

UNIVERSIDADE DE SÃO PAULO

DANIEL JULIEN BARROS DA SILVA SAMPAIO

AUTOMAÇÃO DO MONITORAMENTO DA QUALIDADE DO PROCESSO
DE SOLDA A PONTO RESISTIVA

São Paulo

2010

DANIEL JULIEN BARROS DA SILVA SAMPAIO

AUTOMAÇÃO DO MONITORAMENTO DA QUALIDADE DO PROCESSO
DE SOLDA A PONTO RESISTIVA

Tese apresentada à Escola Politécnica da
Universidade de São Paulo para obtenção do
título de Doutor em Engenharia.

Área de Concentração:
Engenharia de Controle e Automação Mecânica

Orientador:
Prof. Dr. Lucas A. Moscato

São Paulo
2010

Este exemplar foi revisado e alterado em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, 21 de maio de 2010.

Assinatura do autor _____

Assinatura do orientador _____

FICHA CATALOGRÁFICA

Sampaio, Daniel Julien Barros da Silva
Automação do monitoramento da qualidade do processo de solda a ponto resistiva / D.J.B.S. Sampaio. -- ed.rev. -- São Paulo, 2010.
173 p.

Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Mecatrônica e de Sistemas Mecânicos.

1. Qualidade do processo (Monitoramento) 2. Soldagem por ponto 3. Inteligência artificial I. Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia Mecatrônica e de Sistemas Mecânicos II. t.

DEDICATÓRIA

Ao bem mais valioso que me há dado a vida, a “MINHA FAMÍLIA”,
por todo amor, compreensão, carinho e apoio dado durante todos esses anos,
em especial a minha esposa Nice, meu filho Ian, minha mãe Roseli, meu irmão
Henrique e ao meu pai Dimas.

AGRADECIMENTOS

Ao Prof. Dr. Lucas A. Moscato, pela valiosa orientação, paciência, compreensão e apoio cruciais à feitura e conclusão deste trabalho.

Ao estimado amigo Samuel pelo apoio e ajuda perene.

Ao estimado amigo Prof. Dr. Norbert Link pelo apoio técnico e ajuda na viabilização da obtenção dos dados práticos.

A Michael Peschl e Dietmar Zettel da empresa HWH GmbH pelas discussões e apoio técnico e a própria empresa HWH GmbH por autorizar o uso dos dados que validaram este trabalho.

A todos do Programa de Pós-Graduação em Engenharia Mecânica da Poli pela oportunidade de realizar este trabalho.

Aos colegas e amigos da Unesp – Guaratinguetá pelo apoio e compreensão.

Ao CNPQ pela bolsa cedida em parte do período de realização deste trabalho.

Ao Tio Hélio pelo apoio logístico e paciência.

A todos meus amigos que apoiaram e acreditaram que conseguiria terminar este trabalho.

A Nossa Senhora Aparecida por iluminar meu caminho e pela proteção.

"A maior vitória é estar feliz consigo mesmo"
(Daniel Sampaio)

"Dificuldades e obstáculos são fontes valiosas de saúde e
força para qualquer sociedade."
(Albert Einstein)

RESUMO

SAMPAIO, D. J. B. S. **Automação do monitoramento da qualidade do processo de solda a ponto resistiva**. 2010. 173 f. Tese (Doutorado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2010.

Neste trabalho é proposto e avaliado um sistema capaz de monitorar de forma não-destrutiva, não-invasiva, individualizada, em tempo real e em ambiente industrial, a qualidade de soldas produzidas através do processo de solda a ponto resistiva (PSPR), diminuindo ou mesmo eliminando a necessidade dos testes destrutivos, reduzindo custos e aumentando a produtividade. Este sistema de monitoramento é baseado em reconhecimento de padrões, através de redes neurais artificiais do tipo Perceptron multicamadas. As características do processo usadas na entrada da rede neural são os parâmetros ajustados de um modelo matemático parametrizável, criado com o intuito de refletir as propriedades fundamentais da grandeza do processo passível de ser medida e monitorada em tempo real, neste caso a curva de resistência dinâmica. Estes valores ajustados dos parâmetros do modelo são ainda relacionados com os estados ou condições do processo, de forma a permitir a identificação de possíveis causas para falhas detectadas. Para avaliar e validar este sistema, usaram-se dados reais obtidos na produção de lotes de contatos elétricos através do PSPR. Os resultados obtidos mostram que o sistema proposto é capaz de monitorar satisfatoriamente a qualidade do processo investigado, com erro médio quadrático de 16,5 N, na estimação da força de cisalhamento suportada pela solda, no pior caso. O sistema também mostrou-se capaz de identificar a causa para soldas cuja qualidade estimada foi considerada baixa, com taxa de acerto acima de 97%. Esse sistema proposto não contém especificidades de nenhum processo produtivo e, portanto, tem potencial para ser aplicado em outros processos, além do PSPR.

Palavras-chave: Qualidade do processo (Monitoramento). Soldagem por ponto. Inteligência artificial.

ABSTRACT

SAMPAIO, D. J. B. S. **Automatic quality monitoring of resistance spot welding process**. 2010. 173 p. Thesis (Doctorate) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2010.

In this work a non-destructive, non-invasive, individualized, real-time system has been proposed and evaluated to monitor the quality of welds produced by resistance spot welding process (RSWP) in industrial environment. This system is able to reduce or eliminate the need for destructive tests, leading to cost reduction and increase in productivity. This monitoring system is based on pattern recognition with multilayer Perceptron artificial neural networks (ANN). The process features used as input of the ANN are adjusted parameters of a parametric mathematic model created to reflect the fundamental properties of the process variable that is measurable in real time, in this work, the dynamic resistance curve. The adjustable model parameters values are related with the process states and conditions, so that it is possible to identify the causes for detected bad quality. In order to evaluate and validate the proposed system, real data obtained in the production of electric contacts by RSWP were used. The results show that the proposed system is capable of properly monitoring the investigated process quality, with a mean square error of 16.5 N, in the estimation of the shear force supported by the weld, in the worst case. The system proved to be able to identify the causes for detected bad quality, with a reliability of more than 97%. The proposed system contains no productive process specificities, and, therefore, can be applied to other processes.

Keywords: Process quality (Monitoring). Spot welding. Artificial intelligence.

LISTA DE FIGURAS

Figura 2.1 – Representação do Processo de Solda a Ponto Resistiva	25
Figura 2.2 – Valores aproximados das resistências para chapas de aço de 1 mm e eletrodos de cobre de 5 mm de diâmetro	26
Figura 2.3 – Desenho esquemático do PSPR	32
Figura 2.4 – Caminho idealizado da onda através das partes (esquerda) e a forma de onda correspondente obtida (direita) (DENISOV et al., 2004)	34
Figura 2.5 – Imagem da impressão no material após o PSPR (RUISZ et al., 2007)	39
Figura 2.6 – Curva da resistência dinâmica clássica para soldagem de aço	40
Figura 3.1 - Fluxograma do Sistema de Monitoramento da Qualidade Proposto.....	49
Figura 3.2 - Diagrama Esquemático do Sistema de Monitoramento da Qualidade Proposto.....	53
Figura 3.3 - Tela de créditos da ferramenta de software TOMAHAWK	55
Figura 3.4 - Exemplo de encadeamento de <i>plug-ins</i> na ferramenta TOMAHAWK	56
Figura 3.5 - Desenho esquemático de uma máquina de solda a ponto resistiva	57
Figura 3.6 - Desenho esquemático das medições de tensão e corrente no PSPR	58
Figura 3.7 - Uma bobina Rogowski usada na medição de corrente	59
Figura 3.8 - Fixação dos cabos para medição da tensão de soldagem	61
Figura 3.9 - Curva dos dados brutos da variação de tensão durante o PSPR	61
Figura 3.10 - Curva dos dados brutos da variação de corrente durante o PSPR	62
Figura 3.11 - <i>Work list</i> para pré-processamento dos dados de tensão e corrente	63
Figura 3.12 - Curva da variação de tensão durante o PSPR após correções	64
Figura 3.13 - Curva da variação de corrente durante o PSPR após correções	64
Figura 3.14 - Defasagem entre as curvas de tensão (V) (vermelho) e corrente (kA) (preto)	65

Figura 3.15 - Curva da variação da resistência elétrica durante a produção de um contato elétrico	66
Figura 3.16 - Desenho esquemático do arranjo do PSPR	68
Figura 3.17 - Temperatura x Tempo	69
Figura 3.18 - Resistência do material bruto x Tempo	70
Figura 3.19 - R_{ELM} x Tempo	72
Figura 3.20 - R_C x Tempo	73
Figura 3.21 - Resistência Elétrica R x Tempo	73
Figura 3.22 - Tela de Configuração do <i>Plug-in</i> “Model_CalcVariables”	81
Figura 3.23 - Processo de treinamento da rede neural artificial	83
Figura 3.24 - Processo de aplicação da rede neural artificial	84
Figura 4.1 - Esquemático das partes a serem soldadas (superior) e contato elétrico após soldagem (inferior)	89
Figura 4.2 - Esquemático do ajuste da pressão dos eletrodos através de uma mola	90
Figura 4.3 - Detalhes da curva da resistência dinâmica de um dos testes	96
Figura 4.4 - Curva da resistência dinâmica considerando somente o segundo estágio	97
Figura 4.5 - Tela de configuração do <i>plug-in</i> “Model_CalcVariables” preenchida	98
Figura 4.6 - Curva com pior ajuste entre os dados do conjunto analisado	100
Figura 4.7 - Curva com bom ajuste entre os dados do conjunto analisado	100
Figura 4.8 - Resultado da topologia 5-5-1 para os dados de validação	104
Figura 4.9 - Resultado da melhor combinação de parâmetros (5 parâmetros) e da melhor topologia entre as testadas (5-8-1) para o primeiro conjunto de dados	114
Figura 4.10 - Resultado da melhor combinação de parâmetros (5 parâmetros) e da melhor topologia entre as testadas (5-8-1) para o segundo conjunto de dados	115

Figura 4.11 - Relação entre QC e o parâmetro K_{C-SOFT} para o primeiro conjunto de dados	123
Figura 4.12 - Relação entre QC e o parâmetro R_{OC} para o primeiro conjunto de dados	124
Figura 4.13 - Relação entre QC e o parâmetro K_{ELM} para o primeiro conjunto de dados	125
Figura 4.14 - Relação entre QC e o parâmetro R_{OELM} para o primeiro conjunto de dados	126
Figura 4.15 - Relação entre QC e o parâmetro K_C para o primeiro conjunto de dados	127
Figura 4.16 - Fluxograma do procedimento usado para identificar a causa no caso de perda de qualidade por parte da solda para o primeiro conjunto de dados	128
Figura 4.17 - Relação entre QC e o parâmetro K_{C-SOFT} para o segundo conjunto de dados	129
Figura 4.18 - Relação entre QC e o parâmetro R_{OC} para o segundo conjunto de dados	129
Figura 4.19 - Relação entre QC e o parâmetro K_{ELM} para o segundo conjunto de dados	130
Figura 4.20 - Relação entre QC e o parâmetro R_{OELM} para o segundo conjunto de dados	130
Figura 4.21 - Relação entre QC e o parâmetro K_C para o segundo conjunto de dados	130
Figura 4.22 - Fluxograma do procedimento usado para identificar a causa no caso de perda de qualidade por parte da solda para o segundo conjunto de dados	131
Figura A.1. Conexões de um Neurônio (a) Neurônio Biológico; (b) Neurônio Artificial	144
Figura A.2 - Arquitetura de uma RNA típica	146

Figura A.3 - Diagrama de um neurônio.....	146
Figura A.4 - Funções de Ativação de um Neurônio.....	147
Figura A.5 - Separação Linear no Perceptron: (a) Perceptron com duas entradas; (b) Perceptron com três entradas.....	149
Figura A.6 - Gráficos bi-dimensionais de operações lógicas básicas: (a) E ($x_1 \cap x_2$); (b) OU ($x_1 \cup x_2$); (c) OU-exclusivo ($x_1 \oplus x_2$).....	152
Figura A.7 - Perceptron com duas camadas	153
Figura A.8 - Rede Neural que utiliza <i>back-propagation</i> com três camadas	156
Figura A.9 - Rede Neural de três camadas para solucionar a operação OU exclusivo	160
Figura A.10 - Curva de treinamento para a operação OU exclusivo.....	163
Figura A.11 - Limites de decisão construída pela rede neural: (a) E ($x_1 \cap x_2$); (b) OU ($x_1 \cup x_2$); (c) OU-exclusivo ($x_1 \oplus x_2$).....	164

LISTA DE TABELAS

Tabela 4.1 - Resultados iniciais obtidos com a topologia 5-5-1	103
Tabela 4.2 - Resultados de diferentes topologias com 1 parâmetro na entrada da rede.....	106
Tabela 4.3 - Resultados de diferentes topologias com 2 parâmetros na entrada da rede.....	107
Tabela 4.4 - Resultados de diferentes topologias com 3 parâmetros na entrada da rede.....	108
Tabela 4.5 - Resultados de diferentes topologias com 4 parâmetros na entrada da rede.....	109
Tabela 4.6 - Resultados de diferentes topologias com 5 parâmetros na entrada da rede.....	109
Tabela 4.7 - Resultados de diferentes topologias com 1 parâmetro na entrada da rede.....	110
Tabela 4.8 - Resultados de diferentes topologias com 2 parâmetros na entrada da rede.....	111
Tabela 4.9 - Resultados de diferentes topologias com 3 parâmetros na entrada da rede.....	112
Tabela 4.10 - Resultados de diferentes topologias com 4 parâmetros na entrada da rede....	113
Tabela 4.11 - Resultados de diferentes topologias com 5 parâmetros na entrada da rede....	113
Tabela 4.12 - Resultados do sistema proposto por Dilthey e Dichersbach (1999) aplicado no primeiro conjunto de dados com diferentes topologias de rede.....	117
Tabela 4.13 - Resultados do sistema proposto por Dilthey e Dichersbach (1999) aplicado no segundo conjunto de dados com diferentes topologias de rede.....	118
Tabela 4.14 - Resultados do sistema proposto por Aravinthan et al. (2001) aplicado no primeiro conjunto de dados com diferentes topologias de rede.....	119
Tabela 4.15 - Resultados do sistema proposto por Aravinthan et al. (2001) aplicado no segundo conjunto de dados com diferentes topologias de rede.....	119
Tabela 4.16 - Resultados do sistema proposto por Wen et al. (2009) aplicado no primeiro conjunto de dados com diferentes topologias de rede.....	121
Tabela 4.17 - Resultados do sistema proposto por Wen et al. (2009) aplicado no segundo conjunto de dados com diferentes topologias de rede.....	121

Tabela A.1 - Analogia entre Rede Neural Biológica e Artificial.....	144
Tabela A.2. Tabela Verdade para as operações lógicas básicas.....	151
Tabela A.3. Exemplo de treinamento do Perceptron: operação lógica E.....	152
Tabela A.4. Resultados finais do aprendizado da rede de três camadas: a operação lógica OU exclusivo.....	163
Tabela B.1 – Detalhamento dos Testes do Primeiro Conjunto de Dados.....	165
Tabela B.2 – Detalhamento dos Testes do Segundo Conjunto de Dados.....	169

LISTA DE ABREVIATURAS

MAD	Desvio Absoluto Máximo
MSE	Erro Médio Quadrático
PSPR	Processo de Solda a Ponto Resistiva
QC	Qualidade do Contato Produzido
R^2 ou R^2	Coefficiente de Determinação
Recog%	Taxa de Reconhecimento
RNA	Rede Neural Artificial

LISTA DE SÍMBOLOS

α	Coefficiente térmico de resistência
χ^2	Função de mérito (“chi-square”)
i	Corrente de soldagem
K_C	Fator de variação da resistência de contato
K_{C-Soft}	Fator de amolecimento dos materiais
K_{ELM}	Fator de variação eletrodo-material
K_T	Fator de variação da temperatura
L	Indutância equivalente total
Q_{solda}	Quantidade de calor gerado
R	Resistência total dos elementos do circuito
R_{OB}	Resistência elétrica inicial do material bruto
R_{OC}	Resistência elétrica inicial de R_C
R_{OELM}	Resistência elétrica inicial de R_{ELM}
R_B	Resistência elétrica do material bruto
R_C	Resistência elétrica da interface entre os materiais
R_{ELM}	Resistência elétrica do eletrodo e da interface entre eletrodos e materiais
t	tempo
T	Temperatura do processo estimada
T_{fusao}	Temperatura de fusão
T_0	Temperatura inicial
V_L	Tensão da componente indutiva

SUMÁRIO

1	INTRODUÇÃO	19
1.1	MOTIVAÇÃO	19
1.2	OBJETIVO	22
1.3	ESTRUTURA DO TRABALHO	22
2	MONITORAMENTO E CONTROLE DA QUALIDADE DA SOLDA.....	24
2.1	INTRODUÇÃO AO PSPR	24
2.2	EVOLUÇÃO DO MONITORAMENTO E CONTROLE DE QUALIDADE NO PSPR	27
2.3	PERTURBAÇÕES E DIFICULDADES DO PSPR	30
2.4	SISTEMAS BASEADOS EM GRANDEZAS MENSURÁVEIS DO PSPR.....	31
3	O SISTEMA PROPOSTO E SEUS COMPONENTES	48
3.1	DESCRIÇÃO DO SISTEMA DE MONITORAMENTO PROPOSTO	48
3.2	APLICAÇÃO DO SISTEMA NO PSPR.....	52
3.3	FERRAMENTA DE SOFTWARE UTILIZADA	55
3.4	MEDIÇÃO E PROCESSAMENTO DAS GRANDEZAS DO PROCESSO	56
3.4.1	<i>Medição da Corrente e Tensão de Soldagem.....</i>	<i>58</i>
3.4.2	<i>Obtenção da Curva da Resistência Elétrica Dinâmica.....</i>	<i>65</i>
3.5	MODELO MATEMÁTICO PARAMETRIZÁVEL DO PROCESSO	67
3.6	AJUSTE DO MODELO NÃO-LINEAR.....	74
3.6.1	<i>Aspectos Iniciais.....</i>	<i>74</i>
3.6.2	<i>Gradiente e a Matriz Hessiana.....</i>	<i>75</i>
3.6.3	<i>Algoritmo de Levenberg-Marquardt</i>	<i>77</i>
3.6.4	<i>Criação de Plug-in para Ajuste do Modelo</i>	<i>80</i>
3.7	ESTIMAÇÃO DA QUALIDADE UTILIZANDO REDES NEURAIS.....	82

3.7.1	<i>Software para Simulação de Redes Neurais</i>	84
3.8	IDENTIFICAÇÃO DE CAUSAS DE PERDA DE QUALIDADE NO PSPR	85
3.9	BANCO DE DADOS COM HISTÓRICO DE PRODUÇÃO	86
4	AVALIAÇÃO E VALIDAÇÃO DO SISTEMA PROPOSTO	87
4.1	DADOS UTILIZADOS NA AVALIAÇÃO E VALIDAÇÃO DO SISTEMA.....	87
4.1.1	<i>Primeiro Conjunto de Dados</i>	88
4.1.2	<i>Segundo Conjunto de Dados</i>	93
4.2	AVALIAÇÃO DO AJUSTE ENTRE O MODELO E O PROCESSO	96
4.3	ESTIMAÇÃO DA QUALIDADE FINAL DA SOLDA	101
4.4	COMPARAÇÃO COM SISTEMAS PROPOSTOS NA LITERATURA	116
4.5	IDENTIFICAÇÃO DE CAUSAS DE PROBLEMAS NO PROCESSO.....	122
5	CONCLUSÃO.....	132
	REFERÊNCIAS BIBLIOGRÁFICAS	134
	ANEXO A - REDES NEURAIAS ARTIFICIAIS	143
A.1	FUNDAMENTOS DE REDES NEURAIAS ARTIFICIAIS	143
A.2	O NEURÔNIO COMO UM SIMPLES ELEMENTO COMPUTACIONAL	146
A.3	O PERCEPTRON	148
A.4	REDES NEURAIAS MULTICAMADAS	153
A.5	ALGORITMO DE APRENDIZADO BACK-PROPAGATION.....	154
	ANEXO B	165

1 Introdução

1.1 *Motivação*

O monitoramento da qualidade de um processo produtivo assume cada vez mais um papel de destaque no mundo globalizado já que a interligação entre Qualidade, Produtividade e Competitividade são fatores da maior importância no mercado atual e podem determinar o sucesso ou fracasso de determinada empresa, processo ou produto.

Este monitoramento da qualidade pode ser feito de forma individualizada ou por amostragem (HALMSHAW, 1988). Na individualizada, todo o produto, fruto de um determinado processo produtivo, é verificado, em termos de especificações pré-estabelecidas, sendo descartado ou re-trabalhado, caso não esteja dentro dessas especificações. No caso do monitoramento por amostragem, onde uma ou algumas unidades de um lote do produto é verificada, também em termos de especificações pré-estabelecidas, uma amostra fora das especificações pode fazer com que todo o lote seja descartado ou re-trabalhado.

Infelizmente, em muitos produtos e processos, a verificação das especificações não pode ser realizada de forma simples, direta ou individualizada, devido às suas características e complexidades. Por exemplo, para conferir a capacidade de absorção de uma fralda descartável produzida, deve-se molhar a fralda até que ela não consiga mais absorver determinado líquido, verificando assim sua capacidade de absorção. É fácil perceber que esta fralda testada está inutilizada para consumo, já que um monitoramento da qualidade foi realizado utilizando-se um método destrutivo, o que impossibilita um monitoramento individualizado da qualidade.

Outro exemplo, e que será focalizado neste trabalho, é o processo de solda a ponto resistivo amplamente usado na indústria em virtude de sua aparente simplicidade e baixo custo de instalação e execução (BROOMHEAD, 1990). Produzir soldas com qualidade assegurada é um desafio em vários tipos de manufatura e áreas, devido à forte conexão entre a qualidade da solda e os aspectos de segurança e confiabilidade. Por exemplo, um ponto de mau contato de um componente eletro-eletrônico, como o contato de um relê, pode danificar a funcionalidade de um grande sistema elétrico e conduzir o seu controle a paralisar uma planta industrial de produção. Outro exemplo é a possibilidade de causar-se um incêndio devido a um curto-circuito em um componente eletro-eletrônico em um avião. Além da importância de assegurar a qualidade da solda de contatos elétricos em componentes eletro-eletrônicos, outro exemplo é a qualidade da solda na produção de veículos automotivos, já que cada automóvel atualmente possui entre 2000 e 6000 pontos de solda (BROWN; SCHWABER, 2000). Basta multiplicar este número pela quantidade de automóveis produzidos por ano no mundo, para se ter uma idéia de que bilhões de soldas são produzidas anualmente somente na indústria automotiva.

Ensaio destrutivo é a forma mais utilizada para se obter informação confiável a respeito da qualidade da solda. Normalmente, a característica da solda escolhida para definir sua qualidade está diretamente relacionada com sua aplicação. Por exemplo, no caso da fabricação de contatos elétricos, a qualidade da solda é definida pela força de cisalhamento que este contato suporta, ou seja, a característica escolhida é a força de cisalhamento. Já no caso da produção de veículos, a qualidade da solda é definida pelo tamanho do diâmetro do ponto de solda produzido, ou seja, a característica escolhida é o diâmetro final do ponto de solda.

Em partes utilizadas em certas áreas de risco, um a cada dez pontos de solda tem que ser verificado, através de teste destrutivo, para garantir a qualidade e a segurança. Isso conduz

a gastos consideráveis de dinheiro e tempo, além de um problema ambiental. Ensaio não-destrutivos como ultrassom e raios-X têm sido testados e aplicados (ROYE, 2002), mas ainda não são uma solução de baixo custo, pois requerem treinamento e habilidade dos operadores para atingir uma alta precisão, além de não poderem ser facilmente instalados na linha de produção e não possibilitarem um monitoramento individualizado durante a produção, devido ao tempo de operação e preparo ser normalmente maior que o tempo de produção das soldas.

