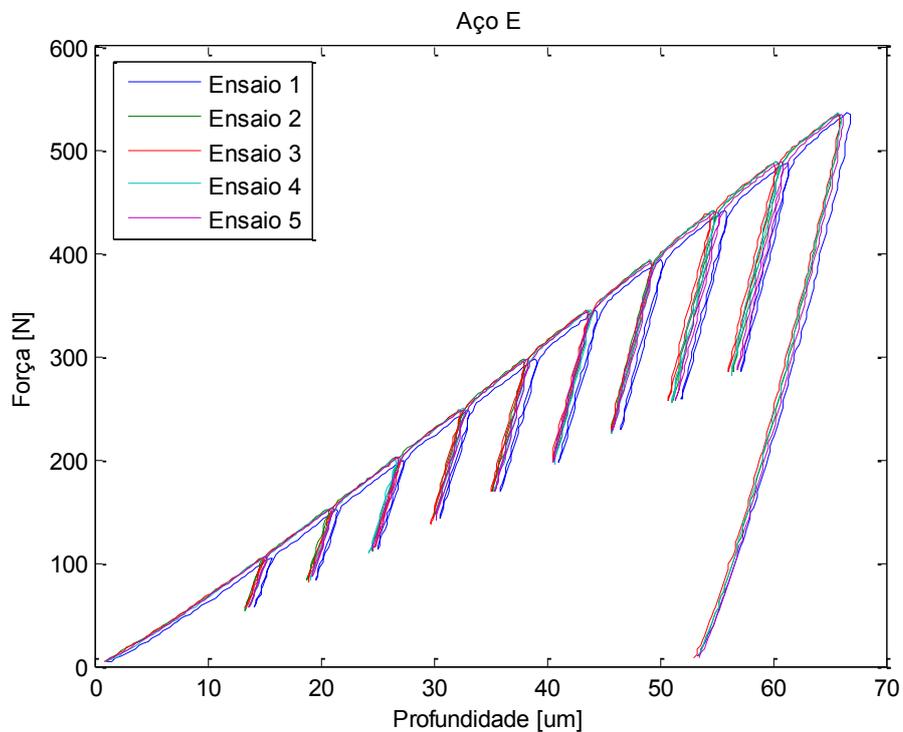


Figura Al.31 - Ensaio de macroindentação instrumentada do Aço “E”, realizado no ProInSitu 2, com uma força máxima de 533 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

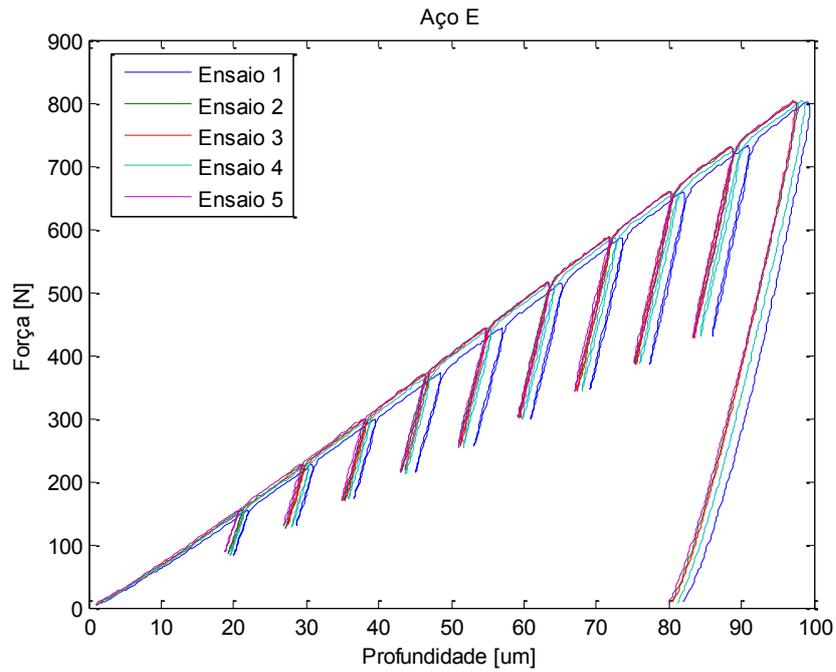


Figura A1.32 - Ensaio de macroindentação instrumentada do Aço "E", realizado no PropInSitu 2, com uma força máxima de 800 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

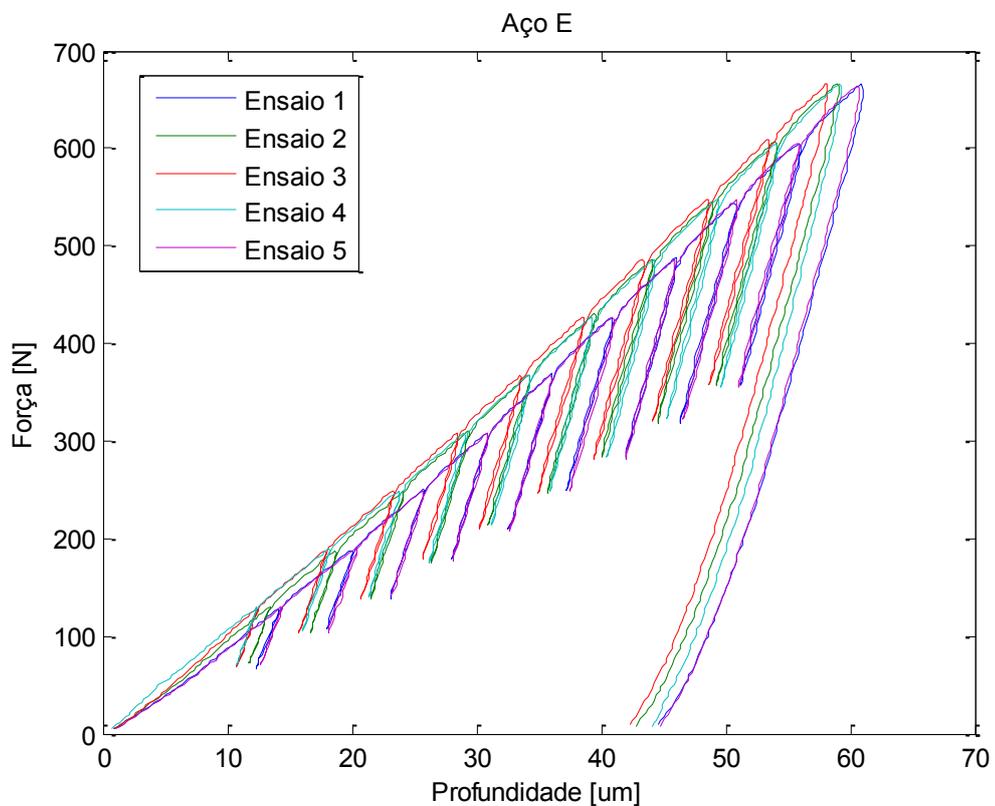


Figura A1.33 - Ensaio de macroindentação instrumentada do Aço "E", realizado no PropInSitu 2, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

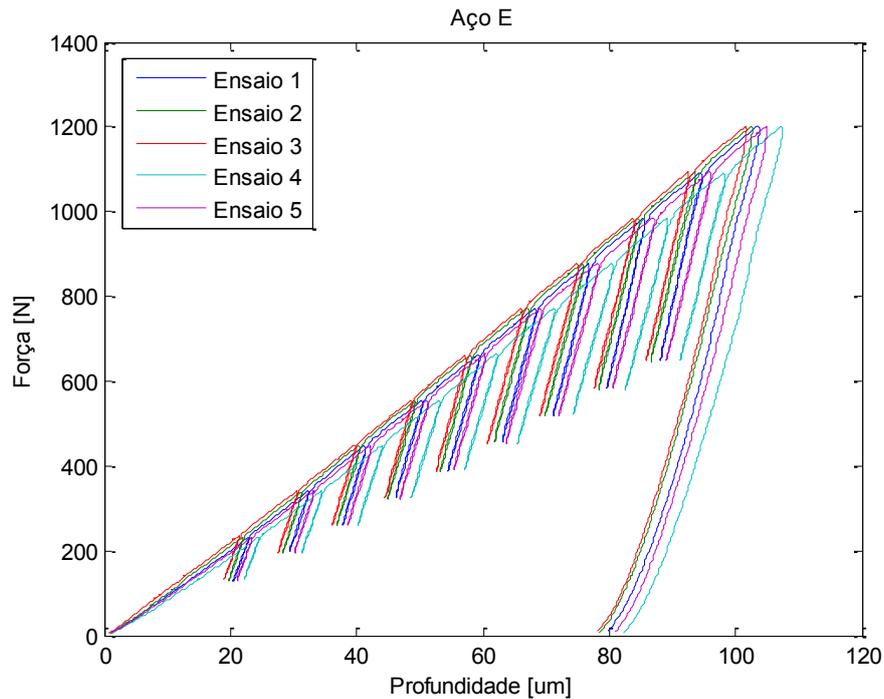


Figura Al.34 - Ensaio de macroindentação instrumentada do Aço "E", realizado no PropInSitu 2, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

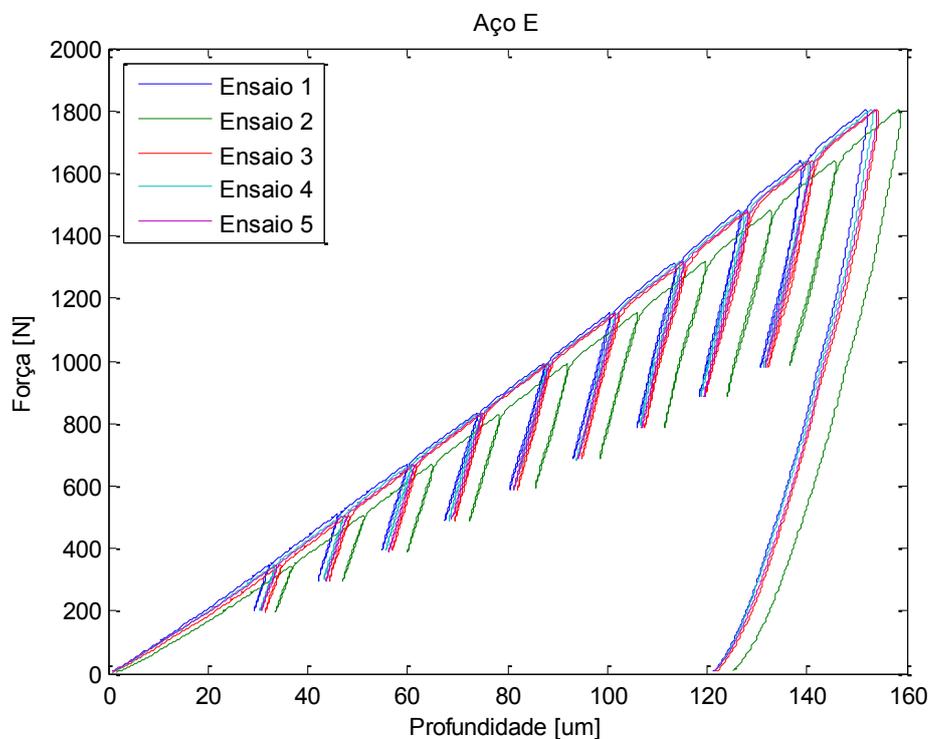


Figura Al.35 - Ensaio de macroindentação instrumentada do Aço "E", realizado no PropInSitu 2, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

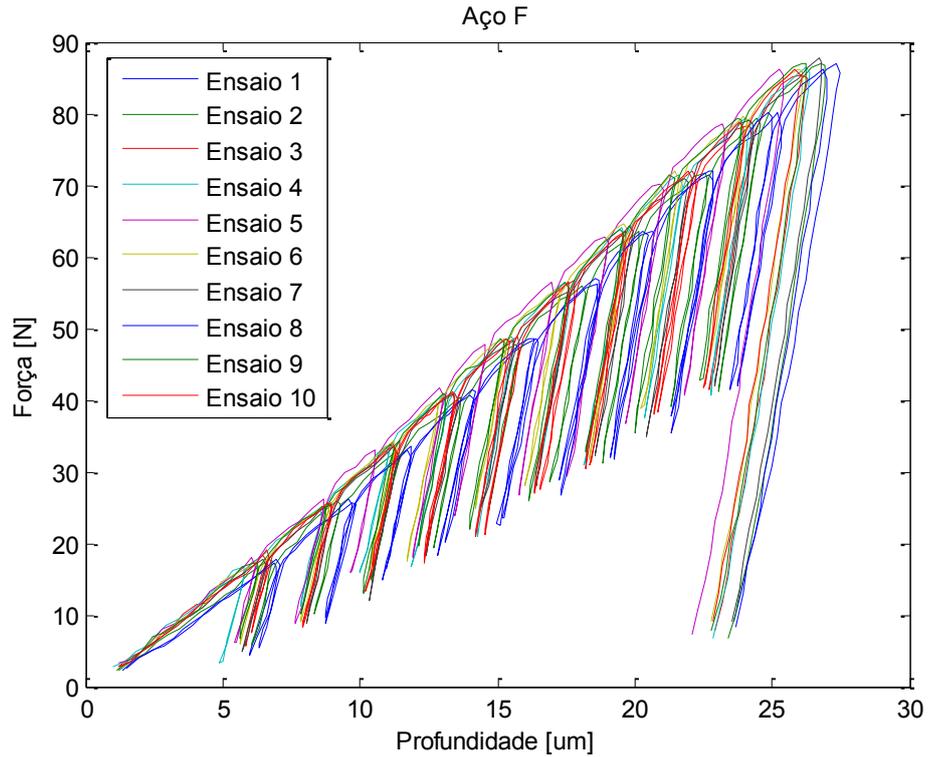


Figura A1.36 - Ensaio de macroindentação instrumentada do Aço “F”, realizado no *PropInSitu 2*, com uma força máxima de 85 N e penetrador esferocônico de diâmetro igual a 0,4 mm (NICOLSI, 2015)

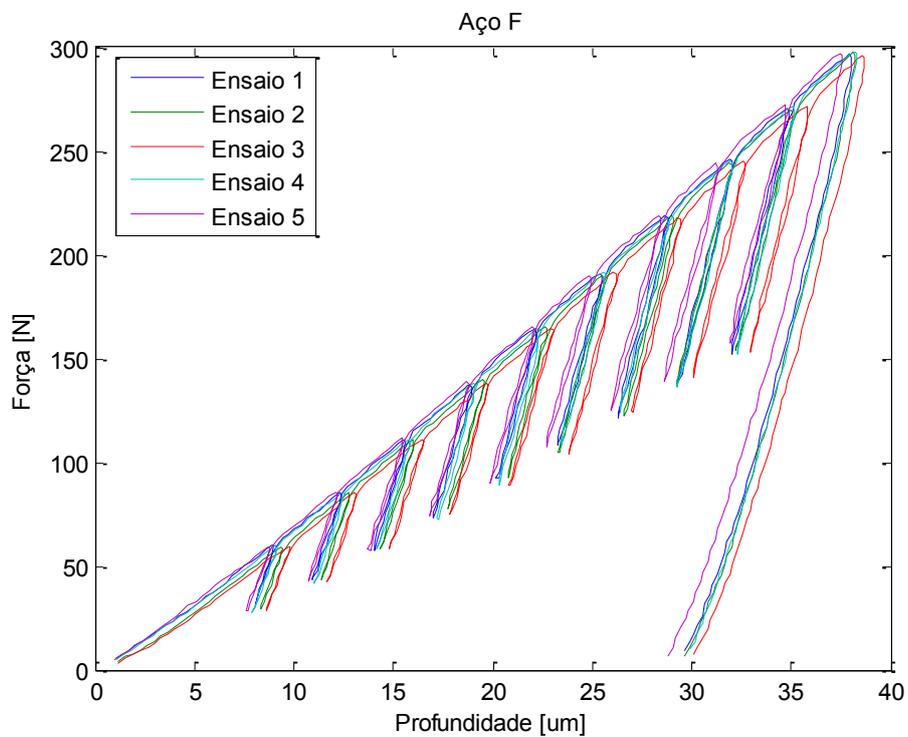


Figura A1.37 - Ensaio de macroindentação instrumentada do Aço “F”, realizado no *PropInSitu 2*, com uma força máxima de 294 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

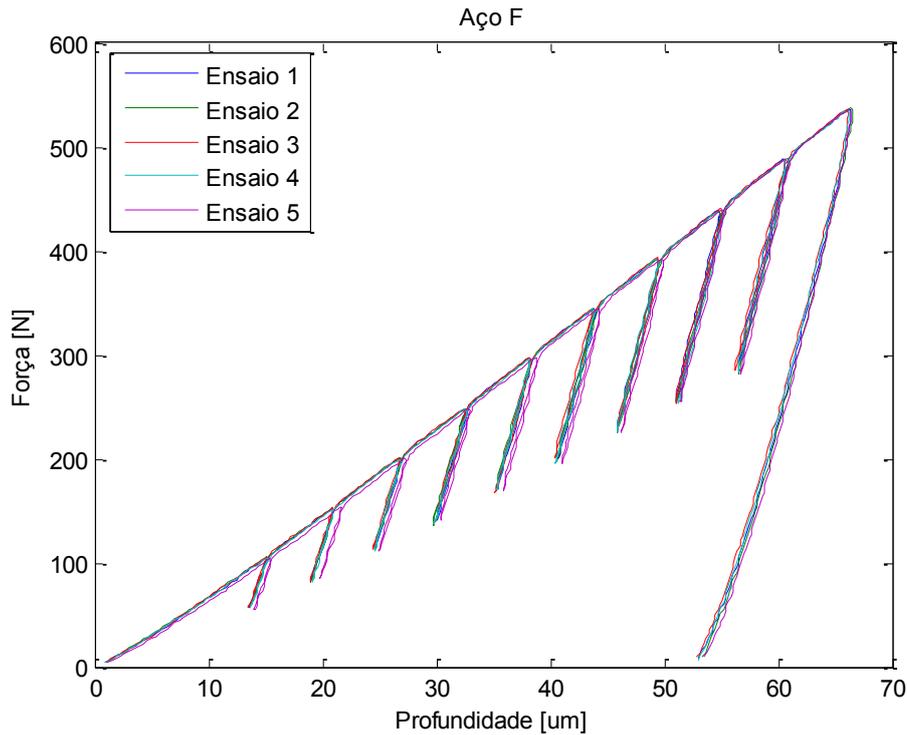


Figura A1.38 - Ensaio de macroindentação instrumentada do Aço "F", realizado no *PropInSitu 2*, com uma força máxima de 533 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

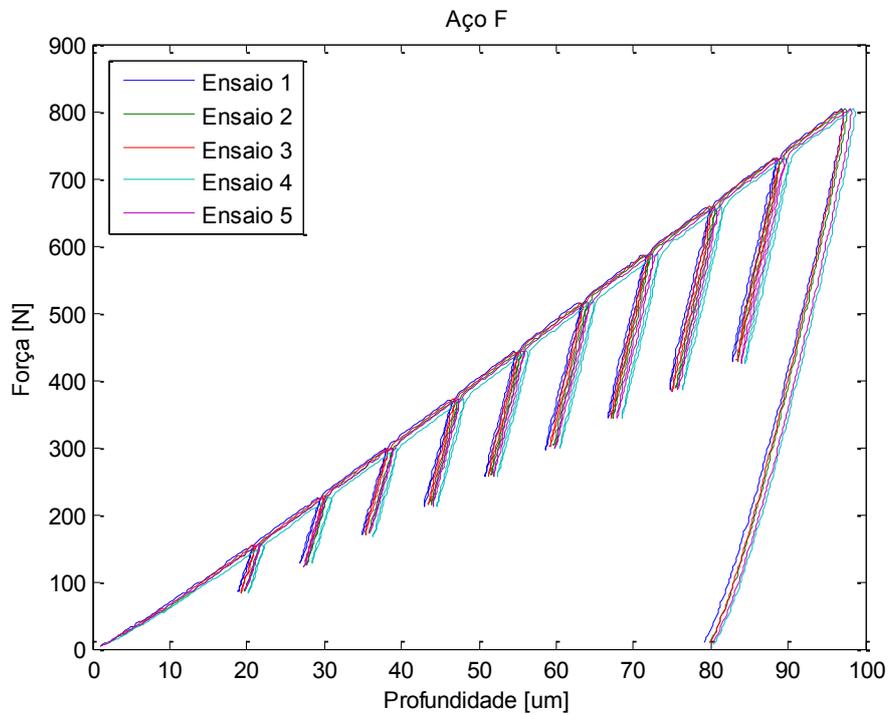


Figura A1.39 - Ensaio de macroindentação instrumentada do Aço "F", realizado no *PropInSitu 2*, com uma força máxima de 800 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

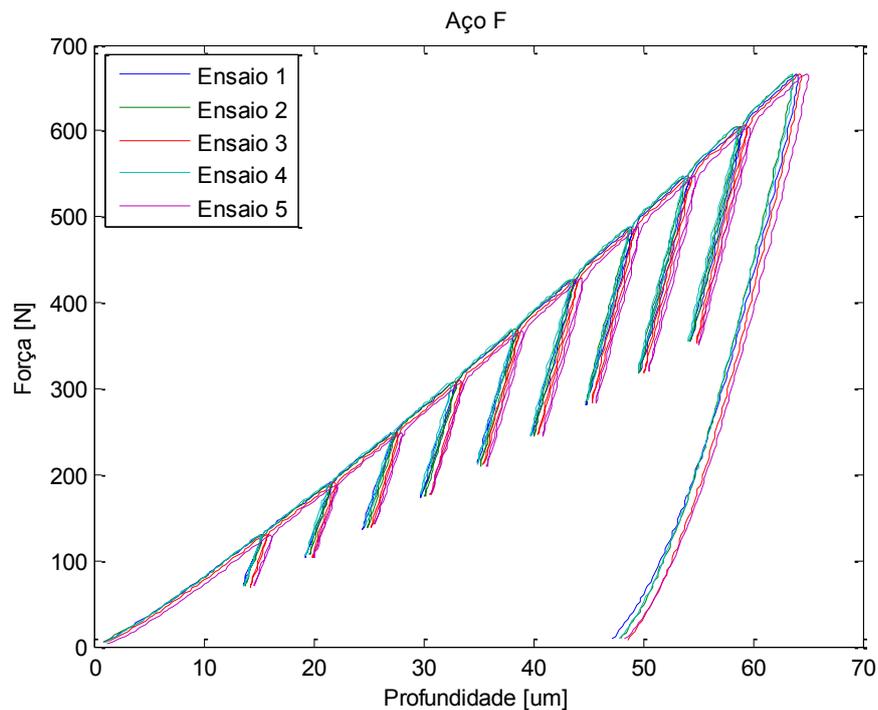


Figura AI.40 - Ensaio de macroindentação instrumentada do Aço "F", realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

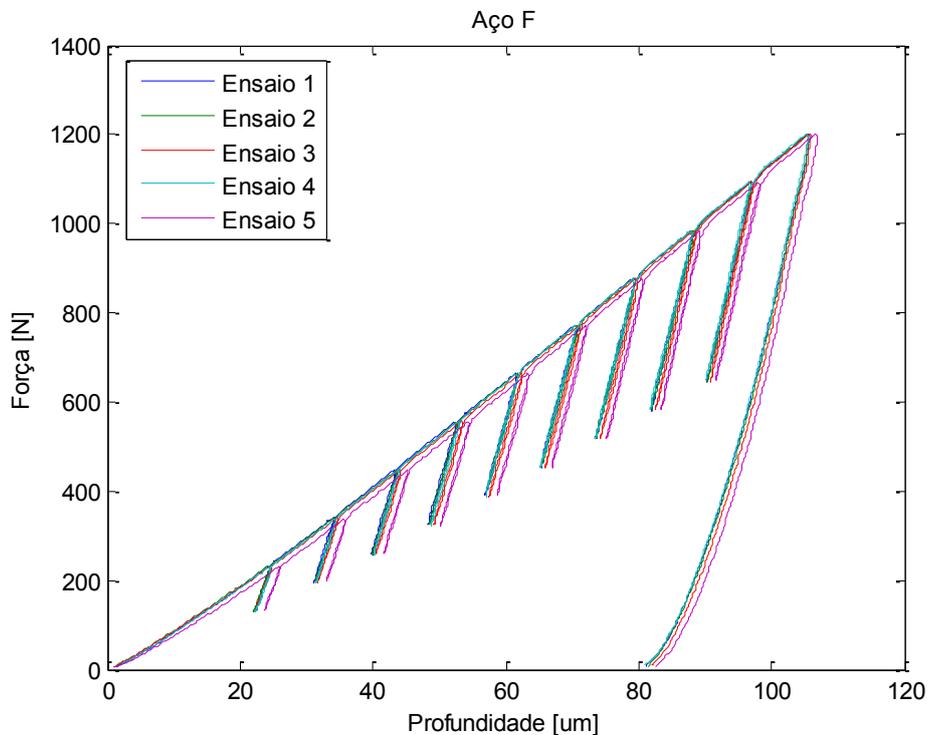


Figura AI.41 - Ensaio de macroindentação instrumentada do Aço "F", realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

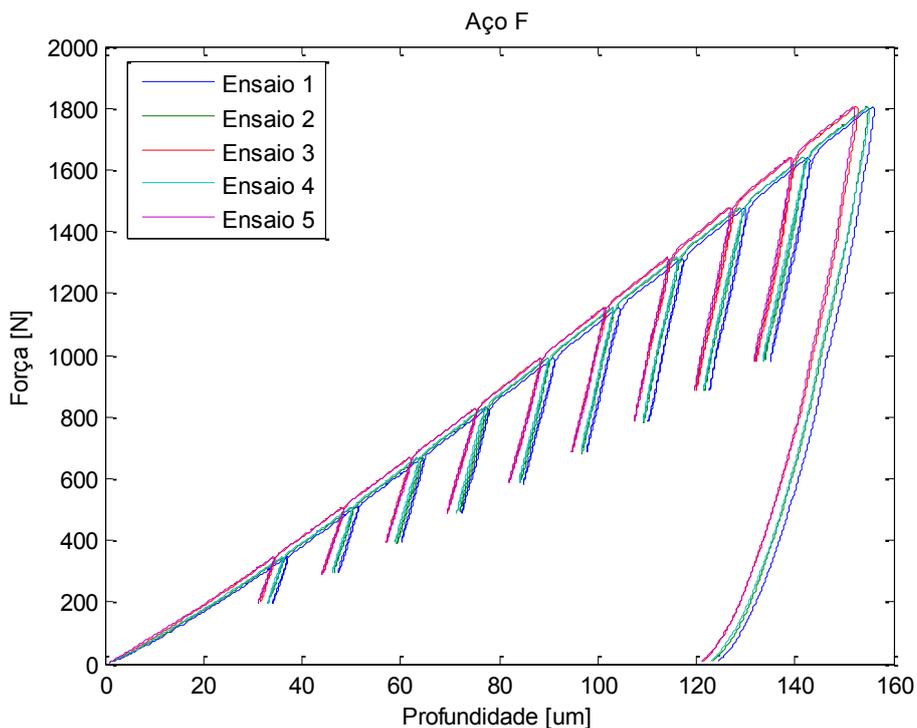


Figura Al.42 - Ensaio de macroindentação instrumentada do Aço “F”, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

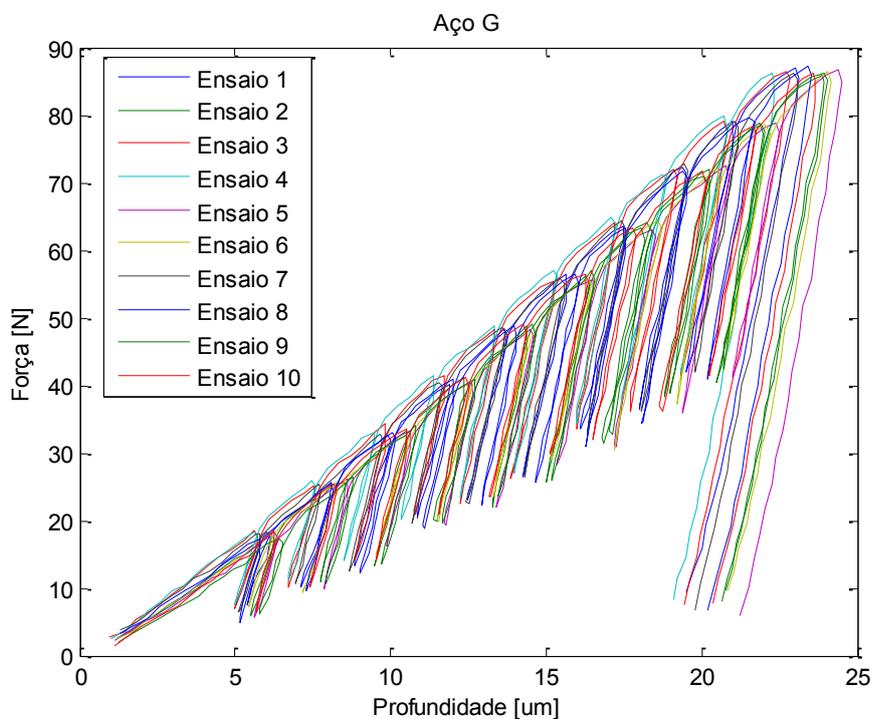


Figura Al.43 - Ensaio de macroindentação instrumentada do Aço “G”, realizado no *PropInSitu 2*, com uma força máxima de 85 N e penetrador esferocônico de diâmetro igual a 0,4 mm (NICOLSI, 2015)

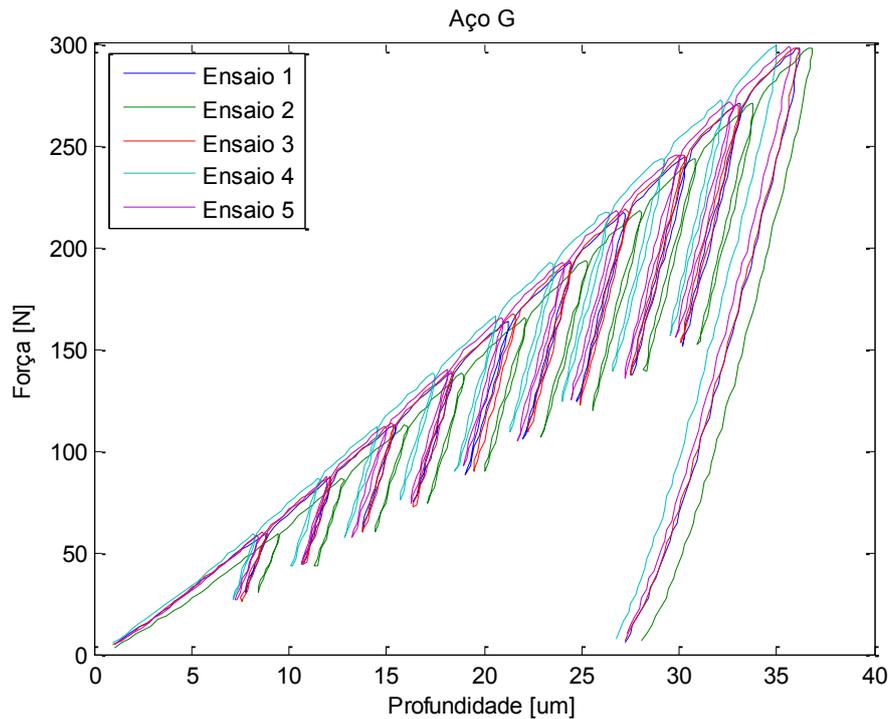


Figura Al.44 - Ensaio de macroindentação instrumentada do Aço “G”, realizado no *PropInSitu 2*, com uma força máxima de 294 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

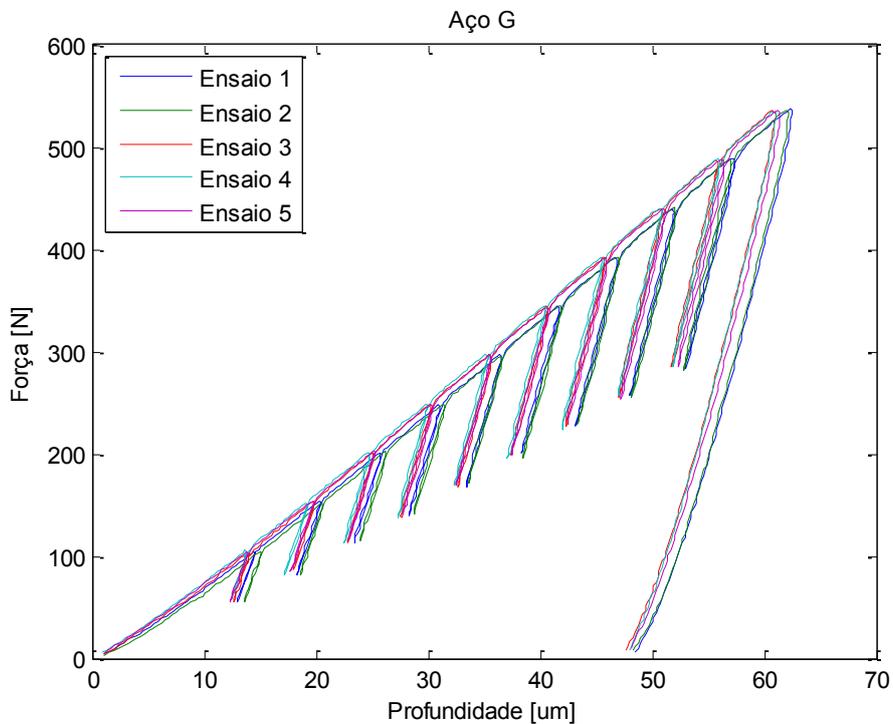


Figura Al.45 - Ensaio de macroindentação instrumentada do Aço “G”, realizado no *PropInSitu 2*, com uma força máxima de 533 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

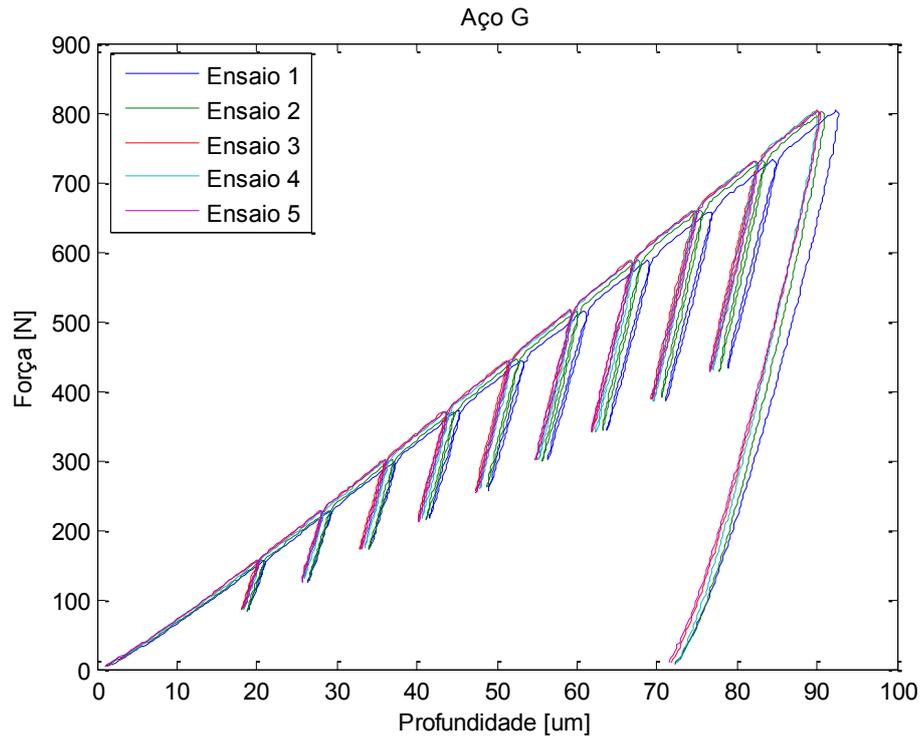


Figura A1.46 - Ensaio de macroindentação instrumentada do Aço “G”, realizado no *PropInSitu 2*, com uma força máxima de 800 N e penetrador esférico de diâmetro igual a 1,0 mm (NICOLSI, 2015)

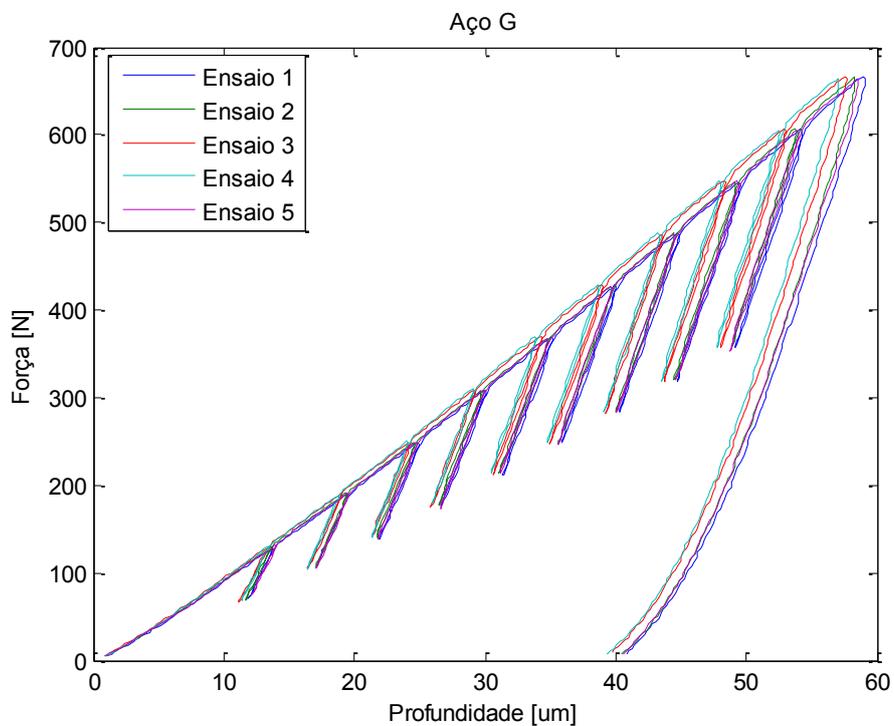


Figura A1.47 - Ensaio de macroindentação instrumentada do Aço “G”, realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

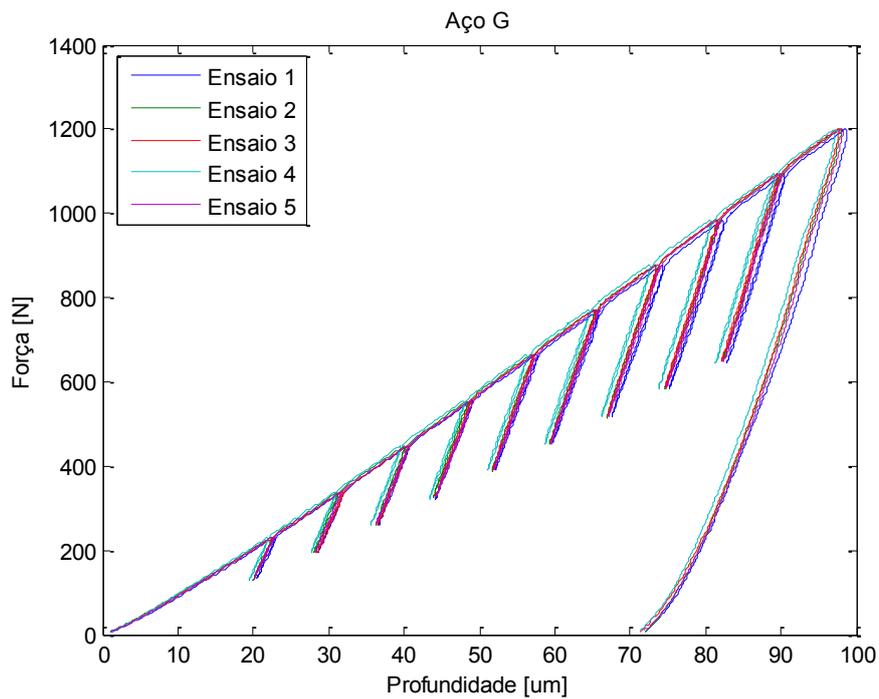


Figura Al.48 - Ensaio de macroindentação instrumentada do Aço “G”, realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

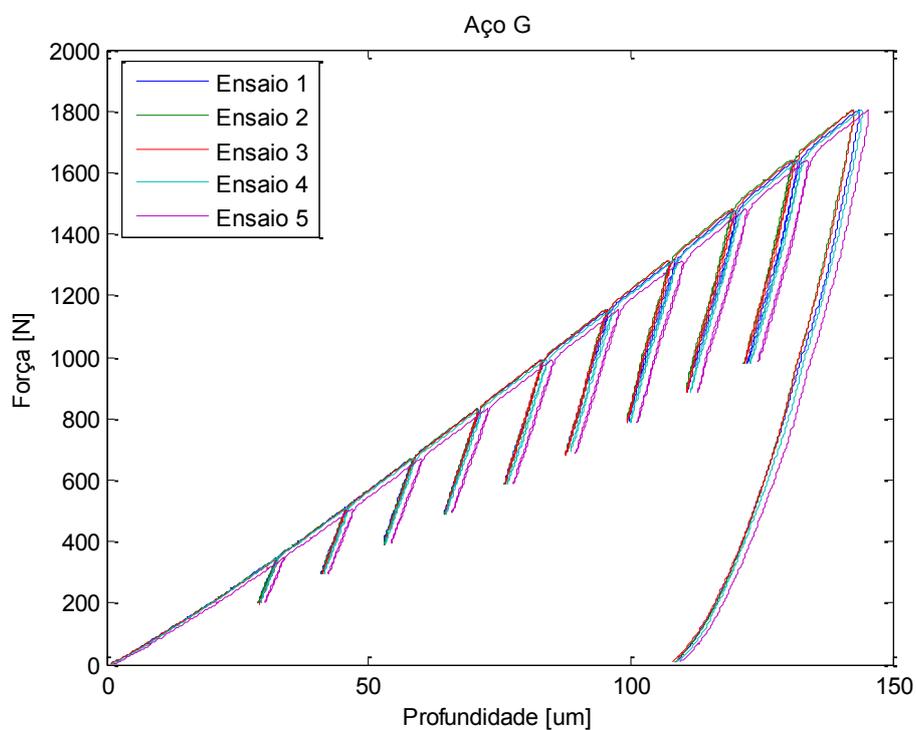


Figura Al.49 - Ensaio de macroindentação instrumentada do Aço “G”, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

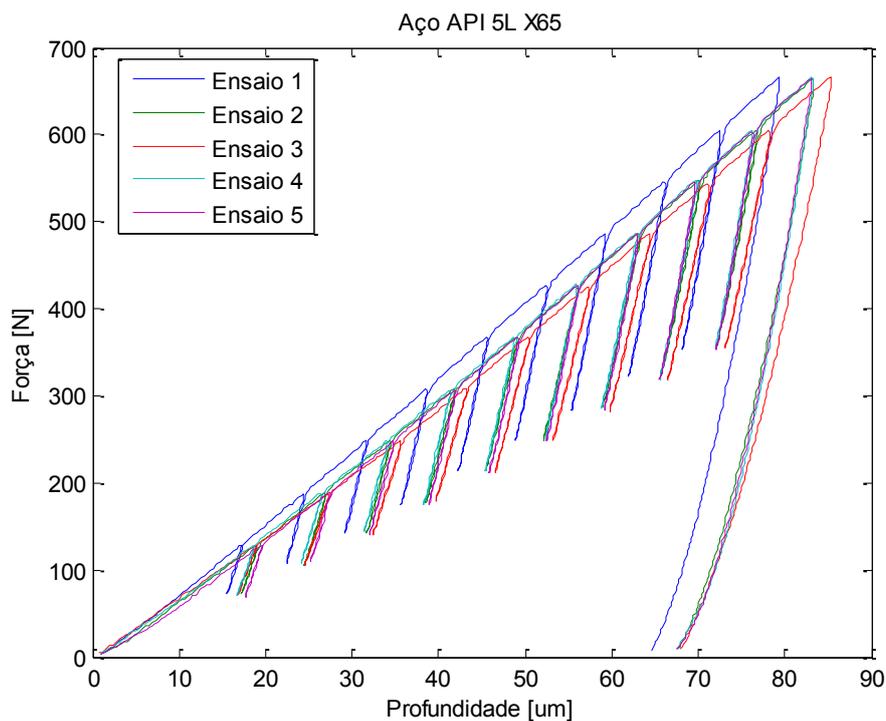


Figura AI.50 - Ensaio de macroindentação instrumentada do CP1 do Aço API 5L X65, realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

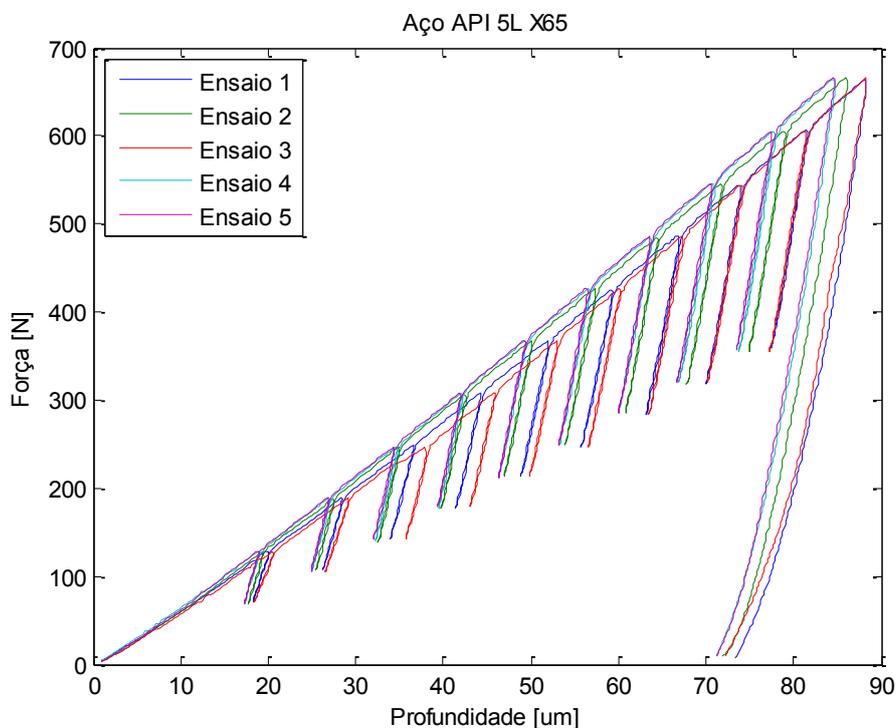


Figura AI.51 - Ensaio de macroindentação instrumentada do CP2 do Aço API 5L X65, realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

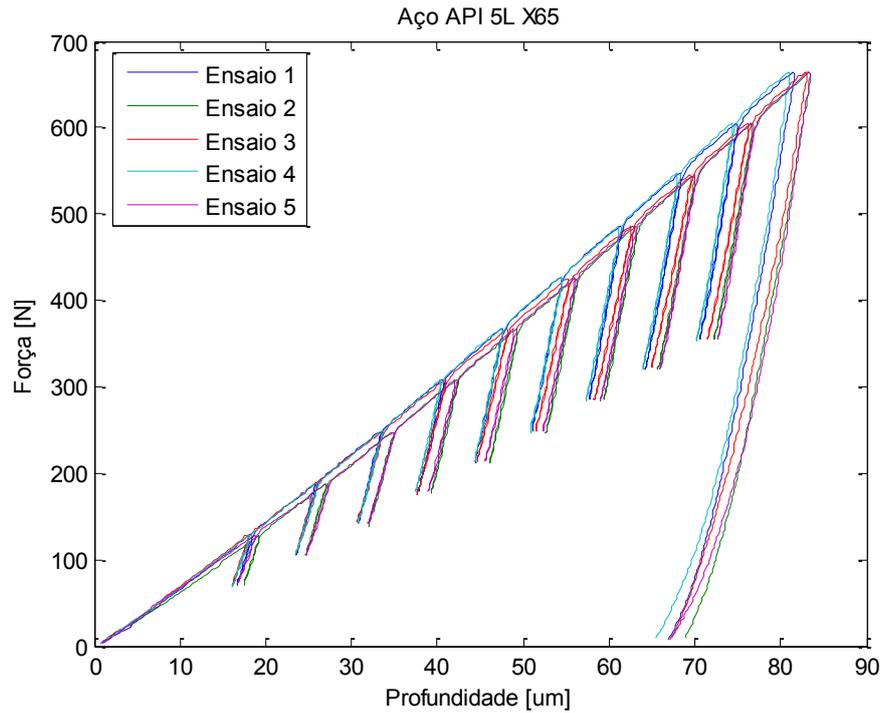


Figura AI.52 - Ensaio de macroindentação instrumentada do CP3 do Aço API 5L X65, realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

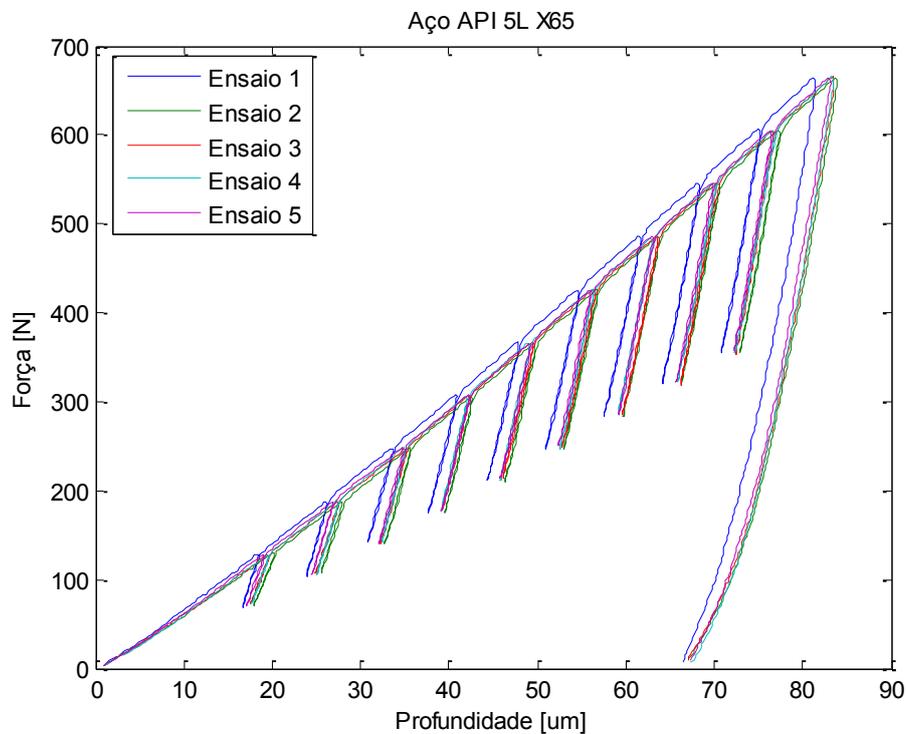


Figura AI.53 - Ensaio de macroindentação instrumentada do CP4 do Aço API 5L X65, realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

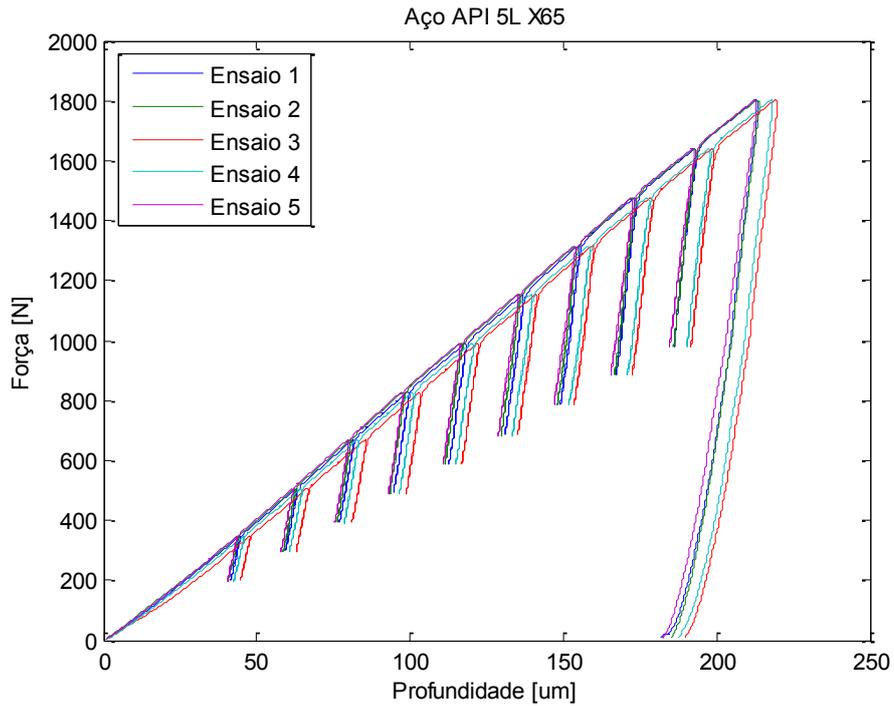


Figura AI.54 - Ensaio de macroindentação instrumentada do CP1 do Aço API 5L X65, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

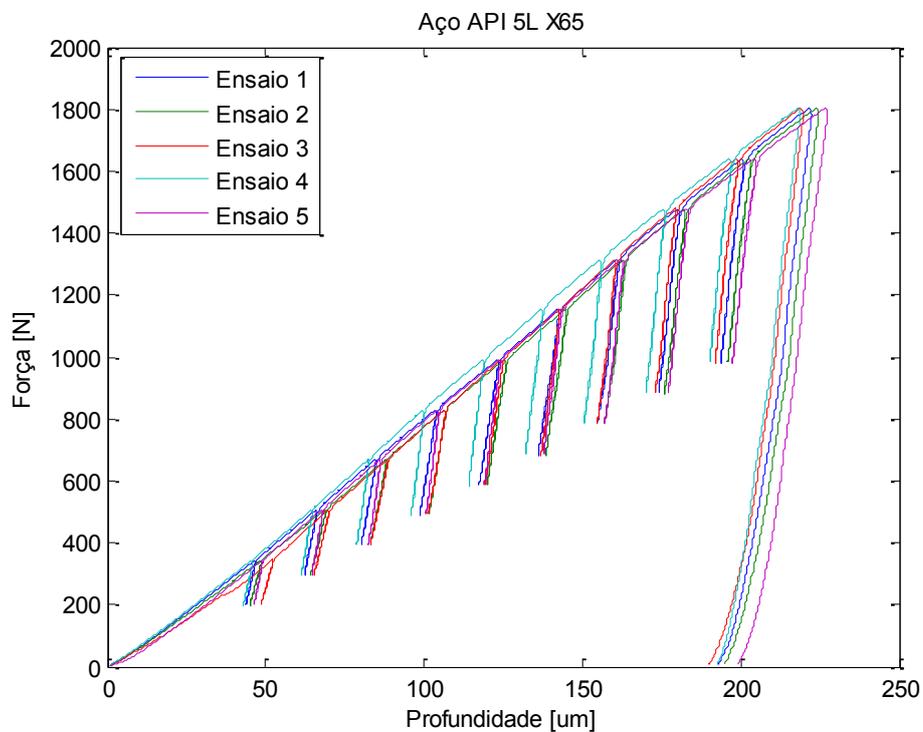


Figura AI.55 - Ensaio de macroindentação instrumentada do CP2 do Aço API 5L X65, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

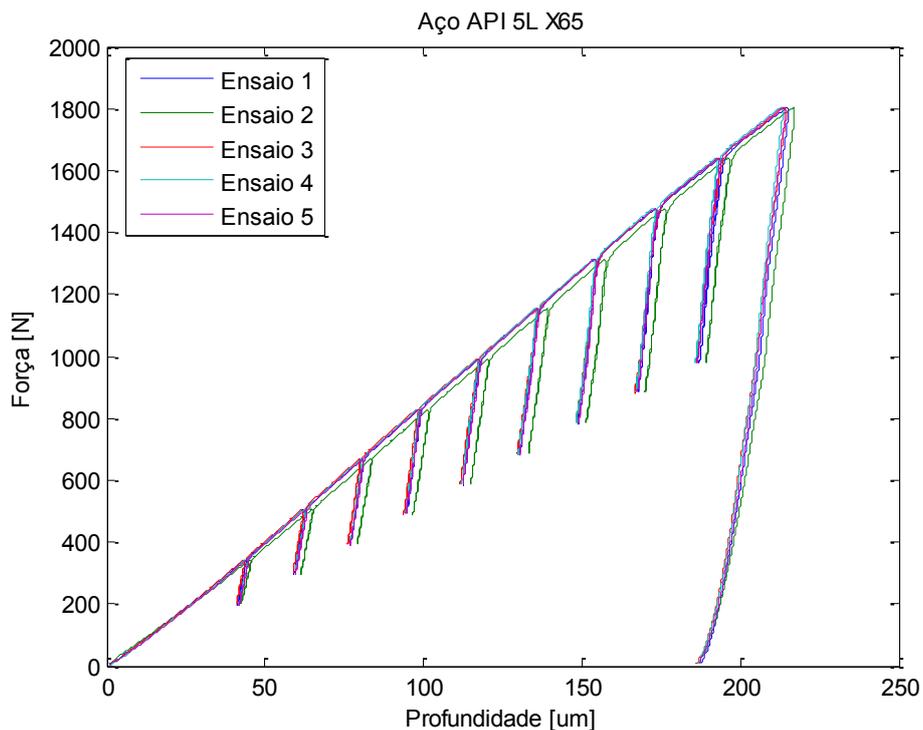


Figura AI.56 - Ensaio de macroindentação instrumentada do CP3 do Aço API 5L X65, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

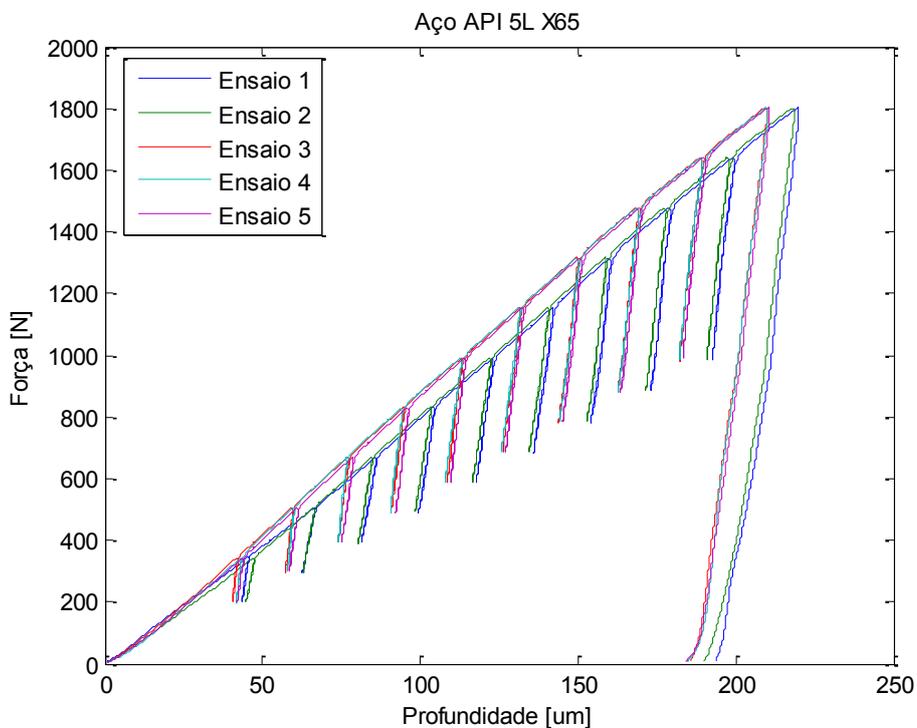


Figura AI.57 - Ensaio de macroindentação instrumentada do CP4 do Aço API 5L X65, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

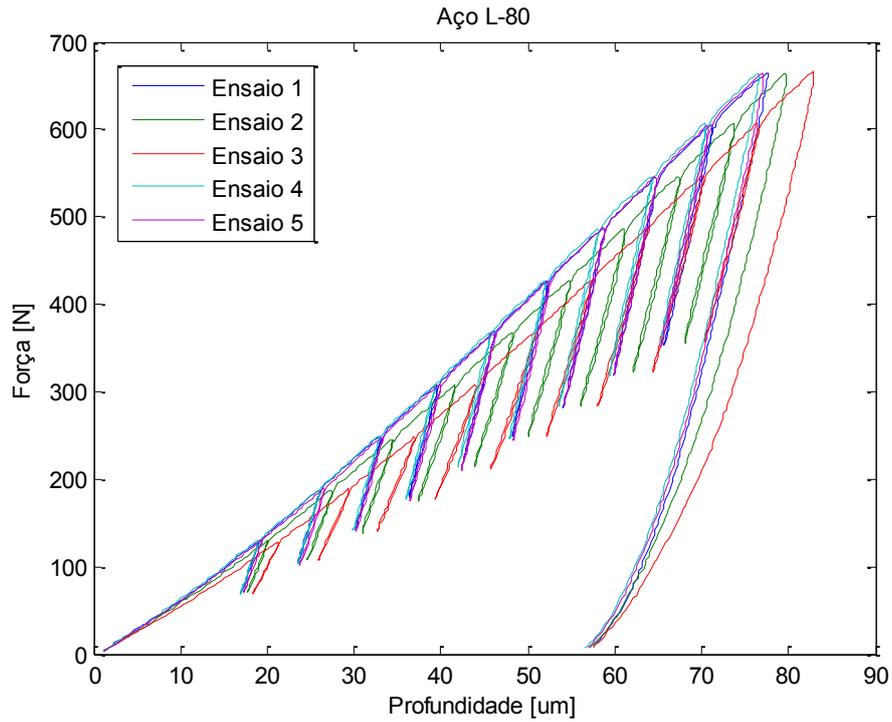


Figura AI. 58 - Ensaio de macroindentação instrumentada do CP1 do Aço L-80, realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

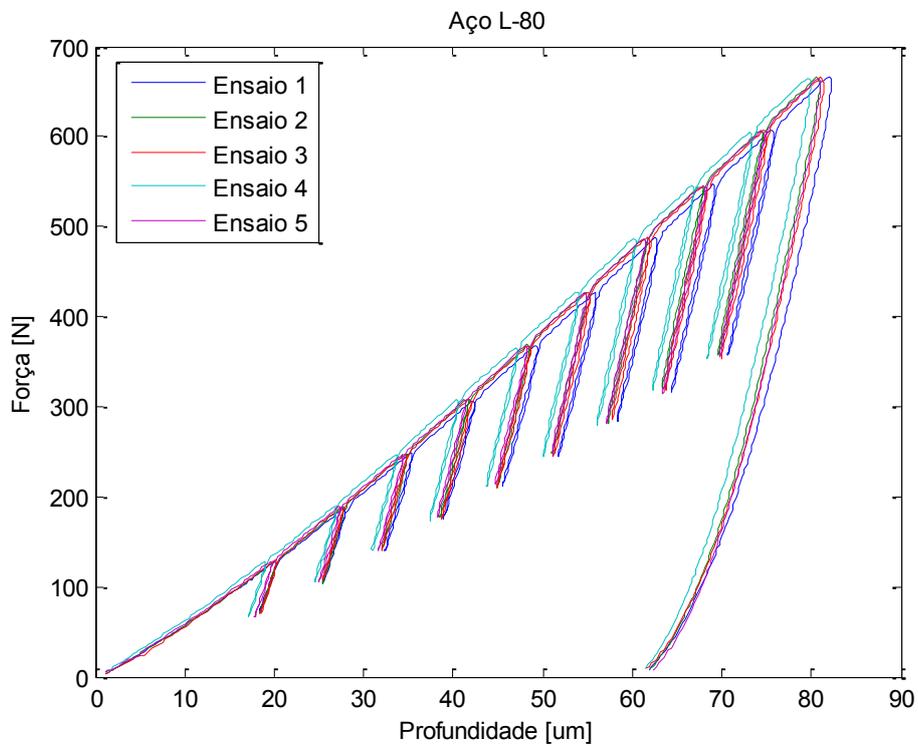


Figura AI.59 - Ensaio de macroindentação instrumentada do CP2 do Aço L-80, realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

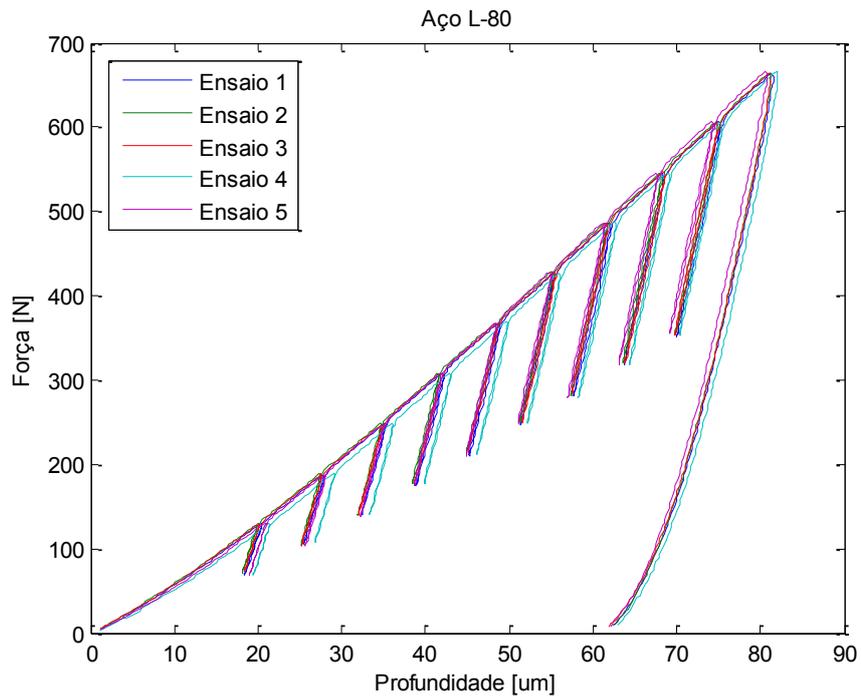


Figura AI.60 - Ensaio de macroindentação instrumentada do CP3 do Aço L-80, realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

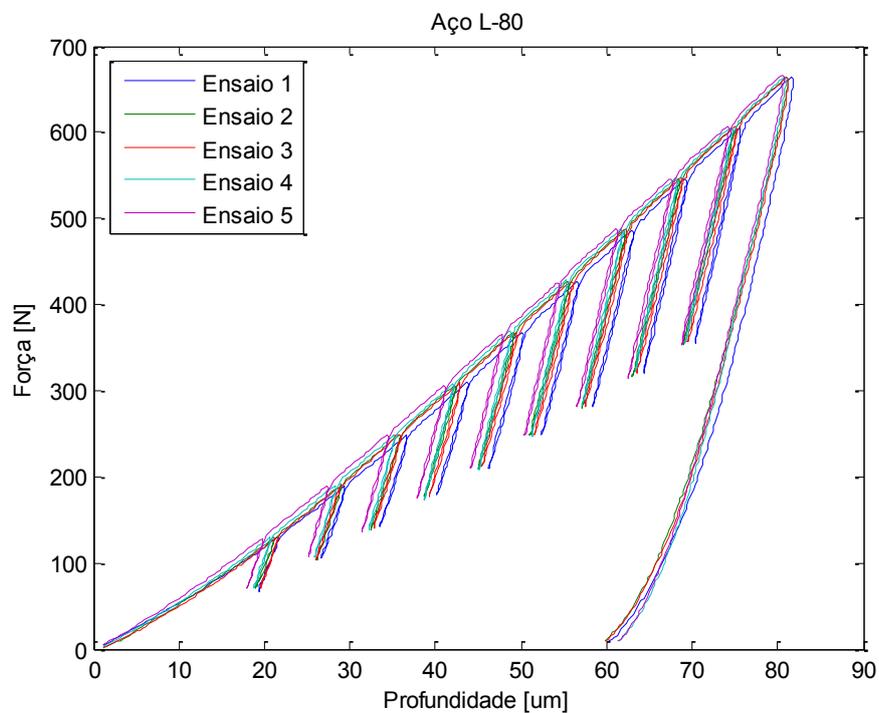


Figura AI.61 - Ensaio de macroindentação instrumentada do CP4 do Aço L-80, realizado no *PropInSitu 2*, com uma força máxima de 662 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLSI, 2015)

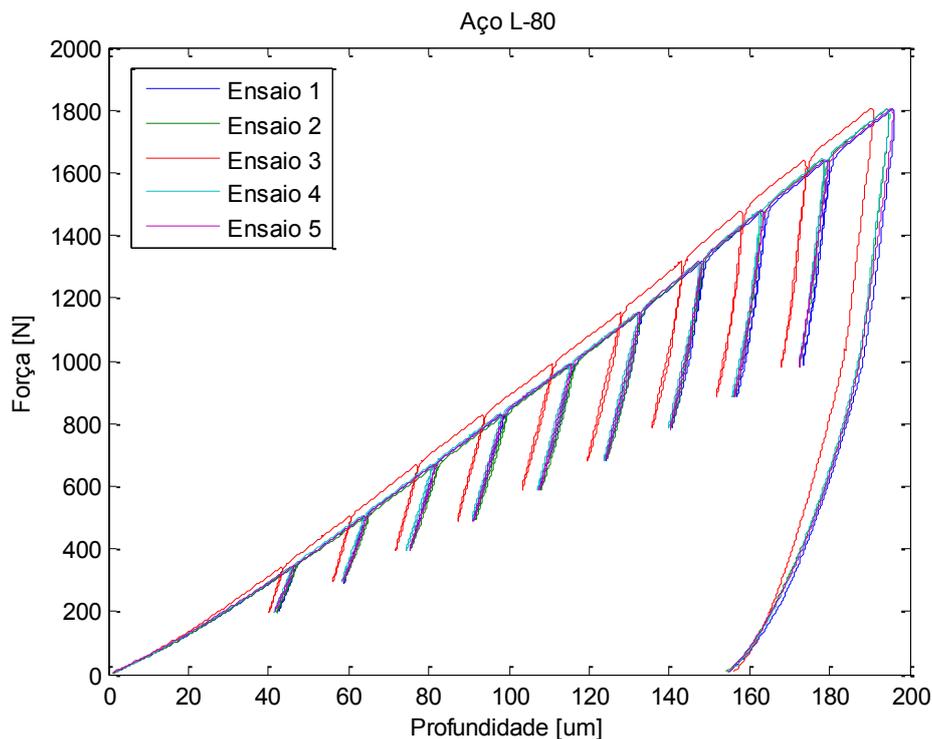


Figura AI.62 - Ensaio de macroindentação instrumentada do CP1 do Aço L-80, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