Estas necessidades serviram de motivação para este trabalho. A principal motivação é propor e avaliar um sistema de monitoramento não-destrutivo da qualidade do processo de solda a ponto resistiva (PSPR) que realize a detecção e o diagnóstico de possíveis falhas no processo de soldagem. Este sistema deve monitorar de forma não-destrutiva, individualizada, em tempo real e em ambiente industrial, a qualidade do processo, além de identificar e fornecer possíveis causas para problemas que possam surgir durante a produção. O processo de solda a ponto resistiva que será analisado e usado para avaliar e validar este trabalho foi escolhido devido à sua abrangência, importância e inexistência de modelos que consigam descrevê-lo com exatidão. Serão utilizados dados reais obtidos na produção de lotes de contatos elétricos através do PSPR, para avaliar e validar este trabalho. O processo de produção de contatos elétricos tem algumas características críticas que são a alta taxa de produção e o pequeno tempo de soldagem de cada parte. É possível encontrar máquinas que produzam mais de 200 partes por minuto e o tempo de soldagem de cada parte é normalmente inferior a 40 milissegundos. Se o controle de qualidade for feito posteriormente à produção, um lote inteiro, que pode chegar a ter mais de 80.000 partes, poderá ser rejeitado. O sistema de monitoramento proposto neste trabalho pode ser adaptado e aplicado também em outros processos produtivos, pois seus componentes não são exclusivamente aplicados no processo de solda a ponto resistiva.

1.2 Objetivo

Com base nas motivações apresentadas anteriormente, o objetivo deste trabalho é propor e avaliar um sistema de monitoramento não-destrutivo da qualidade do PSPR, que opere de forma individualizada, em tempo real e que, ao detectar perda de qualidade no processo, seja capaz de diagnosticar as possíveis causas. Este sistema de monitoramento deve ainda ser exequível em ambiente industrial e apresentar um aspecto generalista, de forma a poder ser aplicado em outros processos, nos quais o monitoramento não possa ser feito de forma direta.

O sistema proposto será aplicado no monitoramento da qualidade de contatos elétricos produzidos pelo PSPR, que é um processo estocástico independente (dinâmico), o que permitirá avaliar seu desempenho e validar sua aplicabilidade.

Em suma, este trabalho deve resultar em um sistema capaz de monitorar de forma não-destrutiva, individualizada, em tempo real e em ambiente industrial, a qualidade dos pontos de solda produzidos, diminuindo ou mesmo eliminando a frequência da necessidade de testes destrutivos, reduzindo custos e aumentando a produtividade. Esse sistema deve ainda facilitar a manutenção do processo produtivo.

1.3 Estrutura do Trabalho

Este trabalho está organizado em cinco capítulos descritos a seguir.

O capítulo 1 mostra a motivação do trabalho e descreve os objetivos e sua organização.

O capítulo 2, intitulado “Monitoramento e Controle da Qualidade da Solda”, apresenta uma revisão bibliográfica sobre o tema e situa o sistema proposto neste trabalho dentro do tema, reforçando os objetivos e mostrando o caráter inovador e original do mesmo.

O capítulo 3, intitulado “O Sistema Proposto e seus Componentes”, apresenta em detalhes o sistema de monitoramento não destrutivo proposto neste trabalho. Inicialmente este será apresentado de forma geral, ou seja, sem conter especificidades de nenhum processo, apresentando assim potencial para ser aplicado em outros processos. Em seguida, este sistema será aplicado no PSPR, e cada um dos componentes do sistema será detalhado de acordo com essa aplicação. São mostradas ainda as ferramentas de software utilizadas neste trabalho.

No capítulo 4, intitulado “Avaliação e Validação do Sistema Proposto”, são apresentados os dados que foram usados para avaliar e validar o sistema proposto neste trabalho, os testes realizados com esses dados e os resultados obtidos.

As conclusões do trabalho são apresentadas no capítulo 5, juntamente com as propostas de futuros trabalhos.

No anexo A são apresentadas as teorias básicas de redes neurais artificiais e do algoritmo de *back-propagation* e, no anexo B, uma apresentação detalhada dos testes de soldagem realizados para obtenção dos dados usados para analisar e validar este trabalho.

2 Monitoramento e Controle da Qualidade da Solda

2.1 Introdução ao PSPR

A solda resistiva foi inventada no final do século XIX, sendo a primeira patente registrada por Elihu Thomson in 1885, o qual obteve grandes avanços nessa técnica nas duas décadas seguintes. Entretanto, sua aplicação industrial em larga escala ocorreu somente no século XX, inicialmente para fins militares, impulsionada principalmente pelas duas guerras mundiais, que demandavam um método barato e confiável para unir materiais (HARDT, 200-?).

As principais vantagens da solda resistiva incluem o uso eficiente de energia, deformação limitada das partes soldadas, altas taxas de produção, automação relativamente fácil e não requerer material para preenchimento. Este método de soldagem produz soldas que normalmente possuem menor resistência mecânica quando comparado a outros métodos de soldagem. Por esta razão, não é apropriado para todos os tipos de aplicação (SAPP, 200-?). É usado em grande escala na indústria automobilística, para fabricação da carroceria de veículos, e na indústria eletro-eletrônica, para fabricação de contatos elétricos.

No início do PSPR, o eletrodo superior se move na direção do eletrodo inferior de forma que as partes a serem soldadas fiquem mantidas pressionadas. A amplitude da força de soldagem pode ser controlada pela pressão de ar em um cilindro pneumático. Após as partes serem pressionadas por algum tempo, o circuito formado pelo secundário do transformador da máquina de solda, pelos braços de soldagem, pelos eletrodos e pelas partes a serem soldadas é energizado (figura 2.1). Dessa maneira uma corrente elétrica irá circular por este circuito. Esta corrente elétrica é chamada de corrente de soldagem e depende das resistências elétricas dos elementos que formam este circuito elétrico.




Figura 2.1 – Representação do Processo de Solda a Ponto Resistiva

Valores aproximados dessas resistências, para chapas de aço de 1 mm de espessura soldadas por eletrodos de cobre de 5 mm de diâmetro, são mostrados na figura 2.2 (PODRZAJ et al., 2008). Estas resistências variam bastante de acordo com a espessura e o tipo de material utilizado. As resistências dos braços de soldagem, eletrodos e secundário do transformador são normalmente consideradas desprezíveis.

A consequência da corrente de soldagem circulando por essas resistências é a geração de calor (efeito Joule), o qual depende do valor nominal dessa corrente, do tempo de soldagem e das resistências dos elementos do circuito, de acordo com a equação:

$$Q_{solda} = \int_0^t i^2(t).R(t)dt \quad (1)$$

onde: Q_{solda} = quantidade de calor gerado;

$i(t)$ = corrente de soldagem;

$R(t)$ = resistência dos elementos do circuito

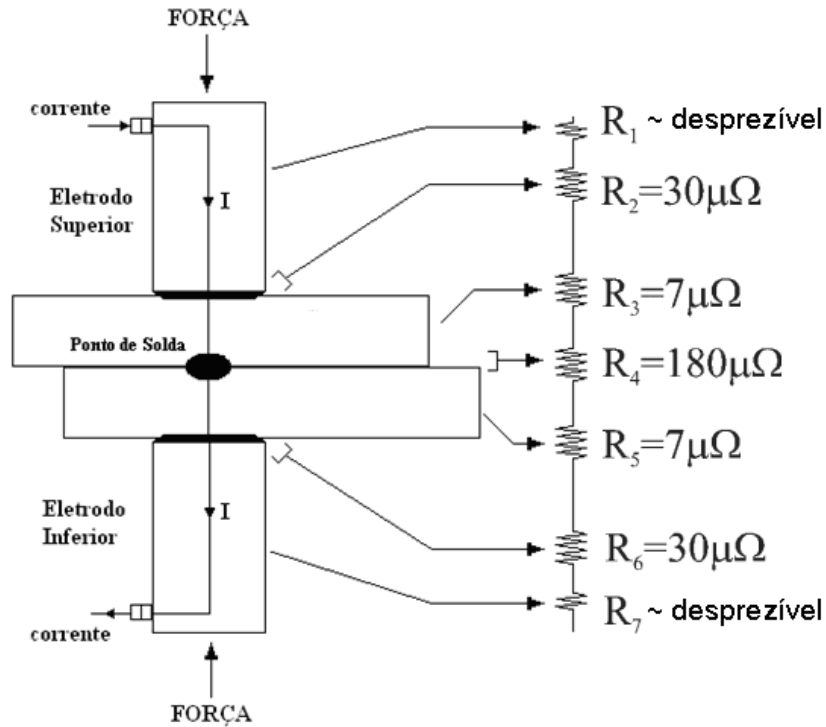


Figura 2.2 – Valores aproximados das resistências para chapas de aço de 1 mm e eletrodos de cobre de 5 mm de diâmetro

O resultado do calor gerado na interface material/material é a formação do botão de solda. O tamanho do botão é importante já que se relaciona com a força suportada pela solda.

Existem dois extremos em termos da quantidade de calor gerado durante o processo de soldagem. Se a quantidade de calor gerado for muito alta, resultará em expulsão de material e se for baixa demais, o botão de solda não se formará, sendo este efeito conhecido como solda fria. Portanto, a quantidade de calor gerado deve estar entre o requerido para uma solda fria e o que provoca expulsão de material. Soldas próximas do ponto de expulsão são preferidas, pois possuem um botão de solda maior e, portanto, uma maior resistência mecânica. A quantidade de calor gerada e, conseqüentemente, o ponto de expulsão depende da corrente de soldagem, do tempo de soldagem e da pressão dos eletrodos sobre os materiais a serem soldados. Se uma combinação apropriada desses parâmetros é escolhida, e não há perturbações no processo, uma solda aceitável é produzida. Embora a expulsão não necessariamente implique em uma diminuição da força suportada pela solda, ela é geralmente

indesejada, pois causa um desgaste maior nos eletrodos, um maior consumo de energia, uma aparência visual insatisfatória da solda e uma reduzida resistência à corrosão, no caso de materiais revestidos (PODRZAJ et al., 2008).

Com as exigências cada vez maiores com relação à qualidade, nas linhas de produção com alto grau de automatização, ter um monitoramento em tempo real da qualidade final do produto e/ou poder controlá-la, é importante para tomar decisões adequadas e minimizar eventuais prejuízos causados pela produção de produtos que não atendam a requisitos mínimos de qualidade.

Tradicionalmente, ensaios destrutivos eram usados para inspecionar a qualidade dos pontos de solda. A força de cisalhamento suportada pelos pontos de solda e o diâmetro do ponto de solda resultante são normalmente usados como parâmetros para se definir se a solda é de boa qualidade ou não. Estes parâmetros são diretamente inspecionados após o processo de fabricação e estão diretamente relacionados, já que o diâmetro do ponto de solda resultante, após o resfriamento da solda, define a resistência mecânica da solda (SAPP, 200-?) (MEOLA et al., 2004).

Nas últimas décadas, métodos não destrutivos surgiram para inspecionar, monitorar e controlar a qualidade das soldas (ROYE, 2002) (WILLIAMS; PARKER, 2004a). Estes métodos serão apresentados no decorrer desse capítulo com as respectivas referências.

2.2 Evolução do Monitoramento e Controle de Qualidade no PSPR

As primeiras máquinas de solda a ponto resistiva eram bem simples. O operador era responsável por aplicar a força de soldagem nos eletrodos, estabelecer a alimentação do circuito, acionando um contator, e controlar a quantidade de calor gerada através do tempo de soldagem. Ele observava a região de soldagem e decidia quando parar o PSPR, baseado

principalmente em sua experiência quanto à cor da solda. Como normalmente o PSPR dura apenas uma fração de segundo, era difícil de se obter repetitividade e soldas de boa qualidade (SAPP, 200-?).

Nasceu então a idéia de que se os parâmetros de soldagem pudessem ser fielmente repetidos em todas as soldagens, o que não era possível com soldadores humanos, isso asseguraria soldas de boa qualidade (SAPP, 200-?). Surgiram então sistemas de controle para se obter precisão e repetitividade do conjunto de parâmetros principais do PSPR, a tensão ou corrente de soldagem, a força aplicada nos eletrodos e o tempo de soldagem. A força de soldagem começou a ser controlada com alto grau de precisão através de sistemas pneumáticos. O tempo de soldagem foi inicialmente controlado com diodos, depois por contadores síncronos que o terminavam após contar um determinado número de ciclos da frequência da rede de alimentação (conhecidos como controladores de corrente alternada de 50/60Hz) (STANWAY, 1992) (HOLDREN, 1993). Com a invenção dos controles de alimentação utilizando fontes chaveadas operando em média frequência (alguns kHz), conhecidos como controles de alimentação CC, surgiram também diferentes estratégias de controle baseadas no conceito de que se manter determinado parâmetro da fonte de alimentação da máquina de solda constante, ao longo do processo de soldagem, seria suficiente para se obter soldas de boa qualidade.

Surgiram os controles de alimentação de corrente constante, nos quais o valor da corrente é monitorado e ajustado durante o processo de soldagem de forma a permanecer o mais constante possível (EL-BANNA et al., 2006). Encontramos também os controles de alimentação de tensão constante, que ao invés da corrente, tentam manter a tensão constante (SHVIRER et al., 1999) (WILLIAMS; PARKER, 2004a). Outro subgrupo é dos controladores de calor constante, que é baseado na ideia de se fornecer uma quantidade específica de calor por solda, isto é, uma quantidade fixa de calor induzido por unidade de

volume (WILLIAMS; PARKER, 2004a) (PODRZAJ et al., 2008). Estes tipos de controle de alimentação possibilitaram a produção de procedimentos de soldagem.

Há várias pesquisas para aperfeiçoar os procedimentos de soldagem embora este tipo de abordagem sempre encontre alguns problemas (IRVING, 1996) (MEWBORNE, 1999) (MARTÍN et al., 2006). Dado o número crescente de materiais utilizados nos PSPR, devido à variedade de geometrias de eletrodos, aos diferentes tipos de máquinas de soldagem, um grande número de procedimentos de soldagem torna-se necessário para cobrir todas as possíveis combinações. Além disso, esta abordagem desconsidera que existem perturbações durante o processo de soldagem (WILLIAMS; PARKER, 2004a). Portanto é imprescindível monitorar e limitar as possíveis perturbações, o que, dependendo do processo, tem sido inviável, em virtude do custo e do tempo necessário.

Atualmente, procedimentos de soldagem estão sendo criados com a ajuda do método de elementos finitos (EISAZADEH et al., 2010). Este tipo de abordagem tem sido utilizado para se ajustar os parâmetros principais de soldagem como intensidade da corrente, tempo de soldagem, força nos eletrodos e geometria dos eletrodos, através de simulações com um modelo de elementos finitos acoplado características térmicas, elétricas e mecânicas. Essas simulações auxiliam bastante na redução de custos já que reduzem ou eliminam a necessidade de onerosos testes experimentais reais normalmente utilizados para se ajustar esses parâmetros (EISAZADEH et al., 2010).

A consideração das perturbações gerou, na última década, outro tipo de abordagem para sistemas de monitoramento e controle da qualidade do PSPR, baseada no monitoramento de variáveis, sinais ou parâmetros do processo possíveis de serem medidos e que pudessem ser relacionados com a qualidade final da solda. Esses sistemas serão abordados no item 2.4. Em termos de controle de alimentação, surgiram recentemente os chamados controles de alimentação inteligentes, que monitoram algumas grandezas e, caso certas características

esperadas dessas grandezas não sejam atingidas, aumentam ou diminuem a corrente de soldagem, a pressão nos eletrodos e/ou o tempo de soldagem durante o PSPR (PODRZAJ et al., 2008).

2.3 Perturbações e Dificuldades do PSPR

Como visto anteriormente, os procedimentos de soldagem podem falhar principalmente devido às perturbações que ocorrem durante o PSPR. As principais perturbações que incidem no PSPR são:

- Perturbações na fonte de alimentação elétrica. Podem ocorrer variações na tensão e/ou corrente de alimentação;
- Condições variáveis da superfície do material a ser soldado. Esta pode estar, por exemplo, contaminada com óleo, empoeirada, empenada afetando assim a resistência de contato;
- Perturbações no sistema pneumático que controla a força de soldagem;
- Área e resistência de contato variável entre os eletrodos e as partes a serem soldadas. Devido ao desgaste dos eletrodos ao longo de sua vida útil, a área de contato tende a aumentar, assim como a possível impregnação de material das partes sendo soldadas, nos casos de expulsão de material, fazem com que a resistência eletrodo-material aumente (WILLIAMS; PARKER, 2004b);
- Variações na espessura e no revestimento das lâminas de material utilizado;
- Posicionamento ou ajuste ruim entre as partes a serem soldadas;
- Existência, próximo ao local da nova solda, de outro ponto de solda, acarretando desvio da corrente de soldagem devido à baixa resistência neste ponto (efeito *shunting*);

- Soldas próximas da borda dos materiais, conhecidas como “edge welding”.

As dificuldades associadas à implementação de um sistema de monitoramento e/ou controle de soldagem são:

- A variável de controle de qualidade, ou seja, a força suportada pela solda teria que ser medida em tempo real, o que é impossível já que somente é conhecida após o resfriamento da solda e necessita-se de um ensaio destrutivo para determinar seu valor;
- Inexistência de um modelo preciso do sistema, ou seja, uma relação entre a força suportada pela solda e todas as variáveis atuantes durante a soldagem;
- Existência de diferentes combinações de parâmetros de soldagem que resultam em uma solda com uma resistência mecânica aceitável, por exemplo, uma corrente de soldagem menor pode ser compensada, dentro de certos limites, por um período maior de soldagem e vice-versa.

Portanto, não se pode projetar um sistema capaz de monitorar e/ou controlar diretamente a força suportada pela solda já que esta não pode ser diretamente medida, o que torna necessário o uso de outras variáveis que possam ser medidas e que sejam correlacionadas com a qualidade da solda.

2.4 Sistemas Baseados em Grandezas Mensuráveis do PSPR

Os sistemas não destrutivos de monitoramento e/ou controle da qualidade do PSPR, baseados em grandezas mensuráveis do processo relacionadas com a qualidade final da solda, tornaram-se o foco principal das pesquisas e desenvolvimento, nesta área, na última década.

As principais variáveis e procedimentos encontrados na literatura são:

- Raio-x;
- Ultrassonografia;
- Medições baseadas na expansão do material durante a soldagem;
- Emissão acústica e sônica durante a soldagem;
- Medição da temperatura através de emissão infravermelha ou termopar;
- Imagem captada por câmera;
- Força de soldagem;
- Variáveis elétricas: a tensão de soldagem, a corrente de soldagem e a resistência dinâmica.

A figura 2.3 mostra um desenho esquemático do PSPR com exemplos de posicionamento dos principais sensores e das principais medições necessárias para se obter as variáveis relacionadas com a qualidade da solda encontradas na literatura, e usadas para monitorar e/ou controlar o PSPR.

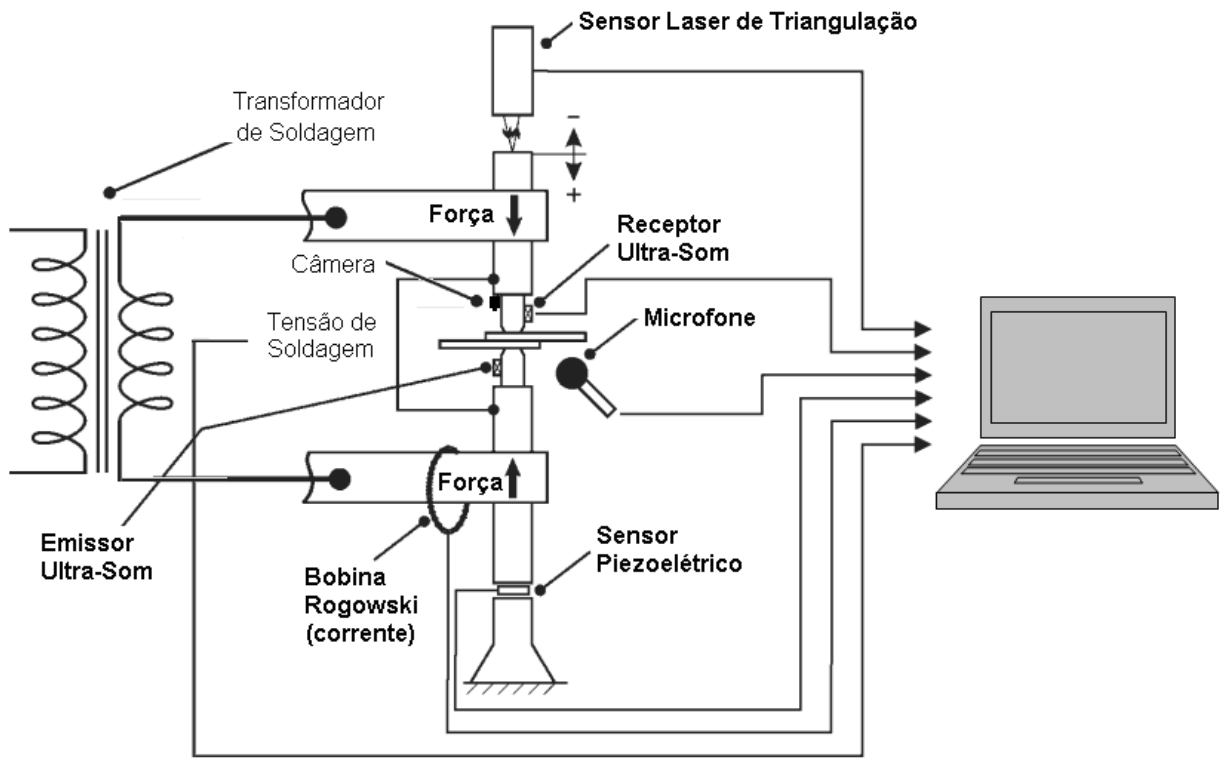


Figura 2.3 – Desenho esquemático do PSPR

O equipamento de raio-x não aparece na figura 2.3, pois é um procedimento difícil de ser incorporado ao equipamento de soldagem e necessita de ambiente especial devido à radiação envolvida. Não é, portanto, realizado no local de produção. Após o término do processo de soldagem, a peça é levada a um local com ambiente adequado à realização do ensaio com raio-x (HALMSHAW, 1988) (ROYE, 2002). Consequentemente, esse tipo de equipamento, apesar de possibilitar uma leitura do diâmetro final da solda, não é viável para se ter um monitoramento ou controle individualizado e em tempo real da qualidade final da solda.

A ultrassonografia pode ser aplicada como na figura 2.3, ou seja, com um transmissor de ultrassom e um receptor de ultrassom em módulos separados, sendo a razão da amplitude entre o sinal transmitido e o sinal recebido usada para estimar o tamanho da solda (VOGT et al., 2006).

Outra técnica de ultrassonografia é aquela que aproveita o eco produzido pelo som para ver em tempo real as reflexões produzidas pelas estruturas (MANSOUR, 1988). Neste caso, transmissor e receptor são montados no mesmo módulo. A onda se propaga através do ponto de solda em uma direção perpendicular às faces das partes unidas. O som vai sendo parcialmente refletido conforme mudanças na densidade e composição das estruturas. Um *scanner* sonográfico determina o tempo desde a transmissão até a recepção do eco e, a partir do intervalo de tempo, calcula a distância (profundidade) onde o foco se formou e também mede a intensidade do eco. De posse dessas informações, é possível gerar uma imagem, alocando para cada pixel da imagem uma intensidade.

A figura 2.4 mostra o caminho de propagação da onda ao longo da amostra e o formato das ondas idealmente recebidas (DENISOV et al., 2004). A presença de reflexão na área entre as partes soldadas indica que estas estão separadas, o que corresponde a uma área não soldada (Fig. 2.4A). Se as partes foram soldadas, não há uma onda de reflexão interna, e

há a reflexão da face oposta da outra parte (Fig. 2.4C). Se a onda se propaga em uma área parcialmente soldada, o sinal resultante é uma combinação das formas de onda de A e C (Fig. 2.4B).




Figura 2.4 – Caminho idealizado da onda através das partes (esquerda) e a forma de onda correspondente obtida (direita) (DENISOV et al., 2004)

No trabalho publicado por VOGT et al. (2006), é apresentado um sistema proprietário aplicado em campo, baseado em técnicas de ultrassonografia, usado para inspecionar e controlar o processo de solda a ponto resistiva. Este sistema pode ser instalado diretamente nos braços de soldagem, integrando a este um sensor ultrassônico. Os sinais de eco são coletados, armazenados e analisados, utilizando lógica *fuzzy* e redes neurais. É obtida então uma relação entre a área do ponto de solda e a qualidade do mesmo. Infelizmente este sistema

apresenta a necessidade de se calibrar o sensor regularmente, não suporta processos com alta taxa de produção, é relativamente caro e os sinais são susceptíveis a flutuações do campo magnético durante a soldagem e não determinam a força de cisalhamento em processos nos quais este é o parâmetro de qualidade.

A técnica de ultrassonografia tem sido explorada também por outros pesquisadores, para medir a qualidade do ponto de solda, principalmente na indústria automobilística, na produção de carrocerias, já que o parâmetro de qualidade para este tipo de solda é o diâmetro da solda e este pode ser facilmente obtido na imagem gerada (DOYUM; SONAT, 2003) (MARTÍN et al., 2007). Mas as soluções propostas baseadas nessa técnica possuem limitações para aplicações em tempo real e parecem funcionar satisfatoriamente somente em laboratório onde não existem tantas perturbações quantas em um ambiente industrial real. Podem ser utilizadas na análise de soldas em uma parte específica da carroceria após a fabricação, mas são de difícil adaptação a uma linha de produção real, e não suportam processos com alta taxa de produção.

Outra técnica amplamente encontrada na literatura é baseada na expansão do material durante a soldagem. Esse tipo de abordagem pode ainda ser dividido em duas classes. A primeira é baseada na medição da pressão exercida por essa expansão na superfície dos eletrodos. A segunda é baseada na medição direta do deslocamento entre os eletrodos durante a expansão.

Existe uma distinta diferença entre a força de soldagem aplicada nos eletrodos e a força térmica na superfície dos eletrodos. A primeira é um importante parâmetro do processo de soldagem a ponto resistivo, já que ela garante o contato entre as partes a serem soldadas, criando então um caminho elétrico para circulação da corrente de soldagem e também ajuda a manter a energia concentrada entre os eletrodos durante a soldagem, evitando que haja expulsão de material. A segunda é aquela que surge devido à expansão do material durante o

processo de soldagem. Essa força térmica é então sentida pelos braços nos quais os eletrodos estão fixados. O seu monitoramento indica se o ponto de soldagem já teve um crescimento suficiente e é usada como retroalimentação para o controle da soldagem, já que reflete o estado do metal durante o processo de soldagem (MESSLER, 1995). Este tipo de abordagem foi explorado por alguns pesquisadores, mas tem como grande desvantagem o fato do sistema necessitar ser extremamente rígido, de forma que a estrutura tenha o mínimo de vibração possível, para ser capaz de medir com precisão a sutil variação de pressão nos eletrodos devido ao crescimento do ponto de solda, portanto reduzindo muito sua real aplicabilidade (HIRSCH, 1993).

A medição direta do deslocamento dos eletrodos durante a expansão tem sido explorada por vários pesquisadores. Um transformador diferencial linear é normalmente utilizado para medir o deslocamento do eletrodo (PENGXIAN et al., 2007). Para evitar a interferência de medição devido à influência do campo magnético, o deslocamento do eletrodo também pode ser medido com um codificador óptico digital, como o sensor laser de triangulação apresentado na figura 2.3 (LEE et al., 2001). Esta técnica parte do princípio de que a quantidade de expansão térmica, fusão e expulsão dos materiais envolvidos pode ser correlacionada com a curvatura e magnitude da curva de deslocamento do eletrodo durante a soldagem (CHO; RHEE, 2003 e 2004). Esta curva de deslocamento dos eletrodos medida pode ser dividida em uma curva de variação e uma curva de tendência, as quais refletem diferentes aspectos da qualidade da solda a ponto resistiva (EL-BANNA et al., 2008). Para analisar as medições de deslocamento do eletrodo, alguns métodos analíticos são utilizados, como análise por Wavelets e análise de Fourier e os dados obtidos são normalmente aplicados em uma rede neural artificial ou em um sistema *neuro-fuzzy* (ZHANG et al., 2005) (JOU, 2001 e 2003) (ZHANG et al., 2007) (XINMIN et al., 2007). A principal limitação dessa técnica é a falta de robustez. De um ponto de vista prático, os problemas com a fiação,

vibrações do equipamento e o campo magnético sempre serão um ponto negativo. Além disso, essa técnica não é adequada para materiais de pequena espessura ($< 0,5\text{mm}$) e em processos com alta taxa de produção.

A técnica baseada na emissão acústica e sônica detecta os sons emitidos durante o processo de soldagem. O termo emissão acústica é utilizado se o sensor é montado na parte a ser soldada ou no eletrodo. Se um microfone comum é usado, utiliza-se o termo emissão sônica. Existem diversas fontes de emissão de som durante o PSPR. A magnitude da emissão acústica e sônica durante a condução da corrente de soldagem depende da quantidade de calor sendo gerado e, portanto, pode ser correlacionada com a força suportada pela solda (PODRZAJ et al., 2005). A maior desvantagem de se medir a emissão acústica é a necessidade de se fixar o sensor ou na parte a ser soldada, o que deve ser feito em todas as partes, consumindo muito tempo, ou nos eletrodos, o que resulta em um sinal com alto grau de ruído devido à circulação interna de líquido para refrigerá-lo. A medição da emissão sônica é bem mais simples e pode alcançar resultados satisfatórios na estimação da força suportada pela solda em laboratório. O principal problema para sua aplicação industrial é o ruído ambiente, normalmente significativo em um ambiente de produção industrial (PODRZAJ et al., 2005).

Ainda outra técnica empregada é aquela baseada na medição da temperatura da solda durante o PSPR. A luz infravermelha emitida e a tensão produzida por um termopar são usadas para medir a temperatura na superfície da solda. A luz infravermelha emitida pode ser relacionada com a força suportada pela solda e usada como entrada em um sistema de controle (PODRZAJ et al., 2008). Entretanto, este sinal não é adequado para uso em ambiente industrial de produção, pois necessita de cuidados especiais para assegurar uma emissividade constante da superfície, e mesmo quando isso é assegurado, a sujeira e a fumaça produzidas durante o PSPR podem contaminar o sinal. A tensão produzida por um termopar também não

é adequada para uso em ambiente de produção devido às dificuldades de fixação do termopar. Seu uso é normalmente limitado ao período de resfriamento da região soldada. A taxa de resfriamento depende do tamanho da lentilha de solda (PODRZAJ et al., 2008).

A imagem captada por uma câmera é usada em um método de visão computacional para estimar a qualidade da solda produzida (RUISZ et al., 2007). A câmera é fixada na pinça de soldagem de forma que seja possível adquirir a imagem da impressão deixada no material pelo PSPR, como mostrado na figura 2.5. O formato e o tamanho das estruturas na impressão são correlacionados com a área da lentilha de solda e permitem estimar a qualidade do ponto de solda. O sistema segmenta a imagem e separa a parte da impressão relativa à marca do eletrodo da parte da impressão que representa a área que sofreu maior impacto do calor gerado pelo processo. Nesta área de maior impacto do calor gerado é então encontrado o diâmetro do ponto de solda. O autor diz obter uma boa precisão na estimativa da qualidade com este sistema proposto e que ele apresenta várias limitações. O sistema necessita de iluminação especial para adquirir-se a imagem. Não pode ser adaptado em todo tipo de máquina de soldagem. O processo de segmentação da imagem depende da variação de contraste entre as áreas alvo, e essa variação nem sempre é suficiente para uma boa segmentação das áreas, conforme o próprio autor relata.

A força de soldagem é medida por um sensor piezoelétrico que necessita ser adaptado ao braço da máquina que segura o eletrodo. Não existem trabalhos que usem exclusivamente este sinal para monitorar ou controlar a qualidade final da solda. Embora esta força não seja usada diretamente para se estimar a qualidade da solda, em conjunto com outros sinais, como o deslocamento do eletrodo e a resistência dinâmica do PSPR, ela tem sido explorada por alguns pesquisadores (LI et al., 2000 e 2001). A força de soldagem é usada também como sinal auxiliar em sistemas de controle da alimentação de soldagem (SUBRAMANIAN et al., 2004) (WILLIAMS; PARKER, 2004a).




Figura 2.5 – Imagem da impressão no material após o PSPR (RUISZ et al., 2007)

As variáveis elétricas são comumente utilizadas já que para medi-las não é necessário o uso de sensores ou equipamentos caros. A tensão de soldagem pode ser medida diretamente nos eletrodos, enquanto a corrente de soldagem pode ser obtida através da tensão induzida medida com uma bobina Rogowski, conforme ilustrado na fig. 2.3. A razão entre a tensão de soldagem e a corrente de soldagem varia durante o processo de soldagem já que a resistividade elétrica dos materiais depende da temperatura e, portanto, varia durante a formação da solda. Por esta razão, é chamada de resistência dinâmica.

Diversas pesquisas mostraram que a resistência dinâmica é particularmente importante porque pode ser usada para monitorar mudanças nas partes soldadas (CHO; RHEE, 2003). Portanto, esta variável é estabelecida como base primária para desenvolvimento da maioria dos sistemas de monitoramento e controle do PSPR.

Para entender qualquer PSPR, é necessário entender a função das várias resistências presentes entre os eletrodos e como estas resistências influenciam a geração de calor nas

várias interfaces. Uma curva teórica clássica da resistência dinâmica durante a soldagem de aço é mostrada na figura 2.6.

O trabalho mais aprofundado de alguns pesquisadores indicou que a curva da resistência dinâmica pode ser subdividida em cinco estágios (WILLIAMS; PARKER, 2004a). No primeiro estágio, a resistência dinâmica tende a diminuir com a melhora no contato entre as partes a serem soldadas devido ao colapso da rugosidade e também devido à melhora no contato entre os eletrodos e as partes.




Figura 2.6 – Curva da resistência dinâmica clássica para soldagem de aço

Em um segundo estágio, a resistência dinâmica atinge um valor mínimo e começa a crescer quando o efeito do aumento da resistividade das partes, devido ao aumento da temperatura, supera o efeito citado no primeiro estágio. No terceiro estágio a resistência dinâmica cresce, devido à predominância do aquecimento das partes. Em um quarto estágio, as partes atingem o nível de aquecimento necessário para iniciar a fusão na interface de contato e esta zona de fusão vai crescendo rapidamente. A taxa de crescimento da resistência dinâmica passa a ser um compromisso entre o aumento da resistência devido ao aquecimento

das partes e uma diminuição da resistência devido ao aumento do tamanho da zona de fusão. Neste estágio atinge-se o pico da resistência dinâmica, conhecido na literatura como pico β (*peak*). No quinto estágio ocorre uma diminuição da resistência dinâmica devido ao crescimento da zona de fusão e ao início de colapso da resistência mecânica das partes que faz com que os eletrodos comecem a penetrar, diminuindo o caminho da corrente. Neste estágio, a solda deve ser finalizada antes que ocorra expulsão de material. Caso haja expulsão de material, uma brusca queda instantânea ocorre na resistência dinâmica, fazendo com que este problema seja facilmente detectado através de análise da curva da resistência dinâmica.

O formato da curva de resistência dinâmica do PSPR pode variar bastante de um processo para outro, influenciado principalmente pelo tipo de material das partes soldadas, utilização de materiais revestidos, espessura dos materiais e tempo de soldagem.

A curva da resistência dinâmica foi escolhida para ser utilizada neste trabalho para desenvolver um sistema capaz de realizar em tempo real e em ambiente industrial o monitoramento da qualidade do PSPR, em que se destacam os seguintes motivos:

- A curva de resistência dinâmica reflete a variação da temperatura e outras alterações na região de soldagem;
- As medições de tensão e corrente necessárias para obtenção da resistência dinâmica não são invasivas, não estorvam a produção da solda, não alteram os parâmetros de soldagem, podem ser feitas em qualquer tipo de pinça de soldagem e são robustas ao ambiente industrial.

Os sistemas de monitoramento e controle da qualidade do PSPR baseados nas medições de variáveis elétricas encontrados na literatura podem ser divididos em três grupos principais (PODRZAJ et al., 2008):

- Sistema de Controle da Qualidade Realimentado: neste sistema os parâmetros de soldagem podem ser ajustados durante o processo de solda, ou seja, dentro do tempo de soldagem, de acordo com os valores de medição intermediários realimentados;
- Sistema de Controle da Qualidade Solda a Solda: neste tipo de sistema os parâmetros de soldagem podem ser ajustados no período entre o final da produção de uma solda e o início da produção de outra. O ajuste para a próxima solda é determinado pelas medições executadas durante a(s) soldagem(s) anterior(es).
- Sistema de Monitoramento da Qualidade: este tipo de sistema não reajusta os parâmetros de soldagem, somente determina a qualidade final da solda. Esta determinação pode ser qualitativa ou quantitativa.

Os primeiros tipos de sistemas de controle da qualidade realimentados eram do tipo liga-desliga. A resistência dinâmica era monitorada e o controle interrompia o processo de soldagem quando um valor pré-determinado era atingido (PODRZAJ et al., 2008).

Depois vieram os sistemas de controle da qualidade realimentados do tipo *tracking*, onde o sistema ajusta a corrente de soldagem de forma a seguir um sinal de referência, como no trabalho de Chen e Araki (1997), que descreve um sistema de controle *fuzzy* adaptativo para o PSPR baseado na identificação da resistência dinâmica durante o PSPR, e no trabalho de Furlanetto, Motomura e Batalha (2008). Este tipo de sistema apresenta resultados melhores que o do tipo liga-desliga, mas ambos são afetados pelas perturbações do PSPR. Além disso, curvas de referência para diferentes materiais e espessuras de materiais ainda necessitam ser obtidas experimentalmente.

Pertencem ainda a este grupo de sistemas os controles de alimentação de corrente constante, de tensão constante e os de calor constante ou potência constante, já mencionados no item 2.2, que monitoram e buscam manter, respectivamente, corrente, tensão e potência

constantes como condição para se obter soldas de boa qualidade. Estes três tipos, principalmente o de corrente constante, são muito utilizados ainda hoje, mas não levam em consideração as perturbações do PSPR, que prejudicam seu desempenho.

Em vista da dificuldade de prover modelos matemáticos eficientes do PSPR para servirem como base de um algoritmo de controle e devido ao curto tempo de soldagem de alguns processos, sistemas de monitoramento da qualidade ganharam ênfase e técnicas alternativas passaram a ser examinadas. A tendência nesses sistemas de monitoramento propostos é a aplicação de técnicas de inteligência artificial, em particular, o uso de redes neurais artificiais e de lógica *fuzzy*. Encontramos também o uso de *Support Vector Machine* (ZHANG; HOU, 2009), mas os resultados apresentados são inferiores aos obtidos com os outros métodos.

O uso de lógica *fuzzy* em sistemas de monitoramento é mais restrito e normalmente é utilizada em sistemas de controle do tipo *tracking* como citado anteriormente. Exemplos de sistemas de monitoramento que utilizam lógica *fuzzy* podem ser encontrados nos trabalhos de Brown et al. (1998), Lee et al. (2001) e Zhang et al. (2007). Já as redes neurais artificiais são amplamente utilizadas para estimar o diâmetro da lentilha de solda ou a força de cisalhamento suportada pela solda ou para classificar as soldas. O tipo mais comum de rede neural utilizada é do tipo *Perceptron* multicamadas, com uma camada escondida, em conjunto com o algoritmo de aprendizagem *backpropagation*. O que basicamente difere os sistemas de monitoramento utilizando essa técnica são as características extraídas das variáveis elétricas medidas que passam a representar as amostras do processo.

No trabalho de Diltthey e Dickersbach (1999), o valor da corrente máxima em cada meio ciclo senoidal e o respectivo valor de tensão neste mesmo tempo foram utilizados como dados de entrada da rede neural possibilitando a essa estimar a força de cisalhamento suportada pelas soldas. Como resultado, obteve-se um erro quadrático médio de 0,27kN em

um processo ajustado para produzir soldas que suportassem 4,3kN. Aravinthan et al. (2001) utilizam esses pontos de máximo da corrente e tensão divididos um pelo outro, ou seja, a curva de resistência dinâmica como entrada da rede neural. Já Ivezic et al. (1999) utilizam na entrada da rede proposta 16 neurônios que recebem dados de oito picos de tensão e seus respectivos picos de corrente, alguns neurônios para os parâmetros estáticos de soldagem e três neurônios organizados como um tipo de registrador de deslocamento, sendo estes caracterizados por uma integração da curva de resistência dinâmica com tempos sucessivamente maiores. Os resultados mostram 95% de precisão na classificação das soldas, como aprovadas ou reprovadas, com relação ao tamanho do ponto de solda resultante.

No trabalho de Garza e Das (2000) é proposto um novo método para cálculo da resistência dinâmica baseado em um modelo variante no tempo que tem como entrada a corrente e como saída, a tensão de soldagem. Em 2001, estes mesmos autores propõem o uso da curva da resistência dinâmica da solda calculada por esse novo método, reduzida para 120 pontos por método de decimação, em um sistema de monitoramento da qualidade baseado em redes neurais artificiais para identificar soldas ruins (GARZA; DAS, 2001). O resultado obtido de 5 erros de classificação em 40 amostras usadas para treinar e testar a rede neural não mostra grandes vantagens em utilizar esse método. Cho e Rhee (2000) propõem medir no circuito primário da máquina de soldagem as variáveis do processo e usá-las para obter a curva de variação da resistência dinâmica através dos eletrodos. Dessa curva, quatro características são extraídas, como desvio padrão, localização e valor do pico de resistência e o ângulo de inclinação durante o crescimento da resistência. Como resultado a resistência dinâmica apresentou um erro de $2\mu\Omega$ quando comparada ao método tradicional de medição no secundário e a estimação da força de cisalhamento pela rede apresentou um erro percentual médio de 8,7228%. Em 2002, estes mesmos autores, ainda usando medições no primário, utilizaram modelos de regressão linear e não-linear com 10 fatores de estimação como entrada

da rede neural (CHO; RHEE, 2002). Como resultado obtiveram um erro médio quadrático de 84N em amostras que suportavam uma força de cisalhamento entre 2,6kN e 3,5kN.

No trabalho de Subramanian et al. (2004), as características extraídas da curva da resistência dinâmica e usadas na entrada da rede neural são a resistência máxima, tempo para atingir a resistência máxima, diferença entre a resistência máxima e a resistência mínima, integral da curva do início ao fim da soldagem, taxa de decaimento da curva após atingir a resistência máxima e a resistência inicial quando os eletrodos iniciam a pressão nas partes. Foi obtida neste trabalho uma precisão de +/- 0,4mm, mas somente 15 amostras foram usadas para validar a rede. Seguindo esta linha, Ling et al. (2009) usam a resistência mínima, resistência máxima, resistência final, tempo para atingir a resistência mínima e tempo para atingir a resistência máxima como entrada de uma rede neural usada para classificar as soldas em 3 classes, boas, ruins ou com expulsão. Na pesquisa de Martín et al. (2006), são usadas como características da rede o tempo de soldagem, a curva de corrente e o tipo de eletrodo. De forma similar, Wen et al. (2009) usam na entrada da rede neural o tempo de soldagem, a curva de corrente e o valor da resistência final da curva de resistência dinâmica. Já Gong et al. (2007) usam o fator de potência dinâmico, calculado através da defasagem entre as curvas de tensão e corrente, como entrada da rede. Essa característica não é muito viável, pois depende de uma altíssima frequência de amostragem em sistema de controle de alimentação em média frequência para se obter um valor razoável da defasagem, caso contrário, a defasagem será basicamente a mesma em todos os pontos. Uma mistura de características de várias medições como tensão, corrente, resistência dinâmica, deslocamento do eletrodo, emissão infravermelha e emissão ultrassônica é usada no trabalho de Cullen et al. (2008). Após testar várias combinações, o melhor resultado foi uma precisão de 90%.

Rede Neural do tipo Hopfield também é encontrada na literatura e usada para classificar as soldas (CHO; RHEE, 2004), mas os resultados apresentados não são melhores

que os encontrados em artigos que utilizam as redes neurais do tipo Perceptron multicamadas. O treinamento das redes usando quantização linear de vetores ao invés do algoritmo de *backpropagation* também é encontrado na literatura e segundo os autores mostra resultados promissores (EL-BANNA et al., 2008).

Conforme mostrado, a maioria dos métodos encontrados na literatura baseados em variáveis elétricas, devido às características geométricas ou estatísticas extraídas da curva tais como valor médio, valor máximo, tempo para se atingir o valor máximo, derivada de crescimento, análise das componentes principais, não apresenta boa reprodutibilidade, ou seja, só funciona com um tipo específico de controlador e de processo. Outros requerem um conjunto muito grande de dados para treinamento e validação. Métodos baseados na medição de outras grandezas, que não as variáveis elétricas, são muito susceptíveis a ruídos diversos nas medições (eletromagnéticos, vibrações, fumaça, som ambiente) e alguns não são possíveis de se implementar em tempo real e em ambiente industrial. Nenhum dos sistemas para monitoramento da qualidade encontrado detecta possíveis causas que podem estar degradando a qualidade do processo caso uma solda de má qualidade seja identificada. Somente fazem uma estimativa não numérica da qualidade final da solda.

Neste trabalho será proposto um sistema que satisfaz as características do grupo dos sistemas de monitoramento da qualidade, mas que além de determinar a qualidade final das soldas, identifica possíveis causas para soldas de qualidade insatisfatória. O sistema proposto tem ainda potencial para ser usado também como sistema de controle solda a solda, como será justificado no capítulo 3.

Este sistema de monitoramento não destrutivo proposto é baseado na curva da resistência elétrica dinâmica obtida durante o processo de soldagem e em um modelo parametrizável fundamentado em propriedades físicas do processo. Este sistema pode ser implementado em campo e em tempo real, não requer um conjunto muito grande de amostras

para treinamento, pode ser aplicado em máquinas de soldagem com qualquer tipo de controlador, apresenta boa imunidade aos ruídos nos sinais medidos e não depende nem de uma amostra estatística específica nem de um comportamento específico da grandeza medida. O sistema proposto tem ainda potencial para ser usado também como sistema de controle solda a solda e também tem potencial de ser aplicado em outros processos. O capítulo 3 apresentará uma descrição detalhada desse sistema de monitoramento proposto e a argumentação para justificar suas características.

3 O Sistema Proposto e seus Componentes

Neste capítulo será apresentado em detalhes o sistema de monitoramento não destrutivo proposto. Inicialmente este será apresentado de forma geral, ou seja, sem conter especificidades de nenhum processo, apresentando assim potencial para ser aplicado em diversos processos. Depois este sistema será aplicado no processo de solda a ponto resistiva, e cada um de seus componentes será detalhado de acordo com essa aplicação. São apresentadas ainda as ferramentas de software utilizadas neste trabalho.

3.1 Descrição do Sistema de Monitoramento Proposto

O sistema de monitoramento da qualidade não destrutivo proposto é baseado em reconhecimento de padrões através de redes neurais artificiais de forma a realizar em tempo real e em um ambiente industrial a estimação da qualidade de cada parte produzida.

Como dito, este sistema é idealizado para processos industriais nos quais o monitoramento da qualidade não possa ser feito de forma direta, ou seja, sem que se utilize um método de ensaio destrutivo.

Um fluxograma do sistema proposto pode ser visto na figura 3.1.

Inicialmente é necessário avaliar o processo e verificar quais grandezas (variáveis ou sinais) podem ser medidas direta ou indiretamente, e se pode haver uma relação entre essas grandezas e a qualidade final do produto produzido pelo processo. A existência dessa relação poderá ser avaliada pelo resultado obtido no treinamento do sistema.

Essas medições devem ser pré-processadas de forma a eliminar o máximo possível de ruído e deixar os dados representativos da grandeza medida.