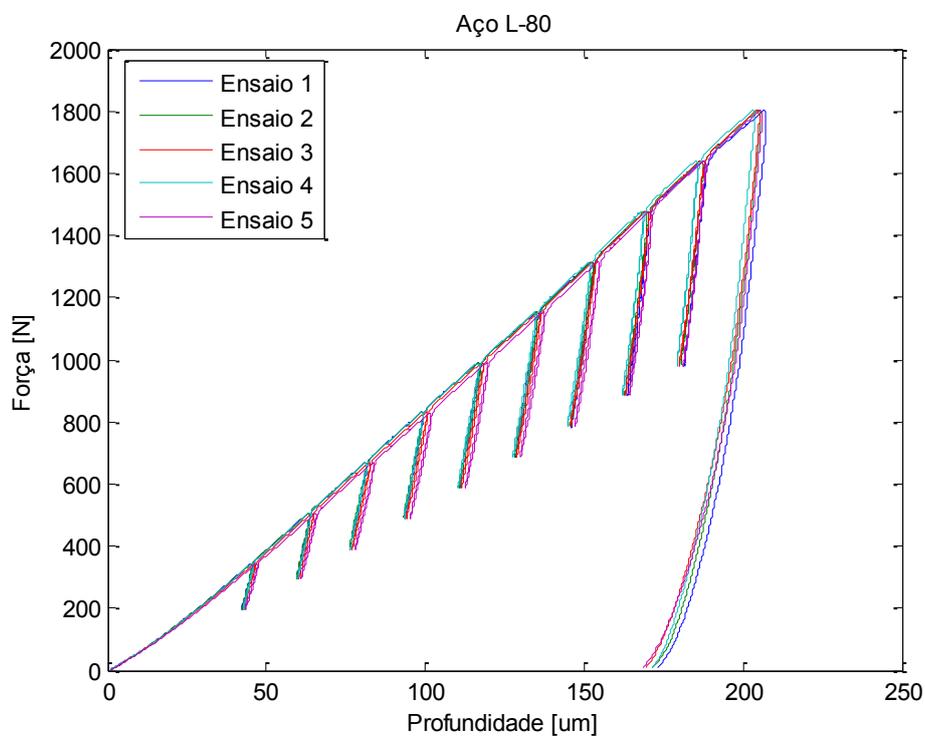


Figura AI.63 - Ensaio de macroindentação instrumentada do CP2 do Aço L-80, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

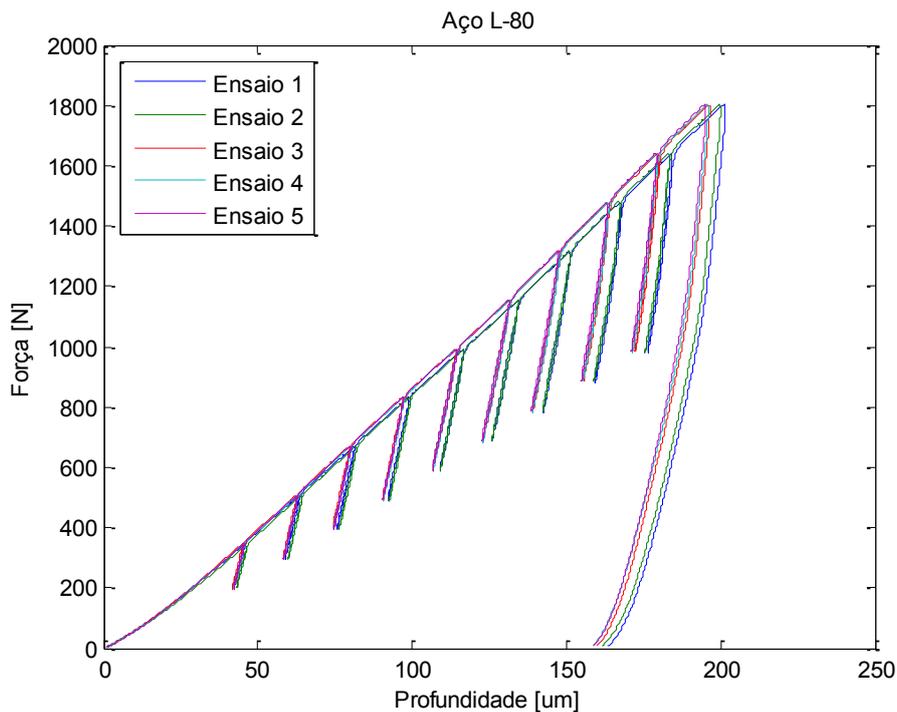


Figura AI.64 - Ensaio de macroindentação instrumentada do CP3 do Aço L-80, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

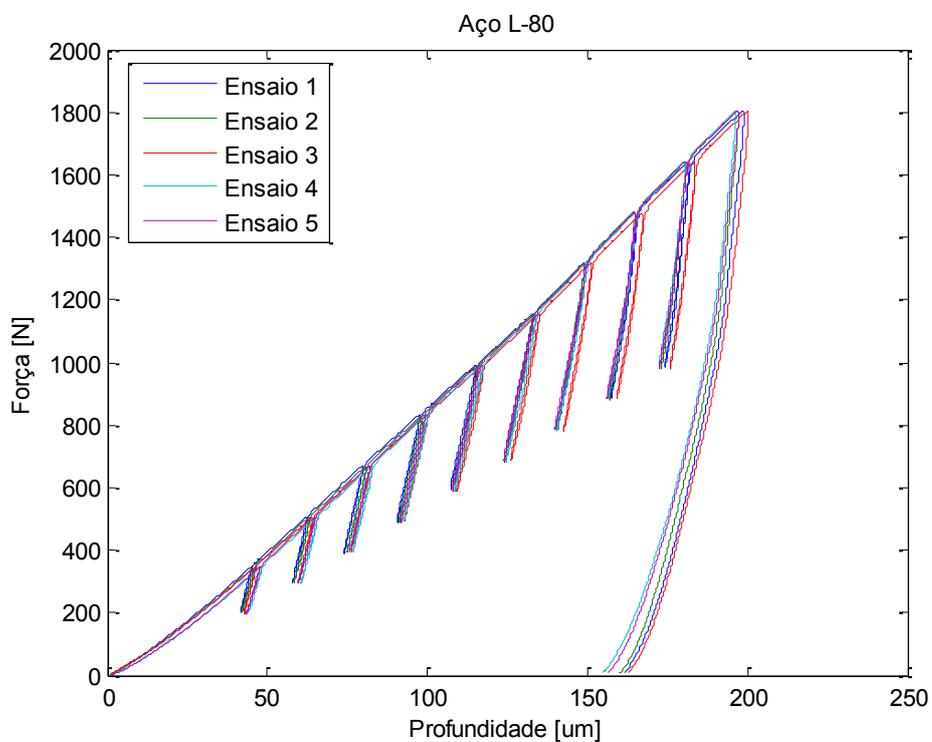


Figura AI.65 - Ensaio de macroindentação instrumentada do CP4 do Aço L-80, realizado no *PropInSitu 2*, com uma força máxima de 1800 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

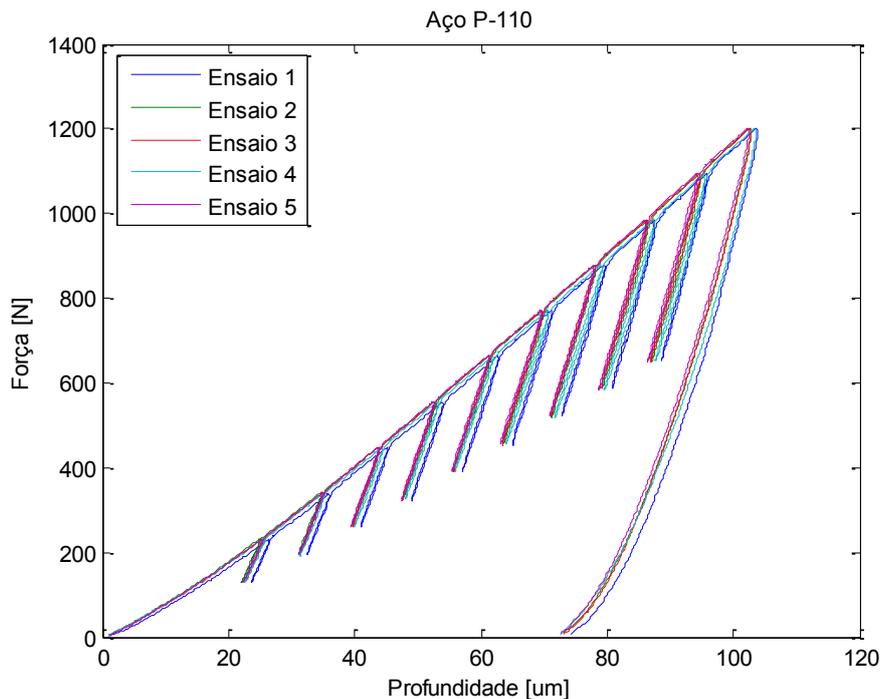


Figura Al.66 - Ensaio de macroindentação instrumentada do CP1 do Aço P-110, realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

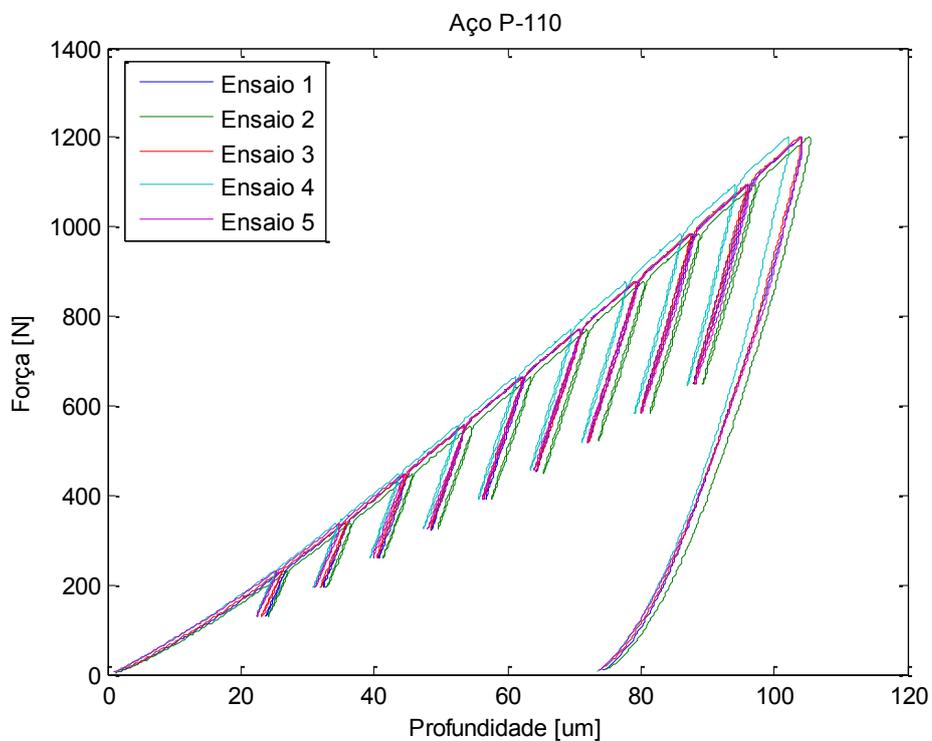


Figura Al.67 - Ensaio de macroindentação instrumentada do CP2 do Aço P-110, realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

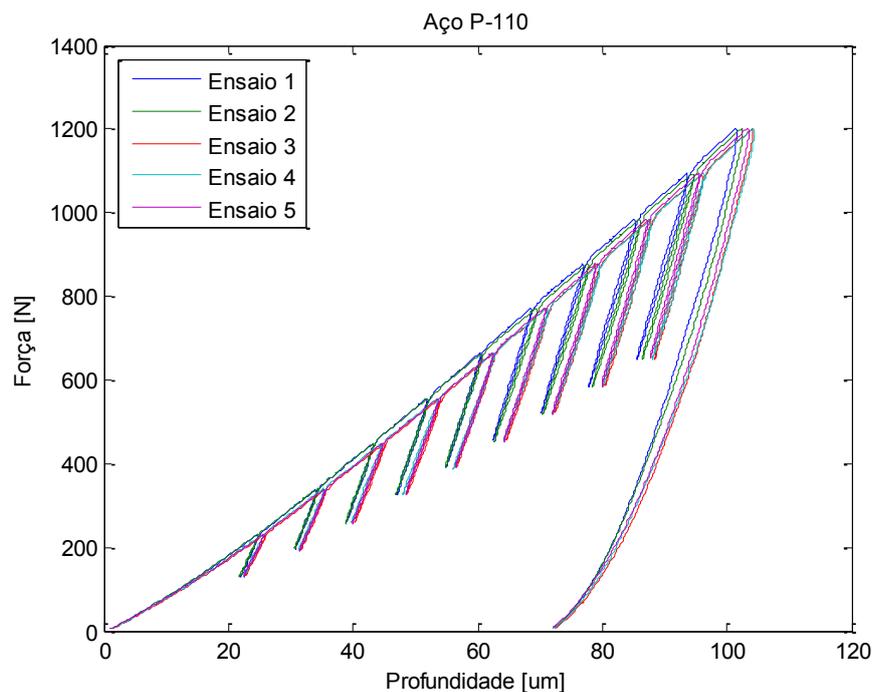


Figura Al.68 - Ensaio de macroindentação instrumentada do CP3 do Aço P-110, realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

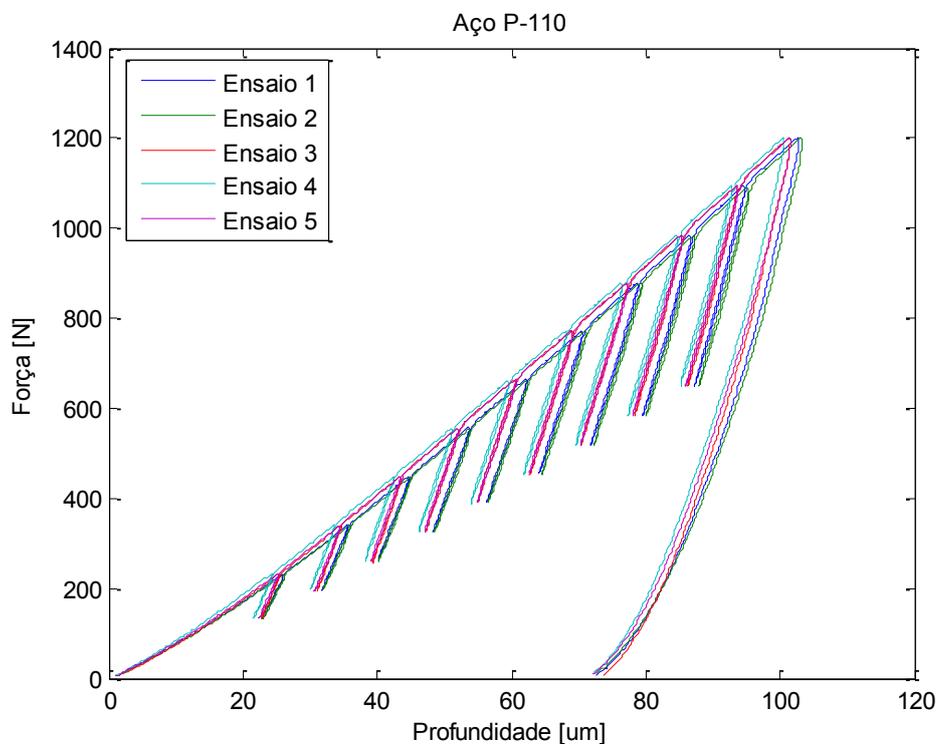


Figura Al.69 - Ensaio de macroindentação instrumentada do CP4 do Aço P-110, realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

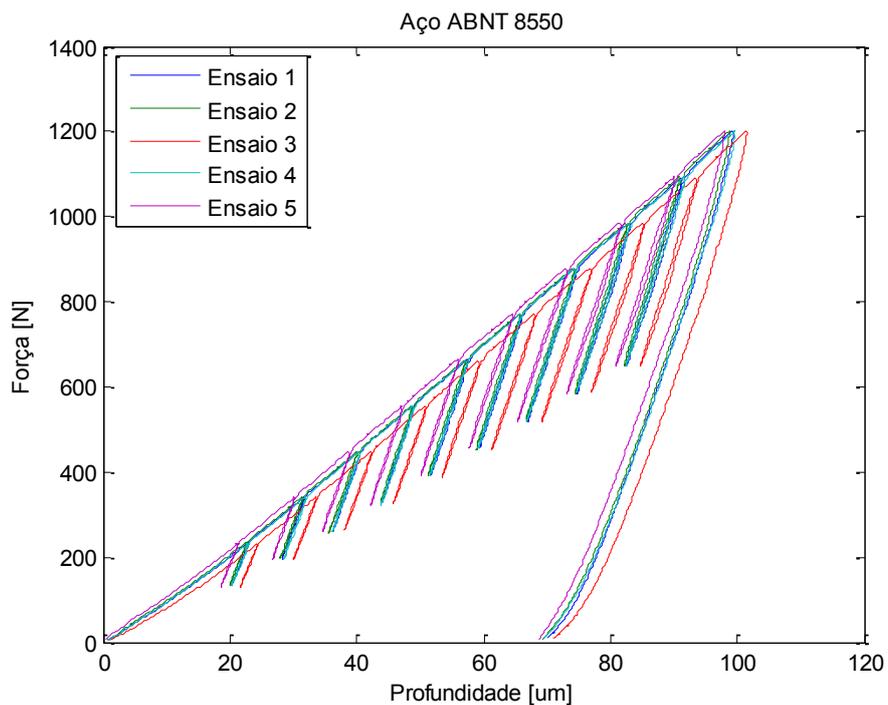


Figura AI.70 - Ensaio de macroindentação instrumentada do CP1 do Aço ABNT 8550, realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

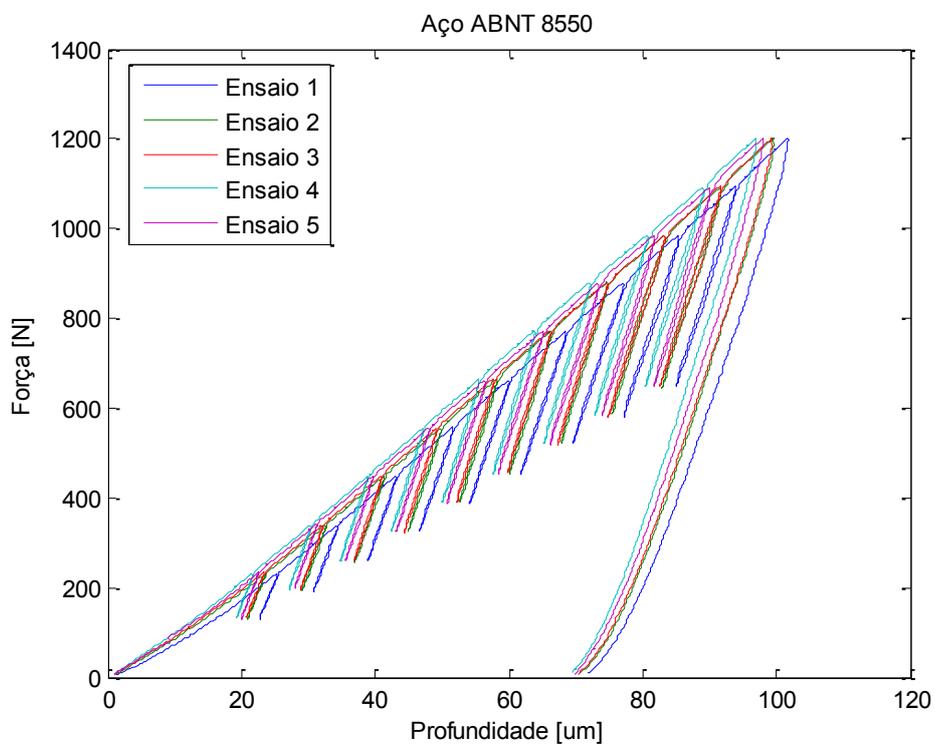


Figura AI.71 - Ensaio de macroindentação instrumentada do CP2 do Aço ABNT 8550, realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

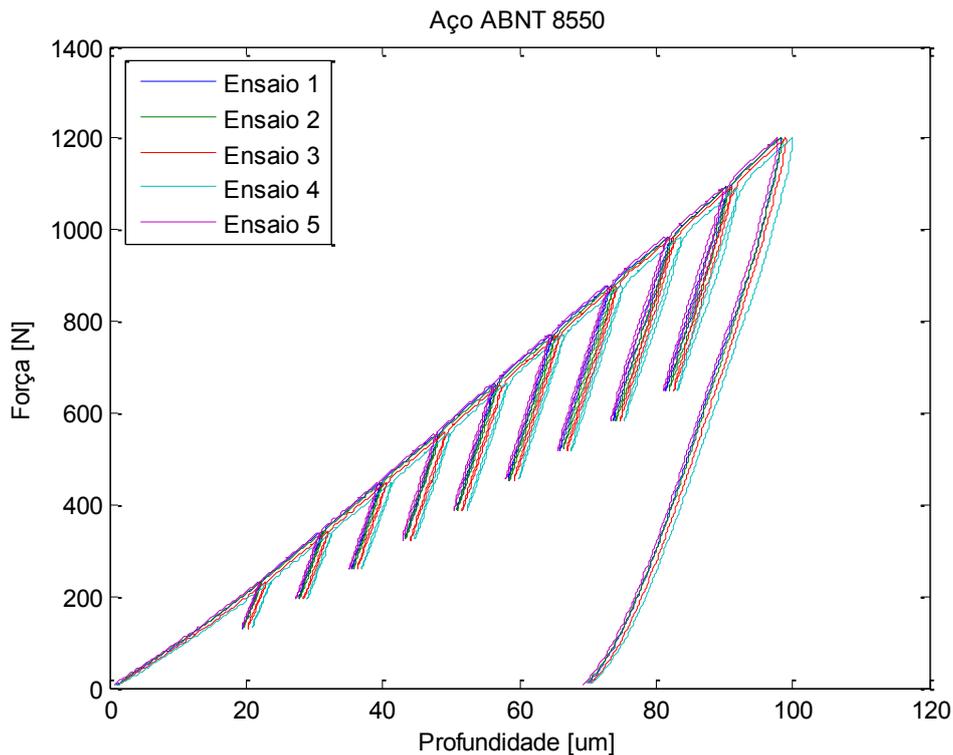


Figura AI.72 - Ensaio de macroindentação instrumentada do CP3 do Aço ABNT 8550, realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

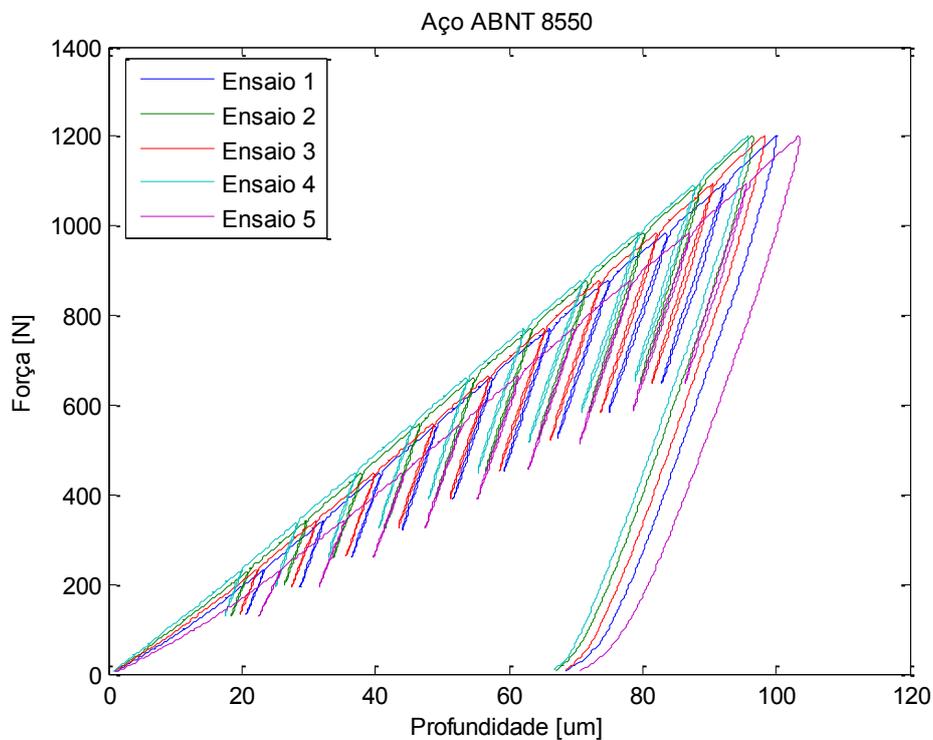


Figura AI.73 - Ensaio de macroindentação instrumentada do CP4 do Aço ABNT 8550, realizado no *PropInSitu 2*, com uma força máxima de 1200 N e penetrador esférico de diâmetro igual a 1,5 mm (NICOLOSI, 2015)

ANEXO II

As dimensões das amostras dos aços de “A” a “G”, utilizadas nos ensaios de macroindentação instrumentada, estão representadas na Fig. All.1.

As dimensões dos corpos de prova do aço ABNT 8550, utilizados nos ensaios de tração, estão evidenciadas na Fig. All.2. Já a região na qual foram realizados os ensaios de macroindentação instrumentada nesse aço é vista na Fig. All.3.

Por sua vez, as dimensões dos corpos de prova dos aços API 5L X65, L80 e P110, empregados nos ensaios de tração, são mostradas na Fig. All.4. Já a região na qual foram realizados os ensaios de macroindentação instrumentada nesses aços é evidenciada na Fig. All.5.

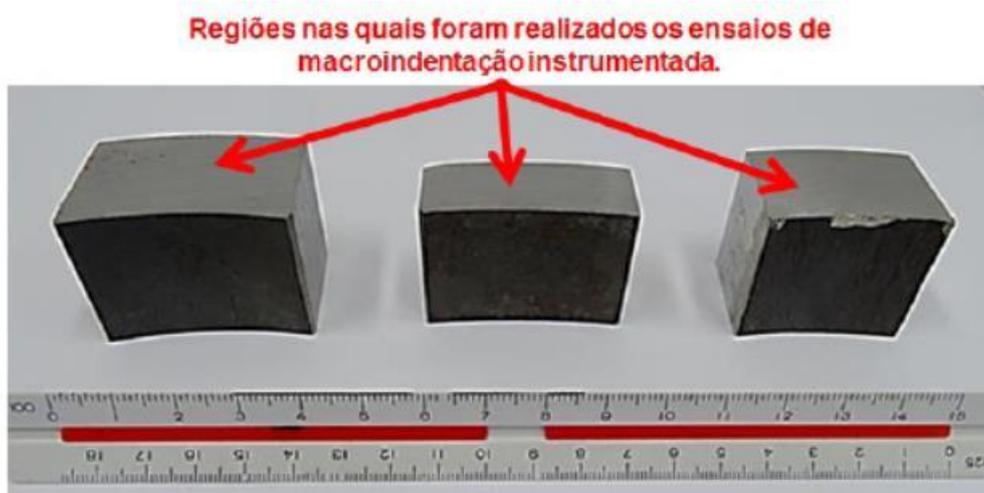


Figura All.1 – Dimensões das amostras dos aços de “A” a “G”, fornecidas pelo fabricante dos tubos e utilizadas nos ensaios de macroindentação (NICOLSI, 2015)

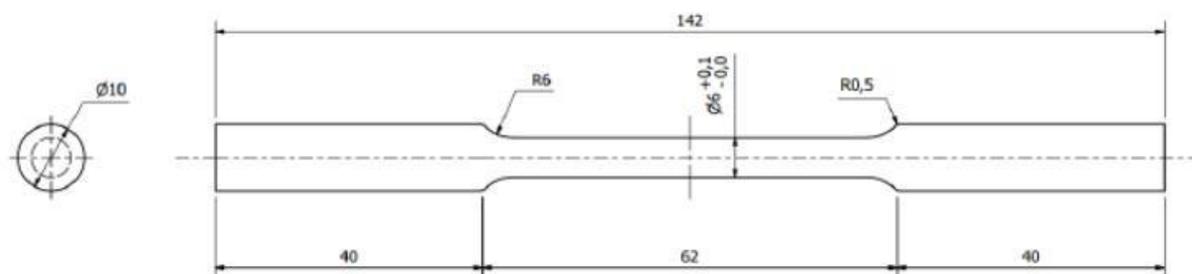


Figura All.2 – Dimensões dos corpos de prova de seção circular removidos das barras dos lotes 2 a 5 e usados nos ensaios de tração do aço ABNT 8550 (NICOLSI, 2015)

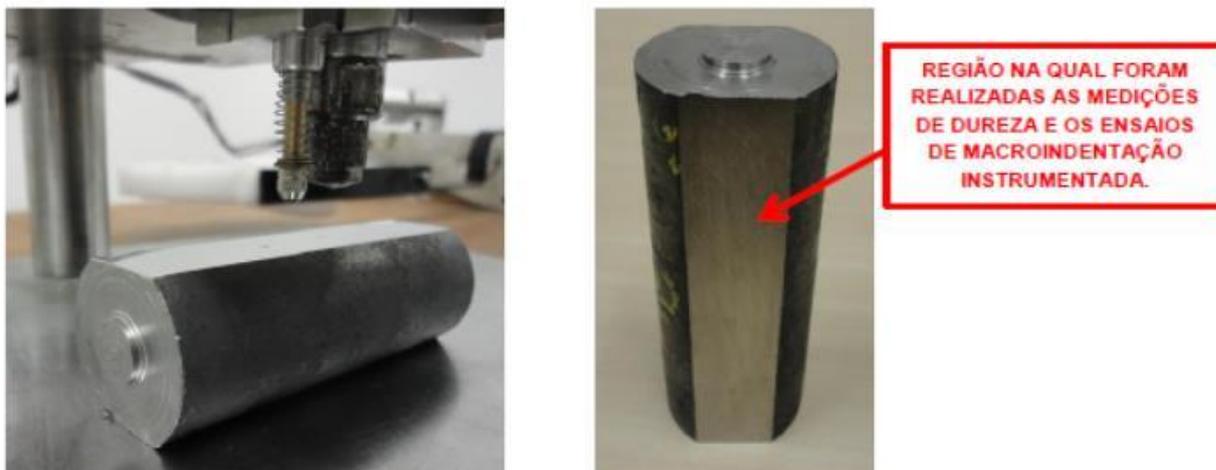


Figura All.3 – Ensaio de macroindentação instrumentada nos trechos removidos das barras dos lotes 2 a 5 do aço ABNT 8550 (foto da esquerda). Trecho usinado por fresamento (foto da direita), com remoção de 4 mm de material de ambos os lados (NICOLSI, 2015)



Figura All.4 – Dimensões dos corpos de prova de seção retangular usados nos ensaios de tração dos aços API 5L X65, L80 e P110 (NICOLSI, 2015)

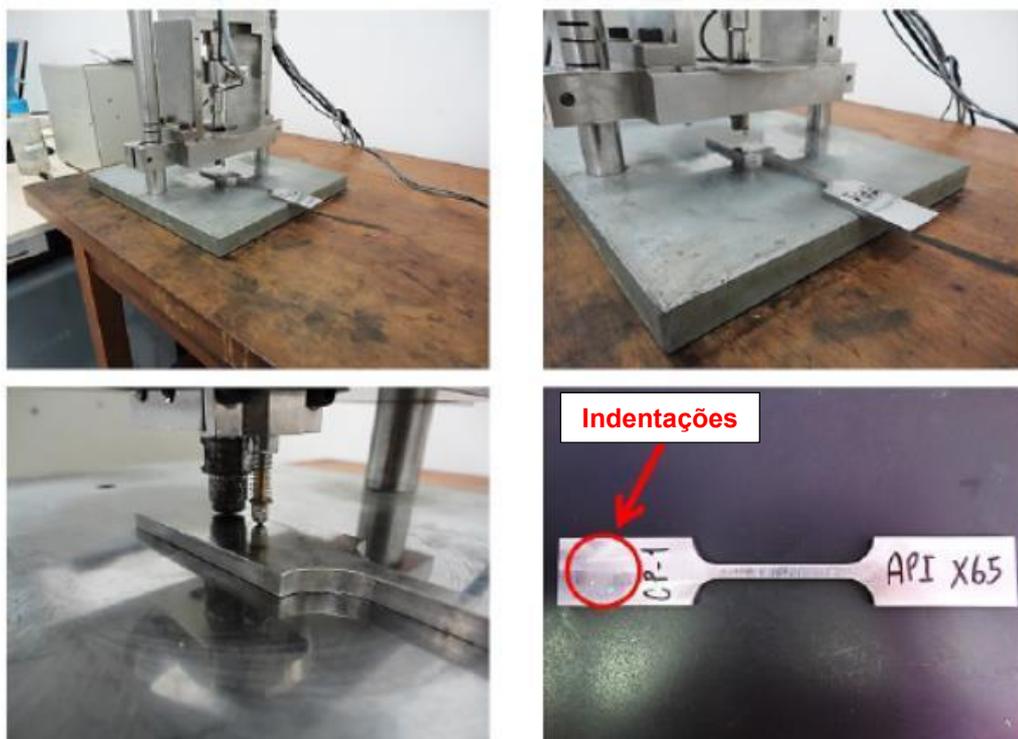


Figura AII.5 – Realização dos ensaios de macroindentação instrumentada nos corpos de prova de tração dos aços API 5L X65, L80 e P110 (NICOLSI, 2015)

APÊNDICE I

Na Tabela Al.1 estão expressos todos os valores das variáveis de entrada das RNAEs, antes da normalização, obtidas considerando os ensaios dos subconjuntos de treinamento e validação. Também são mostrados os limites máximo e mínimo de cada uma delas, os quais foram utilizados, posteriormente, para normalizá-las. Cada entrada foi abreviada pela sigla E.

Já os valores das variáveis de entrada, depois de serem normalizadas, estão representados na Tab. Al.2.