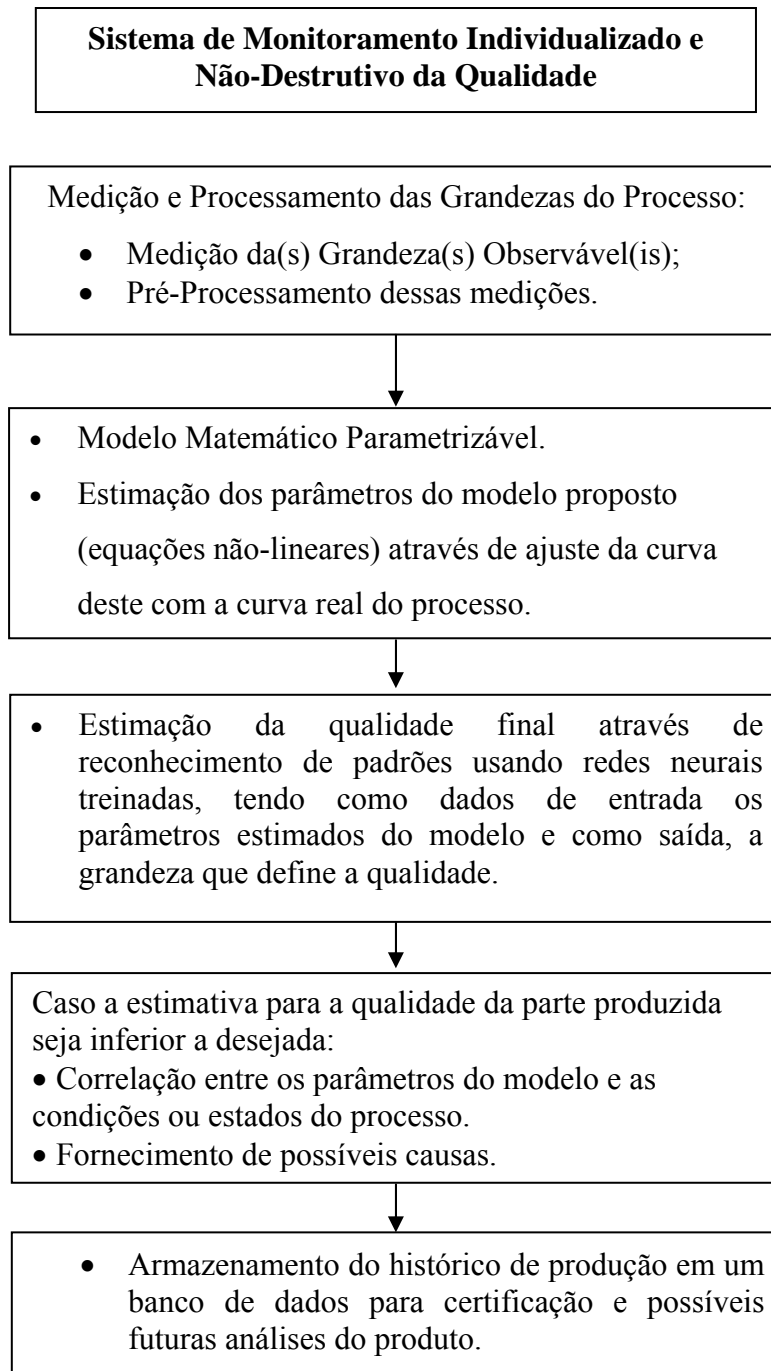


Figura 3.1 - Fluxograma do Sistema de Monitoramento da Qualidade Proposto

É necessário então criar um modelo matemático parametrizável da grandeza observável. Este modelo parametrizável deve ser construído baseado em propriedades físicas dessa grandeza do processo, passível de ser medida e monitorada em tempo real, de forma

direta ou indireta. Este modelo matemático parametrizável não é idealizado para fins de simulação do processo e sim para refletir as propriedades fundamentais da grandeza possível de se observar no processo que descreve.

De posse da curva medida no processo da variação no tempo da grandeza observável e de posse da curva produzida pelo modelo matemático parametrizável, é possível fazer o ajuste dessas curvas, utilizando um método de ajuste de curvas. Este método ajustará os valores dos parâmetros variáveis do modelo, até que se obtenha um ajuste aceitável (menor que um erro pré-determinado) entre a curva gerada pelo modelo e a curva real da grandeza observável do processo. Por tratar-se de um modelo baseado em propriedades físicas conhecidas, estes valores dos parâmetros do modelo obtidos na etapa de ajuste das curvas poderão ser interpretados e relacionados com os estados ou condições do processo de forma a auxiliar na identificação de possíveis problemas que afetem a qualidade.

Como dito, o importante é que o modelo matemático parametrizável reflita as propriedades fundamentais do processo em investigação. Assim, o melhor ajuste da curva gerada pelo modelo refletirá somente aquelas propriedades expressas pelo modelo e resultará em um grupo de valores correspondentes para os parâmetros do modelo. Desta forma, componentes do sinal adquirido que não são refletidas no modelo serão filtradas. Usando os parâmetros do modelo como características do processo em investigação no método de reconhecimento de padrões, somente componentes do sinal adquiridos em conformidade com o modelo determinarão os resultados. Estas características concentram as informações relevantes do sinal (compressão do sinal) e o sinal reconstruído utilizando os valores dos parâmetros do modelo pode ser considerado filtrado por conformidade com o modelo.

Com a utilização de redes neurais artificiais, é possível fazer a estimativa da qualidade final do produto, mas estas redes devem, inicialmente, ser treinadas e validadas com um conjunto de amostras reais do processo.

Conforme citado anteriormente, como características das amostras do processo serão utilizados os parâmetros do modelo matemático parametrizável ajustados na fase anterior.

Cada amostra do processo será, portanto, representada por um conjunto de valores (os valores dos parâmetros ajustados do modelo) e é necessário conhecer o valor da grandeza que define a qualidade para cada amostra (possivelmente obtido através de ensaio destrutivo), ou seja, qual o valor da qualidade final de cada amostra, para que se possa treinar e validar a rede neural.

Uma parte do conjunto de amostras reais do processo é usada para treinar a rede neural e outra parte, para validá-la. Diferentes topologias de rede devem ser testadas de forma a encontrar a melhor topologia para o processo analisado. Dessa forma, a rede será capaz de estimar o valor da qualidade final de cada amostra submetida.

Após o treinamento e a validação da rede neural, analisando os resultados, é possível saber se a grandeza observável e os parâmetros do modelo apresentam uma correlação com a qualidade final do processo, ou seja, se o sistema realmente consegue estimar a qualidade final do processo. Para isso, deve-se verificar se o erro quadrático médio e/ou o erro relativo médio e o coeficiente de determinação (R^2) são aceitáveis. Caso os valores encontrados não sejam aceitáveis, antes de se descartar a grandeza observável, deve-se verificar falhas no modelo matemático criado e reajustá-lo. Caso os resultados ainda não sejam aceitáveis, o sistema proposto neste trabalho não pode ser aplicado ao processo em investigação.

Caso a estimativa para a qualidade final do produto pela rede seja aceitável, o sistema pode ainda ser usado para identificar possíveis problemas no processo em amostras que apresentem uma qualidade estimada inferior à mínima desejada, através da correlação entre os valores dos parâmetros do modelo matemático e as condições do processo. Isso é possível graças à possibilidade de interpretação dos parâmetros do modelo.

Os dados de produção podem ainda ser armazenados em um banco de dados formando um histórico de produção que pode ser usado para certificação do processo e para possíveis análises futuras do produto.

Observando-se as características do sistema de monitoramento da qualidade individualizado e não destrutivo apresentado, algumas conclusões com relação ao sistema podem ser deduzidas:

- Ele é viável já que para sua aplicação só é necessário que alguma grandeza do processo possa ser medida e que um modelo matemático parametrizável baseado nas propriedades físicas dessa grandeza possa ser criado;
- Não contém especificidades de nenhum processo produtivo e, portanto, apresenta potencial para ser aplicado em diferentes processos;
- É realizável em ambiente industrial, desde que as características desse ambiente não inviabilizem a aquisição de sinais do processo;
- Automatiza o monitoramento da qualidade, já que após sua implementação não há mais necessidade de atuação humana na estimativa da qualidade final do produto;
- Pode identificar possíveis problemas no processo, graças à possibilidade de interpretação dos parâmetros do modelo, o qual é baseado em propriedades físicas conhecidas.

3.2 Aplicação do Sistema no PSPR

A avaliação e a validação deste sistema de monitoramento serão realizadas por meio de dados reais obtidos diretamente da produção de lotes de contatos elétricos produzidos através do processo de solda a ponto resistiva.

De forma a facilitar a análise e visualização, a figura 3.2 apresenta um diagrama esquemático ilustrativo do sistema de monitoramento individualizado não destrutivo da qualidade proposto aplicado ao PSPR.

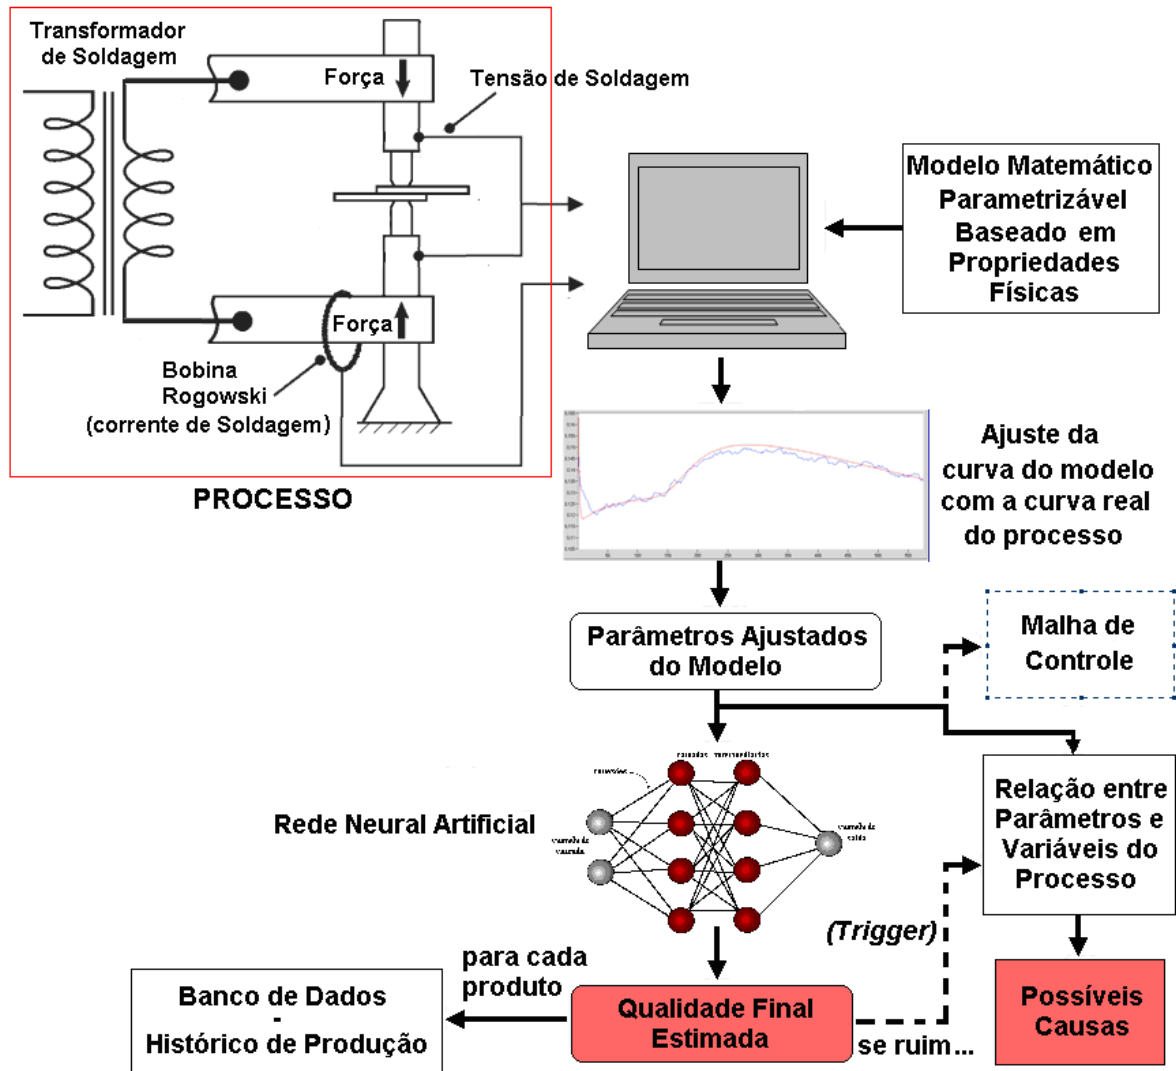


Figura 3.2 - Diagrama Esquemático do Sistema de Monitoramento da Qualidade Proposto

As grandezas medidas do processo e utilizadas como base para o monitoramento da qualidade são a tensão entre os eletrodos e a corrente nos eletrodos durante o processo de solda, por serem relacionadas com a qualidade final da solda conforme vários estudos já demonstraram (DILTNEY; DICKERSBACH, 1999) (CHO; RHEE, 2000) (GARZA; DAS, 2001) e pelas vantagens já citadas no capítulo 2.

Como abordado também no capítulo 2, com a medição dessas grandezas, é possível obter-se a curva da resistência dinâmica do PSPR.

O modelo matemático parametrizável será, portanto, criado baseado nas propriedades físicas da variação da resistência elétrica durante o processo de soldagem.

Por ser tratar de um processo não linear e altamente não determinístico, é necessário um método não linear para realizar o ajuste da curva do modelo com a curva real do processo.

Os parâmetros ajustados do modelo criado podem ser utilizados para caracterizar o processo. Após essa etapa, redes neurais artificiais de diferentes topologias podem ser treinadas e validadas através de um conjunto de amostras do processo, cada qual composta pelos parâmetros ajustados do modelo e pela qualidade final da solda, representada pela força de cisalhamento suportada, obtida através de ensaio destrutivo.

Após o treinamento e validação, a melhor topologia de rede pode ser usada para estimar a qualidade final da solda. Caso essa qualidade esteja comprometida, os parâmetros do modelo podem ser usados para determinar as possíveis causas, auxiliando assim na manutenção do processo. Esses parâmetros do modelo têm ainda o potencial de serem utilizados em uma malha de controle solda a solda, alterando o procedimento de soldagem de acordo com os valores assumidos. Esse potencial não foi analisado por este trabalho e ficará como sugestão para futuros trabalhos.

Os dados de produção podem ser armazenados em um banco de dados formando assim um histórico de produção que pode ser usado para certificação do processo e possíveis análises futuras do produto.

Nos próximos subitens desse capítulo, cada uma dessas etapas de implementação do sistema de monitoramento proposto e os componentes necessários para sua execução serão apresentados e discutidos mais detalhadamente.

3.3 Ferramenta de Software Utilizada

Com o propósito de ler, processar e disponibilizar os dados obtidos do processo, uma ferramenta de software chamada “TOMAHAWK” foi utilizada. O núcleo e o programa principal dessa ferramenta foram desenvolvidos em Visual C++ IDE, em um Instituto da Universidade de Ciências Aplicadas de Karlsruhe, Hochschule Karlsruhe, da Alemanha, chamado IAF (*Institut für Angewandte Forschung*), por Dietmar Zettel, em seu trabalho de mestrado, com a ajuda do autor desse trabalho, Daniel Sampaio, entre 2002 e 2004. A figura 3.3 mostra a tela de créditos da ferramenta de software “TOMAHAWK”.

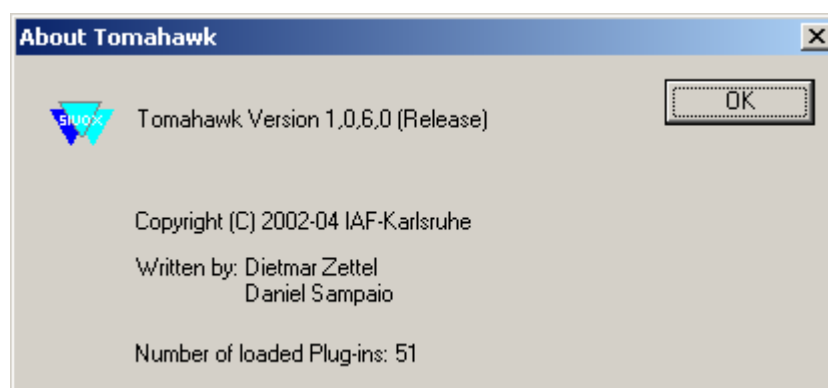


Figura 3.3 - Tela de créditos da ferramenta de software TOMAHAWK

A base dessa ferramenta é uma técnica baseada em *plug-ins* usando *dynamic link library* (DLL). Esses *plug-ins* são módulos fáceis de criar, que permitem o desenvolvimento de algoritmos e que podem ser conectados um ao outro, desde que apresentem compatibilidade de dados, na sequência desejada. Dessa forma, é possível ler um conjunto de dados específico, processar esses dados de acordo com as necessidades e gerar diferentes tipos de saídas. Todos os *plug-ins* utilizam a mesma interface definida pelo programa principal e novos *plug-ins* podem ser criados e facilmente adicionados através da interface padrão. A principal vantagem dessa técnica é que os *plug-ins* podem ser desenvolvidos de

forma independente do programa principal. A figura 3.4 mostra um exemplo genérico de encadeamento de *plug-ins* usando a ferramenta de software “TOMAHAWK”.

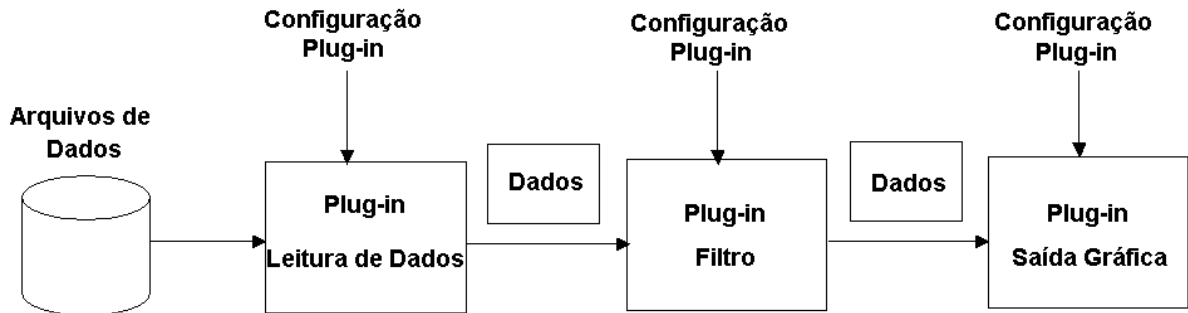


Figura 3.4 - Exemplo de encadeamento de *plug-ins* na ferramenta TOMAHAWK

Com esta ferramenta, os arquivos de dados armazenados são lidos pelo *plug-in* “Leitura de Dados”, são enviados ao *plug-in* “Filtro” e são, então, enviados ao *plug-in* “Saída Gráfica”, que mostra finalmente os dados na tela.

3.4 Medição e Processamento das Grandezas do Processo

O processo de solda a ponto resistiva consiste em unir em um ponto determinado duas ou mais partes metálicas utilizando como base o calor produzido. Um desenho de uma máquina de solda a ponto resistiva pode ser visto na figura 3.5. Uma alta corrente circula nas partes através dos eletrodos fixados na garra, pinça ou pistola de soldagem, produzindo assim uma grande quantidade de calor no ponto de contato entre as partes metálicas, devido à resistência elétrica. Um poço de material fundido é criado neste local devido a este crescente fluxo de energia térmica. Certa pressão deve ser aplicada aos eletrodos, para evitar a expulsão do material fundido devido à expansão térmica. Após a corrente ser desligada, este material

fundido se resfria e um ponto sólido de união é produzido, chamado de ponto de solda, lentilha de solda ou botão de solda.




Figura 3.5 - Desenho esquemático de uma máquina de solda a ponto resistiva

Os eletrodos não devem sofrer fusão durante o fluxo de corrente, razão pela qual são usadas técnicas que não deixam que se atinjam suas temperaturas de fusão, sendo necessário, normalmente, fazer circular através deles um fluido refrigerante.

O PSPR é um processo não linear no qual nem as variáveis de estado nem as “condições relevantes do processo” são acessíveis através de medições diretas e para o qual, devido à inexistência de modelos dinâmicos de alta precisão, não se pode construir observadores confiáveis, já que não se consegue determinar e monitorar todas as variáveis que atuam no sistema.

Duas grandezas físicas que são acessíveis e podem ser medidas durante o PSPR são os sinais de tensão e corrente elétricas. De posse desses sinais, é possível extrair para cada ponto

de solda a resistência elétrica e obter a variação dessa resistência elétrica durante o processo de solda. Assim, a variação da resistência elétrica associada a propriedades físicas do processo é a principal grandeza utilizada neste trabalho e servirá de base para derivar características e estimar outras variáveis do processo, principalmente a qualidade final do ponto de solda.

3.4.1 Medição da Corrente e Tensão de Soldagem

Um desenho esquemático para medições de tensão e corrente no PSPR é mostrado na figura 3.6.

O processo de soldagem utiliza normalmente correntes acima de 1kA, as quais podem chegar a mais de 10kA, dependendo dos materiais envolvidos. As tecnologias mais comuns encontradas no mercado atualmente para se medir altas correntes são a resistência *shunt*, o transformador de corrente, o sensor de efeito Hall e a bobina Rogowski (KOON, 2002).




Figura 3.6 - Desenho esquemático das medições de tensão e corrente no PSPR

A medição de corrente neste trabalho foi realizada utilizando-se uma bobina Rogowski devido às suas características superiores em relação às outras tecnologias (WARD; EXON, 1993). A bobina Rogowski pode ser feita flexível e em forma de cinta aberta, possibilitando sua fixação em torno de um condutor vivo sem causar distúrbios. Ela possui um núcleo de ar, ao invés de um núcleo de ferro, fazendo com que apresente uma baixa indutância e possa responder a altas taxas de variação da corrente a ser medida. Como não tem núcleo de ferro que pode saturar, ela é altamente linear mesmo em altas correntes. Uma bobina Rogowski construída corretamente, com espaçamento simétrico entre seus enrolamentos, é altamente imune à interferência eletromagnética. Além disso, ela tem baixo custo e baixo consumo de energia (RAMBOZ, 1996).

O princípio de funcionamento da bobina Rogowski é baseado na lei de indução de Faraday. De acordo com esta lei, o sinal na saída da bobina Rogowski é um sinal de tensão proporcional à derivada no tempo da corrente medida. Portanto, para se obter um sinal proporcional à corrente medida, o sinal na saída da bobina deve ser integrado. Devido a essa característica, este tipo de sensor não consegue medir correntes contínuas, somente correntes alternadas. A figura 3.7 mostra uma bobina Rogowski usada na medição de corrente.



Figura 3.7 - Uma bobina Rogowski usada na medição de corrente

Inicialmente essa integração necessária foi realizada por software. Mas, com o aumento da frequência básica dos controladores das máquinas de soldagem mais modernas (anteriormente trabalhavam na faixa de 50/60 Hz, atualmente trabalham na faixa de alguns kHz), as taxas de amostragem das placas de aquisição de dados (normalmente na faixa de 20kHz a 50kHz) deixaram de ser suficientes para se obter uma resolução conveniente para se fazer uma integração digital. Para resolver este problema, atualmente, foram desenvolvidas e são utilizadas placas de aquisição de dados com um integrador analógico disponível em suas entradas, que pode ser ativado conforme a necessidade do usuário. Com isso, essa integração necessária no sinal recebido da bobina Rogowski passou a ser feita por *hardware*, diretamente pela placa de aquisição de dados, que possui o integrador analógico disponível em suas entradas, e, portanto, o sinal adquirido é automaticamente integrado pela placa de aquisição.

A medição da tensão de soldagem foi feita de forma direta nos eletrodos da máquina de soldagem. Uma das pontas dos dois cabos necessários para medir a tensão foi fixada em cada um dos dois eletrodos da máquina, através de um anel de fixação, e as outras duas pontas foram ligadas diretamente em uma das entradas da placa de aquisição de dados. A figura 3.8 mostra a fixação dos cabos para medição da tensão de soldagem.

A placa de aquisição de dados utilizada foi o modelo PCI M9720008 da empresa Sinus. Possui duas entradas, ambas com a opção de se usar um integrador analógico, e pode medir diretamente sinais de tensão. As duas entradas possuem uma resolução de conversão analógico/digital de 16 bits e dois amplificadores em série, de ganho ajustável, um antes do integrador e outro após o integrador. A frequência de amostragem é ajustável e foi fixada em 25,6kHz para todos os dados obtidos nesse trabalho.




Figura 3.8 - Fixação dos cabos para medição da tensão de soldagem

Foi criado um *plug-in* para fazer a leitura do arquivo de dados de tensão e corrente obtido durante o processo de soldagem, que foi chamado de “Input BUI” e outro *plug-in*, para mostrar esses dados em forma de gráfico na tela, que foi chamado de “Curve View”. As figuras 3.9 e 3.10 mostram os gráficos dos dados “brutos”, isto é, sem nenhum tipo de pré-processamento, da variação de tensão e corrente, respectivamente, obtidas durante o processo de soldagem de um contato elétrico após a execução desses *plug-ins*.




Figura 3.9 - Curva dos dados brutos da variação de tensão durante o PSPR




Figura 3.10 - Curva dos dados brutos da variação de corrente durante o PSPR

Analisando o gráfico dos dados brutos da tensão, pode-se verificar que existe um pequeno deslocamento horizontal do gráfico, isto é, no início do gráfico, quando há ausência de sinal, ele deveria apresentar o valor zero, mas apresenta um pequeno valor negativo devido a um pequeno *offset* gerado pela placa de aquisição de dados, o qual deve ser corrigido. Verifica-se também que antes do início efetivo da solda e após o seu término, existem dados desnecessários, que, por não apresentarem informação do processo, não necessitam ser salvos. Surge então a necessidade de eliminá-los de forma a reduzir o tamanho do arquivo e consequentemente o espaço físico necessário para armazená-lo, sem prejuízo aos dados que realmente carregam as informações do processo.