Tabela Al.1 – Valores das variáveis de entrada das RNAEs, antes da normalização

	E1 [Pa]	E2 [N/m]	E3 [N/m]	E4	E5 [Pa]	E6 [m]	E7	E8	E9
	4,46E+09	-9,43E+06	2,85E+07	-1,58E+01	1,14E+12	0,0004	0,4	0,9447	1
	4,44E+09	-8,28E+06	3,07E+07	-1,68E+01	1,14E+12	0,0004	0,4	0,9341	1
	4,34E+09	-8,71E+06	2,87E+07	-1,63E+01	1,14E+12	0,0004	0,4	0,9296	1
	4,48E+09	-9,19E+06	3,28E+07	-1,77E+01	1,14E+12	0,0004	0,4	0,9329	1
	4,48E+09	-8,69E+06	2,84E+07	-1,62E+01	1,14E+12	0,0004	0,4	0,9489	1
	4,54E+09	-8,61E+06	3,04E+07	-1,65E+01	1,14E+12	0,0004	0,4	0,9323	1
	4,49E+09	-9,42E+06	3,22E+07	-1,72E+01	1,14E+12	0,0004	0,4	0,9329	1
	4,43E+09	-7,97E+06	3,09E+07	-1,67E+01	1,14E+12	0,0004	0,4	0,9367	1
	4,39E+09	-8,48E+06	3,17E+07	-1,76E+01	1,14E+12	0,0004	0,4	0,9370	1
	4,41E+09	-8,78E+06	3,05E+07	-1,69E+01	1,14E+12	0,0004	0,4	0,9301	1
	4,27E+09	-5,60E+07	5,07E+07	-1,10E+01	6,45E+11	0,0010	0,4	0,8889	1
	4,48E+09	-4,91E+07	4,51E+07	-9,09E+00	6,45E+11	0,0010	0,4	0,8816	1
	4,34E+09	-5,30E+07	5,28E+07	-1,14E+01	6,45E+11	0,0010	0,4	0,8963	1
	4,31E+09	-5,36E+07	4,90E+07	-1,06E+01	6,45E+11	0,0010	0,4	0,8905	1
	4,24E+09	-5,16E+07	5,08E+07	-1,13E+01	6,45E+11	0,0010	0,4	0,8930	1
	4,44E+09	-8,61E+07	5,74E+07	-1,24E+01	6,45E+11	0,0010	0,4	0,9067	1
	4,46E+09	-7,95E+07	5,27E+07	-1,09E+01	6,45E+11	0,0010	0,4	0,9000	1
	4,43E+09	-8,20E+07	5,41E+07	-1,18E+01	6,45E+11	0,0010	0,4	0,9022	1
	4,55E+09	-8,01E+07	5,47E+07	-1,12E+01	6,45E+11	0,0010	0,4	0,9011	1
	4,47E+09	-7,93E+07	5,72E+07	-1,23E+01	6,45E+11	0,0010	0,4	0,9065	1
	4,46E+09	-1,05E+08	6,08E+07	-1,32E+01	6,45E+11	0,0010	0,4	0,9154	1
	4,43E+09	-1,16E+08	5,91E+07	-1,26E+01	6,45E+11	0,0010	0,4	0,9115	1
	4,43E+09	-1,00E+08	5,39E+07	-1,13E+01	6,45E+11	0,0010	0,4	0,9080	1
	4,47E+09	-9,01E+07	5,92E+07	-1,27E+01	6,45E+11	0,0010	0,4	0,9141	1

Tabela A1.1 – Continuação

	E1 [Pa]	E2 [N/m]	E3 [N/m]	E4	E5 [Pa]	E6 [m]	E7	E8	E9
	4,42E+09	-1,02E+08	6,16E+07	-1,35E+01	6,45E+11	0,0010	0,4	0,9174	1
	4,20E+09	-2,61E+08	6,34E+07	-9,15E+00	6,45E+11	0,0015	0,4	0,8765	1
	4,18E+09	-2,54E+08	6,32E+07	-9,50E+00	6,45E+11	0,0015	0,4	0,8798	1
	4,13E+09	-2,52E+08	6,35E+07	-9,35E+00	6,45E+11	0,0015	0,4	0,8827	1
	4,21E+09	-2,57E+08	6,41E+07	-9,39E+00	6,45E+11	0,0015	0,4	0,8794	1
	4,20E+09	-2,58E+08	6,41E+07	-9,03E+00	6,45E+11	0,0015	0,4	0,8777	1
	4,27E+09	-5,96E+08	1,10E+08	-1,60E+01	6,45E+11	0,0015	0,4	0,9170	1
	4,22E+09	-5,84E+08	9,72E+07	-1,47E+01	6,45E+11	0,0015	0,4	0,9118	1
	4,24E+09	-6,14E+08	1,02E+08	-1,48E+01	6,45E+11	0,0015	0,4	0,9138	1
	4,30E+09	-6,02E+08	9,26E+07	-1,36E+01	6,45E+11	0,0015	0,4	0,9066	1
	4,31E+09	-5,61E+08	1,00E+08	-1,47E+01	6,45E+11	0,0015	0,4	0,9127	1
	3,95E+09	-1,39E+08	5,25E+07	-8,01E+00	6,45E+11	0,0015	0,4	0,8534	1
	3,89E+09	-1,37E+08	5,11E+07	-7,97E+00	6,45E+11	0,0015	0,4	0,8522	1
	3,96E+09	-1,39E+08	5,65E+07	-8,68E+00	6,45E+11	0,0015	0,4	0,8629	1
	4,08E+09	-1,33E+08	5,68E+07	-8,57E+00	6,45E+11	0,0015	0,4	0,8608	1
	4,05E+09	-1,31E+08	6,17E+07	-9,65E+00	6,45E+11	0,0015	0,4	0,8726	1
	6,85E+09	-1,54E+07	2,88E+07	-1,02E+01	1,14E+12	0,0004	0,4	0,8842	1
	6,87E+09	-1,51E+07	2,78E+07	-9,45E+00	1,14E+12	0,0004	0,4	0,8774	1
	7,31E+09	-1,50E+07	2,66E+07	-8,95E+00	1,14E+12	0,0004	0,4	0,8657	1
	6,91E+09	-1,52E+07	2,84E+07	-1,00E+01	1,14E+12	0,0004	0,4	0,8831	1
	7,03E+09	-1,47E+07	2,86E+07	-9,38E+00	1,14E+12	0,0004	0,4	0,8764	1
	6,63E+09	-1,54E+07	2,65E+07	-1,01E+01	1,14E+12	0,0004	0,4	0,8834	1
	6,45E+09	-1,54E+07	2,66E+07	-1,03E+01	1,14E+12	0,0004	0,4	0,8724	1
	6,64E+09	-1,62E+07	2,73E+07	-9,61E+00	1,14E+12	0,0004	0,4	0,8716	1
	6,74E+09	-1,51E+07	2,65E+07	-9,66E+00	1,14E+12	0,0004	0,4	0,8740	1
	6,68E+09	-1,44E+07	2,66E+07	-9,69E+00	1,14E+12	0,0004	0,4	0,8757	1
	6,47E+09	-7,74E+07	4,41E+07	-6,09E+00	6,45E+11	0,0010	0,4	0,8054	1
	6,54E+09	-7,73E+07	4,40E+07	-6,02E+00	6,45E+11	0,0010	0,4	0,8151	1
	6,48E+09	-7,38E+07	4,32E+07	-6,00E+00	6,45E+11	0,0010	0,4	0,8060	1
	6,74E+09	-7,60E+07	4,51E+07	-6,05E+00	6,45E+11	0,0010	0,4	0,8081	1
	6,55E+09	-7,33E+07	4,31E+07	-5,85E+00	6,45E+11	0,0010	0,4	0,8052	1
	6,81E+09	-1,21E+08	4,95E+07	-6,60E+00	6,45E+11	0,0010	0,4	0,8296	1
	6,82E+09	-1,22E+08	5,08E+07	-6,82E+00	6,45E+11	0,0010	0,4	0,8316	1
	6,74E+09	-1,23E+08	5,18E+07	-6,94E+00	6,45E+11	0,0010	0,4	0,8341	1
	6,84E+09	-1,18E+08	5,22E+07	-6,92E+00	6,45E+11	0,0010	0,4	0,8367	1
	6,89E+09	-1,22E+08	5,07E+07	-6,67E+00	6,45E+11	0,0010	0,4	0,8301	1
	6,83E+09	-1,67E+08	5,47E+07	-7,33E+00	6,45E+11	0,0010	0,4	0,8481	1
	6,86E+09	-1,68E+08	5,77E+07	-7,79E+00	6,45E+11	0,0010	0,4	0,8532	1
	6,81E+09	-1,65E+08	5,63E+07	-7,55E+00	6,45E+11	0,0010	0,4	0,8505	1
	6,86E+09	-1,60E+08	5,46E+07	-7,41E+00	6,45E+11	0,0010	0,4	0,8494	1
	6,91E+09	-1,64E+08	5,66E+07	-7,65E+00	6,45E+11	0,0010	0,4	0,8510	1

Tabela A1.1 – Continuação

	E1 [Pa]	E2 [N/m]	E3 [N/m]	E4	E5 [Pa]	E6 [m]	E7	E8	E9
	6,19E+09	-4,32E+08	6,59E+07	-6,36E+00	6,45E+11	0,0015	0,4	0,8102	1
	6,24E+09	-4,30E+08	6,86E+07	-6,71E+00	6,45E+11	0,0015	0,4	0,8122	1
	6,31E+09	-4,24E+08	6,94E+07	-6,67E+00	6,45E+11	0,0015	0,4	0,8162	1
	6,27E+09	-4,22E+08	6,79E+07	-6,50E+00	6,45E+11	0,0015	0,4	0,8118	1
	6,32E+09	-4,22E+08	6,57E+07	-6,14E+00	6,45E+11	0,0015	0,4	0,8123	1
	6,45E+09	-9,58E+08	8,23E+07	-7,81E+00	6,45E+11	0,0015	0,4	0,8456	1
	6,51E+09	-9,64E+08	8,23E+07	-7,54E+00	6,45E+11	0,0015	0,4	0,8465	1
	6,55E+09	-9,59E+08	8,68E+07	-7,89E+00	6,45E+11	0,0015	0,4	0,8509	1
	6,56E+09	-9,38E+08	8,13E+07	-7,59E+00	6,45E+11	0,0015	0,4	0,8437	1
	6,50E+09	-9,75E+08	8,11E+07	-7,58E+00	6,45E+11	0,0015	0,4	0,8421	1
	5,84E+09	-2,03E+08	5,13E+07	-5,04E+00	6,45E+11	0,0015	0,4	0,7699	1
	5,92E+09	-1,99E+08	5,35E+07	-5,17E+00	6,45E+11	0,0015	0,4	0,7791	1
	5,98E+09	-1,90E+08	5,34E+07	-5,23E+00	6,45E+11	0,0015	0,4	0,7801	1
	5,99E+09	-1,93E+08	5,67E+07	-5,58E+00	6,45E+11	0,0015	0,4	0,7870	1
	5,95E+09	-2,01E+08	5,55E+07	-5,43E+00	6,45E+11	0,0015	0,4	0,7789	1
	8,48E+09	-1,82E+07	2,62E+07	-7,26E+00	1,14E+12	0,0004	0,4	0,8362	1
	8,30E+09	-1,80E+07	2,60E+07	-7,34E+00	1,14E+12	0,0004	0,4	0,8398	1
	8,37E+09	-1,73E+07	2,64E+07	-7,25E+00	1,14E+12	0,0004	0,4	0,8440	1
	8,43E+09	-1,78E+07	2,60E+07	-7,16E+00	1,14E+12	0,0004	0,4	0,8358	1
	8,39E+09	-1,86E+07	2,66E+07	-7,57E+00	1,14E+12	0,0004	0,4	0,8378	1
	8,19E+09	-1,81E+07	2,52E+07	-7,39E+00	1,14E+12	0,0004	0,4	0,8408	1
	8,73E+09	-1,91E+07	2,78E+07	-7,16E+00	1,14E+12	0,0004	0,4	0,8435	1
	8,54E+09	-1,87E+07	2,66E+07	-7,24E+00	1,14E+12	0,0004	0,4	0,8423	1
	8,46E+09	-1,90E+07	2,77E+07	-7,56E+00	1,14E+12	0,0004	0,4	0,8433	1
	8,46E+09	-1,92E+07	2,62E+07	-7,29E+00	1,14E+12	0,0004	0,4	0,8358	1
	7,58E+09	-8,50E+07	4,20E+07	-4,85E+00	6,45E+11	0,0010	0,4	0,7645	1
	7,79E+09	-8,40E+07	4,39E+07	-4,89E+00	6,45E+11	0,0010	0,4	0,7737	1
	7,85E+09	-8,47E+07	4,25E+07	-4,65E+00	6,45E+11	0,0010	0,4	0,7628	1
	7,70E+09	-8,61E+07	4,28E+07	-4,80E+00	6,45E+11	0,0010	0,4	0,7648	1
	7,75E+09	-8,72E+07	4,26E+07	-4,72E+00	6,45E+11	0,0010	0,4	0,7662	1
	8,05E+09	-1,41E+08	4,82E+07	-5,30E+00	6,45E+11	0,0010	0,4	0,7887	1
	8,13E+09	-1,33E+08	5,06E+07	-5,49E+00	6,45E+11	0,0010	0,4	0,8000	1
	8,15E+09	-1,37E+08	4,90E+07	-5,36E+00	6,45E+11	0,0010	0,4	0,7971	1
	8,14E+09	-1,39E+08	4,92E+07	-5,41E+00	6,45E+11	0,0010	0,4	0,7976	1
	8,10E+09	-1,34E+08	5,05E+07	-5,55E+00	6,45E+11	0,0010	0,4	0,7986	1
	8,08E+09	-1,92E+08	5,87E+07	-6,77E+00	6,45E+11	0,0010	0,4	0,8261	1
	8,23E+09	-1,82E+08	5,46E+07	-6,04E+00	6,45E+11	0,0010	0,4	0,8192	1
	8,26E+09	-1,87E+08	5,63E+07	-6,25E+00	6,45E+11	0,0010	0,4	0,8236	1
	8,16E+09	-1,87E+08	5,46E+07	-6,06E+00	6,45E+11	0,0010	0,4	0,8213	1
	8,25E+09	-1,80E+08	5,45E+07	-5,97E+00	6,45E+11	0,0010	0,4	0,8182	1
	7,73E+09	-4,69E+08	6,11E+07	-4,90E+00	6,45E+11	0,0015	0,4	0,7711	1

Tabela A1.1 – Continuação

	E1 [Pa]	E2 [N/m]	E3 [N/m]	E4	E5 [Pa]	E6 [m]	E7	E8	E9
	7,81E+09	-4,57E+08	5,83E+07	-4,38E+00	6,45E+11	0,0015	0,4	0,7657	1
	7,87E+09	-4,54E+08	6,27E+07	-4,72E+00	6,45E+11	0,0015	0,4	0,7715	1
	7,46E+09	-4,77E+08	6,08E+07	-4,74E+00	6,45E+11	0,0015	0,4	0,7648	1
	7,63E+09	-4,70E+08	6,16E+07	-4,69E+00	6,45E+11	0,0015	0,4	0,7705	1
	7,92E+09	-1,09E+09	8,43E+07	-6,32E+00	6,45E+11	0,0015	0,4	0,8137	1
	7,58E+09	-1,12E+09	7,50E+07	-5,67E+00	6,45E+11	0,0015	0,4	0,7985	1
	7,80E+09	-1,11E+09	7,65E+07	-5,53E+00	6,45E+11	0,0015	0,4	0,8022	1
	7,86E+09	-1,10E+09	7,78E+07	-5,70E+00	6,45E+11	0,0015	0,4	0,8047	1
	7,82E+09	-1,10E+09	7,48E+07	-5,56E+00	6,45E+11	0,0015	0,4	0,8006	1
	7,28E+09	-2,23E+08	5,07E+07	-3,88E+00	6,45E+11	0,0015	0,4	0,7214	1
	7,54E+09	-2,26E+08	5,15E+07	-3,75E+00	6,45E+11	0,0015	0,4	0,7207	1
	7,63E+09	-2,27E+08	5,18E+07	-3,78E+00	6,45E+11	0,0015	0,4	0,7208	1
	7,51E+09	-2,13E+08	5,49E+07	-4,23E+00	6,45E+11	0,0015	0,4	0,7422	1
	7,31E+09	-2,31E+08	5,15E+07	-3,93E+00	6,45E+11	0,0015	0,4	0,7270	1
	7,95E+09	-1,81E+07	2,36E+07	-6,92E+00	1,14E+12	0,0004	0,4	0,8215	1
	8,34E+09	-1,85E+07	2,76E+07	-7,66E+00	1,14E+12	0,0004	0,4	0,8474	1
	8,12E+09	-1,79E+07	2,64E+07	-7,72E+00	1,14E+12	0,0004	0,4	0,8460	1
	8,18E+09	-1,72E+07	2,63E+07	-7,49E+00	1,14E+12	0,0004	0,4	0,8485	1
	8,23E+09	-1,67E+07	2,71E+07	-7,87E+00	1,14E+12	0,0004	0,4	0,8421	1
	8,53E+09	-1,77E+07	2,69E+07	-7,33E+00	1,14E+12	0,0004	0,4	0,8443	1
	8,30E+09	-1,66E+07	2,60E+07	-7,52E+00	1,14E+12	0,0004	0,4	0,8425	1
	8,21E+09	-1,78E+07	2,73E+07	-7,82E+00	1,14E+12	0,0004	0,4	0,8491	1
	8,03E+09	-1,88E+07	2,59E+07	-7,60E+00	1,14E+12	0,0004	0,4	0,8457	1
	8,33E+09	-1,81E+07	2,83E+07	-7,90E+00	1,14E+12	0,0004	0,4	0,8448	1
	7,83E+09	-8,43E+07	4,21E+07	-4,63E+00	6,45E+11	0,0010	0,4	0,7602	1
	7,81E+09	-9,11E+07	4,15E+07	-4,53E+00	6,45E+11	0,0010	0,4	0,7540	1
	7,69E+09	-9,05E+07	4,20E+07	-4,66E+00	6,45E+11	0,0010	0,4	0,7567	1
	7,81E+09	-8,62E+07	4,13E+07	-4,55E+00	6,45E+11	0,0010	0,4	0,7560	1
	7,92E+09	-8,40E+07	4,06E+07	-4,35E+00	6,45E+11	0,0010	0,4	0,7472	1
	8,10E+09	-1,39E+08	4,76E+07	-5,23E+00	6,45E+11	0,0010	0,4	0,7891	1
	8,10E+09	-1,37E+08	4,89E+07	-5,34E+00	6,45E+11	0,0010	0,4	0,7909	1
	8,12E+09	-1,37E+08	4,75E+07	-5,10E+00	6,45E+11	0,0010	0,4	0,7877	1
	8,09E+09	-1,39E+08	4,76E+07	-5,20E+00	6,45E+11	0,0010	0,4	0,7887	1
	8,10E+09	-1,47E+08	5,09E+07	-5,57E+00	6,45E+11	0,0010	0,4	0,7953	1
	8,28E+09	-1,93E+08	5,45E+07	-5,93E+00	6,45E+11	0,0010	0,4	0,8112	1
	8,25E+09	-2,00E+08	5,46E+07	-6,02E+00	6,45E+11	0,0010	0,4	0,8146	1
	8,26E+09	-1,95E+08	5,55E+07	-6,03E+00	6,45E+11	0,0010	0,4	0,8174	1
	8,16E+09	-2,01E+08	5,44E+07	-6,03E+00	6,45E+11	0,0010	0,4	0,8118	1
	8,20E+09	-1,95E+08	5,50E+07	-6,14E+00	6,45E+11	0,0010	0,4	0,8143	1
	7,58E+09	-4,80E+08	6,65E+07	-5,09E+00	6,45E+11	0,0015	0,4	0,7730	1
	7,59E+09	-4,84E+08	6,93E+07	-5,31E+00	6,45E+11	0,0015	0,4	0,7758	1

Tabela A1.1 – Continuação

	E1 [Pa]	E2 [N/m]	E3 [N/m]	E4	E5 [Pa]	E6 [m]	E7	E8	E9
	7,57E+09	-4,88E+08	7,02E+07	-5,65E+00	6,45E+11	0,0015	0,4	0,7793	1
	7,60E+09	-4,85E+08	6,96E+07	-5,33E+00	6,45E+11	0,0015	0,4	0,7745	1
	7,51E+09	-5,08E+08	6,80E+07	-5,45E+00	6,45E+11	0,0015	0,4	0,7771	1
	7,72E+09	-1,16E+09	8,40E+07	-6,64E+00	6,45E+11	0,0015	0,4	0,8155	1
	7,78E+09	-1,15E+09	8,22E+07	-6,45E+00	6,45E+11	0,0015	0,4	0,8134	1
	7,89E+09	-1,16E+09	8,85E+07	-6,95E+00	6,45E+11	0,0015	0,4	0,8175	1
	7,76E+09	-1,13E+09	7,64E+07	-6,09E+00	6,45E+11	0,0015	0,4	0,8076	1
	7,92E+09	-1,16E+09	8,94E+07	-7,18E+00	6,45E+11	0,0015	0,4	0,8193	1
	6,94E+09	-2,29E+08	5,48E+07	-4,58E+00	6,45E+11	0,0015	0,4	0,7358	1
	6,98E+09	-2,32E+08	5,71E+07	-4,66E+00	6,45E+11	0,0015	0,4	0,7462	1
	6,92E+09	-2,29E+08	5,65E+07	-4,66E+00	6,45E+11	0,0015	0,4	0,7479	1
	6,99E+09	-2,27E+08	5,60E+07	-4,61E+00	6,45E+11	0,0015	0,4	0,7476	1
	6,86E+09	-2,29E+08	5,40E+07	-4,49E+00	6,45E+11	0,0015	0,4	0,7380	1
	9,46E+09	-2,19E+07	2,48E+07	-6,05E+00	1,14E+12	0,0004	0,4	0,8019	1
	9,14E+09	-2,13E+07	2,65E+07	-6,49E+00	1,14E+12	0,0004	0,4	0,8217	1
	9,00E+09	-2,03E+07	2,60E+07	-6,73E+00	1,14E+12	0,0004	0,4	0,8236	1
	9,51E+09	-2,05E+07	2,58E+07	-6,16E+00	1,14E+12	0,0004	0,4	0,8127	1
	9,70E+09	-2,10E+07	2,63E+07	-6,38E+00	1,14E+12	0,0004	0,4	0,8188	1
	8,88E+09	-2,06E+07	3,02E+07	-7,54E+00	1,14E+12	0,0004	0,4	0,8401	1
	8,98E+09	-2,07E+07	2,69E+07	-6,80E+00	1,14E+12	0,0004	0,4	0,8230	1
	9,39E+09	-2,05E+07	2,73E+07	-6,62E+00	1,14E+12	0,0004	0,4	0,8269	1
	9,33E+09	-2,20E+07	2,78E+07	-6,88E+00	1,14E+12	0,0004	0,4	0,8248	1
	9,01E+09	-2,14E+07	2,66E+07	-6,85E+00	1,14E+12	0,0004	0,4	0,8196	1
	8,24E+09	-9,23E+07	4,07E+07	-4,15E+00	6,45E+11	0,0010	0,4	0,7277	1
	8,13E+09	-9,87E+07	4,24E+07	-4,45E+00	6,45E+11	0,0010	0,4	0,7410	1
	8,28E+09	-9,63E+07	4,03E+07	-4,07E+00	6,45E+11	0,0010	0,4	0,7313	1
	8,56E+09	-9,22E+07	4,36E+07	-4,32E+00	6,45E+11	0,0010	0,4	0,7438	1
	8,39E+09	-9,35E+07	4,14E+07	-4,15E+00	6,45E+11	0,0010	0,4	0,7378	1
	8,61E+09	-1,52E+08	4,75E+07	-4,84E+00	6,45E+11	0,0010	0,4	0,7659	1
	8,66E+09	-1,61E+08	4,98E+07	-5,02E+00	6,45E+11	0,0010	0,4	0,7714	1
	8,81E+09	-1,54E+08	4,92E+07	-4,88E+00	6,45E+11	0,0010	0,4	0,7722	1
	8,80E+09	-1,47E+08	4,81E+07	-4,80E+00	6,45E+11	0,0010	0,4	0,7751	1
	8,74E+09	-1,47E+08	4,85E+07	-4,92E+00	6,45E+11	0,0010	0,4	0,7710	1
	8,69E+09	-2,13E+08	5,11E+07	-5,13E+00	6,45E+11	0,0010	0,4	0,7819	1
	8,84E+09	-2,13E+08	5,52E+07	-5,58E+00	6,45E+11	0,0010	0,4	0,7973	1
	8,92E+09	-2,05E+08	5,32E+07	-5,26E+00	6,45E+11	0,0010	0,4	0,7932	1
	8,94E+09	-2,14E+08	5,54E+07	-5,56E+00	6,45E+11	0,0010	0,4	0,8014	1
	8,91E+09	-2,11E+08	5,19E+07	-5,02E+00	6,45E+11	0,0010	0,4	0,7870	1
	8,11E+09	-5,28E+08	5,93E+07	-4,10E+00	6,45E+11	0,0015	0,4	0,7271	1
	8,18E+09	-5,17E+08	5,80E+07	-4,04E+00	6,45E+11	0,0015	0,4	0,7336	1
	8,21E+09	-5,31E+08	5,83E+07	-4,10E+00	6,45E+11	0,0015	0,4	0,7306	1

Tabela A1.1 – Continuação

	E1 [Pa]	E2 [N/m]	E3 [N/m]	E4	E5 [Pa]	E6 [m]	E7	E8	E9
	8,23E+09	-5,00E+08	5,59E+07	-3,82E+00	6,45E+11	0,0015	0,4	0,7305	1
	8,15E+09	-5,16E+08	5,79E+07	-4,10E+00	6,45E+11	0,0015	0,4	0,7291	1
	8,38E+09	-1,19E+09	7,47E+07	-5,01E+00	6,45E+11	0,0015	0,4	0,7711	1
	8,45E+09	-1,21E+09	7,71E+07	-5,41E+00	6,45E+11	0,0015	0,4	0,7783	1
	8,44E+09	-1,21E+09	7,60E+07	-5,21E+00	6,45E+11	0,0015	0,4	0,7769	1
	8,35E+09	-1,21E+09	7,32E+07	-5,02E+00	6,45E+11	0,0015	0,4	0,7712	1
	8,27E+09	-1,24E+09	7,35E+07	-5,15E+00	6,45E+11	0,0015	0,4	0,7701	1
	7,54E+09	-2,38E+08	4,83E+07	-3,55E+00	6,45E+11	0,0015	0,4	0,6876	1
	7,62E+09	-2,50E+08	5,11E+07	-3,72E+00	6,45E+11	0,0015	0,4	0,6944	1
	7,72E+09	-2,41E+08	4,99E+07	-3,67E+00	6,45E+11	0,0015	0,4	0,6876	1
	7,78E+09	-2,43E+08	5,18E+07	-3,72E+00	6,45E+11	0,0015	0,4	0,6950	1
	7,56E+09	-2,35E+08	4,84E+07	-3,53E+00	6,45E+11	0,0015	0,4	0,6852	1
	5,64E+09	-8,09E+08	8,43E+07	-1,07E+01	6,45E+11	0,0015	0,4	0,8763	1
	5,63E+09	-7,45E+08	8,46E+07	-1,08E+01	6,45E+11	0,0015	0,4	0,8792	1
	5,47E+09	-7,71E+08	8,24E+07	-1,07E+01	6,45E+11	0,0015	0,4	0,8764	1
	5,52E+09	-7,71E+08	8,33E+07	-1,05E+01	6,45E+11	0,0015	0,4	0,8777	1
	5,65E+09	-7,22E+08	7,65E+07	-9,19E+00	6,45E+11	0,0015	0,4	0,8673	1
	5,42E+09	-7,70E+08	8,32E+07	-1,11E+01	6,45E+11	0,0015	0,4	0,8815	1
	5,36E+09	-8,03E+08	8,38E+07	-1,16E+01	6,45E+11	0,0015	0,4	0,8807	1
	5,49E+09	-8,51E+08	8,54E+07	-1,19E+01	6,45E+11	0,0015	0,4	0,8792	1
	5,51E+09	-7,36E+08	8,69E+07	-1,13E+01	6,45E+11	0,0015	0,4	0,8895	1
	5,30E+09	-7,47E+08	7,89E+07	-1,07E+01	6,45E+11	0,0015	0,4	0,8865	1
	5,60E+09	-7,26E+08	8,35E+07	-1,07E+01	6,45E+11	0,0015	0,4	0,8830	1
	5,55E+09	-7,42E+08	8,23E+07	-1,08E+01	6,45E+11	0,0015	0,4	0,8751	1
	5,62E+09	-7,55E+08	8,11E+07	-9,79E+00	6,45E+11	0,0015	0,4	0,8799	1
	5,65E+09	-7,72E+08	9,21E+07	-1,15E+01	6,45E+11	0,0015	0,4	0,8887	1
	5,63E+09	-7,68E+08	8,93E+07	-1,15E+01	6,45E+11	0,0015	0,4	0,8868	1
	5,47E+09	-7,91E+08	8,64E+07	-1,14E+01	6,45E+11	0,0015	0,4	0,8833	1
	5,51E+09	-8,12E+08	8,57E+07	-1,10E+01	6,45E+11	0,0015	0,4	0,8800	1
	5,74E+09	-7,64E+08	8,42E+07	-9,49E+00	6,45E+11	0,0015	0,4	0,8859	1
	5,73E+09	-7,74E+08	8,10E+07	-8,65E+00	6,45E+11	0,0015	0,4	0,8845	1
	5,71E+09	-7,73E+08	8,42E+07	-9,62E+00	6,45E+11	0,0015	0,4	0,8846	1
	5,60E+09	-1,99E+08	5,95E+07	-6,51E+00	6,45E+11	0,0015	0,4	0,8126	1
	5,32E+09	-1,98E+08	5,69E+07	-6,58E+00	6,45E+11	0,0015	0,4	0,8088	1
	5,21E+09	-1,89E+08	5,00E+07	-6,01E+00	6,45E+11	0,0015	0,4	0,7888	1
	5,34E+09	-1,97E+08	6,18E+07	-7,33E+00	6,45E+11	0,0015	0,4	0,8191	1
	5,34E+09	-2,09E+08	6,18E+07	-7,35E+00	6,45E+11	0,0015	0,4	0,8159	1
	5,02E+09	-1,86E+08	6,49E+07	-8,37E+00	6,45E+11	0,0015	0,4	0,8350	1
	5,16E+09	-1,93E+08	6,29E+07	-7,71E+00	6,45E+11	0,0015	0,4	0,8360	1
	5,03E+09	-2,14E+08	5,47E+07	-7,49E+00	6,45E+11	0,0015	0,4	0,8166	1
	5,24E+09	-1,87E+08	6,58E+07	-7,86E+00	6,45E+11	0,0015	0,4	0,8377	1

Tabela A1.1 – Continuação

	E1 [Pa]	E2 [N/m]	E3 [N/m]	E4	E5 [Pa]	E6 [m]	E7	E8	E9
	5,26E+09	-1,88E+08	6,28E+07	-7,50E+00	6,45E+11	0,0015	0,4	0,8377	1
	5,44E+09	-1,93E+08	6,02E+07	-7,01E+00	6,45E+11	0,0015	0,4	0,8197	1
	5,31E+09	-2,00E+08	5,78E+07	-6,84E+00	6,45E+11	0,0015	0,4	0,8185	1
	5,34E+09	-1,94E+08	5,63E+07	-6,56E+00	6,45E+11	0,0015	0,4	0,8080	1
	5,48E+09	-2,01E+08	6,25E+07	-7,41E+00	6,45E+11	0,0015	0,4	0,8144	1
	5,32E+09	-1,96E+08	6,40E+07	-7,83E+00	6,45E+11	0,0015	0,4	0,8145	1
	5,45E+09	-1,96E+08	6,15E+07	-7,12E+00	6,45E+11	0,0015	0,4	0,8124	1
	5,29E+09	-2,03E+08	5,88E+07	-7,11E+00	6,45E+11	0,0015	0,4	0,8058	1
	5,32E+09	-2,06E+08	5,98E+07	-7,41E+00	6,45E+11	0,0015	0,4	0,8084	1
	5,32E+09	-1,94E+08	6,03E+07	-7,11E+00	6,45E+11	0,0015	0,4	0,8134	1
	5,34E+09	-1,98E+08	5,74E+07	-7,11E+00	6,45E+11	0,0015	0,4	0,8100	1
	8,07E+09	-5,24E+08	5,22E+07	-3,30E+00	6,45E+11	0,0015	0,4	0,7017	1
	8,10E+09	-5,21E+08	5,28E+07	-3,38E+00	6,45E+11	0,0015	0,4	0,7004	1
	7,89E+09	-5,40E+08	5,20E+07	-3,40E+00	6,45E+11	0,0015	0,4	0,6987	1
	8,04E+09	-5,14E+08	4,84E+07	-3,06E+00	6,45E+11	0,0015	0,4	0,6945	1
	8,16E+09	-4,96E+08	5,05E+07	-3,13E+00	6,45E+11	0,0015	0,4	0,6948	1
	7,87E+09	-5,49E+08	5,16E+07	-3,32E+00	6,45E+11	0,0015	0,4	0,6970	1
	8,03E+09	-5,25E+08	5,04E+07	-3,24E+00	6,45E+11	0,0015	0,4	0,7024	1
	8,05E+09	-5,26E+08	5,18E+07	-3,18E+00	6,45E+11	0,0015	0,4	0,7044	1
	8,25E+09	-5,08E+08	5,24E+07	-3,23E+00	6,45E+11	0,0015	0,4	0,7102	1
	8,17E+09	-5,32E+08	5,42E+07	-3,41E+00	6,45E+11	0,0015	0,4	0,7087	1
	8,15E+09	-5,22E+08	5,27E+07	-3,20E+00	6,45E+11	0,0015	0,4	0,7109	1
	8,13E+09	-5,22E+08	5,36E+07	-3,42E+00	6,45E+11	0,0015	0,4	0,7064	1
	8,08E+09	-5,34E+08	5,33E+07	-3,46E+00	6,45E+11	0,0015	0,4	0,7069	1
	8,00E+09	-5,20E+08	5,17E+07	-3,25E+00	6,45E+11	0,0015	0,4	0,7035	1
	8,19E+09	-5,16E+08	5,31E+07	-3,30E+00	6,45E+11	0,0015	0,4	0,7091	1
	8,01E+09	-5,25E+08	5,02E+07	-3,05E+00	6,45E+11	0,0015	0,4	0,6959	1
	8,29E+09	-5,11E+08	5,08E+07	-3,12E+00	6,45E+11	0,0015	0,4	0,6976	1
	8,15E+09	-5,26E+08	5,10E+07	-3,20E+00	6,45E+11	0,0015	0,4	0,6954	1
	8,35E+09	-4,92E+08	4,98E+07	-2,93E+00	6,45E+11	0,0015	0,4	0,6940	1
	7,73E+09	-5,47E+08	5,01E+07	-3,31E+00	6,45E+11	0,0015	0,4	0,6881	1
	6,14E+09	-9,97E+08	9,85E+07	-1,10E+01	6,45E+11	0,0015	0,4	0,8353	1
	6,19E+09	-1,04E+09	1,10E+08	-1,23E+01	6,45E+11	0,0015	0,4	0,8388	1
	6,32E+09	-9,91E+08	1,07E+08	-1,15E+01	6,45E+11	0,0015	0,4	0,8537	1
	6,18E+09	-1,01E+09	1,05E+08	-1,18E+01	6,45E+11	0,0015	0,4	0,8399	1
	6,15E+09	-9,92E+08	9,18E+07	-1,07E+01	6,45E+11	0,0015	0,4	0,8330	1
	5,82E+09	-8,51E+08	9,34E+07	-1,10E+01	6,45E+11	0,0015	0,4	0,8693	1
	5,87E+09	-8,78E+08	9,58E+07	-1,10E+01	6,45E+11	0,0015	0,4	0,8687	1
	5,88E+09	-8,95E+08	9,05E+07	-1,03E+01	6,45E+11	0,0015	0,4	0,8567	1
	5,91E+09	-9,01E+08	1,00E+08	-1,15E+01	6,45E+11	0,0015	0,4	0,8702	1
	5,85E+09	-9,34E+08	9,68E+07	-1,14E+01	6,45E+11	0,0015	0,4	0,8543	1