Com relação aos dados brutos de corrente, pode-se verificar que também existe a necessidade de se corrigir um determinado *offset* horizontal gerado pela placa de aquisição de dados e eliminar os dados desnecessários. Além disso, existe a necessidade de se corrigir o fator de proporcionalidade da bobina Rogowski utilizada, que é de 20 vezes, ou seja, os valores medidos devem ser multiplicados por 20. Foi detectado através de testes com valores constantes de corrente aplicados à placa de aquisição de dados, que a mesma também

apresenta um pequeno erro causado pelo integrador analógico usado para integrar o sinal de corrente, que foi determinado como sendo de $9.1 \cdot 10^{-6}$ kA/amostra, que deve ser corrigido.

De posse dessas observações e desses dados, foram desenvolvidos alguns *plug-ins*. Um primeiro para efetuar as correções necessárias nos dados brutos de tensão, chamado de “Volt offset corection”. O segundo para fazer as correções necessárias nos dados brutos de corrente, chamado de “CurrentManipulation”. Foi criado também um terceiro *plug-in* para eliminar os dados desnecessários de ambas as curvas, que foi chamado de “Cut Curve (Begin End)”.

Como já comentado, os *plug-ins* são conectados um após o outro, formando um encadeamento de tarefas. Este sequenciamento de *plug-ins* é chamado na ferramenta TOMAHAWK de *Work list*. Foi então criada e executada a *Work list* mostrada na figura 3.11.

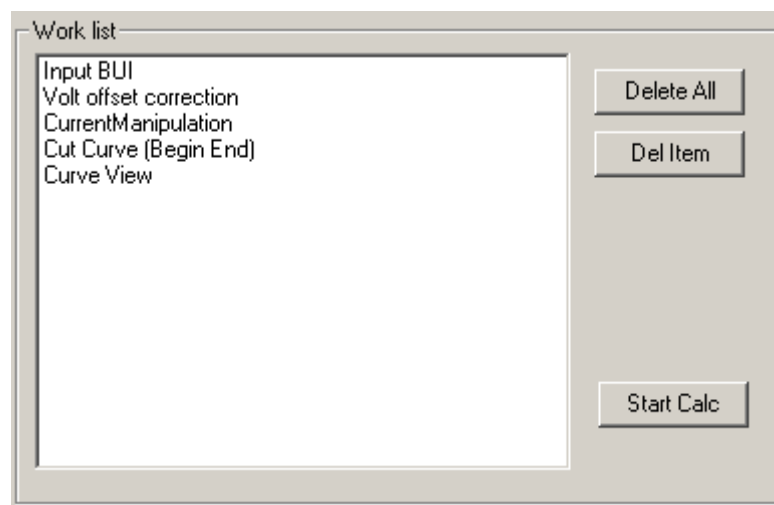


Figura 3.11- *Work list* para pré-processamento dos dados de tensão e corrente

Inicialmente os dados do processo são lidos pelo *plug-in* “Input BUI”; então os dados da tensão de soldagem são corrigidos pelo *plug-in* “Volt offset correction”; depois os dados da corrente de soldagem são corrigidos pelo *plug-in* “CurrentManipulation”; estes dados passam então pelo *plug-in* “Cut Curve (Begin End)” que elimina os dados desnecessários e

finalmente o *plug-in* “Curve View” é executado, mostrando esses dados em forma de gráfico em uma tela. Os resultados obtidos após a execução desse *Work list* são mostrados nas figuras 3.12 e 3.13 para a curva de tensão e corrente, respectivamente.

A figura 3.14 mostra simultaneamente as duas curvas e pode-se notar que existe uma defasagem entre os sinais de tensão e corrente, o que é esperado, devido à indutância presente no circuito secundário do processo de soldagem. Como será abordada no próximo item, essa componente indutiva não é desejada e necessita ser suprimida.




Figura 3.12 - Curva da variação de tensão durante o PSPR após correções




Figura 3.13 - Curva da variação de corrente durante o PSPR após correções




Figura 3.14 - Defasagem entre as curvas de tensão (V) (vermelho) e corrente (kA) (preto)

3.4.2 Obtenção da Curva da Resistência Elétrica Dinâmica

Como dito anteriormente, não é possível medir diretamente a curva de variação da resistência elétrica durante o processo de soldagem. Ela é obtida de forma indireta, medindo-se as curvas de tensão e corrente.

Caso a curva de tensão seja dividida ponto a ponto pela curva de corrente, a curva de resistência resultante inclui tanto as componentes resistivas quanto as componentes indutivas do circuito secundário do PSPR. Deseja-se somente a curva que represente as componentes resistivas do circuito, chamada na literatura de curva de resistência dinâmica do PSPR. Para isso, as componentes indutivas devem ser suprimidas.

Existem na literatura dois métodos principais para suprimir a componente indutiva da curva de resistência (GARZA; DAS, 2001). O método escolhido neste trabalho é o dos picos da curva de corrente. Este método, além de suprimir as componentes indutivas, também realiza uma compressão nos dados, já que cada semi-ciclo é representado por apenas um dado. Este método se baseia no fato da tensão devido à componente indutiva poder ser calculada pela equação 3.1, característica de um indutor:

$$V_L = L \frac{di}{dt} \quad (3.1)$$

onde: V_L = tensão da componente indutiva;

L = indutância equivalente total;

di / dt = derivada da corrente no tempo.

Sabendo-se que a derivada da corrente nos picos da curva de corrente é zero, temos nestes instantes, na curva de tensão, somente a tensão devido à parte resistiva do circuito, ou seja, dividindo-se a tensão instantânea pela corrente instantânea somente nos instantes de pico da corrente, eliminam-se da curva de resistência os efeitos indutivos. Vale lembrar que dessa maneira é feita uma grande compressão dos dados já que em cada meio ciclo somente um valor de resistência é tomado. Foi desenvolvido um *plug-in* para obter-se a curva da variação da resistência elétrica real durante o PSPR, chamado de “Real Resistance”. Incluindo este *plug-in* na *Work list* mostrada na figura 3.11 após o *plug-in* “Cut Curve (Begin End)” e executando-se esta nova *Work list*, obtêm-se a curva da variação da resistência elétrica resultante da produção de um contato elétrico mostrada na figura 3.15.




Figura 3.15 - Curva da variação da resistência elétrica durante a produção de um contato elétrico

3.5 Modelo Matemático Parametrizável do Processo

O modelo matemático parametrizável é a base do sistema proposto neste trabalho. Ele não é criado com a intenção de ser usado para fins de simulação e nem abordar todos os detalhes do processo. Ele é criado para descrever as propriedades físicas fundamentais da grandeza observada do processo em estudo, no caso da solda a ponto resistiva, ou seja, descrever os princípios físicos fundamentais das variações da resistência elétrica durante o PSPR.

Foi criado então um modelo para descrever as variações da resistência elétrica do PSPR chamado de modelo V1. O modelo V1 tem como foco o processo de solda a ponto da produção de contatos elétricos e considera a temperatura igual em todos os pontos do processo devido à espessura não expressiva das partes soldadas.

Sendo a resistência elétrica a grandeza em estudo, determinaremos a resistência elétrica (R) do sistema em estudo como a combinação das resistências de contato entre as partes, da resistência dos materiais a serem soldados e a resistência dos eletrodos, afetadas por leis e propriedades físicas definidas. Desta forma, as variações em R seguirão estas propriedades e leis, sendo invariantes com relação à estratégia de controle usada na máquina de soldagem. Um desenho esquemático do arranjo do PSPR usado para definir o modelo V1 de R é mostrado na figura 3.16.

Assumindo a simetria do arranjo, $R(t)$ é definida pela equação 3.2 como:

$$R(t) = 2 \cdot R_B(t) + R_C(t) + 2 \cdot R_{ELM}(t) \quad (3.2)$$

A resistência elétrica R é a soma da resistência elétrica do material bruto (R_B) com a da interface entre os materiais (resistência de contato R_C) e com a resistência elétrica da interface entre o material e o eletrodo somada com a do próprio eletrodo (R_{ELM}). Cada um desses parâmetros será considerado e discutido individualmente.

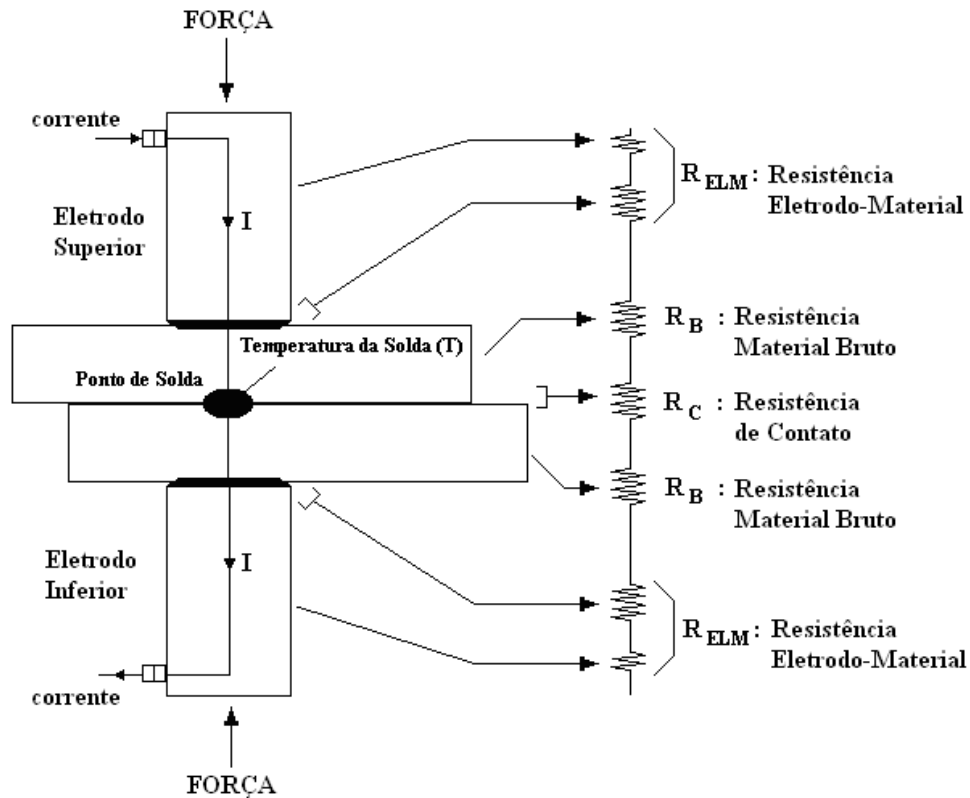


Figura 3.16 - Desenho esquemático do arranjo do PSPR

Uma importante informação no PSPR é o calor produzido. Este calor causa o aumento da temperatura que é a base do PSPR. A resistência elétrica é diretamente dependente da temperatura e este será o primeiro parâmetro a ser definido.

O calor produzido pela corrente circulante I e a reestruturação dos materiais tem um efeito na temperatura do sistema que será modelado por um comportamento exponencial mostrado na figura 3.17. A temperatura do processo T aumenta aproximando-se assintoticamente da temperatura de fusão. Os principais fatores que influenciam na variação da temperatura T são os materiais a serem soldados, a intensidade da corrente circulante e a força aplicada no sistema.

É assumido neste modelo V1 que a temperatura é considerada igual em todo o sistema (materiais muito finos) e que a resistência dos eletrodos é constante.




Figura 3.17 - Temperatura x Tempo

Portanto $T(t)$ pode ser caracterizada pela Eq. 3.3:

$$T(t) = T_0 + (T_{fusao} - T_0) * (1 - e^{-(I(t)*K_T*t)}) \quad (3.3)$$

onde:

$T(t)$: temperatura do processo estimada;

T_0 : temperatura inicial;

T_{fusao} : temperatura de fusão;

$I(t)$: intensidade da corrente no tempo t ;

K_T : fator de variação da temperatura;

t : tempo atual de soldagem.

A resistência elétrica de um material depende da resistividade elétrica do material (ρ). A resistividade do material depende da temperatura e conseqüentemente a resistência elétrica irá igualmente depender da temperatura. Esta dependência está ligada ao coeficiente térmico

de resistência (α) que é característico para cada material. A área e o comprimento também serão afetados pela temperatura devido à expansão dos materiais, mas seus efeitos na resistência elétrica final podem ser considerados desprezíveis, comparados com aquele causado pela variação da resistividade.

A resistência elétrica do material bruto, $R_B(t)$, será caracterizada pela Eq. 3.4:

$$R_B(t) = R_{0B} * [1 + (\alpha * T(t))] \quad (3.4)$$

onde:

R_B : resistência elétrica do material bruto;

R_{0B} : resistência elétrica inicial do material bruto;

α : coeficiente térmico de resistência;

$T(t)$: temperatura do processo estimada pela Eq. 3.3.

A resistência do material bruto apresenta no tempo, usando a Eq. 3.4, o comportamento mostrado na figura 3.18.




Figura 3.18 - Resistência do material bruto x Tempo

Outro componente da resistência elétrica do processo em estudo é a resistência elétrica do eletrodo somada à resistência elétrica da interface entre os eletrodos e os materiais que serão consideradas como sendo uma única resistência chamada de R_{ELM} .

Em um primeiro momento do PSPR, os eletrodos terão uma determinada área de contato com os materiais a serem soldados. Quando os materiais vão ficando mais moles devido ao aumento da temperatura, os eletrodos se ajustarão melhor a eles e até mesmo poderá haver uma penetração aumentando a área de contato. Desta forma, a resistência entre os eletrodos e os materiais diminuirá, já que a corrente terá uma superfície maior para fluir. Esta penetração está também diretamente relacionada com a força aplicada nos eletrodos.

A parcela de resistência elétrica $R_{ELM}(t)$ pode então ser caracterizada pela Eq. 3.5:

$$R_{ELM}(t) = R_{0ELM} * e^{[-(t)/(K_{ELM} * T(t))]} \quad (3.5)$$

onde:

R_{ELM} : resistência elétrica do eletrodo e da interface entre eletrodos e materiais;

R_{0ELM} : resistência elétrica inicial de R_{ELM} ;

t : tempo atual de soldagem;

K_{ELM} : fator de variação eletrodo-material;

$T(t)$: temperatura do processo estimada pela Eq. 3.3.

A resistência elétrica do eletrodo e da interface entre eletrodos e materiais apresenta no tempo, usando Eq. 3.5, o comportamento mostrado na figura 3.19.

A resistência elétrica da interface entre os materiais será chamada de resistência de contato R_C e é a maior responsável pelo calor produzido e necessária para o êxito do PSPR. No início da soldagem, esta resistência é relativamente alta, comparada com as outras duas discutidas e definidas anteriormente, apresentando uma diminuição ao longo do processo, com o melhor ajuste das superfícies dos materiais sendo soldados, devido ao seu amolecimento. Depois disso, R_C continuará a diminuir lentamente até que certo valor de

estabilidade seja atingido. A explicação para este fato é que o aumento da temperatura fará com que os materiais se tornem mais moles e conseqüentemente se ajustem melhor um no outro. Esta parcela de resistência é basicamente influenciada pela força aplicada nos eletrodos e ao tipo de superfície dos materiais a serem soldados.




Figura 3.19 - R_{ELM} x Tempo

Depois que a fusão tem início, esta resistência tende a um leve aumento, por ser a resistência nos líquidos normalmente maior que nos sólidos, mas este efeito será desprezado neste modelo.

A resistência elétrica $R_C(t)$ será então caracterizada pela Eq. 3.6:

$$R_C(t) = R_{0C} - [(R_{0C} * K_{C-soft}) * (1 - e^{-t * K_C * T(t)})] \quad (3.6)$$

onde:

R_C : resistência elétrica da interface entre os materiais;

R_{0C} : resistência elétrica inicial de R_C ;

K_{C-Soft} : fator de amolecimento dos materiais;

K_C : fator de variação da resistência de contato.

R_C apresenta no tempo, usando a Eq. 3.6, o comportamento mostrado na figura 3.20.




Figura 3.20 - R_C x Tempo

Depois que todas as resistências parciais foram definidas, a resistência elétrica do processo em estudo pode ser calculada utilizando a Eq. 3.2. Adotando valores para os parâmetros das equações, uns baseados nas propriedades dos materiais presentes no processo e outros baseados nas características da curva do processo, a curva mostrada na figura 3.21 foi obtida. Esta curva apresenta o mesmo comportamento do chamado “perfil de resistência clássico” que caracteriza uma boa solda de metais (CHO; RHEE, 2004).




Figura 3.21 - Resistência Elétrica R x Tempo

3.6 Ajuste do Modelo não-Linear

3.6.1 Aspectos Iniciais

Diferentemente do ajuste de equações lineares cuja minimização de erro é obtida pela resolução de um sistema linear de equações, o ajuste de equações com dependência não-linear é feito de modo iterativo. Considerando que um modelo depende de forma não-linear de um conjunto de M parâmetros desconhecidos a_k , com $k = 1, 2, 3, \dots, M$, deve-se obter uma função de mérito de χ^2 (“chi-square”) e determinar os valores dos parâmetros do modelo que melhor proporcionam um ajuste através da minimização do erro. Dando valores de tentativa aos parâmetros, desenvolve-se um processo que melhora a solução obtida pelos valores desta tentativa. O processo é então repetido até que χ^2 pare de diminuir ou sua diminuição seja menor que um pequeno valor pré-definido (PRESS et al., 1992). Suficientemente próximo ao mínimo, espera-se que a função χ^2 seja muito próxima a uma função quadrática, podendo ser descrita como:

$$\chi^2(a) \approx \gamma - d \cdot a + \frac{1}{2} a \cdot D \cdot a \quad (3.7)$$

onde d é um vetor M e D é uma matriz $M \times M$. Se a aproximação for boa, para se saltar dos parâmetros da tentativa atual a_{cur} para os parâmetros com uma solução minimizada a_{min} em um simples laço faz-se:

$$a_{min} = a_{cur} + D^{-1} \cdot [-\nabla \chi^2(a_{cur})] \quad (3.8)$$

Por outro lado, a equação 3.7 pode ser uma aproximação a um mínimo local do contorno da função que está sendo minimizada com a_{cur} . Nesse caso, pode-se fazer o gradiente retroceder um degrau, pelo método do declínio do gradiente (“steepest descent method”) da forma mostrada na Eq. 3.9.

$$a_{next} = a_{cur} - constante \times \nabla \chi^2(a_{cur}) \quad (3.9)$$

onde a *constante* é pequena o suficiente para não exaurir a direção descendente do contorno.

É necessário também obter a matriz Hessiana D , sabendo que a matriz Hessiana de uma função de n variáveis é a matriz quadrada $n \times n$ das derivadas parciais de segunda ordem da função. Como a função do modelo que se quer ajustar é conhecida, sabe-se exatamente a forma de χ^2 e também da matriz Hessiana. Então se pode utilizar a Eq. 3.8 sempre que necessário. Caso a Eq. 3.8 falhe em melhorar o ajuste, significando que a aproximação usada para se obter a Eq. 3.7 falhou na obtenção de uma melhor aproximação ao mínimo global, deve-se então utilizar a Eq. 3.9, que é mais completa, para se buscar um melhor ajuste (PRESS et al., 1992).

3.6.2 Gradiente e a Matriz Hessiana

O modelo a ser ajustado é:

$$y = y(x; a) \quad (3.10)$$

E a função de mérito χ^2 é:

$$\chi^2(a) = \sum_{i=1}^N \left[\frac{y_i - y(x_i; a)}{\sigma_i} \right]^2 \quad (3.11)$$

O gradiente de χ^2 com relação aos parâmetros a , que será zero quando χ^2 for mínimo, tem componentes:

$$\frac{\partial \chi^2}{\partial a_k} = -2 \sum_{i=1}^N \frac{[y_i - y(x_i; a)]}{\sigma_i^2} \frac{\partial y(x_i; a)}{\partial a_k}; \quad k = 1, 2, \dots, M \quad (3.12)$$

Tomando uma derivada parcial adicional, tem-se:

$$\frac{\partial \chi^2}{\partial a_k \partial a_l} = 2 \sum_{i=1}^N \frac{1}{\sigma_i^2} \left[\frac{\partial y(x_i; a)}{\partial a_k} \frac{\partial y(x_i; a)}{\partial a_l} - [y_i - y(x_i; a)] \frac{\partial^2 y(x_i; a)}{\partial a_l \partial a_k} \right] \quad (3.13)$$

É convencional remover-se os fatores multiplicativos “2”, definindo-se:

$$\beta_k \equiv -\frac{1}{2} \frac{\partial \chi^2}{\partial a_k} \quad \alpha_{kl} \equiv \frac{1}{2} \frac{\partial^2 \chi^2}{\partial a_k \partial a_l} \quad (3.14)$$

Fazendo $[\alpha] = \frac{1}{2} D$ na Eq. 3.8, essa equação pode ser reescrita como um conjunto de equações lineares:

$$\sum_{l=1}^M \alpha_{kl} \delta a_l = \beta_k \quad (3.15)$$

Esse conjunto é resolvido pelos incrementos δa_l que, adicionados à aproximação atual, fornecem a próxima aproximação. No contexto de mínimos quadrados, a matriz $[\alpha]$, igual à matriz Hessiana multiplicada por $\frac{1}{2}$, é geralmente conhecida como a matriz de curvatura.

A Eq. 3.9, fórmula do declínio do gradiente, pode ser escrita como:

$$\delta a_l = \beta_l \cdot \text{constante} \quad (3.16)$$

É possível observar que as componentes α_{kl} da matriz Hessiana da Eq. 3.13 dependem tanto da derivada primeira como da derivada segunda das funções básicas com relação aos seus parâmetros. A derivada segunda pode ser desconsiderada. A derivada segunda ocorre porque o gradiente da Eq. 3.12 depende de $\partial y / \partial a_k$, então a próxima derivada deverá conter termos envolvendo $\partial^2 y / \partial a_l \partial a_k$. O termo de derivada segunda pode ser desconsiderado quando é igual a zero ou pequeno o suficiente quando comparado ao termo envolvendo a derivada primeira. Ele tem também outra possibilidade de ser consideravelmente pequeno na prática que é o termo que multiplica a derivada segunda na Eq. 3.13, $[y_i - y(x_i; a)]$, para um modelo bem sucedido, deve ser apenas um erro randômico de medida de cada ponto. Esse erro também pode conter sinal, e geralmente não deve ter correlação com o modelo. Portanto, os termos da derivada segunda tendem a se cancelar quando somados com relação a i .

A inclusão dos termos da derivada segunda pode causar instabilidade, se o modelo se ajustar mal ou se o modelo for afetado por “outliers”. Sendo assim, será utilizado como definição de α_{kl} a Eq. 3.17.

$$\alpha_{kl} = \sum_{i=1}^N \frac{1}{\sigma_i^2} \left[\frac{\partial y(x_i; a)}{\partial a_k} \frac{\partial y(x_{i,a})}{\partial a_l} \right] \quad (3.17)$$

Uma menor (ou maior) manipulação de $[\alpha]$ não afeta em como o conjunto final de parâmetros a é alcançado, somente afeta a rota iterativa que é tomada para se chegar lá. A condição quando o χ^2 mínimo é atingido, em que $\beta_k = 0$ para todo k , é independente de como $[\alpha]$ é definido (PRESS et al., 1992).

3.6.3 Algoritmo de Levenberg-Marquardt

O algoritmo de Levenberg-Marquardt proporciona uma solução numérica para o problema de minimizar uma função não-linear de posse de um conjunto de parâmetros dessa função. É um método relativamente robusto que na maioria dos casos encontra uma solução para o problema, mesmo que os parâmetros iniciais estejam muito longe do mínimo desejado. Mas é considerado um algoritmo algumas vezes lento, em virtude do número de iterações que pode necessitar para atingir uma solução satisfatória.

Marquardt melhorou um método anteriormente sugerido por Levenberg, variando suavemente entre os extremos do método Hessiano inverso (Eq. 3.15) e do método do declínio do gradiente (Eq. 3.16). Este último método é usado quando se está longe do mínimo, alternando continuamente para o primeiro método, à medida que vai-se aproximando do mínimo. Este método de Levenberg-Marquardt funciona muito bem na prática e se tornou o padrão para rotinas de mínimos quadrados não-lineares (PRESS et al., 1992).

O método de Levenberg-Marquardt é baseado em duas elementares, mas importantes, percepções. Considerando a “constante” da Eq. 3.16, não há informação no gradiente sobre sua magnitude ou escala. O gradiente indica apenas a inclinação mas não o quanto esta se estende. A primeira percepção de Marquardt é de que as componentes da matriz Hessiana, mesmo que não seja de forma precisa, oferecem alguma informação sobre a escala da ordem de magnitude do problema (PRESS et al., 1992). A variável χ^2 é adimensional, ou seja, é um número puro, o que é evidente a partir de sua definição na Eq. 3.11. Por outro lado, β_k tem a dimensão de $1/a_k$, que pode ser dimensional, ou seja, possuir unidades como centímetro quadrado, ou quilowatt-hora, entre outros (cada componente de β_k pode ter diferentes unidades). A constante de proporcionalidade entre β_k e δa_k deve ter, portanto, a dimensão de a_k^2 .

Observando as componentes de $[\alpha]$, é possível verificar que há apenas uma variável com essas dimensões, que é $1/\alpha_{kk}$, o elemento correspondente na diagonal principal. Esta deve ser portanto a escala da “constante”, mas como esta pode ser muito grande, divide-se a constante por um fator adimensional λ , em que $\lambda \gg 1$, para reduzir o degrau. Em outras palavras, substitui-se a Eq. 3.16 por:

$$\delta a_l = \frac{1}{\lambda \alpha_{ll}} \beta_l \quad \text{ou} \quad \lambda \alpha_{ll} \delta a_l = \beta_l \quad (3.18)$$

É necessário que α_{ll} seja positivo, mas isso é garantido por definição (Eq. 3.17).

A segunda percepção de Marquardt é que a Eq. 3.18 e a Eq. 3.15 podem ser combinadas, se for definida uma nova matriz α' com as seguintes descrições:

$$\alpha'_{jj} \equiv \alpha_{jj} (1 + \lambda)$$

$$\alpha'_{jk} \equiv \alpha_{jk} \quad (j \neq k) \quad (3.19)$$

Utilizando α' e combinando a Eq. 3.18 com a Eq. 3.15, obtem-se a Eq. 3.20:

$$\sum_{l=1}^M \alpha'_{kl} \delta a_l = \beta_k \quad (3.20)$$

Quando λ é muito grande, a matriz α' é forçada a ser diagonalmente dominante, então a Eq. 3.20 direciona-se para ser idêntica a Eq. 3.18. Por outro lado, se λ se aproxima de zero, a Eq. 3.20 direciona-se para ser idêntica a Eq. 3.15 (PRESS et al., 1992).

Atribuindo-se um valor inicial para o conjunto de parâmetros “ a ” a serem ajustados, Marquardt sugere os seguintes passos:

1° passo: Calcular $\chi^2(a)$;

2° passo: Escolher um valor modesto para λ , como por exemplo $\lambda = 0,001$;

3° passo: Resolver a equação linear (3.20) para δa e estimar $\chi^2(a + \delta a)$;

4° passo: Se $\chi^2(a + \delta a) \geq \chi^2(a)$, multiplicar λ por um fator de 10 (ou qualquer outro fator significativo) e voltar para o 3° passo;

5° passo: Se $\chi^2(a + \delta a) < \chi^2(a)$, dividir λ por um fator de 10 e atualizar a possível solução $a \leftarrow a + \delta a$, retornando ao 3° passo.

Também é necessária uma condição para parar as iterações. Iterar até obter a precisão do processador é geralmente desnecessário, já que o mínimo é na melhor das hipóteses apenas uma estimativa estatística dos parâmetros a . Uma mudança nos parâmetros que mudam χ^2 de um valor $\ll 1$ não é significativo estatisticamente; além disso, não é incomum encontrar parâmetros rodeando próximos ao mínimo em um vale de topologia complicada (PRESS et al., 1992).

Essas considerações sugerem que, na prática, deve-se parar a iteração na primeira ou segunda ocasião em que χ^2 decresce de um valor desprezível, digamos menor do que 0,01 ou algum valor da ordem de 10^{-3} . Não se deve parar, caso após algum passo χ^2 cresça; isso apenas indica que λ ainda não atingiu um ajuste ótimo.

Uma vez que um mínimo aceitável seja encontrado, deve-se fazer $\lambda = 0$ e calcular a matriz da eq. 3.25 que é a matriz de covariância estimada dos padrões de erros dos parâmetros de ajuste “ a ”.

$$[C] \equiv [\alpha]^{-1} \quad \text{Eq. 3.25}$$

3.6.4 Criação de *Plug-in* para Ajuste do Modelo

Foi então criado um *plug-in* para a ferramenta de software “TOMAHAWK” com a implementação do método de Levenberg-Marquardt e com todos os parâmetros do modelo matemático parametrizável descrito no item 3.5. Este *plug-in* tem a função de realizar o ajuste da curva gerada pelo modelo com a curva real do processo, através do ajuste dos parâmetros do modelo selecionados como variáveis na tela de configuração desse *plug-in*, que foi chamado de “Model_CalcVariables”. A tela de configuração desse *plug-in* é mostrada na figura 3.22.

Como é possível observar na figura 3.22, após selecionar o método de Levenberg-Marquardt é necessário configurar outras quatro variáveis. A primeira chamada de “Prec.” é onde se define a condição de precisão mínima de ajuste aceitável para encerrar as iterações. A segunda chamada de “Iter.” é onde se define o número máximo de iterações permitido de forma a se evitar que o algoritmo entre em um *looping* infinito caso não se atinja a precisão

desejada de ajuste entre as curvas. As variáveis “Mult.” e “Div.” são os fatores de multiplicação e divisão, respectivamente, usados no 4º e 5º passo descritos no item anterior.

Outro item importante da tela de configuração é encontrado no campo “Extras” chamado de “Sample Frequency” que é onde se coloca o valor da frequência de amostragem atual dos dados da curva real que será utilizada como base para o ajuste da curva do modelo.

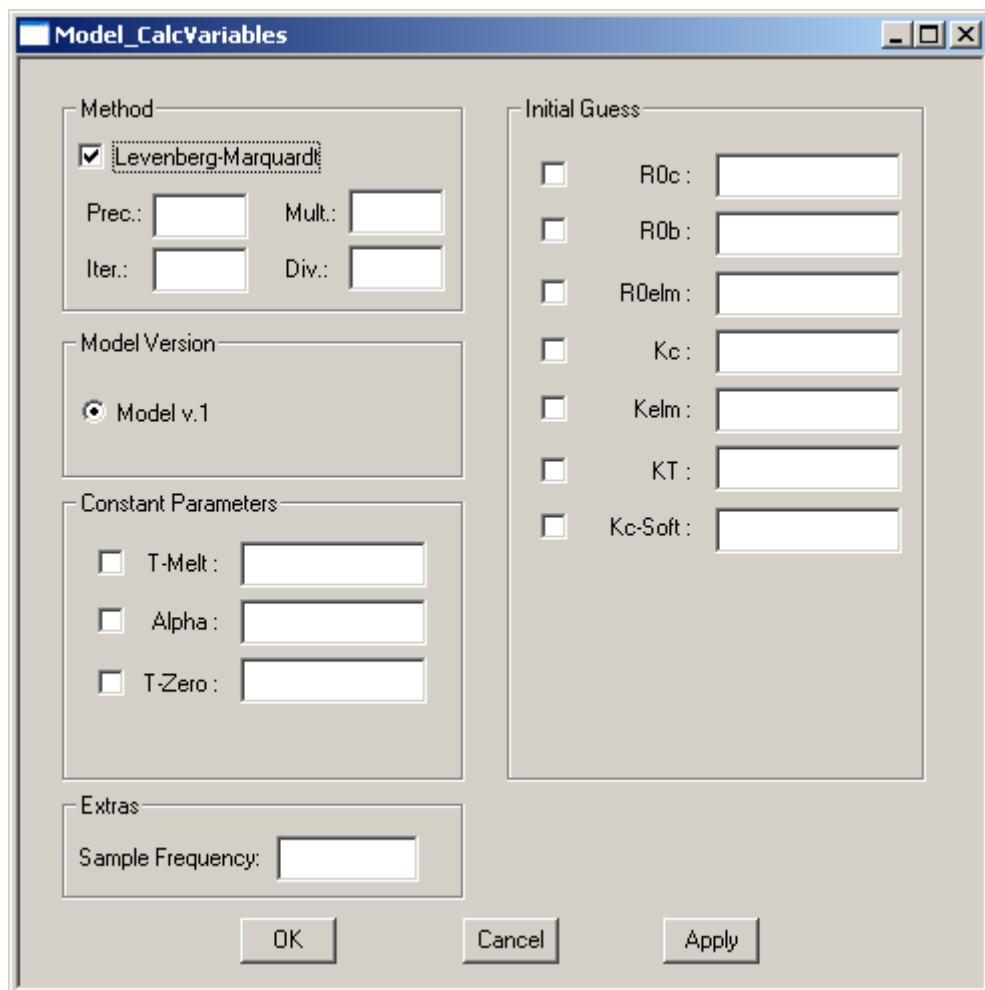


Figura 3.22 - Tela de Configuração do *Plug-in* “Model_CalcVariables”

Os demais itens da tela são os parâmetros do modelo matemático parametrizável criado que devem ser inicializados antes da execução do *plug-in*. É possível, através de um quadrado de checagem, selecionar os parâmetros do modelo que podem ter seus valores

alterados durante o procedimento de ajuste das curvas, ou seja, estes parâmetros serão definidos como parâmetros variáveis. Os parâmetros que não tiverem o quadrado de checagem selecionado terão o valor inicial mantido ao longo do processo de ajuste, ou seja, serão definidos como parâmetros fixos.

3.7 Estimação da Qualidade Utilizando Redes Neurais

A utilização de redes neurais torna possível encontrar a relação entre os dados do processo (a variação da corrente e tensão no tempo) e a qualidade do ponto de solda, sem nenhum conhecimento das variáveis que possam afetar o processo durante a soldagem. Diferente de outros métodos, as redes neurais são capazes de aprender através de amostras.

As redes neurais apresentam algumas características que são importantes para a realização deste trabalho. Uma rede neural pode ser projetada para representar funções não-lineares, o que vai ao encontro das necessidades do PSPR. Ela realiza um mapeamento entre entrada e saída através de amostras do processo, modelando um fenômeno não-linear, uma tarefa de difícil execução, visto que as relações entre as variáveis de entrada e saída não são totalmente conhecidas. A rede neural tem a habilidade de aprender com seu ambiente e com isso melhorar seu desempenho através de um processo iterativo de ajustes aplicado nos seus pesos sinápticos. Portanto quanto maior a diversidade de situações apresentadas no treinamento da rede, melhor será seu desempenho, apesar de sua generalização. A generalização em redes neurais pode ser explicada como a capacidade da rede para fornecer respostas coerentes para padrões desconhecidos. O benefício proporcionado pela capacidade de generalização de um modelo neural é considerável, em função da resposta da rede a padrões desconhecidos ou diferentes dos padrões de treinamento. A alta capacidade de

generalização também proporciona robustez ao modelo quando os dados ou exemplos estão sob o efeito de ruído.

Neste trabalho, serão utilizadas redes neurais artificiais do tipo multicamadas. O algoritmo de *back-propagation* será utilizado para efetuar o treinamento da rede. No anexo A encontra-se a teoria básica de redes neurais artificiais e do algoritmo de *back-propagation*.

Portanto, é necessário treinar as redes neurais antes de utilizá-las para estimar a qualidade do processo de solda a ponto resistiva. As figuras 3.23 e 3.24 ilustram o processo de treinamento e aplicação de uma rede neural.

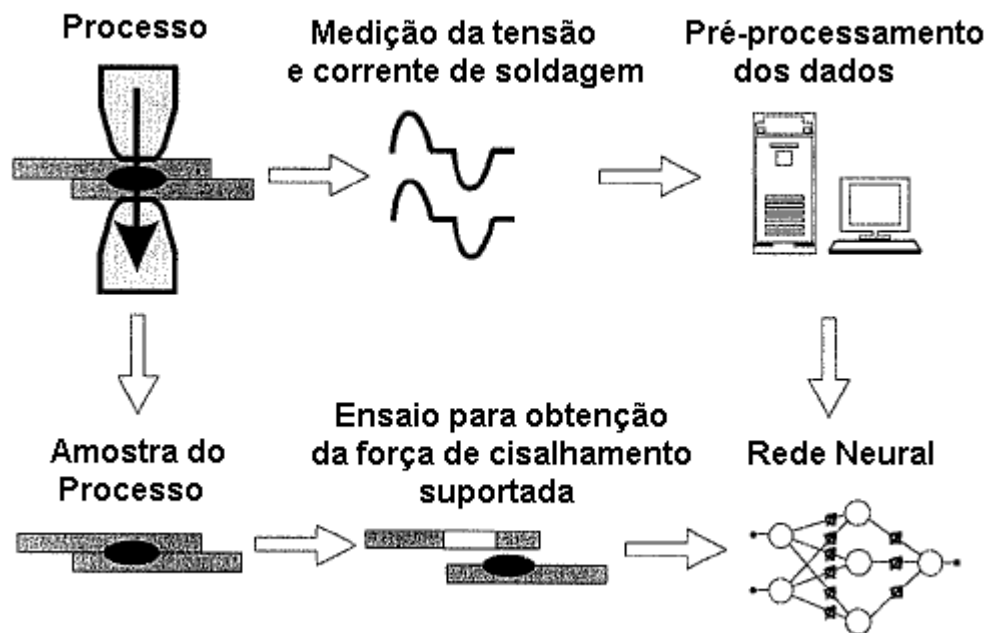


Figura 3.23 - Processo de treinamento da rede neural artificial

No treinamento, para cada amostra do processo, são apresentados à entrada da rede os parâmetros estimados do modelo matemático criado e à saída da rede, o valor da força de cisalhamento suportada obtida através de ensaio destrutivo. Desta forma, através do algoritmo de *back-propagation*, a rede é treinada para estimar a qualidade da solda. Depois de ser treinada, ao se apresentar à entrada da rede os parâmetros estimados do modelo matemático

que representam uma determinada solda, ela é capaz de estimar a qualidade dessa solda produzida, ou seja, de estimar a força de cisalhamento suportada pela solda.

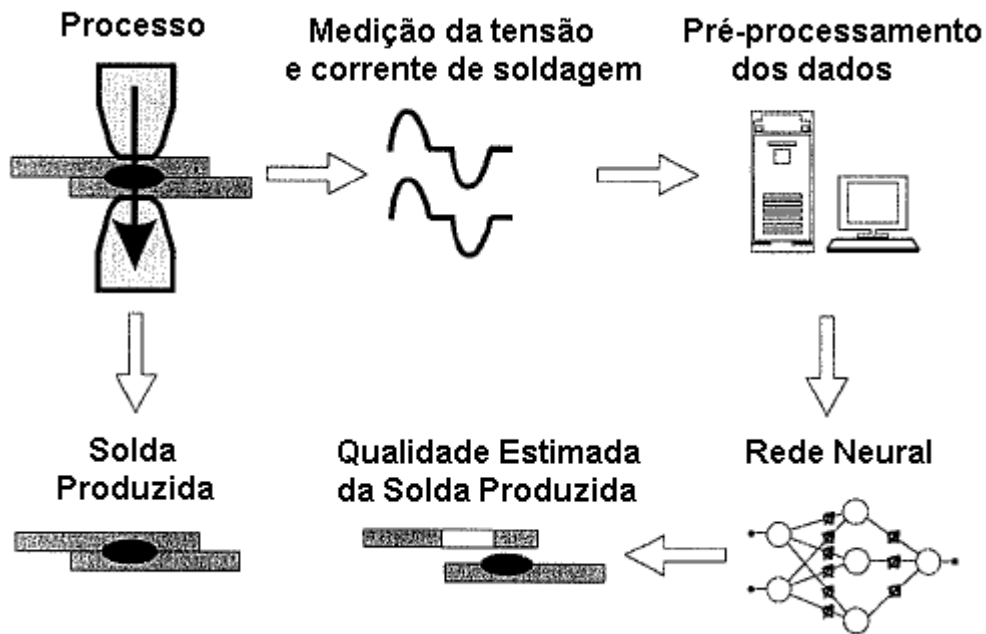


Figura 3.24 - Processo de aplicação da rede neural artificial

No capítulo 4 o sistema de monitoramento proposto será avaliado com dados reais e os resultados serão apresentados.

3.7.1 Software para Simulação de Redes Neurais

Desde 1989, o Instituto para Sistemas Paralelos e Distribuídos de Alta Performance da Universidade de Stuttgart, na Alemanha, disponibiliza um simulador de redes neurais artificiais chamado SNNS (*Stuttgarter Neuronaler Netzwerk Simulator*). A motivação para o desenvolvimento desse simulador foi criar uma ferramenta de software que simulasse redes neurais artificiais sem a necessidade de grandes configurações e tempo de desenvolvimento.

O simulador SNNS consiste de dois componentes principais, um núcleo de simulação e uma interface gráfica para o usuário. O núcleo de simulação opera na estrutura de dados

interna da rede neural artificial e executa todas as operações de aprendizado e verificação. Este núcleo pode também ser usado sem outras partes como um programa em C incorporado em uma aplicação personalizada. A ferramenta suporta qualquer tipo de topologia de rede. O SNNS pode ser expandido pelo usuário através de funções de ativação, funções de saída e procedimentos de aprendizagem, os quais devem ser escritos em linguagem C e conectados ao núcleo de simulação.

Esta foi a ferramenta escolhida para simular as redes neurais neste trabalho, principalmente por ser um *open source code*. Foi desenvolvido um *plug-in* na ferramenta TOMAHAWK, chamado “SNNS Output”, que cria um arquivo de lote (também conhecidos por .bat) que executa o núcleo de simulação do SNNS, calculando e apresentando na topologia de rede neural desejada os seus resultados.

3.8 Identificação de Causas de Perda de Qualidade no PSPR

A rápida identificação de perda de qualidade e também das possíveis causas para esta perda de qualidade são extremamente importantes, para minimizar custos e aumentar a produtividade.

O sistema proposto tem o potencial de fornecer uma grande ajuda na manutenção do processo, já que pode relacionar os parâmetros do modelo com condições ou estados do processo, fornecendo possíveis causas para problemas que possam surgir e serem identificados durante a produção, auxiliando assim para que a manutenção seja realizada o mais breve possível, de forma a minimizar as consequências da perda de qualidade do processo.

Através da obtenção de amostras do processo, por meio da execução de um procedimento de testes que englobe simulações das principais perturbações do processo, é

possível analisar e comprovar o comportamento dos parâmetros do modelo matemático criado e, assim, encontrar os valores que estes assumem em condições normais e em condições de perda de qualidade devido a essas perturbações. Quanto melhor for este procedimento de testes, melhor será a obtenção da correlação dos valores dos parâmetros do modelo com as perturbações do processo que acarretam perda da qualidade.

Esse potencial de identificação de causas de perda de qualidade é investigado neste trabalho e os resultados serão mostrados no capítulo 4.

3.9 Banco de Dados com Histórico de Produção

Os dados do PSPR podem ser armazenados em um banco de dados formando assim um histórico de produção que pode ser usado para certificação do processo e em futuras análises. Essa característica de arquivamento e acompanhamento dos produtos se tornou uma condição necessária em muitos padrões industriais de qualidade e as informações da produção devem ser documentadas para se atingir este objetivo.

Além disso, essa informação pode ser usada para *Data Mining*. No caso do processo de solda a ponto resistiva, é possível utilizar-se *Data Mining* para buscar-se um procedimento de soldagem otimizado para um determinado processo ou definir um procedimento de soldagem para um novo processo de soldagem que se adapte à medida que novos dados vão sendo armazenados.

A construção e utilização do banco de dados não foi investigada neste trabalho e ficará como sugestão para futuros trabalhos. Como referência ficam os trabalhos de Zhang et al. (2003) e Tuovinen et al. (2007).

4 Avaliação e Validação do Sistema Proposto

Neste capítulo serão feitas a avaliação e validação do sistema proposto. Inicialmente serão apresentados os dados que foram usados para avaliar e validar o sistema e a forma e condições nas quais eles foram adquiridos. Depois será avaliado se o modelo matemático parametrizável criado é capaz de reproduzir o comportamento da curva da resistência dinâmica que ele descreve. Após esta etapa, os parâmetros ajustados do modelo serão utilizados nas próximas etapas do sistema. Primeiramente será analisada a capacidade de esses parâmetros serem usados para treinar uma rede neural artificial tornando-a capaz de estimar a qualidade final da solda. Para isso, é feito um estudo para identificar qual a melhor combinação de parâmetros do modelo na entrada da rede e qual a melhor topologia de rede para estimar a qualidade final da solda. Através dos resultados obtidos, será possível concluir se o sistema proposto é capaz de fazer uma boa estimação da qualidade final da solda, através de comparação com resultados encontrados na literatura e obtidos utilizando outras características da curva de resistência dinâmica. Será então avaliada a capacidade do sistema de fornecer possíveis causas para problemas que possam surgir durante a produção dos contatos elétricos.

4.1 Dados Utilizados na Avaliação e Validação do Sistema

Dois conjuntos de dados foram obtidos diretamente na linha de produção de contatos elétricos produzidos através do PSPR. A aquisição dos dados foi realizada com uma diferença de 10 meses entre cada conjunto, em duas máquinas similares. O segundo conjunto de dados apresenta um roteiro de testes mais completo que o do primeiro. É composto por 240 amostras

do processo, enquanto o primeiro é composto por 185 amostras. A seguir, cada conjunto de dados será detalhado, mostrando as particularidades do processo e a forma como os dados foram adquiridos.

4.1.1 Primeiro Conjunto de Dados

O primeiro conjunto de dados obtido é relativo a uma linha de produção de contatos elétricos produzidos através do PSPR, usados principalmente na indústria eletro-eletrônica. Este processo de soldagem é caracterizado por um pequeno período de soldagem, de 25-40 ms, e pela velocidade de produção que pode chegar a 300 partes por minuto. Estes contatos elétricos são produzidos em quantidades de 50.000 até 500.000 partes por semana. Eles têm a função de pontes para as chaves de produtos como relés, termostatos e interruptores, exercendo assim um papel essencial já que se um contato falha, o produto como um todo perde sua função.

Os contatos elétricos produzidos neste teste têm a função de serem utilizados como mola auxiliar de contato em termostatos. Os materiais usados para confeccionar o contato elétrico foram uma pequena chapa de níquel-berílio de 28,3 mm de comprimento, 8,5 mm de largura e 0,1 mm de espessura, usada como material da base, e um pequeno contato de níquel-prata de 2,3mm de comprimento, 1,5 mm de largura e 0,7 mm de altura, usado como material de contato, como ilustrado na figura 4.1.

O tipo de material e a espessura muito fina das partes a serem soldadas resultam em uma resistência de contato muito baixa entre elas. Para que o calor produzido pela circulação de corrente se concentre nessa região, e não na região entre os eletrodos e as partes, nesse tipo de processo é necessário um artifício, para aumentar a resistência de contato entre as partes a serem soldadas. Esse artifício é chamado de *welding help*, que se baseia na produção

de pequenas saliências no material da base, na área que será soldada, obtidas por processo de prensagem.




Figura 4.1 - Esquemático das partes a serem soldadas (superior) e contato elétrico após soldagem (inferior)

Todos os testes foram executados em uma máquina na linha de produção e não em laboratório, para prover condições reais de produção. O tipo de controle de alimentação presente na máquina de soldagem era o de média frequência com controle de corrente constante.

Foi possível instalar tanto a bobina Rogowski, para medição da corrente, quanto os cabos no eletrodo, para medição de tensão, sem necessidade de modificações ou adaptações

na máquina de soldagem ou na linha de produção e sem obstruir a execução da solda. O lado de saída dos cabos da bobina Rogowski e da medição de tensão foi ligado à placa de aquisição de dados instalada em um computador pessoal montado em uma mesa junto à linha de produção.

Dentre os principais parâmetros do procedimento de soldagem padrão usado, destaca-se o tempo de soldagem total de 24 milissegundos, dividido em dois estágios, sendo o primeiro estágio somente para aquecimento e queima de impurezas presentes na superfície do material e o segundo estágio para a soldagem propriamente dita. O primeiro estágio possui um tempo de soldagem de 10 milissegundos, com uma corrente de 1,4 kA aplicada durante este estágio. O segundo estágio possui um tempo de soldagem de 14 milissegundos, com uma corrente de 3,7 kA aplicada durante este estágio. Outro parâmetro importante é a pressão exercida nos eletrodos. No caso desta máquina, essa pressão não é fornecida nem medida diretamente, mas ajustada por meio de uma mola. A unidade de medida é o comprimento da mola que foi comprimida, ou seja, a diferença entre o tamanho natural da mola e o tamanho após uma compressão. A figura 4.2 mostra um esquemático do ajuste da pressão.




Figura 4.2 - Esquemático do ajuste da pressão dos eletrodos através de uma mola

A temperatura dos eletrodos neste processo foi mantida em torno de 16 °C, através de um eficiente sistema de resfriamento baseado na circulação de um líquido refrigerante no seu interior.