Tabela A1.1 – Continuação

	E1 [Pa]	E2 [N/m]	E3 [N/m]	E4	E5 [Pa]	E6 [m]	E7	E8	E9
	5,97E+09	-8,86E+08	8,95E+07	-9,32E+00	6,45E+11	0,0015	0,4	0,8436	1
	6,01E+09	-9,27E+08	9,32E+07	-9,50E+00	6,45E+11	0,0015	0,4	0,8410	1
	6,12E+09	-9,11E+08	9,00E+07	-9,08E+00	6,45E+11	0,0015	0,4	0,8413	1
	6,13E+09	-9,50E+08	8,81E+07	-8,84E+00	6,45E+11	0,0015	0,4	0,8351	1
	6,17E+09	-9,52E+08	8,84E+07	-8,71E+00	6,45E+11	0,0015	0,4	0,8385	1
	6,05E+09	-9,47E+08	9,22E+07	-9,64E+00	6,45E+11	0,0015	0,4	0,8435	1
	6,10E+09	-9,58E+08	9,60E+07	-9,91E+00	6,45E+11	0,0015	0,4	0,8415	1
	6,01E+09	-9,44E+08	8,93E+07	-9,40E+00	6,45E+11	0,0015	0,4	0,8399	1
	6,12E+09	-1,01E+09	8,46E+07	-8,58E+00	6,45E+11	0,0015	0,4	0,8181	1
	6,11E+09	-9,96E+08	8,39E+07	-8,51E+00	6,45E+11	0,0015	0,4	0,8217	1
	5,72E+09	-2,00E+08	4,55E+07	-4,54E+00	6,45E+11	0,0015	0,4	0,7424	1
	5,56E+09	-2,15E+08	4,39E+07	-4,68E+00	6,45E+11	0,0015	0,4	0,7210	1
	5,37E+09	-2,15E+08	4,05E+07	-4,55E+00	6,45E+11	0,0015	0,4	0,6963	1
	5,79E+09	-2,02E+08	4,74E+07	-4,75E+00	6,45E+11	0,0015	0,4	0,7445	1
	5,76E+09	-2,08E+08	4,59E+07	-4,65E+00	6,45E+11	0,0015	0,4	0,7404	1
	5,42E+09	-2,07E+08	5,04E+07	-5,53E+00	6,45E+11	0,0015	0,4	0,7624	1
	5,50E+09	-2,02E+08	4,98E+07	-5,36E+00	6,45E+11	0,0015	0,4	0,7705	1
	5,48E+09	-2,05E+08	4,97E+07	-5,35E+00	6,45E+11	0,0015	0,4	0,7696	1
	5,57E+09	-1,99E+08	5,07E+07	-5,38E+00	6,45E+11	0,0015	0,4	0,7757	1
	5,48E+09	-1,97E+08	5,10E+07	-5,52E+00	6,45E+11	0,0015	0,4	0,7797	1
	5,44E+09	-2,00E+08	4,92E+07	-5,38E+00	6,45E+11	0,0015	0,4	0,7693	1
	5,46E+09	-1,97E+08	4,93E+07	-5,31E+00	6,45E+11	0,0015	0,4	0,7720	1
	5,46E+09	-1,99E+08	5,00E+07	-5,41E+00	6,45E+11	0,0015	0,4	0,7688	1
	5,43E+09	-2,08E+08	4,98E+07	-5,28E+00	6,45E+11	0,0015	0,4	0,7660	1
	5,51E+09	-2,07E+08	4,83E+07	-5,11E+00	6,45E+11	0,0015	0,4	0,7679	1
	5,42E+09	-2,19E+08	4,70E+07	-5,16E+00	6,45E+11	0,0015	0,4	0,7388	1
	5,47E+09	-2,20E+08	4,31E+07	-4,51E+00	6,45E+11	0,0015	0,4	0,7331	1
	5,47E+09	-2,19E+08	4,45E+07	-4,64E+00	6,45E+11	0,0015	0,4	0,7361	1
	5,48E+09	-2,02E+08	4,55E+07	-4,75E+00	6,45E+11	0,0015	0,4	0,7557	1
	5,52E+09	-2,00E+08	4,57E+07	-4,70E+00	6,45E+11	0,0015	0,4	0,7575	1
	7,72E+09	-5,69E+08	6,22E+07	-4,62E+00	6,45E+11	0,0015	0,4	0,7275	1
	7,80E+09	-5,56E+08	5,99E+07	-4,32E+00	6,45E+11	0,0015	0,4	0,7222	1
	7,80E+09	-5,47E+08	5,83E+07	-4,11E+00	6,45E+11	0,0015	0,4	0,7225	1
	7,74E+09	-5,55E+08	5,95E+07	-4,26E+00	6,45E+11	0,0015	0,4	0,7123	1
	7,83E+09	-5,56E+08	5,77E+07	-4,14E+00	6,45E+11	0,0015	0,4	0,7163	1
	7,68E+09	-5,55E+08	5,63E+07	-3,88E+00	6,45E+11	0,0015	0,4	0,7175	1
	7,61E+09	-5,64E+08	5,76E+07	-4,24E+00	6,45E+11	0,0015	0,4	0,7181	1
	7,71E+09	-5,55E+08	5,77E+07	-4,23E+00	6,45E+11	0,0015	0,4	0,7172	1
	7,84E+09	-5,62E+08	6,51E+07	-4,82E+00	6,45E+11	0,0015	0,4	0,7338	1
	7,69E+09	-5,47E+08	5,95E+07	-4,26E+00	6,45E+11	0,0015	0,4	0,7164	1
	7,89E+09	-5,53E+08	5,65E+07	-3,90E+00	6,45E+11	0,0015	0,4	0,7202	1

Tabela A1.1 – Continuação

	E1 [Pa]	E2 [N/m]	E3 [N/m]	E4	E5 [Pa]	E6 [m]	E7	E8	E9
	7,82E+09	-5,44E+08	5,77E+07	-4,05E+00	6,45E+11	0,0015	0,4	0,7146	1
	7,70E+09	-5,55E+08	5,85E+07	-4,41E+00	6,45E+11	0,0015	0,4	0,7114	1
	7,68E+09	-5,61E+08	5,69E+07	-4,18E+00	6,45E+11	0,0015	0,4	0,7058	1
	7,75E+09	-5,82E+08	5,81E+07	-4,35E+00	6,45E+11	0,0015	0,4	0,7097	1
	7,81E+09	-6,03E+08	6,28E+07	-4,70E+00	6,45E+11	0,0015	0,4	0,7210	1
	7,76E+09	-5,74E+08	6,28E+07	-4,74E+00	6,45E+11	0,0015	0,4	0,7167	1
	7,89E+09	-5,62E+08	6,49E+07	-4,58E+00	6,45E+11	0,0015	0,4	0,7349	1
	7,96E+09	-5,43E+08	6,32E+07	-4,39E+00	6,45E+11	0,0015	0,4	0,7283	1
	7,89E+09	-5,55E+08	5,94E+07	-4,22E+00	6,45E+11	0,0015	0,4	0,7216	1
Máximo	9,70E+09	-7,97E+06	1,10E+08	-2,93E+00	1,14E+12	-	-	-	-
Mínimo	3,89E+09	-1,24E+09	2,36E+07	-1,77E+01	6,45E+11	-	-	-	-
Limite Máximo	1,16E+10	-6,38E+06	1,32E+08	-2,35E+00	1,37E+12	-	-	-	-
Limite Mínimo	3,11E+09	-1,49E+09	1,89E+07	-2,13E+01	5,16E+11	-	-	-	-

Tabela A1.2 – Entradas E1 a E5 normalizadas entre 0 e 1

E1	E2	E3	E4	E5	E6	E7	E8	E9
0,1577	0,9979	0,0851	0,2884	0,7324	0,0004	0,4000	0,9447	1,0000
0,1563	0,9987	0,1041	0,2349	0,7324	0,0004	0,4000	0,9341	1,0000
0,1446	0,9984	0,0869	0,2618	0,7324	0,0004	0,4000	0,9296	1,0000
0,1601	0,9981	0,1225	0,1873	0,7324	0,0004	0,4000	0,9329	1,0000
0,1605	0,9984	0,0836	0,2708	0,7324	0,0004	0,4000	0,9489	1,0000
0,1676	0,9985	0,1018	0,2539	0,7324	0,0004	0,4000	0,9323	1,0000
0,1613	0,9980	0,1173	0,2132	0,7324	0,0004	0,4000	0,9329	1,0000
0,1549	0,9989	0,1056	0,2422	0,7324	0,0004	0,4000	0,9367	1,0000
0,1503	0,9986	0,1127	0,1934	0,7324	0,0004	0,4000	0,9370	1,0000
0,1527	0,9984	0,1024	0,2331	0,7324	0,0004	0,4000	0,9301	1,0000
0,1357	0,9666	0,2807	0,5433	0,1514	0,0010	0,4000	0,8889	1,0000
0,1600	0,9713	0,2309	0,6439	0,1514	0,0010	0,4000	0,8816	1,0000
0,1435	0,9686	0,2987	0,5234	0,1514	0,0010	0,4000	0,8963	1,0000
0,1403	0,9682	0,2651	0,5665	0,1514	0,0010	0,4000	0,8905	1,0000
0,1322	0,9696	0,2814	0,5262	0,1514	0,0010	0,4000	0,8930	1,0000
0,1561	0,9463	0,3397	0,4670	0,1514	0,0010	0,4000	0,9067	1,0000
0,1576	0,9508	0,2978	0,5501	0,1514	0,0010	0,4000	0,9000	1,0000
0,1545	0,9491	0,3100	0,5019	0,1514	0,0010	0,4000	0,9022	1,0000
0,1682	0,9504	0,3154	0,5311	0,1514	0,0010	0,4000	0,9011	1,0000
0,1594	0,9509	0,3372	0,4752	0,1514	0,0010	0,4000	0,9065	1,0000
0,1581	0,9339	0,3694	0,4245	0,1514	0,0010	0,4000	0,9154	1,0000

Tabela A1.2 – Continuação

E1	E2	E3	E4	E5	E6	E7	E8	E9
0,1545	0,9265	0,3541	0,4560	0,1514	0,0010	0,4000	0,9115	1,0000
0,1542	0,9367	0,3085	0,5295	0,1514	0,0010	0,4000	0,9080	1,0000
0,1597	0,9437	0,3554	0,4513	0,1514	0,0010	0,4000	0,9141	1,0000
0,1536	0,9354	0,3761	0,4102	0,1514	0,0010	0,4000	0,9174	1,0000
0,1273	0,8288	0,3918	0,6409	0,1514	0,0015	0,4000	0,8765	1,0000
0,1259	0,8336	0,3902	0,6221	0,1514	0,0015	0,4000	0,8798	1,0000
0,1198	0,8348	0,3933	0,6303	0,1514	0,0015	0,4000	0,8827	1,0000
0,1284	0,8311	0,3985	0,6278	0,1514	0,0015	0,4000	0,8794	1,0000
0,1272	0,8308	0,3980	0,6471	0,1514	0,0015	0,4000	0,8777	1,0000
0,1358	0,6028	0,7997	0,2777	0,1514	0,0015	0,4000	0,9170	1,0000
0,1301	0,6109	0,6898	0,3460	0,1514	0,0015	0,4000	0,9118	1,0000
0,1322	0,5911	0,7331	0,3400	0,1514	0,0015	0,4000	0,9138	1,0000
0,1393	0,5989	0,6492	0,4076	0,1514	0,0015	0,4000	0,9066	1,0000
0,1410	0,6266	0,7184	0,3466	0,1514	0,0015	0,4000	0,9127	1,0000
0,0987	0,9104	0,2962	0,7006	0,1514	0,0015	0,4000	0,8534	1,0000
0,0912	0,9119	0,2843	0,7027	0,1514	0,0015	0,4000	0,8522	1,0000
0,0999	0,9110	0,3310	0,6655	0,1514	0,0015	0,4000	0,8629	1,0000
0,1135	0,9148	0,3338	0,6713	0,1514	0,0015	0,4000	0,8608	1,0000
0,1097	0,9162	0,3776	0,6144	0,1514	0,0015	0,4000	0,8726	1,0000
0,4380	0,9939	0,0876	0,5865	0,7324	0,0004	0,4000	0,8842	1,0000
0,4414	0,9942	0,0783	0,6248	0,7324	0,0004	0,4000	0,8774	1,0000
0,4925	0,9942	0,0679	0,6512	0,7324	0,0004	0,4000	0,8657	1,0000
0,4452	0,9940	0,0838	0,5955	0,7324	0,0004	0,4000	0,8831	1,0000
0,4594	0,9944	0,0855	0,6283	0,7324	0,0004	0,4000	0,8764	1,0000
0,4132	0,9940	0,0669	0,5931	0,7324	0,0004	0,4000	0,8834	1,0000
0,3921	0,9939	0,0676	0,5820	0,7324	0,0004	0,4000	0,8724	1,0000
0,4136	0,9934	0,0743	0,6163	0,7324	0,0004	0,4000	0,8716	1,0000
0,4258	0,9941	0,0675	0,6138	0,7324	0,0004	0,4000	0,8740	1,0000
0,4186	0,9946	0,0679	0,6120	0,7324	0,0004	0,4000	0,8757	1,0000
0,3938	0,9522	0,2224	0,8024	0,1514	0,0010	0,4000	0,8054	1,0000
0,4023	0,9523	0,2215	0,8060	0,1514	0,0010	0,4000	0,8151	1,0000
0,3949	0,9546	0,2144	0,8069	0,1514	0,0010	0,4000	0,8060	1,0000
0,4254	0,9531	0,2308	0,8042	0,1514	0,0010	0,4000	0,8081	1,0000
0,4038	0,9549	0,2136	0,8148	0,1514	0,0010	0,4000	0,8052	1,0000
0,4339	0,9229	0,2696	0,7754	0,1514	0,0010	0,4000	0,8296	1,0000
0,4355	0,9224	0,2810	0,7637	0,1514	0,0010	0,4000	0,8316	1,0000
0,4261	0,9218	0,2898	0,7576	0,1514	0,0010	0,4000	0,8341	1,0000
0,4370	0,9246	0,2932	0,7582	0,1514	0,0010	0,4000	0,8367	1,0000
0,4436	0,9224	0,2800	0,7714	0,1514	0,0010	0,4000	0,8301	1,0000
0,4362	0,8917	0,3159	0,7370	0,1514	0,0010	0,4000	0,8481	1,0000
0,4396	0,8915	0,3422	0,7126	0,1514	0,0010	0,4000	0,8532	1,0000

Tabela A1.2 – Continuação

E1	E2	E3	E4	E5	E6	E7	E8	E9
0,4333	0,8932	0,3294	0,7252	0,1514	0,0010	0,4000	0,8505	1,0000
0,4395	0,8967	0,3145	0,7328	0,1514	0,0010	0,4000	0,8494	1,0000
0,4460	0,8940	0,3321	0,7198	0,1514	0,0010	0,4000	0,8510	1,0000
0,3614	0,7132	0,4143	0,7882	0,1514	0,0015	0,4000	0,8102	1,0000
0,3671	0,7148	0,4382	0,7698	0,1514	0,0015	0,4000	0,8122	1,0000
0,3746	0,7190	0,4451	0,7716	0,1514	0,0015	0,4000	0,8162	1,0000
0,3701	0,7202	0,4317	0,7808	0,1514	0,0015	0,4000	0,8118	1,0000
0,3758	0,7204	0,4124	0,7997	0,1514	0,0015	0,4000	0,8123	1,0000
0,3914	0,3596	0,5588	0,7113	0,1514	0,0015	0,4000	0,8456	1,0000
0,3981	0,3555	0,5583	0,7256	0,1514	0,0015	0,4000	0,8465	1,0000
0,4035	0,3586	0,5983	0,7074	0,1514	0,0015	0,4000	0,8509	1,0000
0,4047	0,3729	0,5501	0,7233	0,1514	0,0015	0,4000	0,8437	1,0000
0,3974	0,3483	0,5477	0,7234	0,1514	0,0015	0,4000	0,8421	1,0000
0,3201	0,8676	0,2860	0,8576	0,1514	0,0015	0,4000	0,7699	1,0000
0,3298	0,8707	0,3046	0,8509	0,1514	0,0015	0,4000	0,7791	1,0000
0,3365	0,8761	0,3042	0,8475	0,1514	0,0015	0,4000	0,7801	1,0000
0,3371	0,8741	0,3330	0,8293	0,1514	0,0015	0,4000	0,7870	1,0000
0,3329	0,8692	0,3225	0,8372	0,1514	0,0015	0,4000	0,7789	1,0000
0,6302	0,9920	0,0642	0,7406	0,7324	0,0004	0,4000	0,8362	1,0000
0,6087	0,9922	0,0630	0,7362	0,7324	0,0004	0,4000	0,8398	1,0000
0,6168	0,9926	0,0666	0,7410	0,7324	0,0004	0,4000	0,8440	1,0000
0,6241	0,9923	0,0630	0,7456	0,7324	0,0004	0,4000	0,8358	1,0000
0,6186	0,9918	0,0679	0,7241	0,7324	0,0004	0,4000	0,8378	1,0000
0,5960	0,9921	0,0555	0,7334	0,7324	0,0004	0,4000	0,8408	1,0000
0,6590	0,9914	0,0787	0,7459	0,7324	0,0004	0,4000	0,8435	1,0000
0,6364	0,9917	0,0682	0,7417	0,7324	0,0004	0,4000	0,8423	1,0000
0,6276	0,9915	0,0773	0,7245	0,7324	0,0004	0,4000	0,8433	1,0000
0,6268	0,9914	0,0641	0,7387	0,7324	0,0004	0,4000	0,8358	1,0000
0,5238	0,9471	0,2040	0,8677	0,1514	0,0010	0,4000	0,7645	1,0000
0,5486	0,9478	0,2205	0,8657	0,1514	0,0010	0,4000	0,7737	1,0000
0,5554	0,9473	0,2083	0,8782	0,1514	0,0010	0,4000	0,7628	1,0000
0,5379	0,9463	0,2106	0,8704	0,1514	0,0010	0,4000	0,7648	1,0000
0,5445	0,9456	0,2093	0,8744	0,1514	0,0010	0,4000	0,7662	1,0000
0,5794	0,9095	0,2583	0,8441	0,1514	0,0010	0,4000	0,7887	1,0000
0,5881	0,9149	0,2797	0,8339	0,1514	0,0010	0,4000	0,8000	1,0000
0,5907	0,9122	0,2650	0,8409	0,1514	0,0010	0,4000	0,7971	1,0000
0,5894	0,9107	0,2672	0,8384	0,1514	0,0010	0,4000	0,7976	1,0000
0,5850	0,9138	0,2784	0,8310	0,1514	0,0010	0,4000	0,7986	1,0000
0,5831	0,8753	0,3505	0,7666	0,1514	0,0010	0,4000	0,8261	1,0000
0,6002	0,8821	0,3147	0,8050	0,1514	0,0010	0,4000	0,8192	1,0000
0,6039	0,8785	0,3295	0,7939	0,1514	0,0010	0,4000	0,8236	1,0000

Tabela A1.2 – Continuação

E1	E2	E3	E4	E5	E6	E7	E8	E9
0,5922	0,8784	0,3148	0,8041	0,1514	0,0010	0,4000	0,8213	1,0000
0,6025	0,8834	0,3135	0,8087	0,1514	0,0010	0,4000	0,8182	1,0000
0,5423	0,6888	0,3719	0,8649	0,1514	0,0015	0,4000	0,7711	1,0000
0,5517	0,6967	0,3473	0,8925	0,1514	0,0015	0,4000	0,7657	1,0000
0,5581	0,6986	0,3862	0,8748	0,1514	0,0015	0,4000	0,7715	1,0000
0,5105	0,6832	0,3693	0,8737	0,1514	0,0015	0,4000	0,7648	1,0000
0,5300	0,6882	0,3767	0,8763	0,1514	0,0015	0,4000	0,7705	1,0000
0,5634	0,2705	0,5759	0,7899	0,1514	0,0015	0,4000	0,8137	1,0000
0,5246	0,2535	0,4945	0,8247	0,1514	0,0015	0,4000	0,7985	1,0000
0,5498	0,2565	0,5079	0,8317	0,1514	0,0015	0,4000	0,8022	1,0000
0,5570	0,2667	0,5194	0,8228	0,1514	0,0015	0,4000	0,8047	1,0000
0,5518	0,2655	0,4928	0,8303	0,1514	0,0015	0,4000	0,8006	1,0000
0,4892	0,8541	0,2804	0,9192	0,1514	0,0015	0,4000	0,7214	1,0000
0,5190	0,8520	0,2874	0,9260	0,1514	0,0015	0,4000	0,7207	1,0000
0,5298	0,8514	0,2898	0,9241	0,1514	0,0015	0,4000	0,7208	1,0000
0,5156	0,8607	0,3177	0,9005	0,1514	0,0015	0,4000	0,7422	1,0000
0,4930	0,8489	0,2875	0,9161	0,1514	0,0015	0,4000	0,7270	1,0000
0,5680	0,9921	0,0416	0,7582	0,7324	0,0004	0,4000	0,8215	1,0000
0,6133	0,9918	0,0769	0,7195	0,7324	0,0004	0,4000	0,8474	1,0000
0,5869	0,9922	0,0665	0,7162	0,7324	0,0004	0,4000	0,8460	1,0000
0,5950	0,9927	0,0653	0,7286	0,7324	0,0004	0,4000	0,8485	1,0000
0,6008	0,9931	0,0723	0,7084	0,7324	0,0004	0,4000	0,8421	1,0000
0,6351	0,9924	0,0710	0,7368	0,7324	0,0004	0,4000	0,8443	1,0000
0,6083	0,9931	0,0626	0,7268	0,7324	0,0004	0,4000	0,8425	1,0000
0,5982	0,9923	0,0742	0,7110	0,7324	0,0004	0,4000	0,8491	1,0000
0,5767	0,9917	0,0617	0,7224	0,7324	0,0004	0,4000	0,8457	1,0000
0,6127	0,9921	0,0830	0,7066	0,7324	0,0004	0,4000	0,8448	1,0000
0,5535	0,9476	0,2043	0,8793	0,1514	0,0010	0,4000	0,7602	1,0000
0,5508	0,9429	0,1997	0,8848	0,1514	0,0010	0,4000	0,7540	1,0000
0,5368	0,9434	0,2040	0,8777	0,1514	0,0010	0,4000	0,7567	1,0000
0,5508	0,9463	0,1979	0,8836	0,1514	0,0010	0,4000	0,7560	1,0000
0,5643	0,9478	0,1909	0,8941	0,1514	0,0010	0,4000	0,7472	1,0000
0,5857	0,9107	0,2530	0,8476	0,1514	0,0010	0,4000	0,7891	1,0000
0,5853	0,9124	0,2643	0,8421	0,1514	0,0010	0,4000	0,7909	1,0000
0,5878	0,9122	0,2525	0,8544	0,1514	0,0010	0,4000	0,7877	1,0000
0,5845	0,9111	0,2532	0,8495	0,1514	0,0010	0,4000	0,7887	1,0000
0,5852	0,9053	0,2820	0,8299	0,1514	0,0010	0,4000	0,7953	1,0000
0,6066	0,8747	0,3137	0,8105	0,1514	0,0010	0,4000	0,8112	1,0000
0,6026	0,8694	0,3150	0,8060	0,1514	0,0010	0,4000	0,8146	1,0000
0,6041	0,8730	0,3222	0,8055	0,1514	0,0010	0,4000	0,8174	1,0000
0,5922	0,8692	0,3133	0,8054	0,1514	0,0010	0,4000	0,8118	1,0000

Tabela A1.2 – Continuação

E1	E2	E3	E4	E5	E6	E7	E8	E9
0,5964	0,8733	0,3181	0,7999	0,1514	0,0010	0,4000	0,8143	1,0000
0,5238	0,6815	0,4195	0,8549	0,1514	0,0015	0,4000	0,7730	1,0000
0,5252	0,6786	0,4439	0,8436	0,1514	0,0015	0,4000	0,7758	1,0000
0,5226	0,6760	0,4518	0,8255	0,1514	0,0015	0,4000	0,7793	1,0000
0,5270	0,6779	0,4470	0,8423	0,1514	0,0015	0,4000	0,7745	1,0000
0,5156	0,6627	0,4324	0,8362	0,1514	0,0015	0,4000	0,7771	1,0000
0,5402	0,2269	0,5739	0,7733	0,1514	0,0015	0,4000	0,8155	1,0000
0,5472	0,2326	0,5577	0,7833	0,1514	0,0015	0,4000	0,8134	1,0000
0,5608	0,2246	0,6137	0,7569	0,1514	0,0015	0,4000	0,8175	1,0000
0,5452	0,2423	0,5068	0,8022	0,1514	0,0015	0,4000	0,8076	1,0000
0,5640	0,2268	0,6213	0,7449	0,1514	0,0015	0,4000	0,8193	1,0000
0,4492	0,8501	0,3161	0,8821	0,1514	0,0015	0,4000	0,7358	1,0000
0,4534	0,8481	0,3368	0,8777	0,1514	0,0015	0,4000	0,7462	1,0000
0,4471	0,8502	0,3315	0,8780	0,1514	0,0015	0,4000	0,7479	1,0000
0,4545	0,8515	0,3269	0,8806	0,1514	0,0015	0,4000	0,7476	1,0000
0,4391	0,8503	0,3095	0,8865	0,1514	0,0015	0,4000	0,7380	1,0000
0,7446	0,9895	0,0522	0,8044	0,7324	0,0004	0,4000	0,8019	1,0000
0,7071	0,9899	0,0667	0,7811	0,7324	0,0004	0,4000	0,8217	1,0000
0,6903	0,9906	0,0628	0,7685	0,7324	0,0004	0,4000	0,8236	1,0000
0,7500	0,9905	0,0609	0,7988	0,7324	0,0004	0,4000	0,8127	1,0000
0,7726	0,9901	0,0650	0,7867	0,7324	0,0004	0,4000	0,8188	1,0000
0,6769	0,9904	0,1001	0,7255	0,7324	0,0004	0,4000	0,8401	1,0000
0,6885	0,9903	0,0702	0,7646	0,7324	0,0004	0,4000	0,8230	1,0000
0,7364	0,9905	0,0743	0,7742	0,7324	0,0004	0,4000	0,8269	1,0000
0,7289	0,9895	0,0785	0,7605	0,7324	0,0004	0,4000	0,8248	1,0000
0,6919	0,9899	0,0683	0,7622	0,7324	0,0004	0,4000	0,8196	1,0000
0,6015	0,9422	0,1919	0,9049	0,1514	0,0010	0,4000	0,7277	1,0000
0,5885	0,9379	0,2074	0,8890	0,1514	0,0010	0,4000	0,7410	1,0000
0,6063	0,9395	0,1890	0,9088	0,1514	0,0010	0,4000	0,7313	1,0000
0,6389	0,9422	0,2178	0,8955	0,1514	0,0010	0,4000	0,7438	1,0000
0,6186	0,9413	0,1983	0,9048	0,1514	0,0010	0,4000	0,7378	1,0000
0,6450	0,9021	0,2523	0,8681	0,1514	0,0010	0,4000	0,7659	1,0000
0,6507	0,8962	0,2720	0,8590	0,1514	0,0010	0,4000	0,7714	1,0000
0,6688	0,9009	0,2671	0,8662	0,1514	0,0010	0,4000	0,7722	1,0000
0,6675	0,9050	0,2576	0,8705	0,1514	0,0010	0,4000	0,7751	1,0000
0,6596	0,9055	0,2610	0,8642	0,1514	0,0010	0,4000	0,7710	1,0000
0,6549	0,8611	0,2841	0,8527	0,1514	0,0010	0,4000	0,7819	1,0000
0,6717	0,8611	0,3201	0,8292	0,1514	0,0010	0,4000	0,7973	1,0000
0,6816	0,8664	0,3023	0,8460	0,1514	0,0010	0,4000	0,7932	1,0000
0,6832	0,8600	0,3220	0,8303	0,1514	0,0010	0,4000	0,8014	1,0000
0,6801	0,8623	0,2911	0,8589	0,1514	0,0010	0,4000	0,7870	1,0000

Tabela A1.2 – Continuação

E1	E2	E3	E4	E5	E6	E7	E8	E9
0,5867	0,6489	0,3558	0,9073	0,1514	0,0015	0,4000	0,7271	1,0000
0,5949	0,6563	0,3444	0,9107	0,1514	0,0015	0,4000	0,7336	1,0000
0,5976	0,6466	0,3474	0,9074	0,1514	0,0015	0,4000	0,7306	1,0000
0,6008	0,6677	0,3261	0,9223	0,1514	0,0015	0,4000	0,7305	1,0000
0,5912	0,6569	0,3442	0,9075	0,1514	0,0015	0,4000	0,7291	1,0000
0,6177	0,2034	0,4915	0,8595	0,1514	0,0015	0,4000	0,7711	1,0000
0,6262	0,1876	0,5131	0,8383	0,1514	0,0015	0,4000	0,7783	1,0000
0,6246	0,1879	0,5029	0,8485	0,1514	0,0015	0,4000	0,7769	1,0000
0,6145	0,1888	0,4789	0,8589	0,1514	0,0015	0,4000	0,7712	1,0000
0,6056	0,1674	0,4809	0,8521	0,1514	0,0015	0,4000	0,7701	1,0000
0,5194	0,8439	0,2595	0,9365	0,1514	0,0015	0,4000	0,6876	1,0000
0,5289	0,8358	0,2838	0,9276	0,1514	0,0015	0,4000	0,6944	1,0000
0,5403	0,8418	0,2732	0,9302	0,1514	0,0015	0,4000	0,6876	1,0000
0,5477	0,8406	0,2901	0,9273	0,1514	0,0015	0,4000	0,6950	1,0000
0,5222	0,8464	0,2603	0,9375	0,1514	0,0015	0,4000	0,6852	1,0000
0,2964	0,4601	0,5767	0,5577	0,1514	0,0015	0,4000	0,8763	1,0000
0,2955	0,5032	0,5787	0,5536	0,1514	0,0015	0,4000	0,8792	1,0000
0,2771	0,4852	0,5599	0,5607	0,1514	0,0015	0,4000	0,8764	1,0000
0,2822	0,4855	0,5676	0,5717	0,1514	0,0015	0,4000	0,8777	1,0000
0,2979	0,5186	0,5078	0,6388	0,1514	0,0015	0,4000	0,8673	1,0000
0,2709	0,4858	0,5669	0,5357	0,1514	0,0015	0,4000	0,8815	1,0000
0,2642	0,4637	0,5723	0,5134	0,1514	0,0015	0,4000	0,8807	1,0000
0,2785	0,4315	0,5861	0,4978	0,1514	0,0015	0,4000	0,8792	1,0000
0,2808	0,5091	0,5992	0,5262	0,1514	0,0015	0,4000	0,8895	1,0000
0,2566	0,5015	0,5289	0,5564	0,1514	0,0015	0,4000	0,8865	1,0000
0,2917	0,5155	0,5697	0,5571	0,1514	0,0015	0,4000	0,8830	1,0000
0,2858	0,5049	0,5583	0,5562	0,1514	0,0015	0,4000	0,8751	1,0000
0,2937	0,4962	0,5479	0,6069	0,1514	0,0015	0,4000	0,8799	1,0000
0,2973	0,4847	0,6447	0,5154	0,1514	0,0015	0,4000	0,8887	1,0000
0,2950	0,4876	0,6202	0,5163	0,1514	0,0015	0,4000	0,8868	1,0000
0,2766	0,4722	0,5952	0,5199	0,1514	0,0015	0,4000	0,8833	1,0000
0,2814	0,4579	0,5884	0,5432	0,1514	0,0015	0,4000	0,8800	1,0000
0,3078	0,4898	0,5757	0,6230	0,1514	0,0015	0,4000	0,8859	1,0000
0,3069	0,4832	0,5474	0,6673	0,1514	0,0015	0,4000	0,8845	1,0000
0,3049	0,4837	0,5757	0,6159	0,1514	0,0015	0,4000	0,8846	1,0000
0,2916	0,8702	0,3577	0,7798	0,1514	0,0015	0,4000	0,8126	1,0000
0,2591	0,8710	0,3350	0,7764	0,1514	0,0015	0,4000	0,8088	1,0000
0,2457	0,8770	0,2742	0,8064	0,1514	0,0015	0,4000	0,7888	1,0000
0,2616	0,8715	0,3778	0,7366	0,1514	0,0015	0,4000	0,8191	1,0000
0,2614	0,8636	0,3781	0,7359	0,1514	0,0015	0,4000	0,8159	1,0000
0,2237	0,8790	0,4053	0,6819	0,1514	0,0015	0,4000	0,8350	1,0000
0,2398	0,8745	0,3881	0,7168	0,1514	0,0015	0,4000	0,8360	1,0000