O critério de qualidade definido para este tipo de solda a ponto resistiva é a força de cisalhamento obtida através de ensaio destrutivo. Portanto, todos os pontos de solda executados especialmente para compor este conjunto de dados passaram por um ensaio destrutivo para determinar a força de cisalhamento suportada por cada um deles. Pontos de solda que suportem uma força de cisalhamento maior que 400 N são considerados soldas de boa qualidade. Mas, para garantir soldas boas, o procedimento de soldagem padrão usado foi definido para tentar produzir soldas que suportem uma força de cisalhamento média de 550 N.

Durante os testes, alguns parâmetros do procedimento de soldagem foram modificados de forma a artificialmente simular diferentes situações que podem ocorrer durante o processo de soldagem e possam vir a prejudicar a qualidade final do ponto de solda, ou seja, simular diferentes perturbações que possam estar presentes no processo. Em alguns testes, o valor da corrente nominal aplicada durante o segundo estágio de soldagem foi alterada. Em outros, a força nominal aplicada pelos eletrodos foi alterada e o artifício para aumentar a resistência de contato entre as partes a serem soldadas, o *welding help*, não foi utilizado. Essas variações são importantes para a fase de treinamento da rede neural artificial, para que esta se adapte melhor ao processo.

Este primeiro conjunto de dados é composto por 185 testes que foram executados seguindo o roteiro apresentado a seguir:

- Testes de números 1 a 15: procedimento de soldagem padrão;
- Testes de números 16 a 30: procedimento de soldagem padrão com aumento da força aplicada nos eletrodos em 6,3%;

- Testes de números 31 a 45: procedimento de soldagem padrão com aumento da força aplicada nos eletrodos em 9,5%;
- Testes de números 46 a 60: procedimento de soldagem padrão com aumento da força aplicada nos eletrodos em 12,7%;
- Testes de números 61 a 75: procedimento de soldagem padrão com aumento da força aplicada nos eletrodos em 15,8%;
- Testes de números 76 a 90: procedimento de soldagem padrão;
- Testes de números 91 a 105: procedimento de soldagem padrão com redução da corrente do segundo estágio de soldagem de 3,7 kA para 3,5 kA;
- Testes de números 106 a 120: procedimento de soldagem padrão com redução da corrente do segundo estágio de soldagem de 3,7 kA para 3,2 kA;
- Testes de números 121 a 135: procedimento de soldagem padrão com redução da corrente do segundo estágio de soldagem de 3,7 kA para 2,8 kA;
- Testes de números 136 a 150: procedimento de soldagem padrão com redução da corrente do segundo estágio de soldagem de 3,7 kA para 2,4 kA;
- Testes de números 151 a 165: procedimento de soldagem padrão;
- Testes de números 166 a 185: procedimento de soldagem padrão em material sem *welding help*.

Os testes de número 70, 73 e 121 apresentaram problemas na execução do ensaio destrutivo para determinação da força de cisalhamento suportada e infelizmente tiveram que ser descartados.

A tabela B.1 do Anexo B mostra um detalhamento maior de cada teste realizado como o nome do arquivo em que os dados de tensão e corrente foram salvos, o procedimento de

soldagem utilizado, o número de soldas que os eletrodos executaram até o momento do teste e o resultado do ensaio destrutivo de cada parte produzida.

4.1.2 Segundo Conjunto de Dados

O segundo conjunto de dados obtido para avaliar o sistema proposto neste trabalho é relativo também ao processo de produção de contatos elétricos produzidos através do PSPR, mas foram obtidos 10 meses após o primeiro conjunto de dados e em uma linha de produção similar, mas não a mesma do primeiro.

Os materiais usados para confeccionar o contato elétrico foram os mesmos. Uma pequena chapa de níquel-berílio de 28,3 mm de comprimento, 8,5 mm de largura e 0,1 mm de espessura, usada como material da base, e um pequeno contato de níquel-prata de 2,3 mm de comprimento, 1,5 mm de largura e 0,7 mm de altura, usado como material de contato, como ilustrado na figura 4.1, sendo, portanto, necessário o uso de *welding help* no material da base.

O procedimento de soldagem padrão foi o mesmo utilizado na obtenção do primeiro conjunto de dados, destacando-se o tempo de soldagem total de 24 milissegundos, dividido em dois estágios, sendo o primeiro estágio somente para aquecimento e queima de impurezas presentes na superfície do material e o segundo estágio para a soldagem propriamente dita. A pressão exercida nos eletrodos também é ajustada por meio de uma mola, como ilustrado na figura 4.2. A temperatura dos eletrodos também foi mantida em torno de 16 °C, através de um eficiente sistema de resfriamento baseado na circulação de um líquido refrigerante no seu interior.

Todos os testes também foram executados em uma máquina na linha de produção, e não em laboratório, para prover condições reais de produção. O tipo de controle de alimentação presente na máquina de soldagem era o de média frequência com controle de

corrente constante. O critério de qualidade é a força de cisalhamento obtida através de ensaio destrutivo. Pontos de solda que suportem uma força de cisalhamento maior que 400 N são considerados soldas de boa qualidade. Mas, para garantir soldas boas, o procedimento de soldagem padrão usado busca produzir soldas que suportem uma força de cisalhamento média de 550 N.

Durante estes testes, parâmetros do procedimento de soldagem também foram modificados de forma a artificialmente simular diferentes situações que podem ocorrer durante o processo de soldagem e possam vir a prejudicar a qualidade final do ponto de solda, ou seja, simular diferentes perturbações que possam estar presentes no processo. Enquanto no primeiro conjunto de dados os valores da corrente de soldagem e da força de soldagem somente foram reduzidos, neste segundo conjunto de dados, estes valores, além de serem reduzidos, foram também aumentados durante os testes.

O segundo conjunto de dados é composto por 240 testes que foram executados seguindo o roteiro apresentado a seguir:

- Testes de números 1 a 15: procedimento de soldagem padrão;
- Testes de números 16 a 30: procedimento de soldagem padrão com aumento da força aplicada nos eletrodos em 6,3%;
- Testes de números 31 a 45: procedimento de soldagem padrão com aumento da força aplicada nos eletrodos em 9,5%;
- Testes de números 46 a 60: procedimento de soldagem padrão com aumento da força aplicada nos eletrodos em 12,7%;
- Testes de números 61 a 75: procedimento de soldagem padrão com aumento da força aplicada nos eletrodos em 15,8%;
- Testes de números 76 a 90: procedimento de soldagem padrão com redução da força aplicada nos eletrodos em 6,3%;

- Testes de números 91 a 105: procedimento de soldagem padrão;
- Testes de números 106 a 120: procedimento de soldagem padrão com redução da corrente do segundo estágio de soldagem de 3,7 kA para 3,5 kA;
- Testes de números 121 a 135: procedimento de soldagem padrão com redução da corrente do segundo estágio de soldagem de 3,7 kA para 3,2 kA;
- Testes de números 136 a 150: procedimento de soldagem padrão com redução da corrente do segundo estágio de soldagem de 3,7 kA para 2,8 kA;
- Testes de números 151 a 165: procedimento de soldagem padrão com redução da corrente do segundo estágio de soldagem de 3,7 kA para 2,4 kA;
- Testes de números 166 a 180: procedimento de soldagem padrão com aumento da corrente do segundo estágio de soldagem de 3,7 kA para 4,0 kA;
- Testes de números 181 a 195: novo procedimento de soldagem padrão (a corrente de soldagem padrão passou a ser de 3,8 kA);
- Testes de números 196 a 210: novo procedimento de soldagem padrão em material sem *welding help*.
- Testes de números 211 a 225: novo procedimento de soldagem padrão;
- Testes de números 226 a 240: novo procedimento de soldagem padrão após 2525 soldas do teste 225;

Os testes de número 24, 111, 203, 219, 220 e 221 apresentaram problemas na execução do ensaio destrutivo para determinação da força de cisalhamento suportada e tiveram que ser descartados.

A tabela B.2 do Anexo B mostra um detalhamento maior de cada teste deste segundo conjunto de dados como o nome do arquivo em que os dados de tensão e corrente foram salvos, o procedimento de soldagem utilizado, o número de soldas que os eletrodos

executaram até o momento do teste e o resultado do ensaio destrutivo de cada parte produzida.

4.2 Avaliação do Ajuste entre o Modelo e o Processo

Inicialmente é necessário avaliar se o modelo matemático parametrizável criado é capaz de reproduzir o comportamento da grandeza que ele descreve. Para esse fim foram utilizadas as curvas da resistência dinâmica, obtidas da forma descrita no item 3.4, de cada teste que compõe o primeiro conjunto de dados. A curva da resistência dinâmica de um dos testes do primeiro conjunto de dados é mostrada em detalhes na figura 4.3.

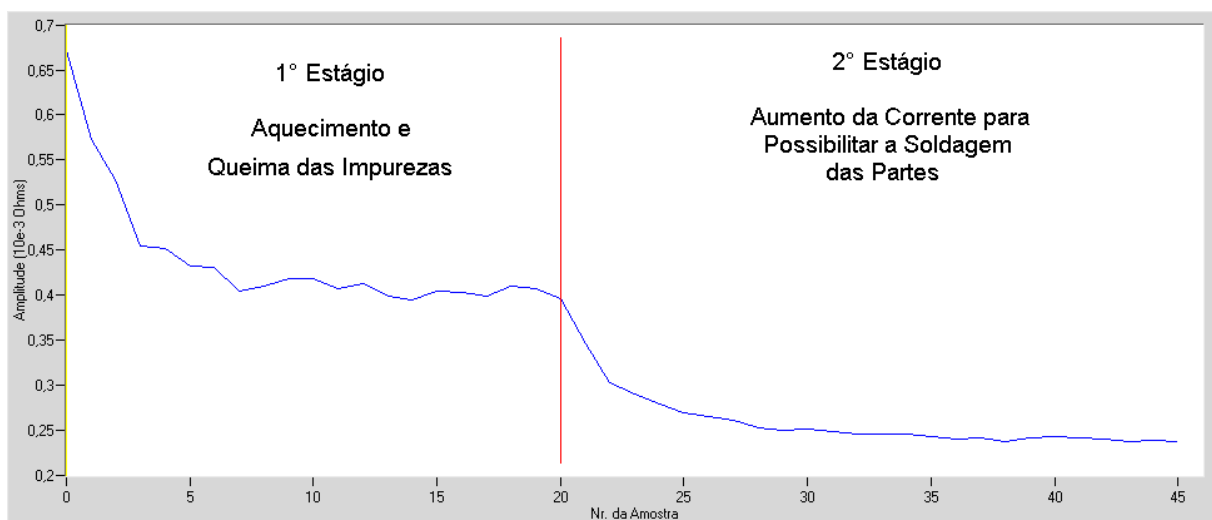


Figura 4.3 - Detalhes da curva da resistência dinâmica de um dos testes

Na figura 4.3 é possível identificar perfeitamente a divisão entre os dois estágios de soldagem que compõem o procedimento de soldagem dos contatos elétricos. O primeiro estágio é somente para aquecimento e queima de impurezas presentes na superfície do material, e o segundo estágio, para a soldagem propriamente dita.

Portanto, somente o segundo estágio será usado para fins de ajuste do modelo, pois é onde efetivamente acontece a soldagem. Para isso, foi utilizado o *plug-in* “Cut Curve (Begin End)” já citado anteriormente que também pode ser configurado para excluir os dados anteriores a uma determinada amostra. Neste caso, o *plug-in* “Cut Curve (Begin End)” foi configurado para excluir as amostras anteriores a amostra de número 20. O formato da curva da resistência dinâmica, considerando somente o segundo estágio de soldagem, usada para representar cada teste do primeiro conjunto de dados e também do segundo conjunto de dados, por estes serem similares, é mostrado na figura 4.4.




Figura 4.4 - Curva da resistência dinâmica considerando somente o segundo estágio

Utilizando-se agora o *plug-in* “Model CalcVariables”, que foi criado para ajustar a curva obtida com os parâmetros do modelo e a curva real obtida do PSPR, é possível avaliar se o modelo matemático parametrizável criado consegue reproduzir o comportamento do processo em análise.

O primeiro passo é preencher os campos da tela de configuração do *plug-in* “Model CalcVariables”. A tela de configuração já preenchida é mostrada na figura 4.5.

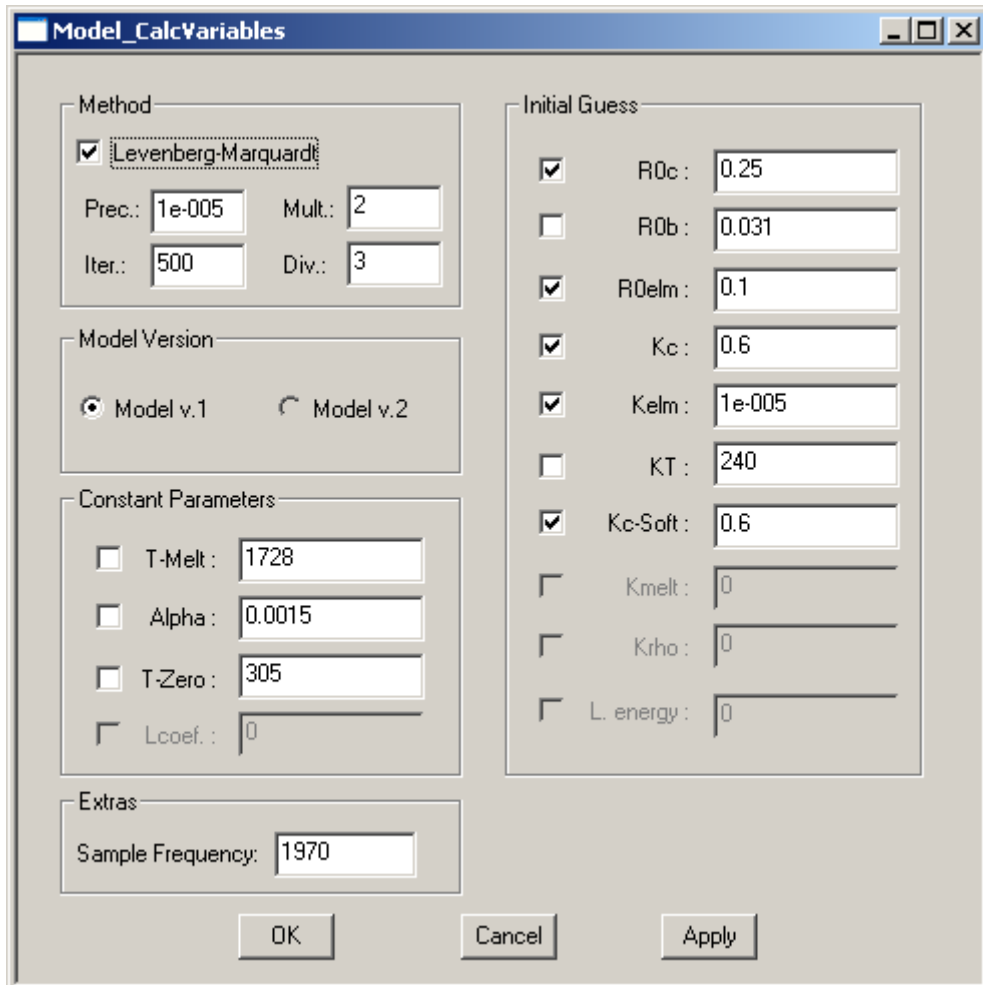


Figura 4.5 - Tela de configuração do *plug-in* “Model_CalcVariables” preenchida

Para o método de Levenberg-Marquardt, optou-se por uma precisão de 0,00001, um número máximo de iterações de 500 e as variáveis “Mult.” e “Div.” com os valores de 2 e 3, respectivamente. Como o método usado para obter a resistência dinâmica seleciona apenas um valor de cada semi-ciclo, que é o valor no pico de corrente, e isso representa uma redução de aproximadamente 13 vezes no número de amostras total, a frequência de amostragem inicial que era de 25,6 kHz também sofre uma redução de aproximadamente 13 vezes e passa a ser de 1970 Hz. Esse valor foi incluído no campo denominado “Sample Frequency”.

Com relação ao modelo matemático parametrizável, cinco parâmetros foram definidos como de valor fixo (T_{melt} , α , T_0 , R_{OB} e K_T) e cinco parâmetros foram definidos como de valor

ajustável (R_{OC} , R_{OELM} , K_C , K_{ELM} e K_{C-Soft}). O motivo dessa escolha é que os parâmetros referentes à temperatura de fusão dos materiais envolvidos, ao coeficiente térmico de resistência (α), à temperatura inicial, à resistência inicial do material bruto e à variação da temperatura nestes materiais podem ser considerados iguais em todos os testes. Os demais parâmetros podem sofrer variação de um teste para outro, de acordo com as condições do processo. Os valores escolhidos para os parâmetros do modelo foram baseados no valor real das propriedades dos materiais envolvidos (T_{melt} , $alpha$, K_T), na condição ambiente do processo (T_0), na proporção entre o valor da resistência total inicial média (de aproximadamente 0,38 m Ω) e suas componentes R_{OC} , R_{OELM} e R_{OB} , sendo $R_{OC} > R_{OELM} > R_{OB}$ (foi utilizada uma proporção de aproximadamente 2,5 vezes). Para K_C , K_{ELM} e K_{C-Soft} , foram utilizados inicialmente os valores de 0,5, 0,00005 e 0,5, respectivamente. Foi realizado um ajuste da curva do modelo com uma curva da resistência dinâmica obtida pela média ponto a ponto das curvas da resistência dinâmica de cada teste. Obteve-se então para os valores ajustados de K_C , K_{ELM} e K_{C-Soft} , respectivamente, aproximadamente 0,6, 0,00001 e 0,6, que passaram a ser os valores iniciais desses parâmetros.

Ao se executar uma nova “Work list” contendo esse *plug-in*, foi possível verificar a qualidade do ajuste entre a curva do modelo e a do processo. As figuras 4.6 e 4.7 mostram os resultados de dois testes do algoritmo de ajuste usando o modelo matemático parametrizável com a configuração descrita anteriormente e o primeiro conjunto de dados.

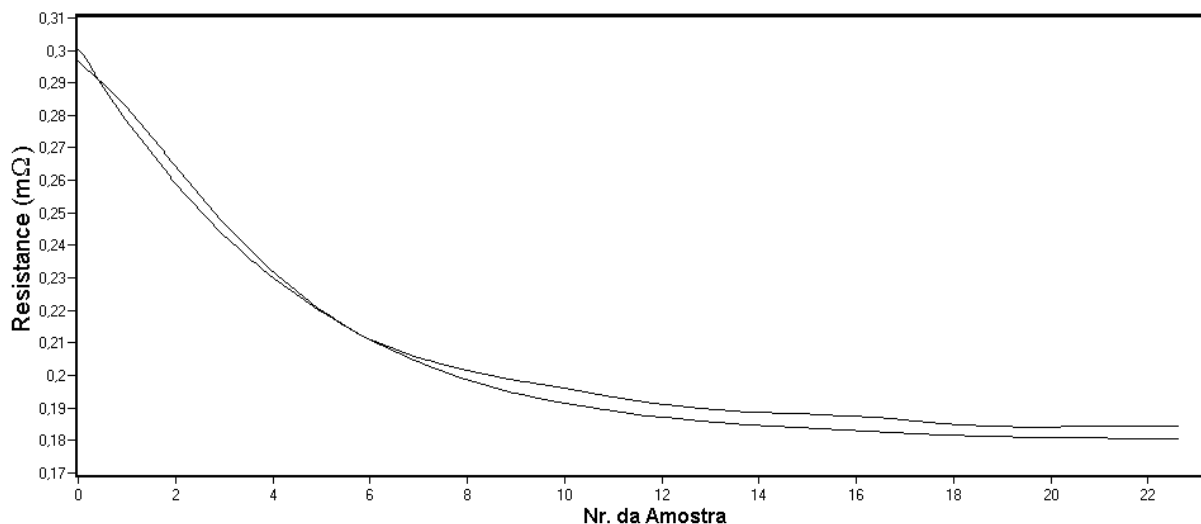


Figura 4.6 - Curva com pior ajuste entre os dados do conjunto analisado




Figura 4.7 - Curva com bom ajuste entre os dados do conjunto analisado

A figura 4.6 ilustra a curva resultante dos parâmetros do modelo com pior ajuste entre todos os testes do referido conjunto de dados e a figura 4.7 mostra uma curva que obteve um bom ajuste. Comparando as duas, é possível verificar que a curva com pior ajuste apresenta um erro quadrático médio superior ao da curva com bom ajuste; mas esse erro ainda pode ser considerado baixo e, portanto, não há necessidade de isolá-la do conjunto principal de curvas e analisá-la separadamente. Além disso, essa variação pode ser causada por variações no

processo que não são refletidas no modelo, mostrando que, conforme mencionado, as componentes do sinal adquirido que não são refletidas no modelo serão filtradas.

Com base nesses resultados, pode-se afirmar que o modelo matemático parametrizável criado é capaz de reproduzir com erro aceitável o comportamento da grandeza que ele descreve. Portanto, os valores dos cinco parâmetros ajustáveis podem ser usados como dados de entrada em uma rede neural artificial multicamadas, treinada com o algoritmo de *back-propagation*, para tentar-se estimar a qualidade final da solda.

4.3 Estimação da Qualidade Final da Solda

Após a comprovação que o modelo criado é capaz de reproduzir com erro aceitável o comportamento da curva de resistência dinâmica, é possível testar a etapa do sistema que faz a estimação da qualidade final da solda. Esta estimação será feita por uma rede neural artificial do tipo *Perceptron* multicamada, treinada com o algoritmo de *back-propagation*, usando a função de aprendizagem Rprop. Na etapa de treinamento da rede, os parâmetros do modelo que caracterizam cada teste serão utilizados como dados de entrada da rede e o valor da força de cisalhamento do respectivo teste será apresentado à saída da rede.

Usando o *plug-in* “SNNS Output”, feito para acessar o simulador SNNS, conforme descrito no item 3.7 deste trabalho, alguns testes iniciais foram feitos usando topologias tanto com uma camada oculta como com duas camadas ocultas, assim como diferentes parâmetros de treinamento, de forma que a rede estimasse em seu único neurônio de saída a força de cisalhamento suportada por cada ponto de solda. Nestes testes iniciais de rede, foram utilizadas as 182 amostras de soldagem do primeiro conjunto de dados e todos os parâmetros ajustáveis do modelo; portanto, a rede foi configurada com 5 neurônios de entrada. Para o treinamento da rede neural, foram utilizadas 122 amostras e para a validação da rede, as

outras 60 amostras. Nos dois grupos de dados, dados de treinamento e dados de validação, foram incluídas amostras com as diferentes condições de processo testadas em campo. As topologias usadas nestes testes iniciais foram 5-3-1, ou seja, 5 neurônios na camada de entrada, 3 neurônios em uma camada intermediária oculta e 1 neurônio na camada de saída, 5-5-1, 5-3-3-1 e 5-5-5-1. Para cada topologia, foram utilizadas diferentes configurações da função de aprendizagem Rprop, usada pela ferramenta SNNS para fazer o treinamento da rede. Para cada topologia e configuração, foram realizadas três inicializações da rede e respectivo treinamento, de forma que se pudessem comparar os resultados, diminuindo as chances de um falso resultado causado pela paralisação da rede em um mínimo local. Os resultados obtidos com apenas uma camada oculta foram cerca de 20% superiores aos obtidos com duas camadas ocultas. Para esta análise, levaram-se em consideração os seguintes itens, que serão utilizados ao longo de todo restante do trabalho:

- **MSE**: é o erro médio quadrático entre o valor estimado e o valor real de todas as amostras;
- **R² ou R²**: é o coeficiente de determinação. O chamado coeficiente de determinação (R^2) é o quadrado do coeficiente de correlação de Pearson. É uma medida da proporção da variabilidade em uma variável que é explicada pela variabilidade da outra. Esse coeficiente varia de 0 a 1. Zero corresponde a nenhuma correlação entre as variações das variáveis em questão. 1 corresponde à correlação perfeita. É pouco comum que tenhamos uma correlação perfeita ($R^2=1$) na prática, porque existem muitos fatores que determinam as relações entre variáveis na vida real;
- **Recog%**: é a taxa de reconhecimento. Considerando-se uma margem de erro aceitável, determina qual o percentual de amostras que se encaixa dentro desta margem. A margem de erro máxima aceitável neste trabalho é de 75 N, o qual é um

valor bem razoável, tendo em vista que o processo investigado trabalha com um ponto de operação de 550 N.

- **MAD:** é o desvio absoluto máximo, ou seja, o erro absoluto máximo encontrado.

A melhor topologia entre as testadas inicialmente foi a 5-5-1, tendo como configuração da função de aprendizagem Rprop, usada pela ferramenta SNNS, um delta zero de 0,0001, um delta máximo de 3, um alpha de 3, e valores de inicialização dos pesos aleatórios variando de -1 a 1 (para mais informações sobre estes parâmetros, consultar o manual da ferramenta SNNS) (MACHE, 1995). Os resultados da melhor entre as três inicializações, obtidos na topologia 5-5-1, são mostrados na tabela 4.1.