Tabela A1.2 – Continuação

E1	E2	E3	E4	E5	E6	E7	E8	E9
0,2249	0,8600	0,3159	0,7283	0,1514	0,0015	0,4000	0,8166	1,0000
0,2492	0,8785	0,4132	0,7089	0,1514	0,0015	0,4000	0,8377	1,0000
0,2516	0,8781	0,3868	0,7280	0,1514	0,0015	0,4000	0,8377	1,0000
0,2737	0,8745	0,3641	0,7534	0,1514	0,0015	0,4000	0,8197	1,0000
0,2583	0,8697	0,3425	0,7627	0,1514	0,0015	0,4000	0,8185	1,0000
0,2619	0,8740	0,3301	0,7772	0,1514	0,0015	0,4000	0,8080	1,0000
0,2776	0,8689	0,3841	0,7328	0,1514	0,0015	0,4000	0,8144	1,0000
0,2589	0,8721	0,3974	0,7102	0,1514	0,0015	0,4000	0,8145	1,0000
0,2737	0,8724	0,3754	0,7478	0,1514	0,0015	0,4000	0,8124	1,0000
0,2551	0,8675	0,3519	0,7485	0,1514	0,0015	0,4000	0,8058	1,0000
0,2588	0,8656	0,3606	0,7324	0,1514	0,0015	0,4000	0,8084	1,0000
0,2591	0,8737	0,3651	0,7485	0,1514	0,0015	0,4000	0,8134	1,0000
0,2611	0,8711	0,3394	0,7486	0,1514	0,0015	0,4000	0,8100	1,0000
0,5811	0,6515	0,2938	0,9498	0,1514	0,0015	0,4000	0,7017	1,0000
0,5856	0,6534	0,2989	0,9456	0,1514	0,0015	0,4000	0,7004	1,0000
0,5604	0,6406	0,2918	0,9443	0,1514	0,0015	0,4000	0,6987	1,0000
0,5777	0,6582	0,2599	0,9620	0,1514	0,0015	0,4000	0,6945	1,0000
0,5922	0,6705	0,2786	0,9587	0,1514	0,0015	0,4000	0,6948	1,0000
0,5578	0,6347	0,2884	0,9487	0,1514	0,0015	0,4000	0,6970	1,0000
0,5768	0,6509	0,2777	0,9529	0,1514	0,0015	0,4000	0,7024	1,0000
0,5795	0,6503	0,2899	0,9558	0,1514	0,0015	0,4000	0,7044	1,0000
0,6030	0,6621	0,2957	0,9534	0,1514	0,0015	0,4000	0,7102	1,0000
0,5933	0,6462	0,3114	0,9436	0,1514	0,0015	0,4000	0,7087	1,0000
0,5915	0,6531	0,2977	0,9547	0,1514	0,0015	0,4000	0,7109	1,0000
0,5891	0,6533	0,3063	0,9433	0,1514	0,0015	0,4000	0,7064	1,0000
0,5828	0,6448	0,3033	0,9410	0,1514	0,0015	0,4000	0,7069	1,0000
0,5733	0,6541	0,2888	0,9524	0,1514	0,0015	0,4000	0,7035	1,0000
0,5955	0,6567	0,3012	0,9495	0,1514	0,0015	0,4000	0,7091	1,0000
0,5741	0,6506	0,2763	0,9630	0,1514	0,0015	0,4000	0,6959	1,0000
0,6080	0,6601	0,2815	0,9590	0,1514	0,0015	0,4000	0,6976	1,0000
0,5904	0,6501	0,2831	0,9547	0,1514	0,0015	0,4000	0,6954	1,0000
0,6145	0,6729	0,2724	0,9690	0,1514	0,0015	0,4000	0,6940	1,0000
0,5417	0,6362	0,2750	0,9490	0,1514	0,0015	0,4000	0,6881	1,0000
0,3549	0,3333	0,7014	0,5447	0,1514	0,0015	0,4000	0,8353	1,0000
0,3606	0,3043	0,8056	0,4745	0,1514	0,0015	0,4000	0,8388	1,0000
0,3760	0,3371	0,7724	0,5182	0,1514	0,0015	0,4000	0,8537	1,0000
0,3601	0,3238	0,7571	0,5007	0,1514	0,0015	0,4000	0,8399	1,0000
0,3569	0,3367	0,6421	0,5599	0,1514	0,0015	0,4000	0,8330	1,0000
0,3173	0,4318	0,6568	0,5407	0,1514	0,0015	0,4000	0,8693	1,0000
0,3231	0,4136	0,6772	0,5444	0,1514	0,0015	0,4000	0,8687	1,0000
0,3244	0,4017	0,6307	0,5783	0,1514	0,0015	0,4000	0,8567	1,0000
0,3282	0,3979	0,7184	0,5151	0,1514	0,0015	0,4000	0,8702	1,0000

Tabela A1.2 – Continuação

E1	E2	E3	E4	E5	E6	E7	E8	E9
0,3209	0,3755	0,6865	0,5237	0,1514	0,0015	0,4000	0,8543	1,0000
0,3357	0,4082	0,6226	0,6317	0,1514	0,0015	0,4000	0,8436	1,0000
0,3404	0,3805	0,6548	0,6223	0,1514	0,0015	0,4000	0,8410	1,0000
0,3533	0,3912	0,6266	0,6444	0,1514	0,0015	0,4000	0,8413	1,0000
0,3546	0,3648	0,6101	0,6572	0,1514	0,0015	0,4000	0,8351	1,0000
0,3586	0,3637	0,6127	0,6641	0,1514	0,0015	0,4000	0,8385	1,0000
0,3453	0,3670	0,6461	0,6147	0,1514	0,0015	0,4000	0,8435	1,0000
0,3509	0,3592	0,6796	0,6005	0,1514	0,0015	0,4000	0,8415	1,0000
0,3400	0,3693	0,6204	0,6277	0,1514	0,0015	0,4000	0,8399	1,0000
0,3531	0,3244	0,5786	0,6706	0,1514	0,0015	0,4000	0,8181	1,0000
0,3514	0,3337	0,5725	0,6744	0,1514	0,0015	0,4000	0,8217	1,0000
0,3063	0,8695	0,2344	0,8840	0,1514	0,0015	0,4000	0,7424	1,0000
0,2877	0,8597	0,2201	0,8765	0,1514	0,0015	0,4000	0,7210	1,0000
0,2646	0,8596	0,1901	0,8837	0,1514	0,0015	0,4000	0,6963	1,0000
0,3146	0,8686	0,2516	0,8729	0,1514	0,0015	0,4000	0,7445	1,0000
0,3107	0,8640	0,2380	0,8786	0,1514	0,0015	0,4000	0,7404	1,0000
0,2709	0,8651	0,2778	0,8318	0,1514	0,0015	0,4000	0,7624	1,0000
0,2802	0,8683	0,2727	0,8406	0,1514	0,0015	0,4000	0,7705	1,0000
0,2780	0,8661	0,2718	0,8413	0,1514	0,0015	0,4000	0,7696	1,0000
0,2884	0,8705	0,2804	0,8396	0,1514	0,0015	0,4000	0,7757	1,0000
0,2784	0,8715	0,2834	0,8323	0,1514	0,0015	0,4000	0,7797	1,0000
0,2733	0,8695	0,2671	0,8396	0,1514	0,0015	0,4000	0,7693	1,0000
0,2759	0,8718	0,2684	0,8437	0,1514	0,0015	0,4000	0,7720	1,0000
0,2752	0,8701	0,2738	0,8383	0,1514	0,0015	0,4000	0,7688	1,0000
0,2716	0,8641	0,2725	0,8450	0,1514	0,0015	0,4000	0,7660	1,0000
0,2819	0,8648	0,2593	0,8542	0,1514	0,0015	0,4000	0,7679	1,0000
0,2710	0,8568	0,2473	0,8513	0,1514	0,0015	0,4000	0,7388	1,0000
0,2764	0,8561	0,2133	0,8859	0,1514	0,0015	0,4000	0,7331	1,0000
0,2764	0,8567	0,2254	0,8789	0,1514	0,0015	0,4000	0,7361	1,0000
0,2780	0,8681	0,2349	0,8728	0,1514	0,0015	0,4000	0,7557	1,0000
0,2823	0,8694	0,2360	0,8755	0,1514	0,0015	0,4000	0,7575	1,0000
0,5401	0,6216	0,3820	0,8798	0,1514	0,0015	0,4000	0,7275	1,0000
0,5498	0,6302	0,3617	0,8959	0,1514	0,0015	0,4000	0,7222	1,0000
0,5495	0,6358	0,3471	0,9068	0,1514	0,0015	0,4000	0,7225	1,0000
0,5430	0,6306	0,3580	0,8991	0,1514	0,0015	0,4000	0,7123	1,0000
0,5529	0,6299	0,3421	0,9053	0,1514	0,0015	0,4000	0,7163	1,0000
0,5364	0,6307	0,3298	0,9191	0,1514	0,0015	0,4000	0,7175	1,0000
0,5276	0,6249	0,3412	0,8999	0,1514	0,0015	0,4000	0,7181	1,0000
0,5389	0,6306	0,3422	0,9006	0,1514	0,0015	0,4000	0,7172	1,0000
0,5551	0,6263	0,4075	0,8695	0,1514	0,0015	0,4000	0,7338	1,0000
0,5365	0,6358	0,3578	0,8988	0,1514	0,0015	0,4000	0,7164	1,0000
0,5605	0,6318	0,3311	0,9179	0,1514	0,0015	0,4000	0,7202	1,0000

Tabela A1.2 – Continuação

E1	E2	E3	E4	E5	E6	E7	E8	E9
0,5519	0,6379	0,3419	0,9102	0,1514	0,0015	0,4000	0,7146	1,0000
0,5380	0,6308	0,3489	0,8908	0,1514	0,0015	0,4000	0,7114	1,0000
0,5355	0,6266	0,3346	0,9032	0,1514	0,0015	0,4000	0,7058	1,0000
0,5446	0,6125	0,3457	0,8944	0,1514	0,0015	0,4000	0,7097	1,0000
0,5511	0,5984	0,3869	0,8755	0,1514	0,0015	0,4000	0,7210	1,0000
0,5447	0,6177	0,3870	0,8733	0,1514	0,0015	0,4000	0,7167	1,0000
0,5608	0,6262	0,4059	0,8818	0,1514	0,0015	0,4000	0,7349	1,0000
0,5692	0,6388	0,3906	0,8918	0,1514	0,0015	0,4000	0,7283	1,0000
0,5609	0,6305	0,3572	0,9010	0,1514	0,0015	0,4000	0,7216	1,0000

APÊNDICE II

As Figuras AII.1 a AII.17 representam os gráficos dos erros de treinamento e validação em função da geração do AG. Esses erros foram obtidos durante os treinamentos das RNAEs, realizados conforme a Tab. 4.1, para estimar a dureza Brinell.

Já o gráfico representado na Figura AII.18 indica o resultado do treinamento, via método AG-LMRB*, da RNAE de melhor desempenho obtida através da configuração 8 (Tab. 4.1).

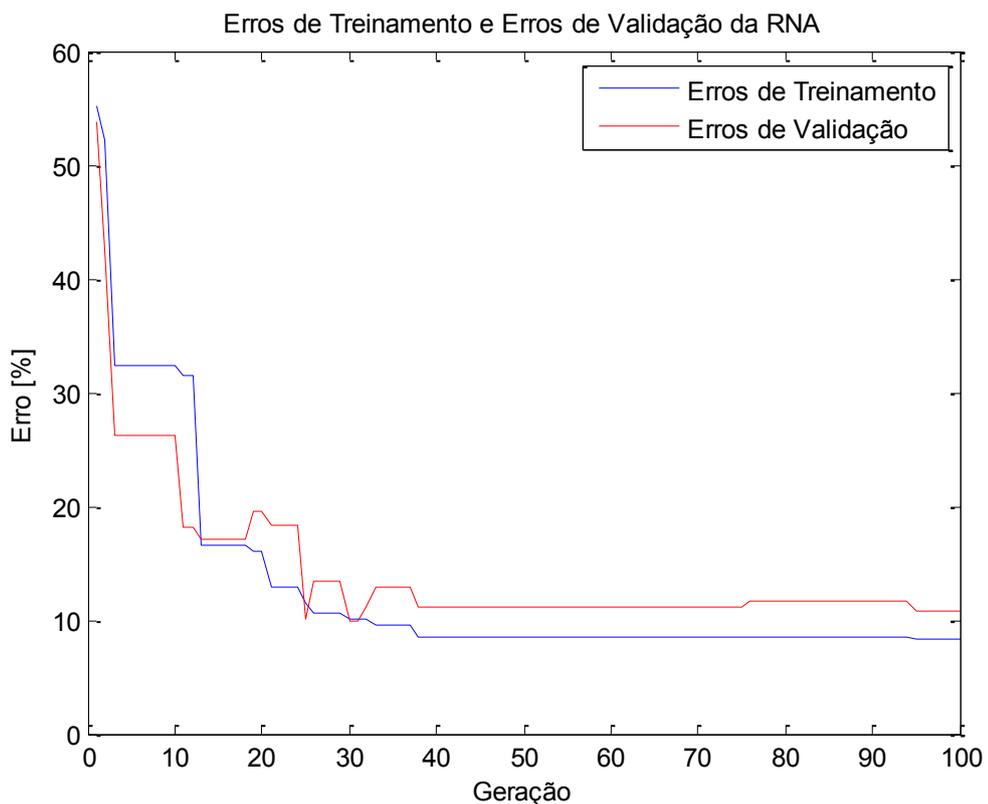


Figura AII.1 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 1 da Tab. 4.1 para estimar a dureza Brinell

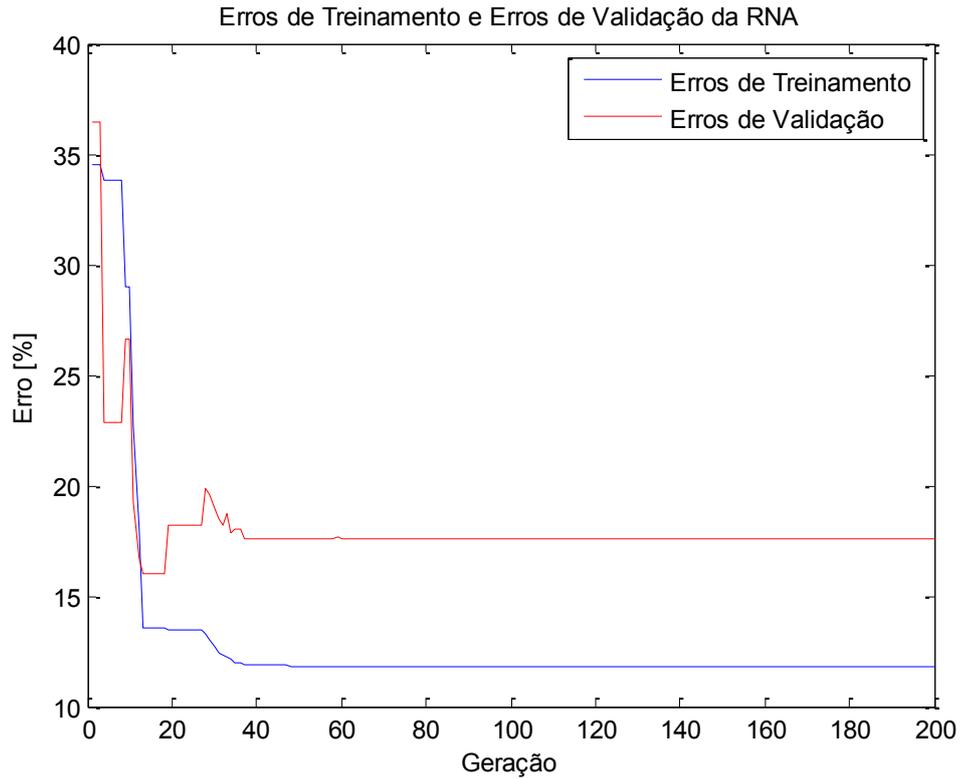


Figura AII.2 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 2 da Tab. 4.1 para estimar a dureza Brinell

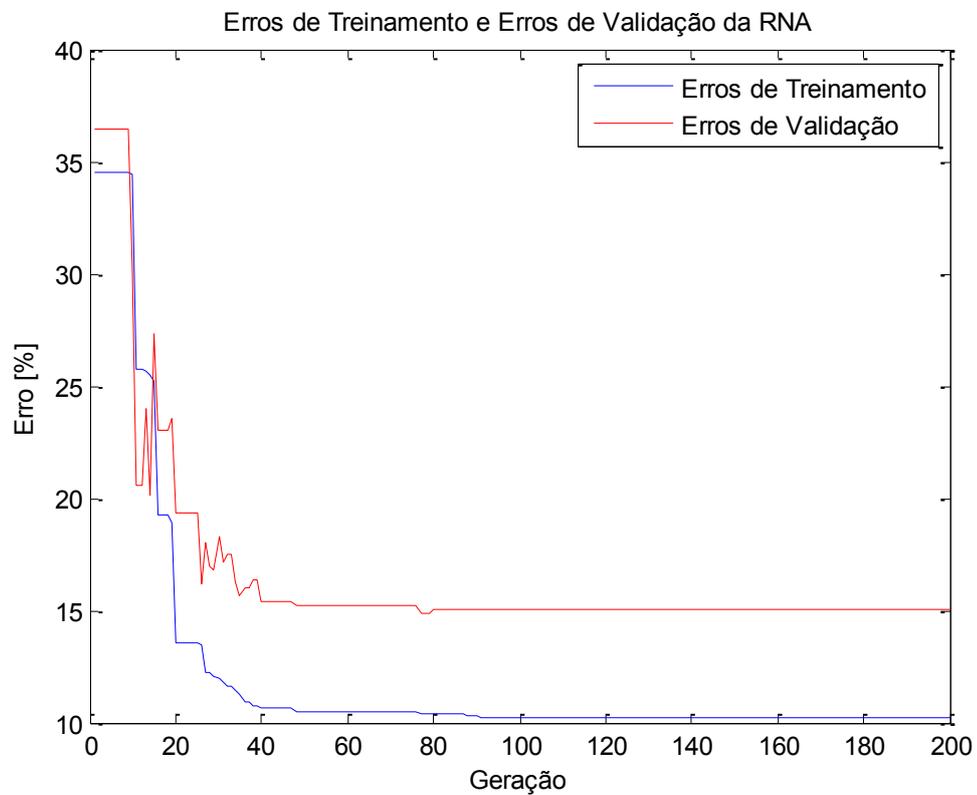


Figura AII.3 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 3 da Tab. 4.1 para estimar a dureza Brinell

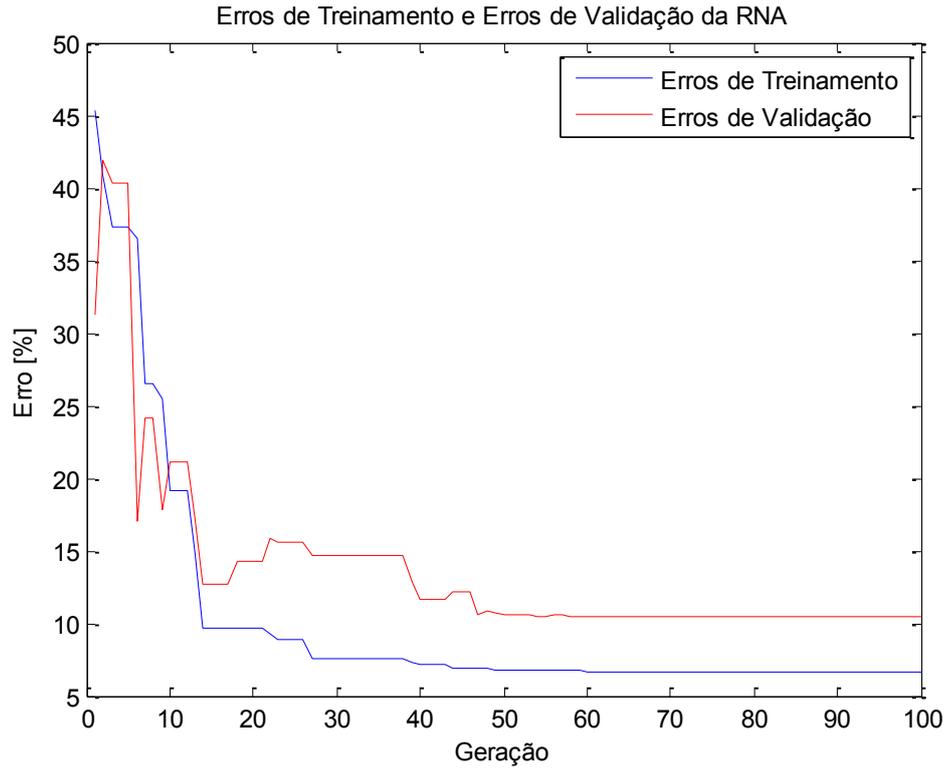


Figura AII.4 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 4 da Tab. 4.1 para estimar a dureza Brinell

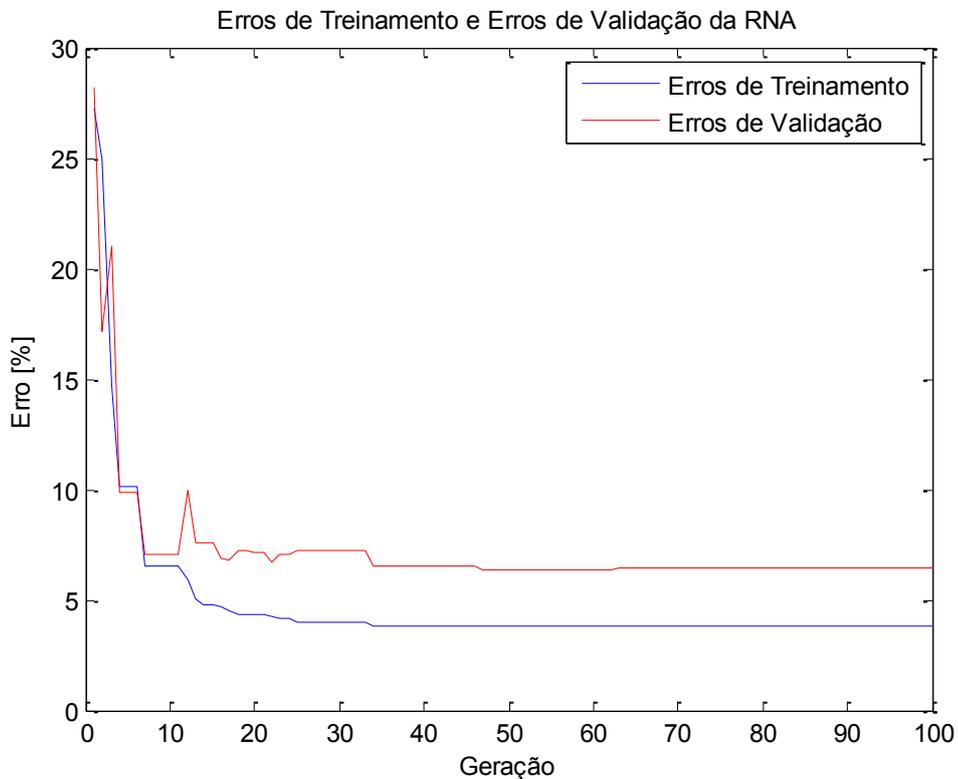


Figura AII.5 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 5 da Tab. 4.1 para estimar a dureza Brinell

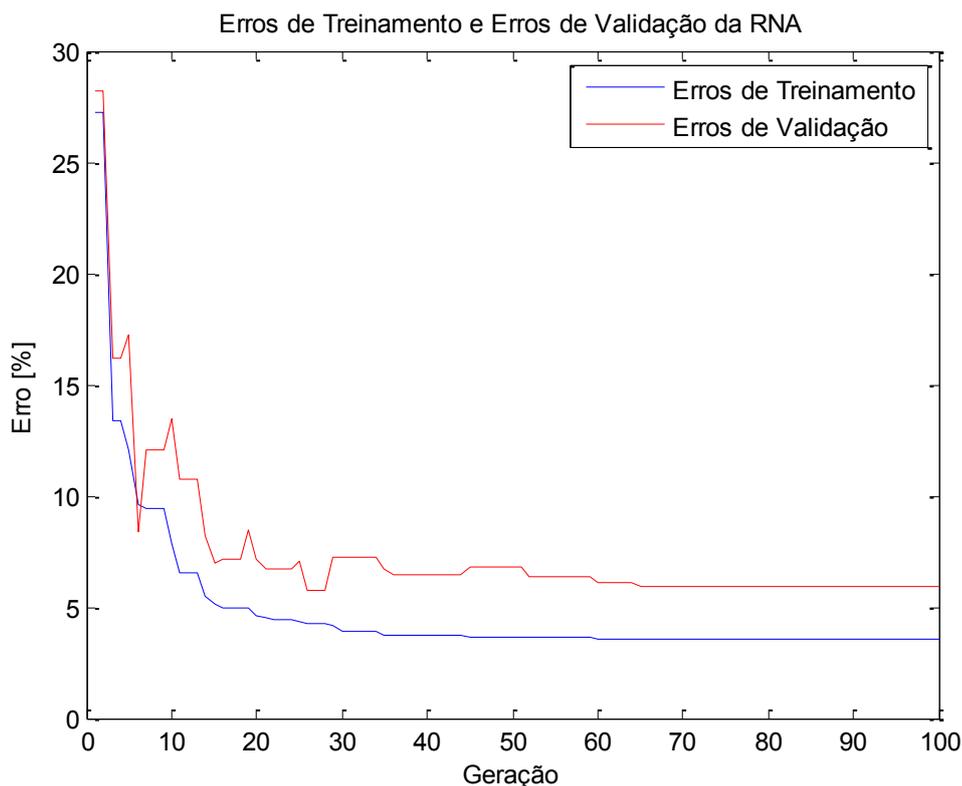


Figura AII.6 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 6 da Tab. 4.1 para estimar a dureza Brinell

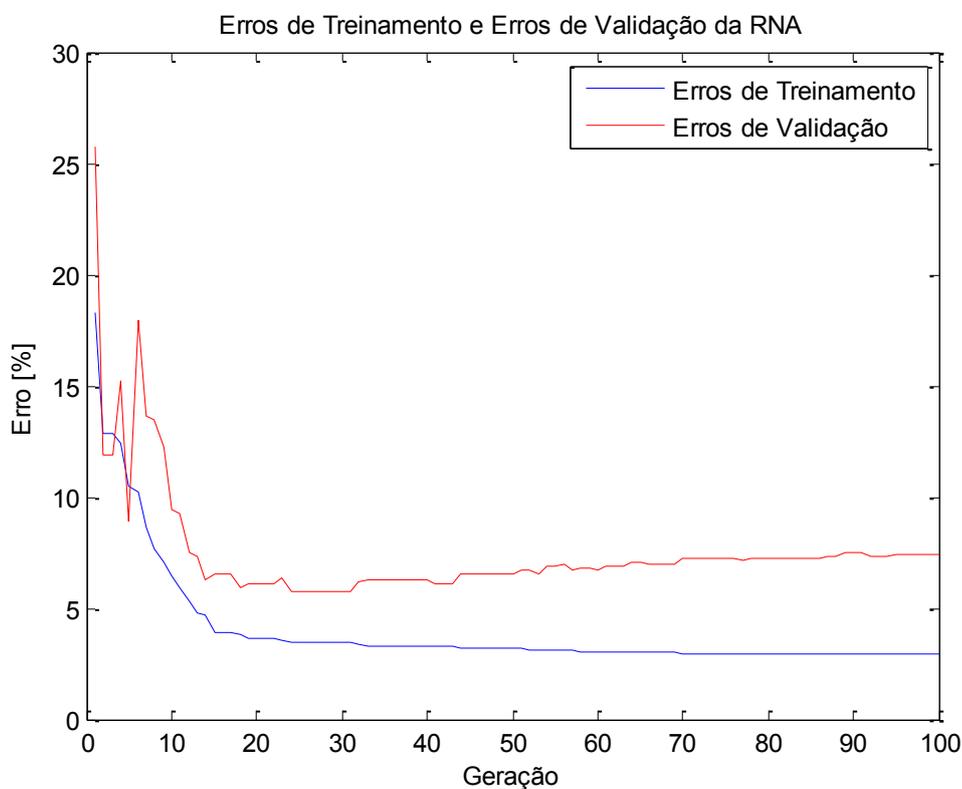


Figura AII.7 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 7 da Tab. 4.1 para estimar a dureza Brinell

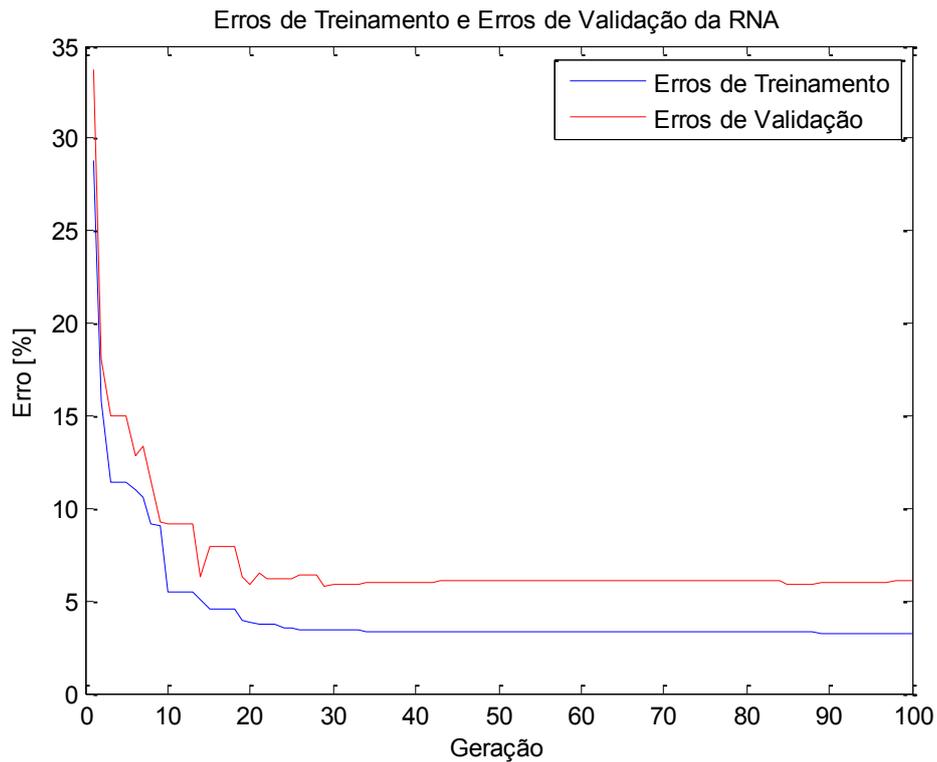


Figura All.8 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 8 da Tab. 4.1 para estimar a dureza Brinell

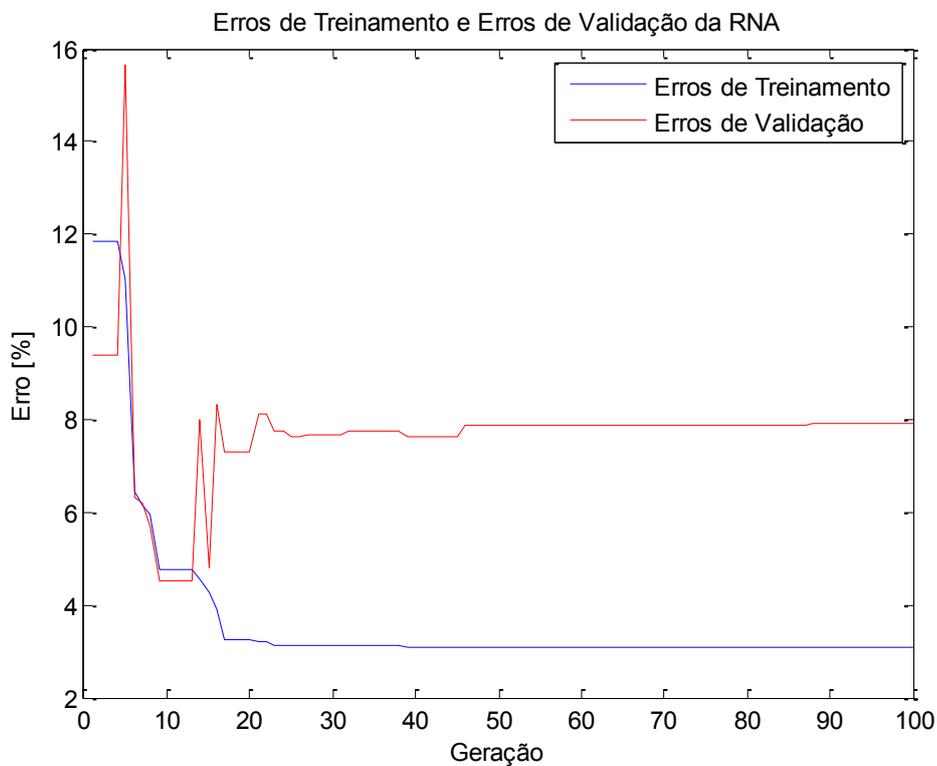


Figura All.9 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 9 da Tab. 4.1 para estimar a dureza Brinell

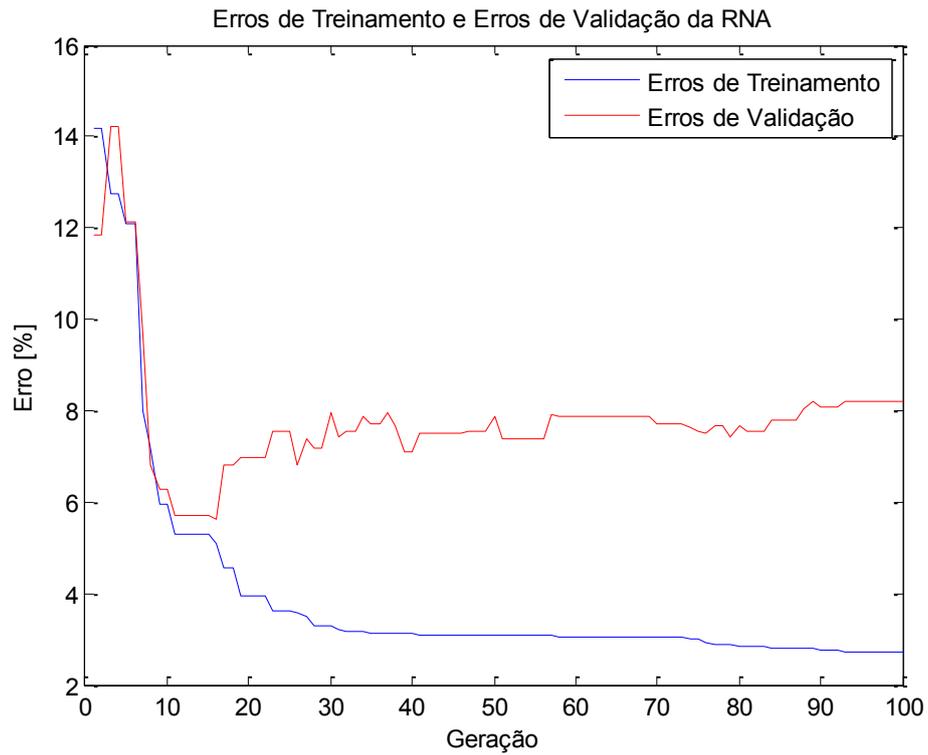


Figura AII.10 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 10 da Tab. 4.1 para estimar a dureza Brinell

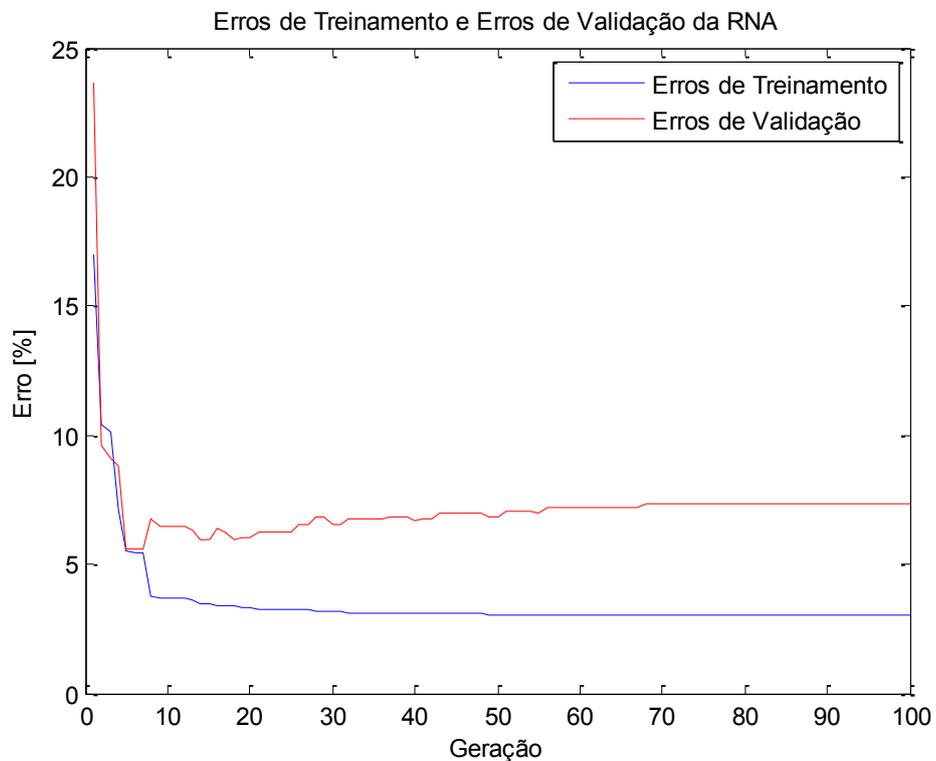


Figura AII.11 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 11 da Tab. 4.1 para estimar a dureza Brinell

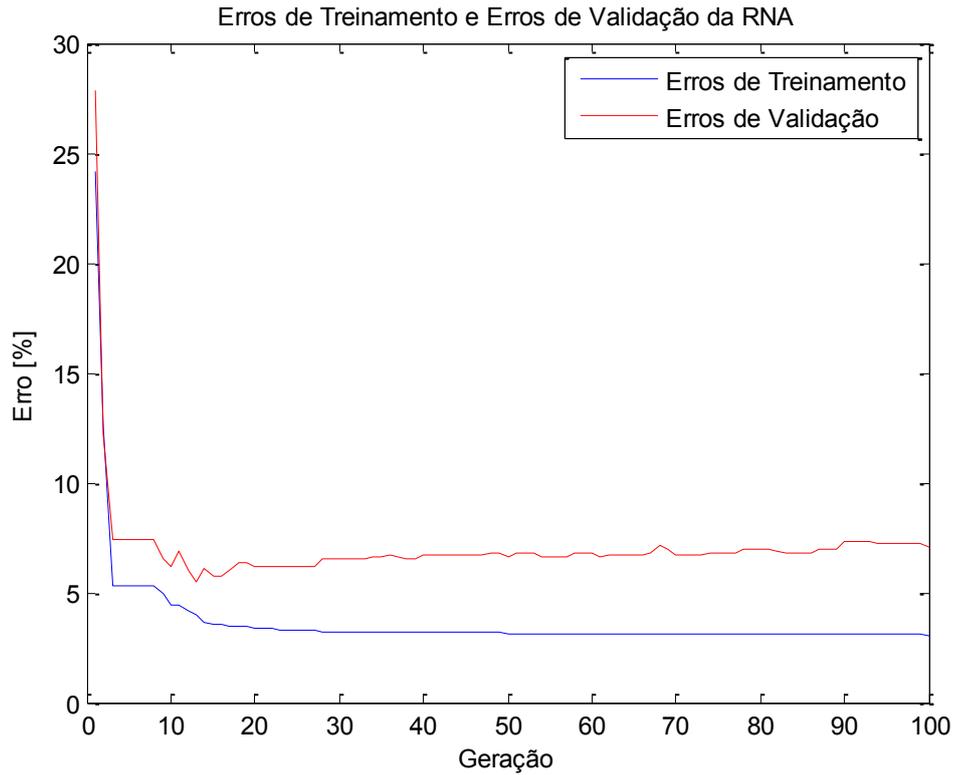


Figura AII.12 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 12 da Tab. 4.1 para estimar a dureza Brinell

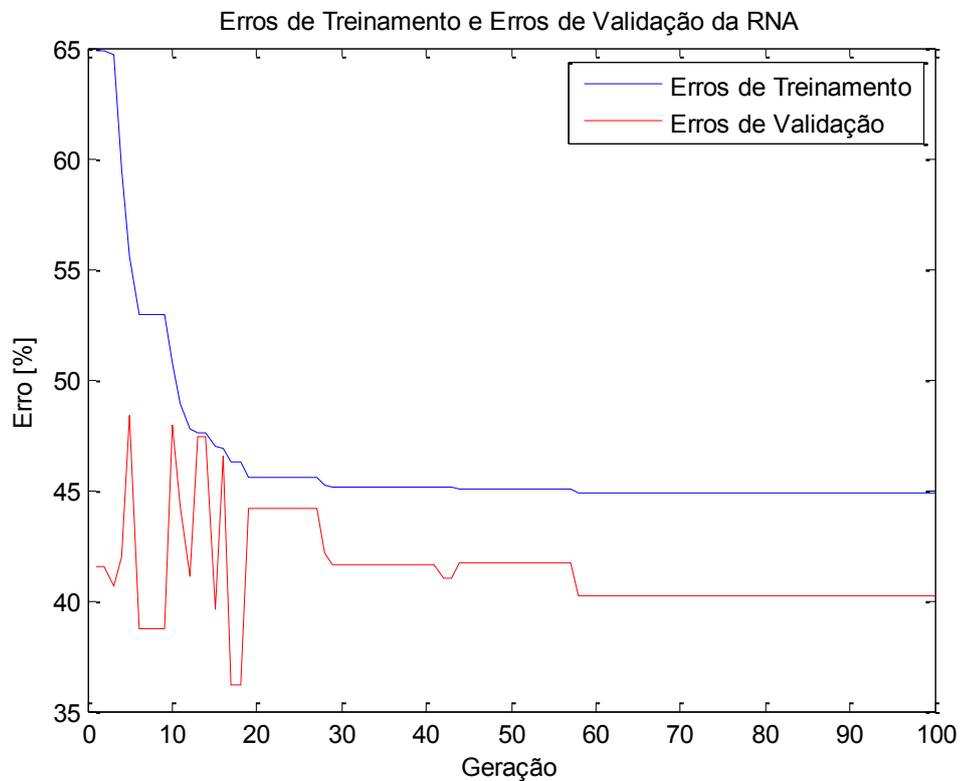


Figura AII.13 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 13 da Tab. 4.1 para estimar a dureza Brinell

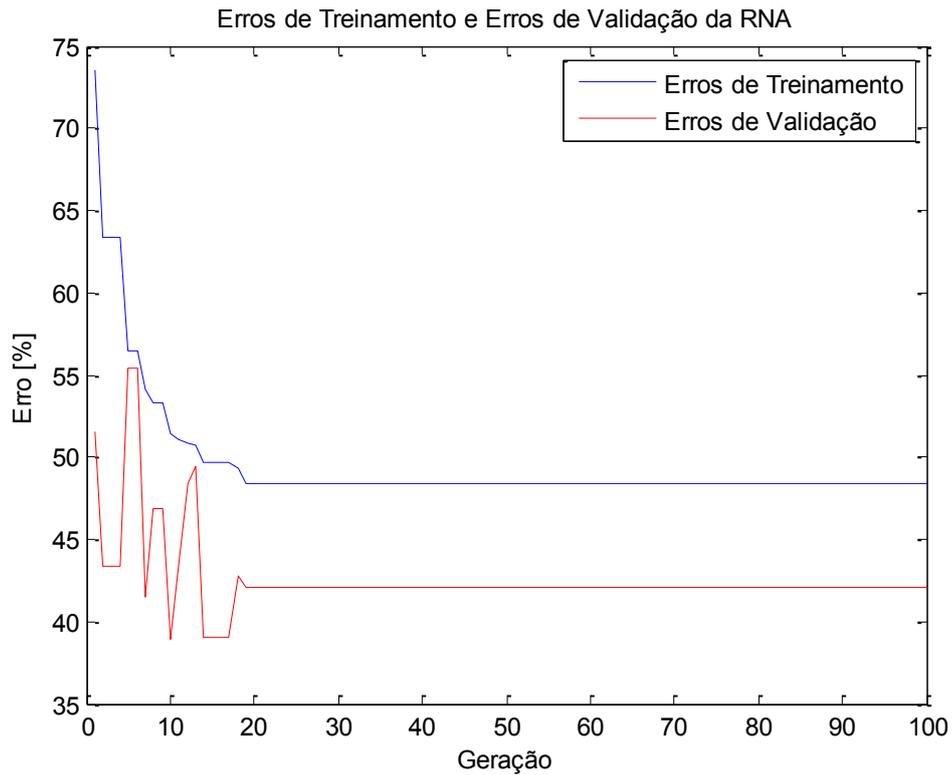


Figura All.14 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 14 da Tab. 4.1 para estimar a dureza Brinell

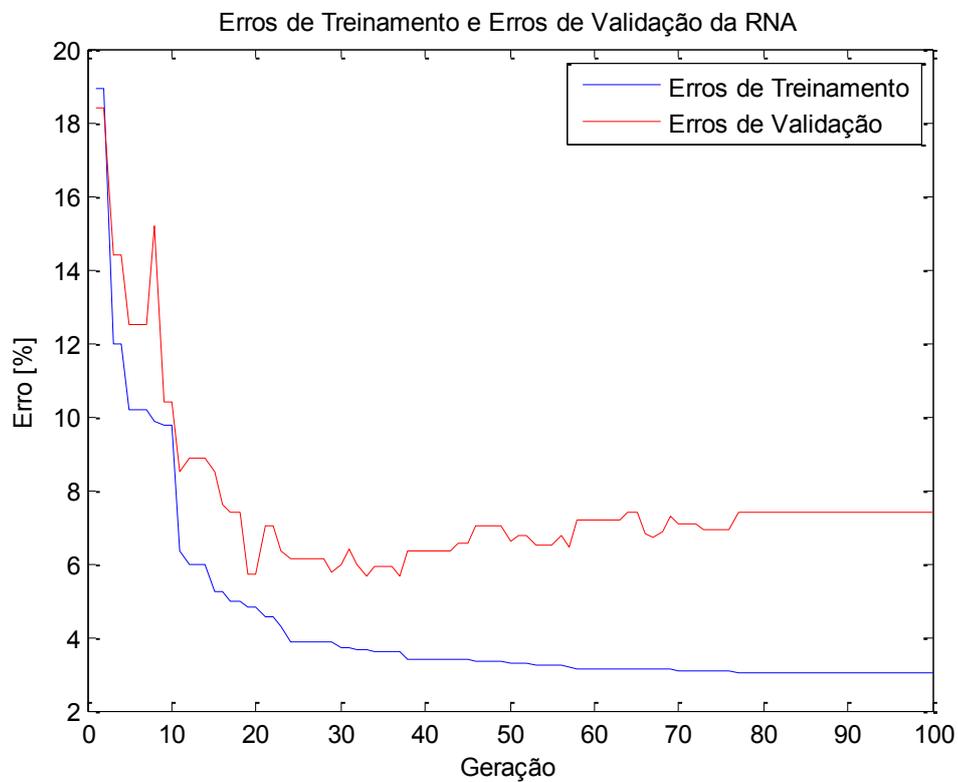


Figura All.15 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 15 da Tab. 4.1 para estimar a dureza Brinell

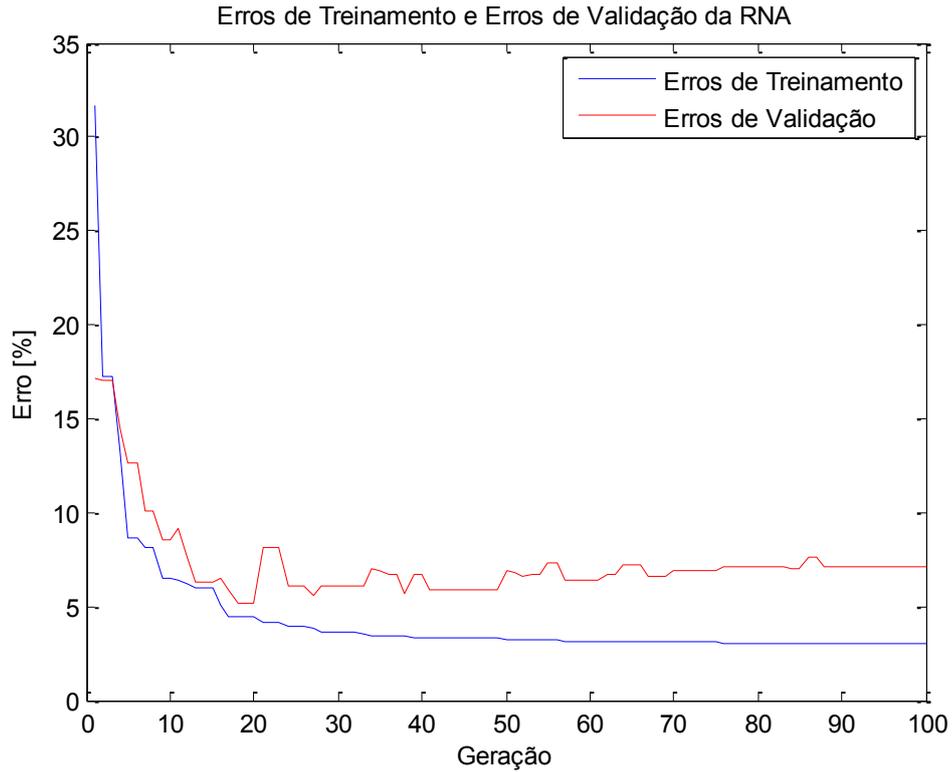


Figura All.16 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 16 da Tab. 4.1 para estimar a dureza Brinell

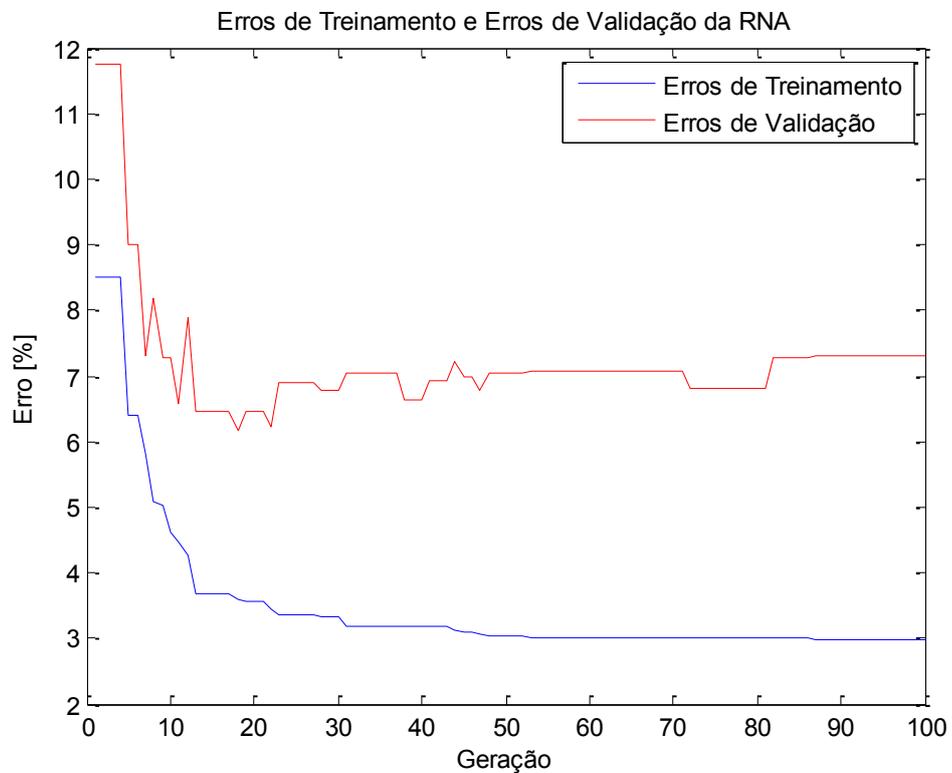


Figura All.17 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 17 da Tab. 4.1 para estimar a dureza Brinell

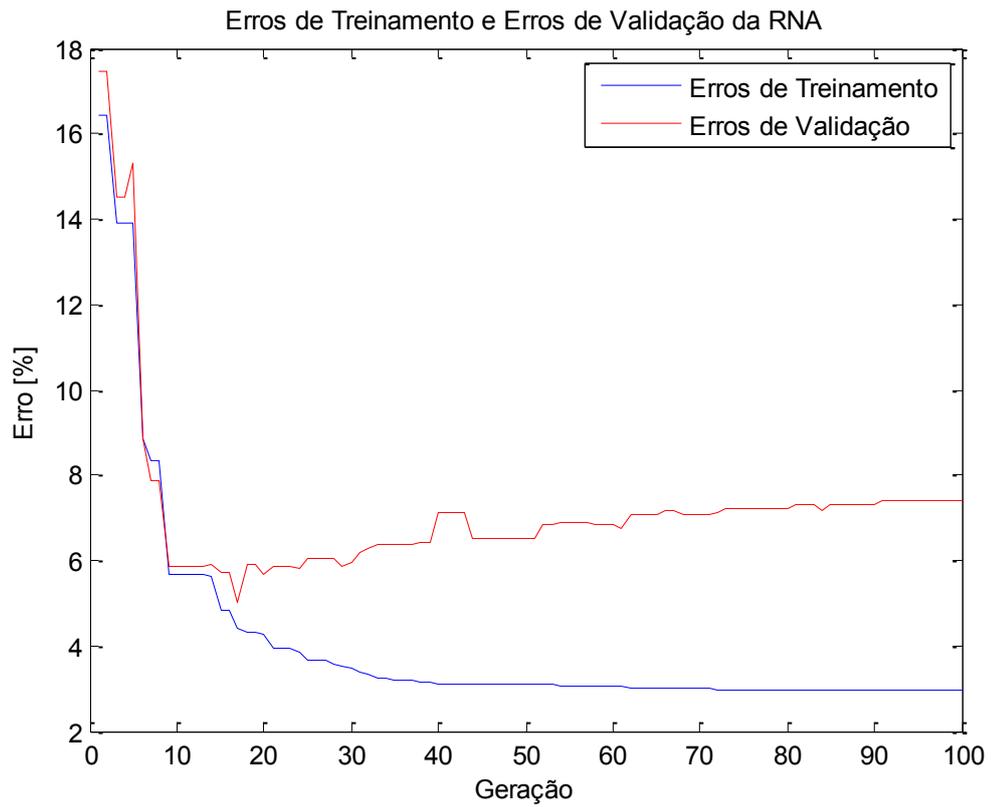


Figura AII.18 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 8 da Tab. 4.1 e método de treinamento AG-LMRB*, para estimar a dureza Brinell

APÊNDICE III

As Figuras AIV.1 a AIV.12 representam os gráficos dos erros de treinamento e validação em função da geração do AG. Esses erros foram obtidos durante os treinamentos das RNAEs, realizados conforme a Tab. 4.4 para estimar o limite de resistência.

Já o gráfico representado na Figura AIV.13 indica o resultado do treinamento, via método AG-LMRB*, da RNAE de melhor desempenho obtida através da configuração 7 (Tab. 4.4).

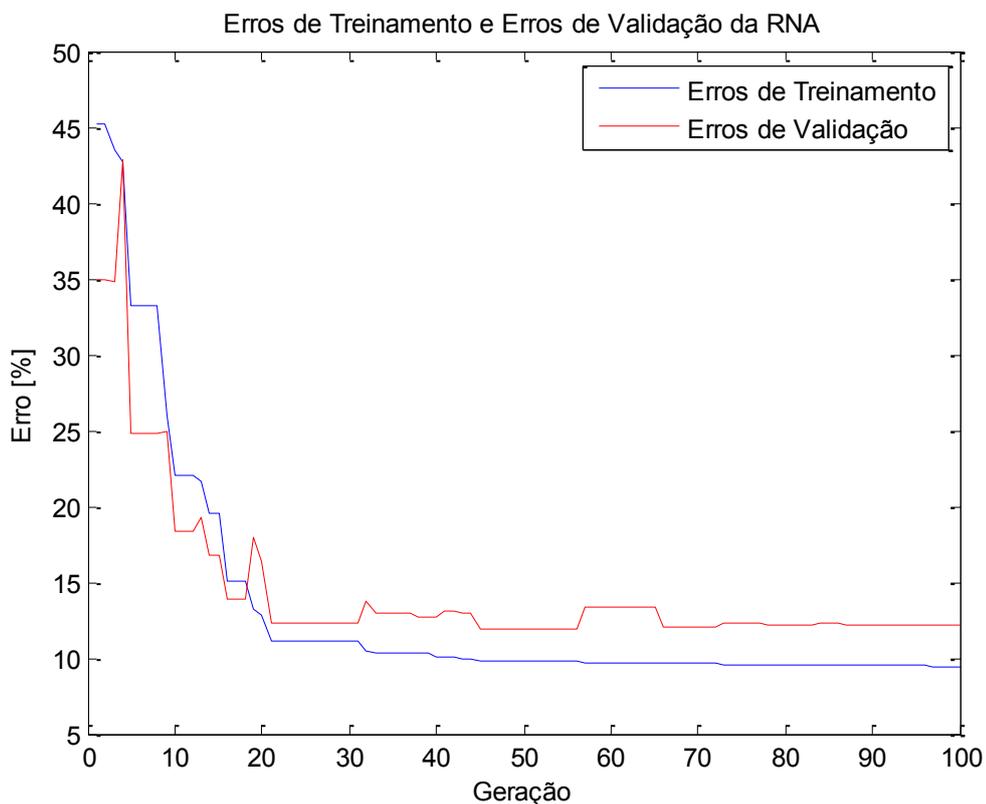


Figura AIII.1 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 1 da Tab. 4.4 para estimar o limite de resistência

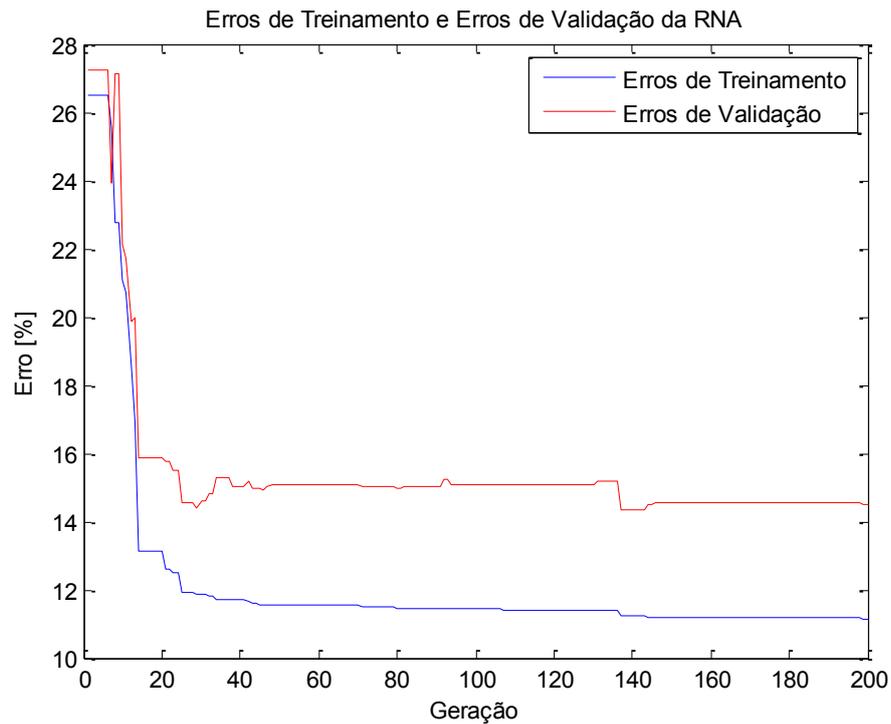


Figura AIII.2 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 2 da Tab. 4.4 para estimar o limite de resistência

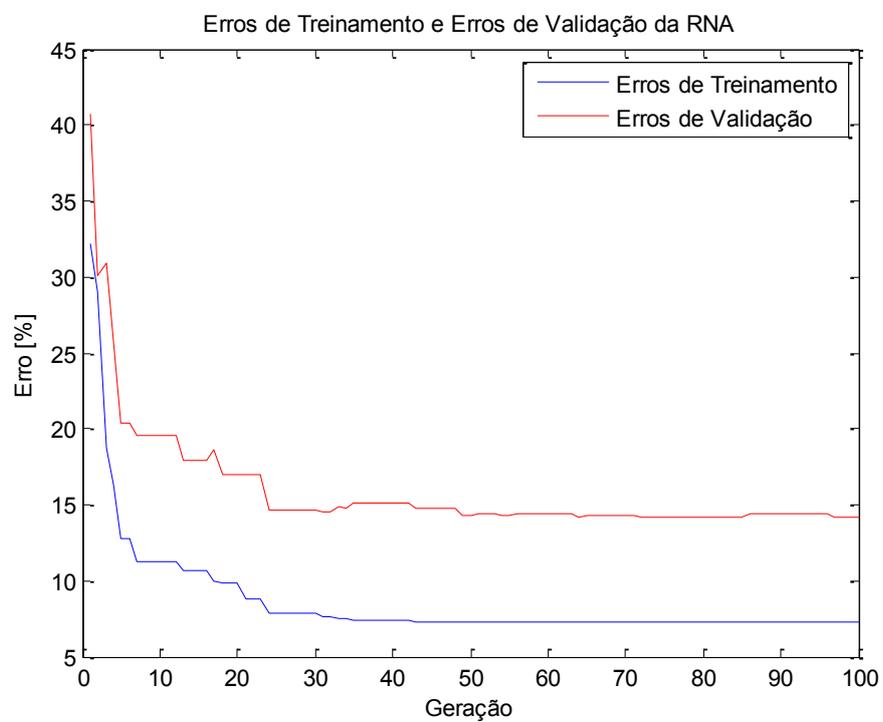


Figura AIII.3 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 3 da Tab. 4.4 para estimar o limite de resistência

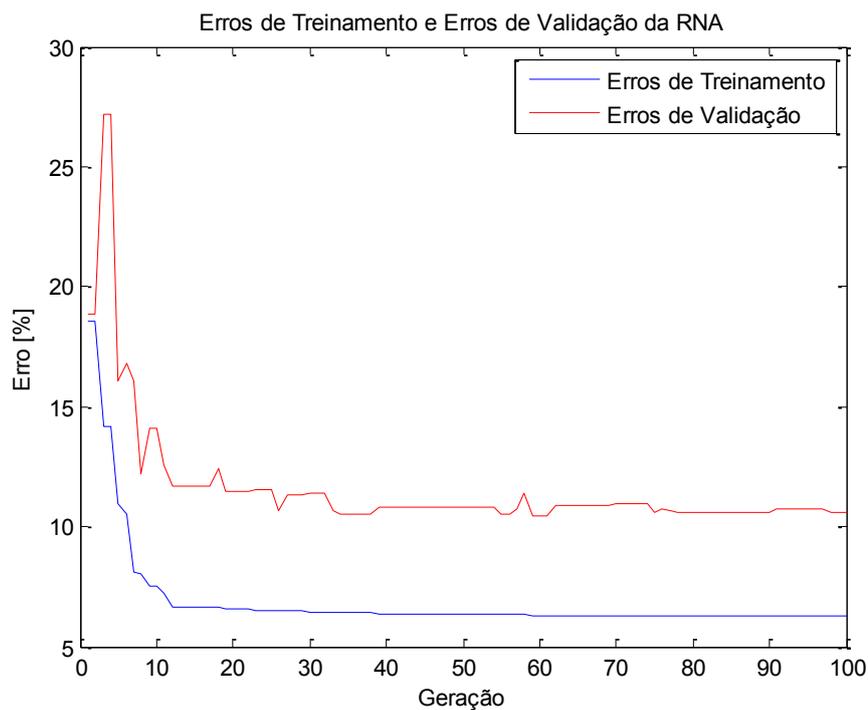


Figura AIII.4 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 4 da Tab. 4.4 para estimar o limite de resistência

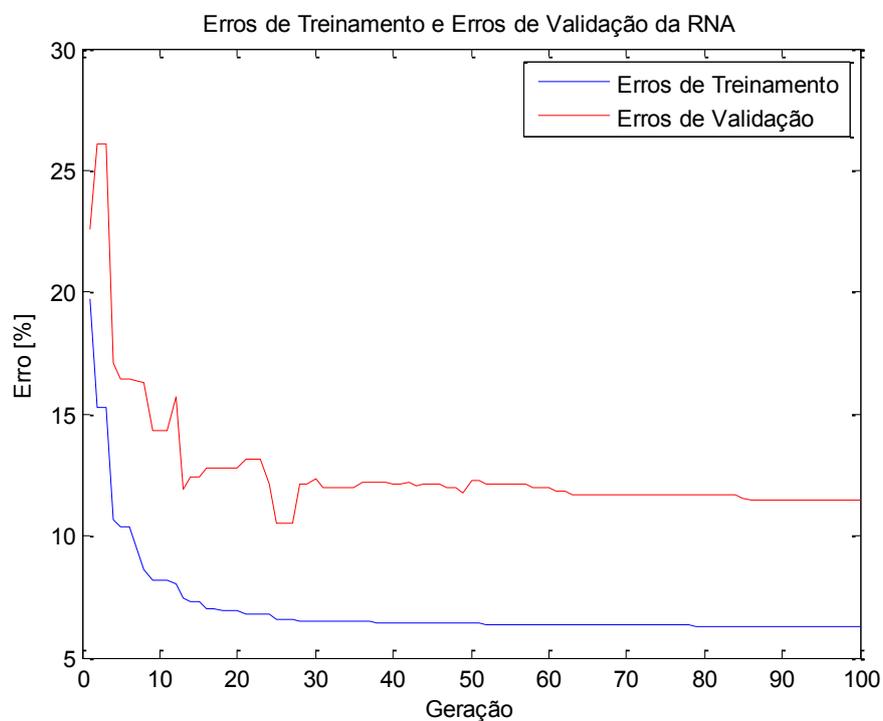


Figura AIII.5 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 5 da Tab. 4.4 para estimar o limite de resistência

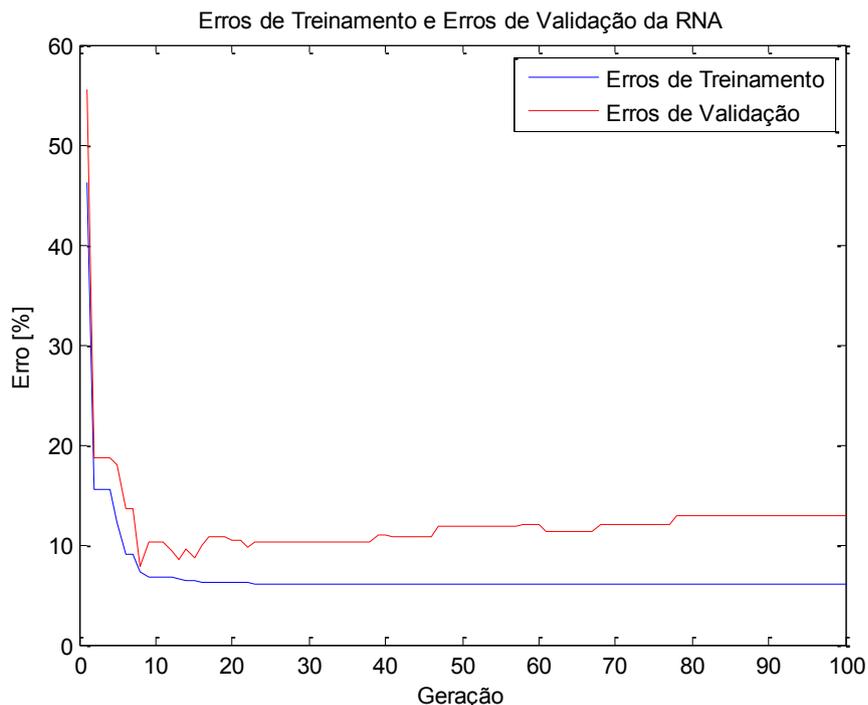


Figura AIII.6 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 6 da Tab. 4.4 para estimar o limite de resistência

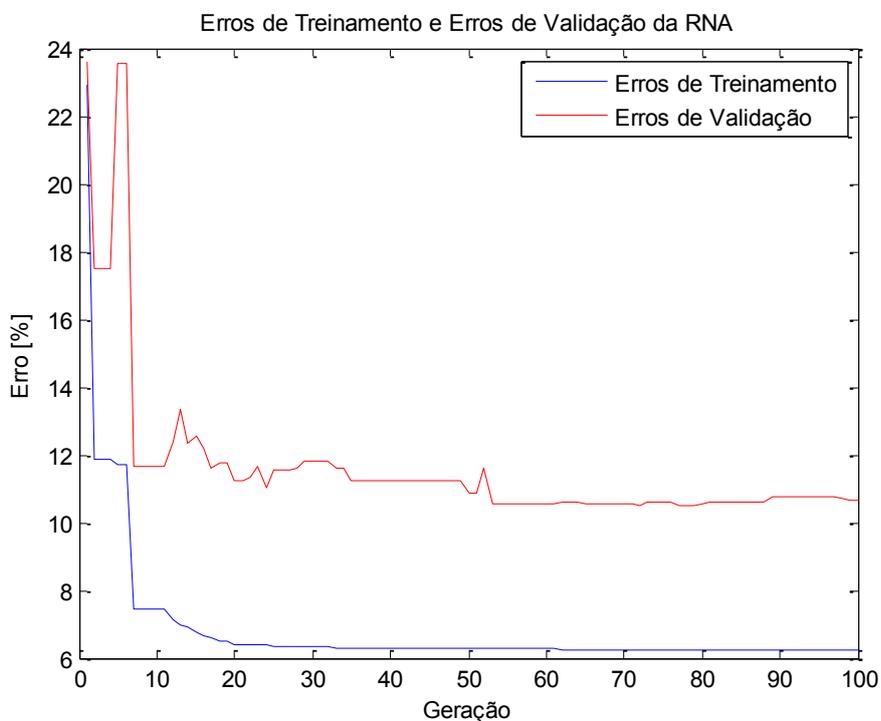


Figura AIII.7 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 7 da Tab. 4.4 para estimar o limite de resistência

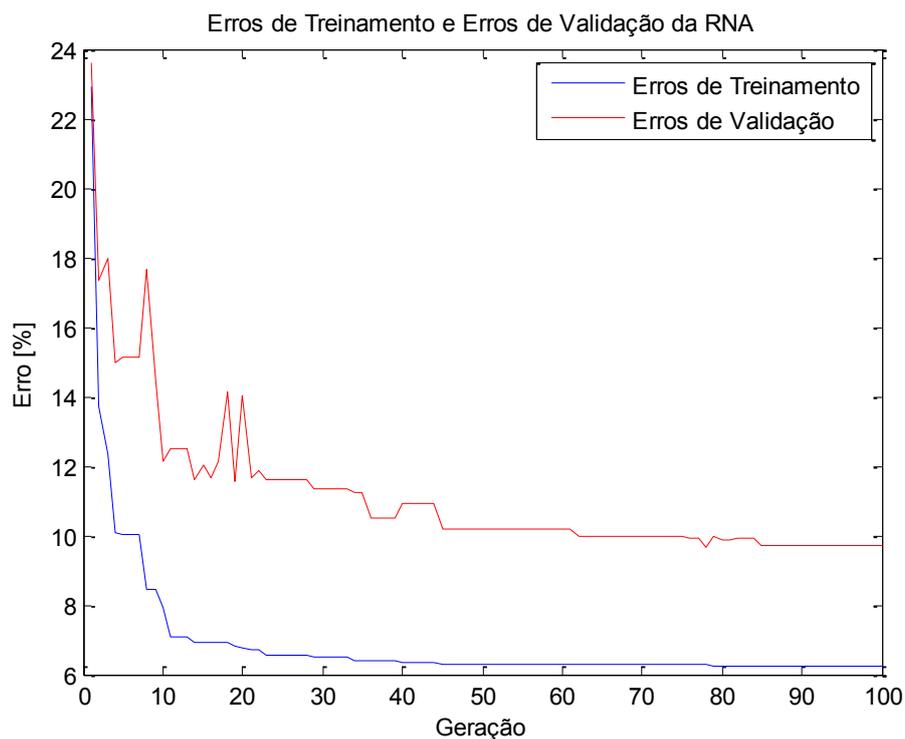


Figura AIII.8 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 8 da Tab. 4.4 para estimar o limite de resistência

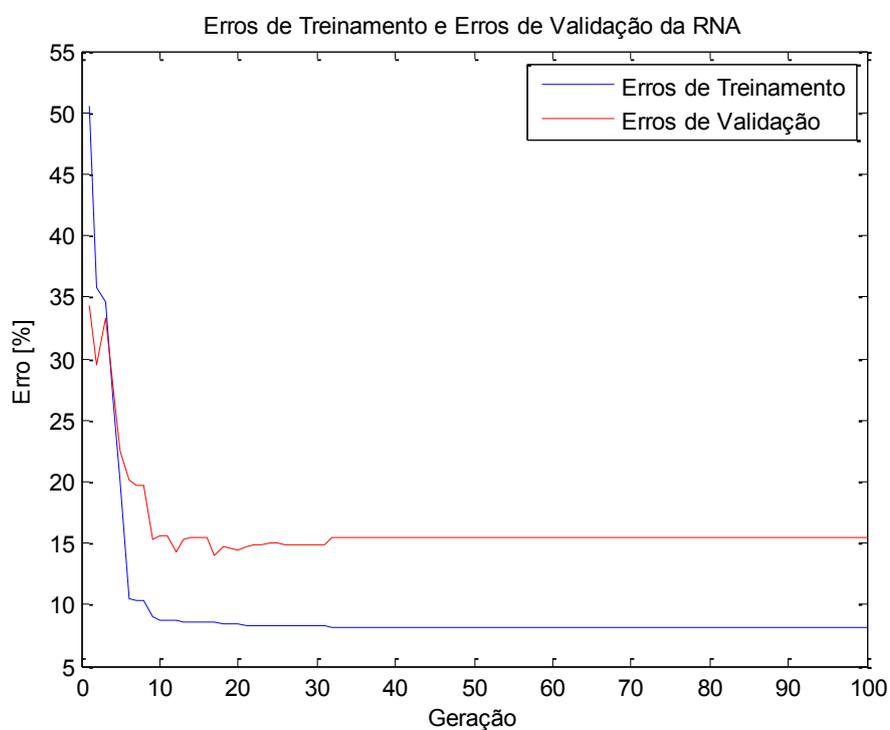


Figura AIII.9 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 9 da Tab. 4.4 para estimar o limite de resistência

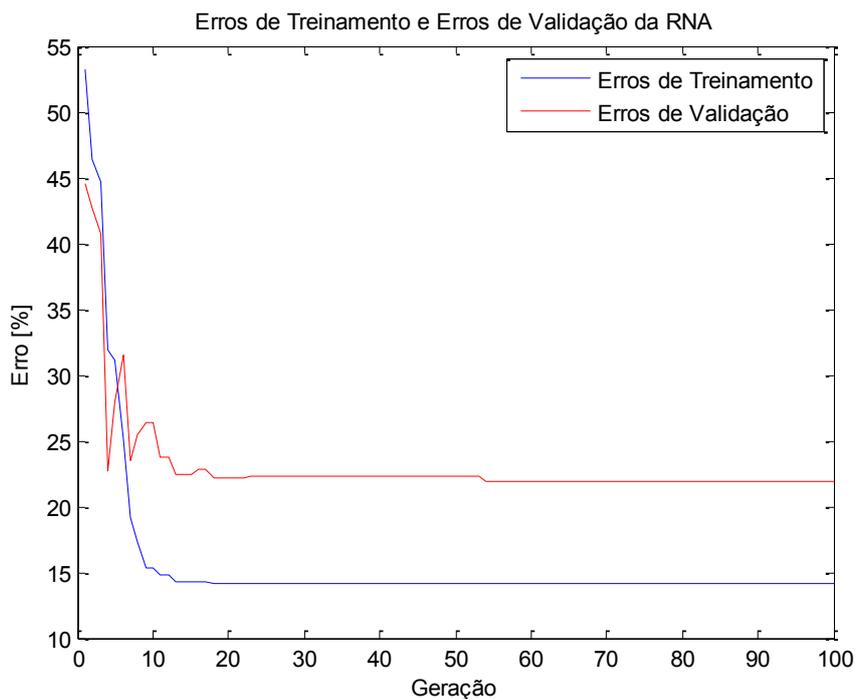


Figura AIII.10 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 10 da Tab. 4.4 para estimar o limite de resistência

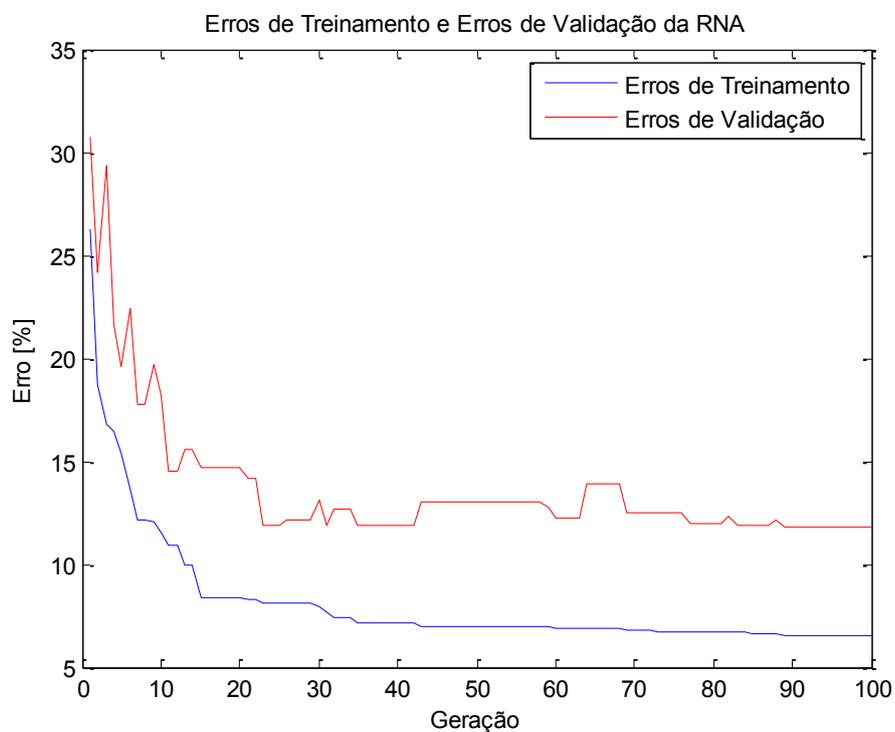


Figura AIII.11 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 11 da Tab. 4.4 para estimar o limite de resistência

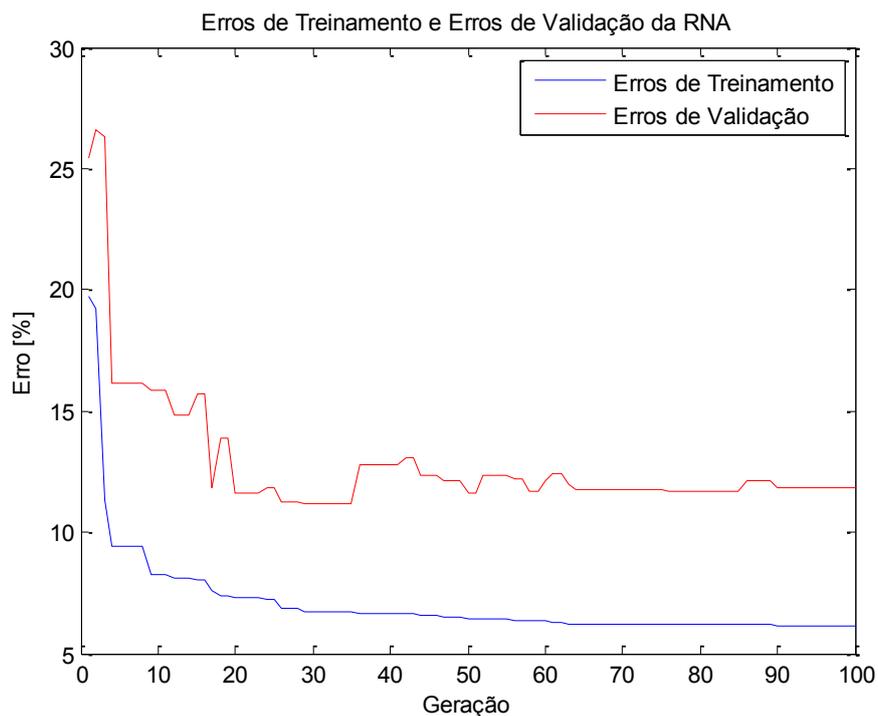


Figura AIII.12 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 12 da Tab. 4.4 para estimar o limite de resistência

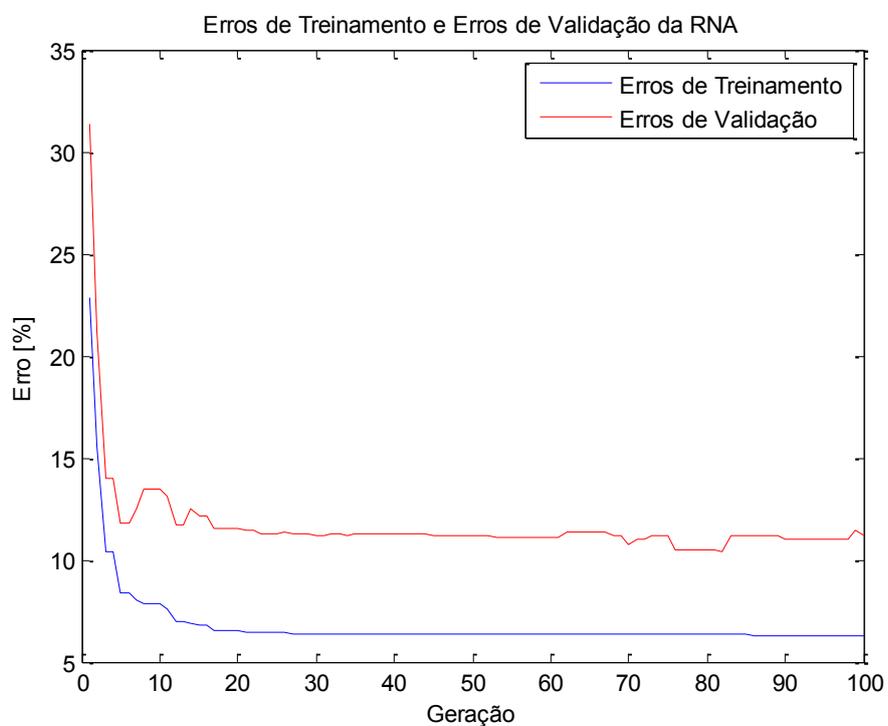


Figura AIII.13 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 7 da Tab. 4.4 e método de treinamento AG-LMRB*, para estimar o limite de resistência

APÊNDICE IV

As Figuras AIV.1 a AIV.9 representam os gráficos dos erros de treinamento e validação em função da geração do AG. Esses erros foram obtidos durante os treinamentos das RNAEs, realizados conforme a Tab. 4.7 para estimar o limite de escoamento.

Já o gráfico representado na Figura AIV.10 indica o resultado do treinamento, via método AG-LMRB*, da RNAE de melhor desempenho obtida através da configuração 5 (Tab. 4.7).

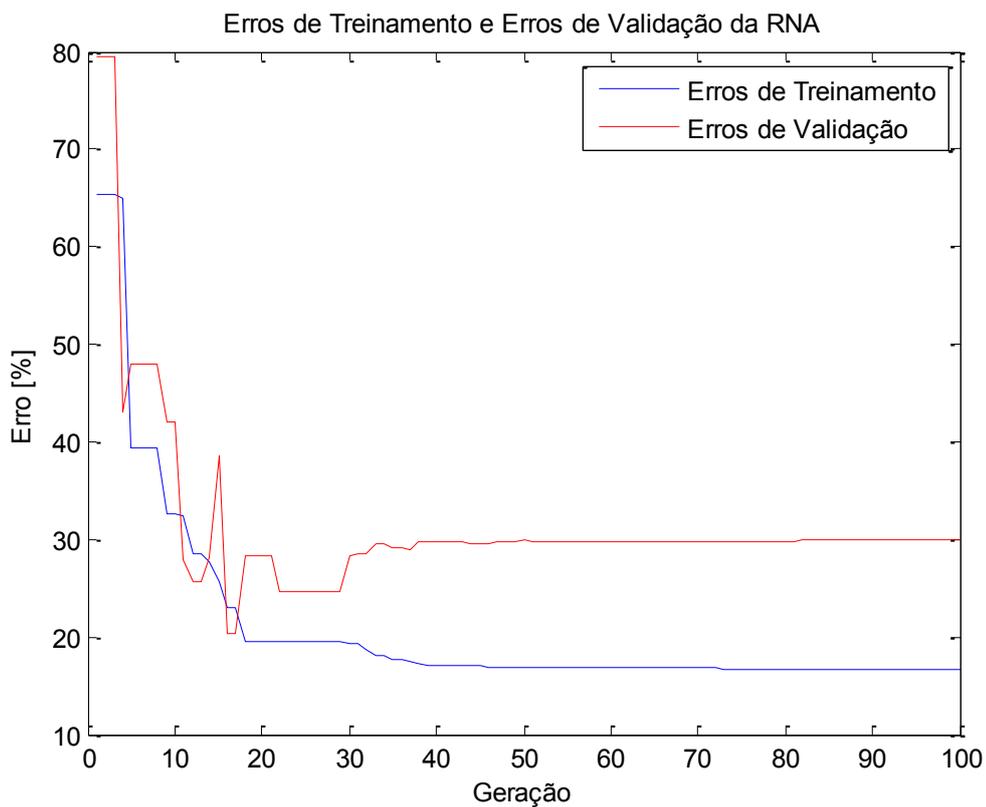


Figura AIV.1 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 1 da Tab. 4.7 para estimar o limite de escoamento

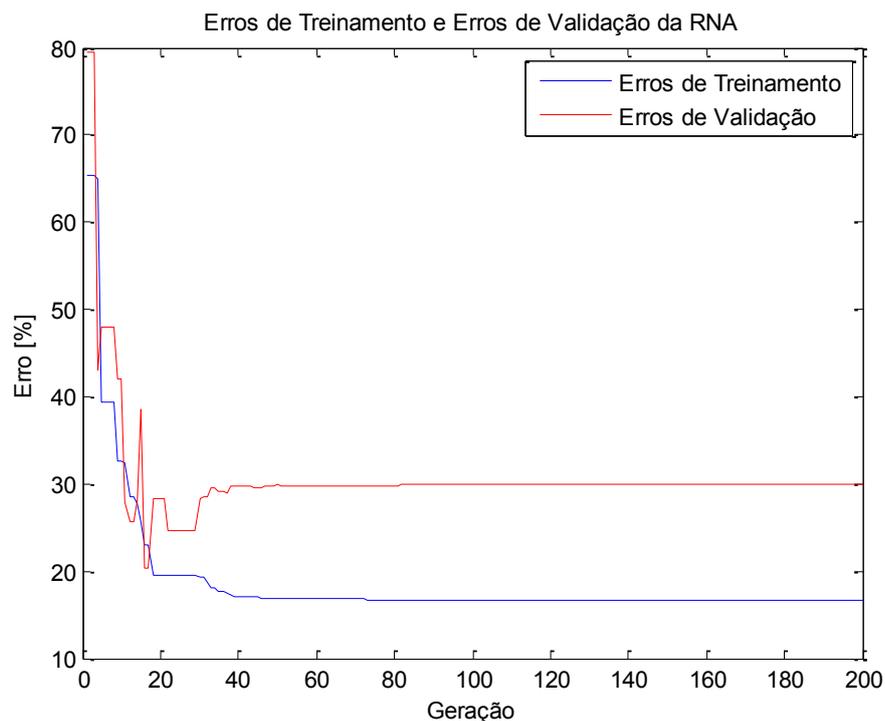


Figura AIV.2 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 2 da Tab. 4.7 para estimar o limite de escoamento

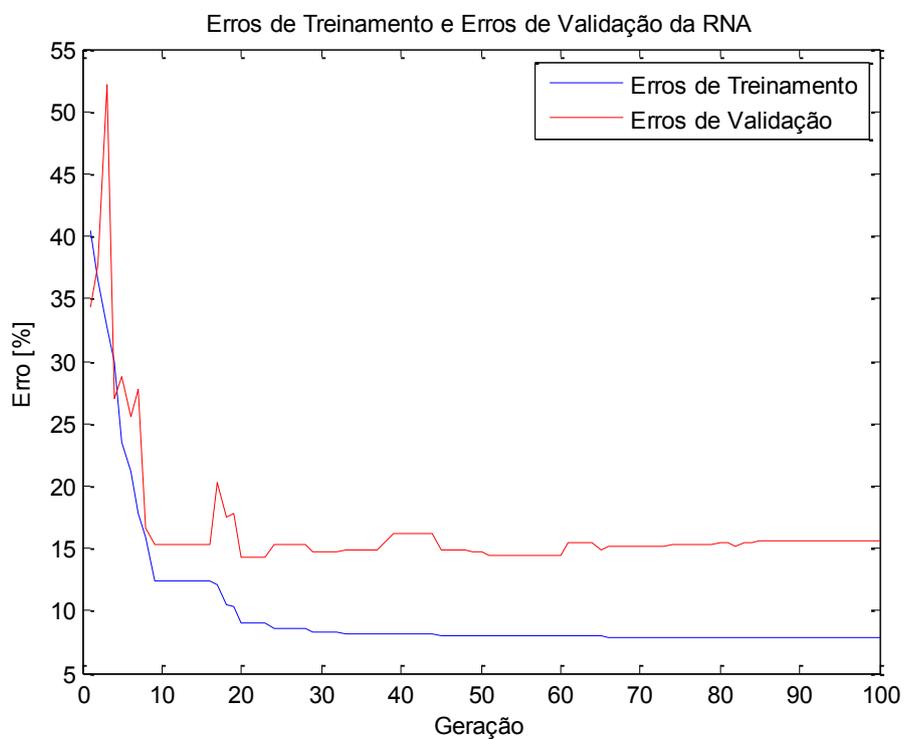


Figura AIV.3 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 3 da Tab. 4.7 para estimar o limite de escoamento

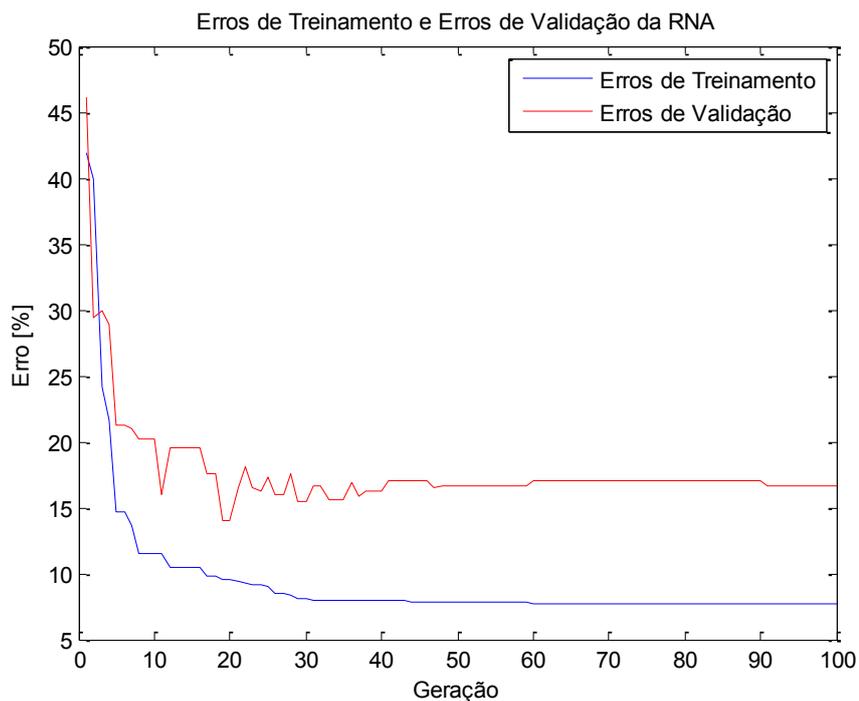


Figura AIV.4 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 4 da Tab. 4.7 para estimar o limite de escoamento

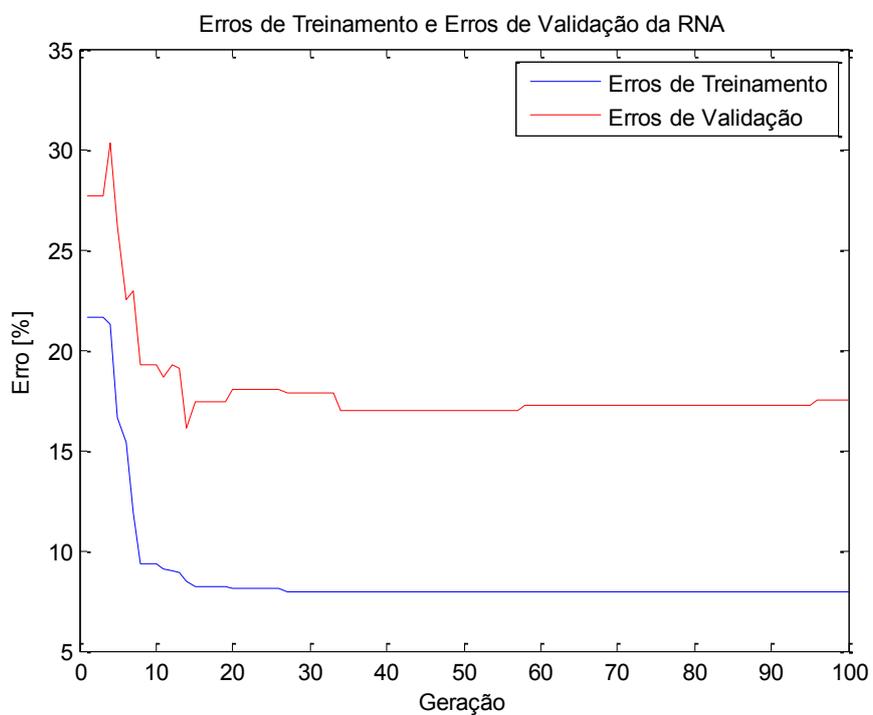


Figura AIV.5 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 5 da Tab. 4.7 para estimar o limite de escoamento

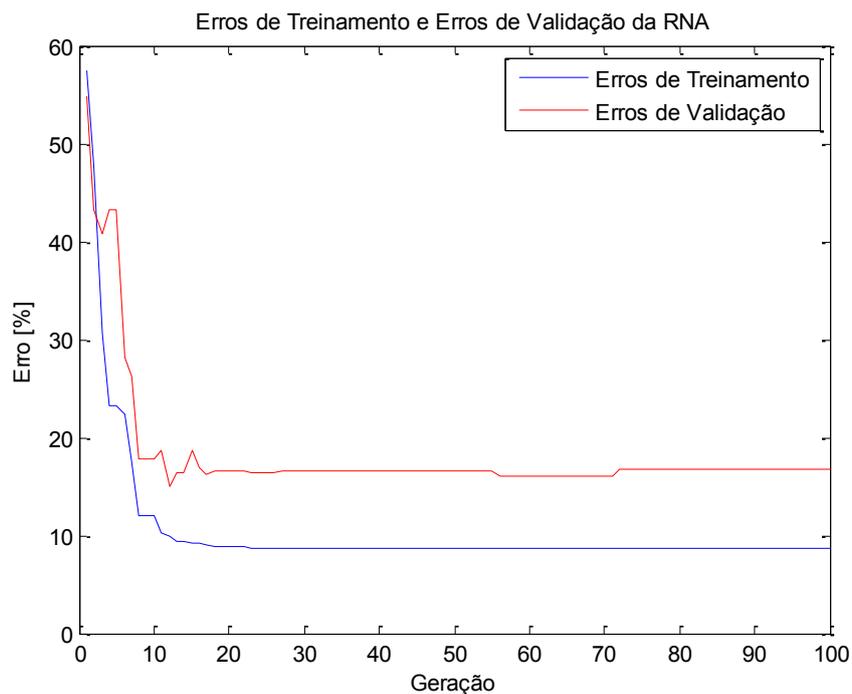


Figura AIV.6 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 6 da Tab. 4.7 para estimar o limite de escoamento

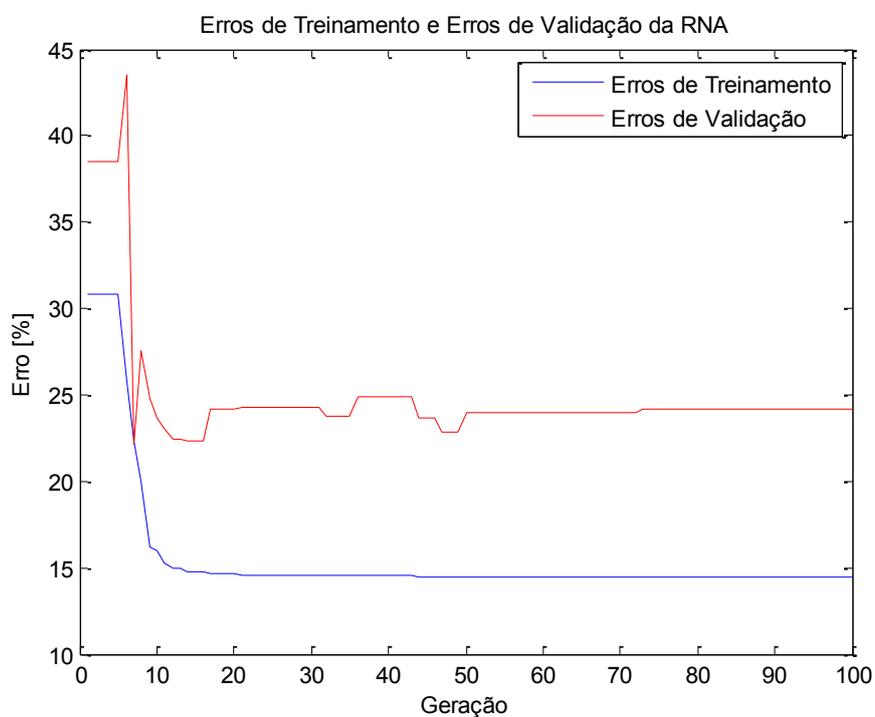


Figura AIV.7 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 7 da Tab. 4.7 para estimar o limite de escoamento

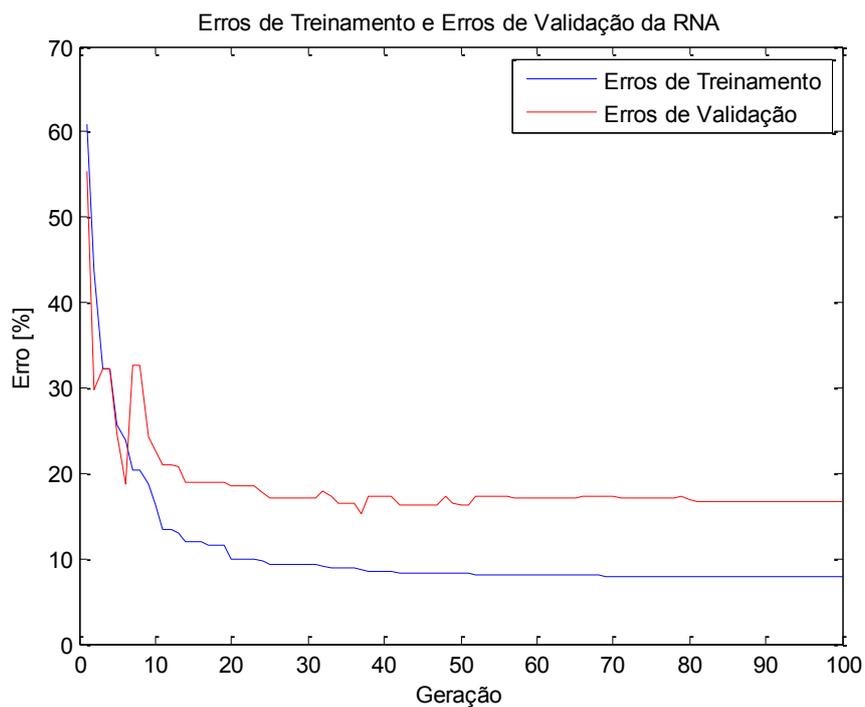


Figura AIV.8 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 8 da Tab. 4.7 para estimar o limite de escoamento

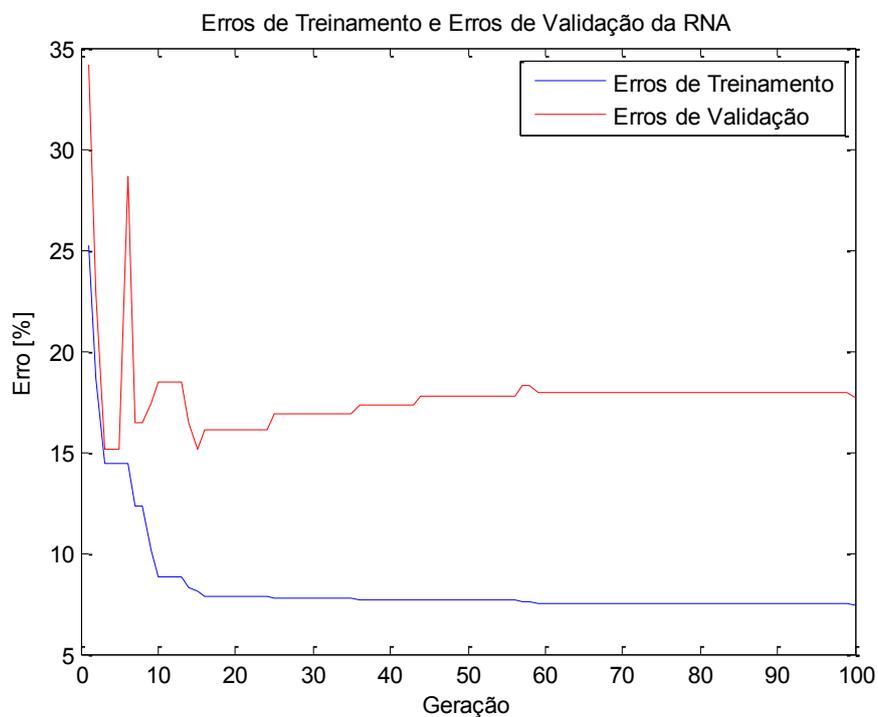


Figura AIV.9 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 9 da Tab. 4.7 para estimar o limite de escoamento

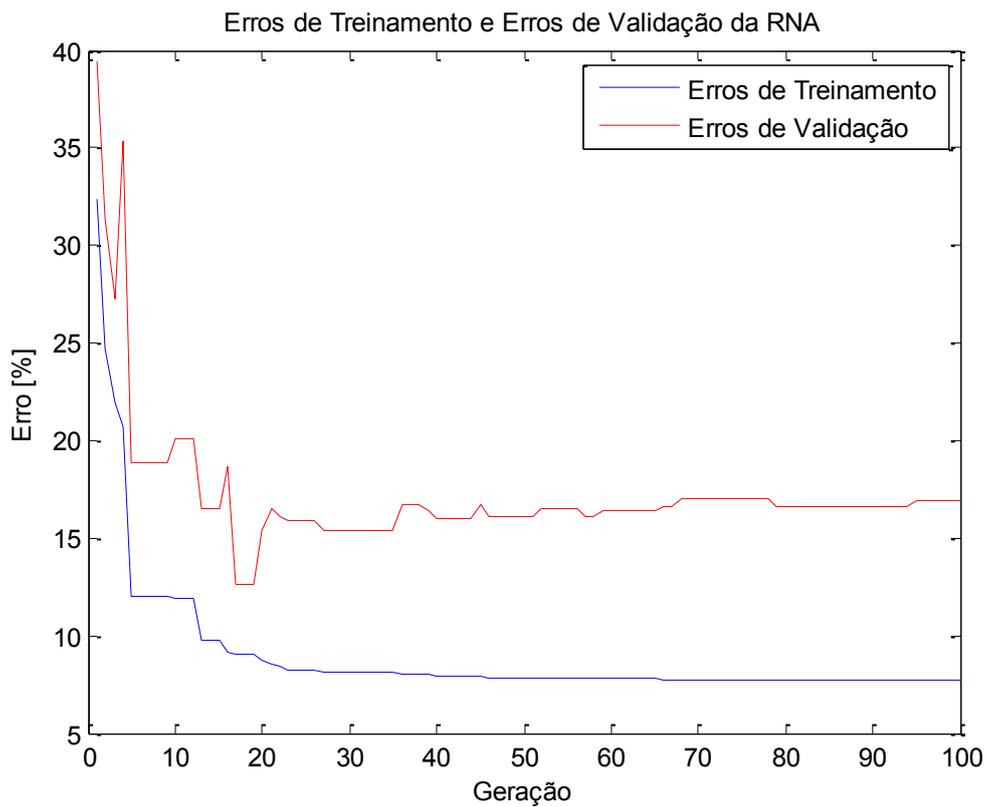


Figura AIV.10 – Erros de treinamento e validação obtidos durante o treinamento da RNAE, realizado conforme a configuração 5 da Tab. 4.7 e método de treinamento AG-LMRB*, para estimar o limite de escoamento