Tabela 4.1 - Resultados iniciais obtidos com a topologia 5-5-1

5-5-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,11116	0,89951	97%	1,06659	0,09933	0,90883	100%	0,68959

Os resultados mostrados na tabela 4.1 revelam que a etapa do sistema proposto que faz a estimação da qualidade da solda, no processo em análise, pode ser realizada com sucesso, já que um erro médio quadrático de 9,933 N para se estimar a força de cisalhamento, equivalendo a um erro percentual absoluto médio menor que 6%, é um excelente resultado, pois é melhor do que os resultados encontrados na literatura. Além disso, o coeficiente de determinação em torno de 0,9 mostra uma excelente relação entre os parâmetros ajustáveis do modelo criado e a força de cisalhamento suportada pela solda. A figura 4.8 mostra um gráfico com os valores reais e os valores estimados da qualidade dos testes do conjunto de dados usado para validar a rede neural, mostrando que para a topologia 5-5-1 foi possível obter uma taxa de reconhecimento de 100%, considerando a tolerância de 75 N. Esta figura foi obtida

através da leitura dos resultados da ferramenta SNNS usando um programa relacionado à ferramenta chamado “NETRESULT”.




Figura 4.8 - Resultado da topologia 5-5-1 para os dados de validação

Apesar dos resultados iniciais serem satisfatórios, há a possibilidade de existir uma topologia melhor e, principalmente, pode haver entre os cinco parâmetros ajustáveis do modelo um ou mais parâmetros que não sejam necessários ou, mesmo, que prejudiquem a estimativa da qualidade final da solda por parte da rede neural. Para responder a esta questão, foi feito um estudo para identificar qual a melhor combinação de parâmetros do modelo na entrada da rede e qual a melhor topologia de rede, entre as usadas no estudo, para estimar a qualidade final da solda.

Neste estudo foram testadas, para cada combinação possível de parâmetros do modelo usada na entrada da rede, cinco topologias de rede com uma camada oculta, já que este tipo de topologia apresentou resultados superiores. O número de neurônios na camada oculta nessas

cinco topologias de rede testadas foram, respectivamente, 3, 5, 8, 10 e 15 neurônios. Para cada topologia testada, foram realizadas três inicializações da rede e respectivos treinamentos e validações, sendo o melhor resultado entre as três inicializações o escolhido como resultado da topologia.

Como dito anteriormente, todas as combinações possíveis com os cinco parâmetros ajustáveis do modelo foram testadas na entrada da rede, ou seja, foi testado cada parâmetro individualmente, combinados dois a dois, combinados três a três, combinados quatro a quatro, e os cinco parâmetros juntos.

A configuração da função de aprendizagem Rprop, usada pela ferramenta SNNS, foi a mesma utilizada no melhor teste entre os testes realizados inicialmente, ou seja, utilizou-se um delta zero de 0,0001, um delta máximo de 3 e um alpha de 3. Os valores de inicialização dos pesos também foram aleatórios, variando de -1 a 1.

Inicialmente este estudo foi feito no primeiro conjunto de dados, utilizando, para o treinamento da rede neural, 122 testes, e para a validação da rede, seus outros 60 testes. Nos dois grupos de dados, dados de treinamento e dados de validação, foram incluídos testes com as diferentes condições de processo testadas em campo e estes grupos não foram alterados durante o estudo.

As tabelas 4.2, 4.3, 4.4, 4.5 e 4.6 mostram os resultados do estudo com as diferentes topologias testadas e com as possíveis combinações de um parâmetro, dois parâmetros, três parâmetros, quatro parâmetros e cinco parâmetros na entrada da rede, respectivamente.

O(s) parâmetro(s) utilizado(s) na entrada da rede aparecem do lado esquerdo das tabelas. A topologia utilizada aparece na linha superior de cada grupo de resultados, significando, por exemplo, o valor 1-3-1, que existe 1 neurônio na camada de entrada, 3 neurônios na camada intermediária oculta e 1 neurônio na camada de saída, sendo o resultado deste neurônio a estimativa da força de cisalhamento suportada pela solda.

Os resultados destacados em vermelho são os da validação da melhor entre as cinco topologias de rede testadas para cada combinação de parâmetros utilizada na entrada da rede.

Tabela 4.2 - Resultados de diferentes topologias com 1 parâmetro na entrada da rede

	1-3-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c	0,79876	0,27794	76%	3,33297	0,88457	0,18809	76%	2,89173
R0elm	0,41438	0,62541	81%	1,75013	0,44388	0,59258	78%	1,80921
Kc	0,52995	0,52094	79%	2,82026	0,39184	0,64034	83%	2,25607
Kelm	0,44873	0,51176	80%	3,32995	0,44588	0,59074	83%	2,52337
Kc-soft	0,15979	0,85554	95%	1,02598	0,1567	0,85616	93%	0,9694
	1-5-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c	0,80043	0,27642	76%	3,34969	0,88345	0,18912	75%	2,89009
R0elm	0,38923	0,64814	80%	1,77608	0,43685	0,59903	73%	1,80422
Kc	0,52938	0,52145	79%	2,81761	0,3926	0,63964	83%	2,25263
Kelm	0,44542	0,59734	81%	3,32378	0,39863	0,63411	83%	2,46745
Kc-soft	0,15973	0,8556	95%	1,02311	0,15626	0,85657	93%	0,96378
	1-8-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c	0,80061	0,27627	76%	3,3805	0,88484	0,18784	73%	2,8938
R0elm	0,39573	0,64226	79%	1,78512	0,43599	0,59982	73%	1,7961
Kc	0,53208	0,51901	80%	2,81181	0,39263	0,63962	81%	2,24558
Kelm	0,43801	0,60405	81%	3,31711	0,4123	0,62156	85%	2,55953
Kc-soft	0,15952	0,85579	95%	1,02567	0,15611	0,85671	93%	0,9613
	1-10-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c	0,82195	0,25697	76%	3,30457	0,88925	0,18078	70%	2,83942
R0elm	0,39096	0,64658	80%	1,79444	0,43854	0,59747	70%	1,80838
Kc	0,53313	0,51806	79%	2,80567	0,39244	0,63979	81%	2,24509
Kelm	0,43938	0,60281	81%	3,33564	0,41297	0,62095	85%	2,53333
Kc-soft	0,15955	0,85576	95%	1,02471	0,15611	0,85671	93%	0,9618
	1-15-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c	0,826	0,25331	76%	3,31931	0,89684	0,17682	71%	2,84769
R0elm	0,41752	0,62257	77%	1,82311	0,44431	0,59218	76%	1,80551
Kc	0,5401	0,51176	80%	2,85571	0,388	0,64387	85%	2,29939
Kelm	0,44644	0,59643	81%	3,35432	0,41898	0,61543	85%	2,53334
Kc-soft	0,15963	0,85569	95%	1,02643	0,15649	0,85636	93%	0,96612

Tabela 4.3 - Resultados de diferentes topologias com 2 parâmetros na entrada da rede

	2-3-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm	0,22139	0,79986	89%	1,31257	0,25173	0,76894	83%	1,10807
R0c_Kc	0,41972	0,62058	88%	3,13716	0,33133	0,69588	93%	2,46041
R0c_Kelm	0,80067	0,27622	76%	3,36655	0,88533	0,18739	78%	2,88677
R0c_Kc-soft	0,13582	0,87722	98%	0,89231	0,12576	0,88457	98%	0,82558
R0elm_Kc	0,31379	0,71633	81%	1,50705	0,24193	0,77794	85%	1,38636
R0elm_Kelm	0,44049	0,6018	77%	1,81156	0,45996	0,57782	76%	1,57923
R0elm_Kc-soft	0,13172	0,88092	98%	1,05499	0,13398	0,87702	98%	0,85613
Kc_Kelm	0,52945	0,52138	80%	2,82247	0,3924	0,63983	83%	2,25491
Kc_Kc-soft	0,13717	0,876	98%	0,99267	0,12304	0,88706	96%	0,80768
Kelm_Kc-soft	0,15953	0,85578	95%	1,02521	0,15595	0,85686	93%	0,96203
	2-5-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm	0,22992	0,79215	90%	1,33727	0,26092	0,7605	81%	1,12662
R0c_Kc	0,42436	0,61638	89%	3,10142	0,31458	0,71126	93%	2,44053
R0c_Kelm	0,8008	0,27609	77%	3,34326	0,88282	0,18969	75%	2,88685
R0c_Kc-soft	0,13592	0,87713	98%	0,89302	0,12586	0,88447	98%	0,82234
R0elm_Kc	0,32571	0,70556	81%	1,54333	0,24135	0,77847	85%	1,38147
R0elm_Kelm	0,4399	0,60234	77%	1,80496	0,45887	0,57882	76%	1,58066
R0elm_Kc-soft	0,13113	0,88145	98%	1,0573	0,13488	0,87619	98%	0,86213
Kc_Kelm	0,53243	0,51869	81%	2,82499	0,39138	0,64076	83%	2,25697
Kc_Kc-soft	0,13509	0,87788	98%	0,97467	0,12395	0,88623	96%	0,80168
Kelm_Kc-soft	0,1594	0,8559	95%	1,02664	0,15609	0,85673	93%	0,96238
	2-8-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm	0,2669	0,75872	90%	2,11064	0,26694	0,75498	86%	1,10016
R0c_Kc	0,42431	0,61643	88%	3,1085	0,30976	0,71568	95%	2,43483
R0c_Kelm	0,82651	0,25285	76%	3,30902	0,89643	0,1772	70%	2,83305
R0c_Kc-soft	0,1357	0,87733	97%	0,88338	0,12594	0,8844	98%	0,82348
R0elm_Kc	0,32179	0,7091	81%	1,53585	0,24203	0,77784	85%	1,37103
R0elm_Kelm	0,44036	0,60192	78%	1,81076	0,45954	0,57821	76%	1,57674
R0elm_Kc-soft	0,13123	0,88137	98%	1,05463	0,13487	0,8762	98%	0,85742
Kc_Kelm	0,5366	0,51492	81%	2,81099	0,3919	0,64029	81%	2,24764
Kc_Kc-soft	0,13856	0,87473	97%	1,02559	0,12241	0,88764	96%	0,84054
Kelm_Kc-soft	0,15925	0,85603	95%	1,02549	0,15564	0,85713	93%	0,96331
	2-10-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm	0,25069	0,77338	89%	2,3259	0,29606	0,72825	76%	1,37327
R0c_Kc	0,4292	0,61201	86%	3,06729	0,31654	0,70946	93%	2,40978
R0c_Kelm	0,82737	0,25208	76%	3,3055	0,89697	0,1767	70%	2,8359
R0c_Kc-soft	0,13586	0,87718	97%	0,88096	0,12594	0,8844	98%	0,83774
R0elm_Kc	0,31909	0,71155	80%	1,53203	0,24048	0,77926	85%	1,38972
R0elm_Kelm	0,44003	0,60222	78%	1,80885	0,45817	0,57946	76%	1,57693
R0elm_Kc-soft	0,13189	0,88077	98%	1,06136	0,13475	0,87631	98%	0,8624
Kc_Kelm	0,53224	0,51886	81%	2,81718	0,39189	0,6403	83%	2,25106
Kc_Kc-soft	0,1329	0,87985	97%	0,95507	0,12218	0,88785	95%	0,80916
Kelm_Kc-soft	0,15979	0,85555	95%	1,01852	0,15596	0,85684	93%	0,95884
	2-15-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm	0,23363	0,7888	87%	1,37326	0,24876	0,77167	83%	1,04374
R0c_Kc	0,44296	0,59957	86%	3,02746	0,31074	0,71478	91%	2,3821
R0c_Kelm	0,82666	0,25272	76%	3,30755	0,89708	0,1766	68%	2,83107
R0c_Kc-soft	0,13545	0,87755	97%	0,87914	0,1268	0,88361	98%	0,83104
R0elm_Kc	0,30478	0,72448	81%	1,49918	0,23952	0,78015	86%	1,38604
R0elm_Kelm	0,44072	0,60159	77%	1,81566	0,45969	0,57807	76%	1,57512
R0elm_Kc-soft	0,13212	0,88056	98%	1,06	0,13413	0,87688	98%	0,85878
Kc_Kelm	0,52977	0,5211	80%	2,8168	0,39289	0,63937	83%	2,24986
Kc_Kc-soft	0,1375	0,8757	97%	1,01146	0,12272	0,88736	96%	0,83452
Kelm_Kc-soft	0,15946	0,85585	95%	1,0252	0,15645	0,85639	93%	0,97178

Tabela 4.4 - Resultados de diferentes topologias com 3 parâmetros na entrada da rede

	3-3-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc	0,20516	0,81453	90%	1,25778	0,16318	0,8522	91%	1,03874
R0c_R0elm_Kelm	0,23734	0,78544	91%	1,73469	0,2524	0,76832	85%	1,09242
R0c_R0elm_Kc-soft	0,12144	0,89022	99%	0,98122	0,12371	0,88645	98%	0,90066
R0c_Kc_Kelm	0,42155	0,61893	89%	3,11391	0,33184	0,69541	93%	2,43928
R0c_Kc_Kc-soft	0,12189	0,88981	99%	0,8869	0,10243	0,90597	100%	0,71198
R0c_Kelm_Kc-soft	0,13881	0,87451	98%	0,91251	0,12715	0,88329	98%	0,83311
R0elm_Kc_Kelm	0,31421	0,71596	80%	1,51255	0,24021	0,77951	85%	1,38484
R0elm_Kc_Kc-soft	0,11881	0,89259	97%	1,11977	0,10341	0,90508	100%	0,69445
R0elm_Kelm_Kc-soft	0,13147	0,88114	98%	1,05876	0,13379	0,87719	98%	0,86057
Kc_Kelm_Kc-soft	0,1396	0,8738	98%	1,04656	0,12578	0,88454	96%	0,76868
	3-5-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc	0,20449	0,81514	90%	1,2528	0,16589	0,84773	93%	1,05371
R0c_R0elm_Kelm	0,22544	0,7962	90%	1,35802	0,24825	0,77214	83%	1,07935
R0c_R0elm_Kc-soft	0,12373	0,88814	98%	1,00819	0,12451	0,88571	98%	0,91732
R0c_Kc_Kelm	0,43105	0,61034	86%	3,10196	0,3115	0,71408	91%	2,44534
R0c_Kc_Kc-soft	0,1223	0,88943	98%	0,90859	0,10079	0,90748	100%	0,73426
R0c_Kelm_Kc-soft	0,13607	0,87699	97%	0,89245	0,12565	0,88329	98%	0,83311
R0elm_Kc_Kelm	0,32616	0,70515	81%	1,57179	0,24102	0,77877	83%	1,40629
R0elm_Kc_Kc-soft	0,1159	0,89522	98%	1,10024	0,10339	0,90509	100%	0,65365
R0elm_Kelm_Kc-soft	0,13115	0,88144	98%	1,05259	0,13484	0,87623	98%	0,85574
Kc_Kelm_Kc-soft	0,13831	0,87496	97%	1,01222	0,12241	0,88764	96%	0,82731
	3-8-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc	0,19747	0,82148	93%	1,20066	0,16095	0,85226	95%	1,02841
R0c_R0elm_Kelm	0,26285	0,76238	89%	1,92217	0,25893	0,76233	86%	1,0849
R0c_R0elm_Kc-soft	0,12245	0,8893	99%	0,98385	0,12188	0,88813	98%	0,88736
R0c_Kc_Kelm	0,42351	0,61716	89%	3,10676	0,30619	0,71895	95%	2,43688
R0c_Kc_Kc-soft	0,12321	0,88861	99%	0,91571	0,10038	0,90786	100%	0,73785
R0c_Kelm_Kc-soft	0,13578	0,87725	97%	0,88253	0,12613	0,88422	98%	0,82376
R0elm_Kc_Kelm	0,32398	0,70713	80%	1,57593	0,24032	0,77941	85%	1,40997
R0elm_Kc_Kc-soft	0,11835	0,893	98%	1,1171	0,10308	0,90538	100%	0,69329
R0elm_Kelm_Kc-soft	0,13203	0,88064	98%	1,05949	0,13481	0,87625	98%	0,86092
Kc_Kelm_Kc-soft	0,13299	0,87978	97%	0,94594	0,12533	0,88473	96%	0,80787
	3-10-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc	0,22866	0,79329	90%	1,27106	0,16758	0,84618	95%	0,8855
R0c_R0elm_Kelm	0,26476	0,76066	89%	1,85354	0,26395	0,75772	81%	1,13604
R0c_R0elm_Kc-soft	0,12018	0,89135	99%	0,96295	0,12317	0,88694	98%	0,88853
R0c_Kc_Kelm	0,4339	0,60776	85%	3,04421	0,31788	0,70823	91%	2,38643
R0c_Kc_Kc-soft	0,12248	0,88928	99%	0,90356	0,10044	0,9078	100%	0,7235
R0c_Kelm_Kc-soft	0,1367	0,87642	97%	0,89558	0,12589	0,88445	98%	0,83129
R0elm_Kc_Kelm	0,33006	0,70163	81%	1,56093	0,24154	0,77829	85%	1,40994
R0elm_Kc_Kc-soft	0,11895	0,89246	97%	1,11872	0,10361	0,9049	100%	0,70205
R0elm_Kelm_Kc-soft	0,13175	0,88089	98%	1,05464	0,1337	0,87727	98%	0,85274
Kc_Kelm_Kc-soft	0,13275	0,87999	97%	0,94446	0,12542	0,88487	96%	0,80923
	3-15-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc	0,23702	0,78573	88%	1,30936	0,17277	0,84141	91%	0,92476
R0c_R0elm_Kelm	0,23219	0,7901	88%	1,34369	0,26393	0,75774	81%	1,13758
R0c_R0elm_Kc-soft	0,12052	0,89105	99%	0,96753	0,12437	0,88584	98%	0,89783
R0c_Kc_Kelm	0,44463	0,59806	86%	3,02044	0,31065	0,714866	91%	2,39636
R0c_Kc_Kc-soft	0,12653	0,88562	99%	0,93412	0,10186	0,9065	100%	0,70456
R0c_Kelm_Kc-soft	0,13651	0,87659	97%	0,89479	0,12585	0,88448	98%	0,82741
R0elm_Kc_Kelm	0,32641	0,70492	81%	1,54546	0,24057	0,77918	85%	1,37624
R0elm_Kc_Kc-soft	0,11822	0,89313	97%	1,11803	0,10306	0,9054	100%	0,69085
R0elm_Kelm_Kc-soft	0,13176	0,88088	98%	1,05947	0,13445	0,87659	98%	0,86027
Kc_Kelm_Kc-soft	0,13226	0,88043	97%	0,94911	0,12211	0,88791	95%	0,81466

Tabela 4.5 - Resultados de diferentes topologias com 4 parâmetros na entrada da rede

	4-3-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm	0,20369	0,81587	90%	1,26197	0,16052	0,85265	91%	0,99526
R0c_R0elm_Kc_Kc-soft	0,11806	0,89327	96%	1,1126	0,10054	0,90771	100%	0,72797
R0c_R0elm_Kelm_Kc-soft	0,12093	0,89068	99%	0,97299	0,12423	0,88596	98%	0,89948
R0c_Kc_Kelm_Kc-soft	0,12174	0,88994	99%	0,88633	0,1023	0,9061	100%	0,70672
R0elm_Kc_Kelm_Kc-soft	0,11878	0,89262	97%	1,12087	0,10324	0,90524	100%	0,69475
	4-5-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm	0,18652	0,83138	93%	1,16491	0,15848	0,85453	95%	0,91603
R0c_R0elm_Kc_Kc-soft	0,11232	0,89846	97%	1,07672	0,09775	0,91027	100%	0,70668
R0c_R0elm_Kelm_Kc-soft	0,12164	0,89003	99%	0,98673	0,12366	0,88649	98%	0,90048
R0c_Kc_Kelm_Kc-soft	0,11986	0,89164	98%	0,90358	0,1025	0,90591	98%	0,77399
R0elm_Kc_Kelm_Kc-soft	0,11938	0,89207	97%	1,12838	0,10381	0,90471	100%	0,685
	4-8-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm	0,19208	0,82636	93%	0,82636	0,16021	0,85294	95%	0,88315
R0c_R0elm_Kc_Kc-soft	0,11413	0,89682	97%	1,09501	0,09856	0,90952	100%	0,71769
R0c_R0elm_Kelm_Kc-soft	0,12085	0,89074	99%	0,97311	0,12541	0,88489	98%	0,90753
R0c_Kc_Kelm_Kc-soft	0,12351	0,88834	99%	0,93037	0,10025	0,90798	100%	0,72351
R0elm_Kc_Kelm_Kc-soft	0,11966	0,89182	97%	1,13206	0,1036	0,90491	100%	0,68569
	4-10-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm	0,21673	0,80407	92%	1,23236	0,16132	0,85192	95%	1,00926
R0c_R0elm_Kc_Kc-soft	0,11143	0,89926	97%	1,06371	0,09754	0,91047	100%	0,70023
R0c_R0elm_Kelm_Kc-soft	0,12113	0,89049	99%	0,97859	0,12491	0,88535	98%	0,90195
R0c_Kc_Kelm_Kc-soft	0,12221	0,88952	99%	0,90596	0,10071	0,90756	100%	0,74031
R0elm_Kc_Kelm_Kc-soft	0,11975	0,89174	97%	1,13752	0,10345	0,90504	100%	0,69101
	4-15-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm	0,18655	0,83135	93%	1,17979	0,16326	0,85014	91%	0,90355
R0c_R0elm_Kc_Kc-soft	0,11149	0,8992	97%	1,06888	0,09797	0,91007	100%	0,69572
R0c_R0elm_Kelm_Kc-soft	0,12173	0,88995	99%	0,98474	0,12523	0,88505	98%	0,90817
R0c_Kc_Kelm_Kc-soft	0,12471	0,88726	99%	0,92881	0,10105	0,90724	100%	0,74299
R0elm_Kc_Kelm_Kc-soft	0,11696	0,89426	98%	1,11225	0,10261	0,90581	100%	0,67696

Tabela 4.6 - Resultados de diferentes topologias com 5 parâmetros na entrada da rede

	5-3-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm_Kc-soft	0,11804	0,89329	96%	1,11316	0,10051	0,90773	100%	0,73618
	5-5-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm_Kc-soft	0,11116	0,89951	97%	1,06659	0,09933	0,90883	100%	0,68959
	5-8-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm_Kc-soft	0,11194	0,8988	97%	1,0725	0,0968	0,91114	100%	0,69913
	5-10-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm_Kc-soft	0,11683	0,89438	96%	1,11267	0,09996	0,90825	100%	0,72543
	5-15-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm_Kc-soft	0,11932	0,89213	97%	1,12576	0,09934	0,90881	100%	0,72097

Após a realização do estudo com o primeiro conjunto de dados, este foi repetido com o segundo conjunto de dados, utilizando-se as mesmas configurações descritas anteriormente, com a única diferença que, como este segundo conjunto possui mais testes, foram utilizados para o treinamento da rede neural 154 testes e para a validação da rede, seus outros 80 testes. As tabelas 4.7, 4.8, 4.9, 4.10 e 4.11 mostram os resultados do estudo com as diferentes topologias testadas e com as possíveis combinações de um parâmetro, dois parâmetros, três parâmetros, quatro parâmetros e cinco parâmetros na entrada da rede, respectivamente.

Tabela 4.7 - Resultados de diferentes topologias com 1 parâmetro na entrada da rede

	1-3-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c	1,15365	0,0846	67%	3,08723	0,95439	0,06407	71%	2,8373
R0elm	0,67358	0,46553	77%	3,0659	0,55762	0,45316	68%	1,93166
Kc	0,89562	0,28934	67%	3,32002	0,53655	0,47382	78%	2,6145
Kelm	1,26036	0,00006	66%	3,16307	1,01973	0,00001	61%	2,78307
Kc-soft	0,30627	0,75698	85%	2,17796	0,27406	0,73124	87%	1,83626
	1-5-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c	1,15538	0,08323	66%	3,09099	0,95468	0,063679	68%	2,83259
R0elm	0,67817	0,46189	77%	3,05451	0,55937	0,45144	68%	1,91804
Kc	0,88803	0,29536	70%	3,28546	0,51818	0,49184	80%	2,65152
Kelm	1,26028	0,00001	66%	3,17085	1,01977	0,00004	61%	2,79085
Kc-soft	0,30631	0,75695	85%	2,1738	0,27414	0,73116	87%	1,8345
	1-8-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c	1,26014	0,00011	66%	3,1558	1,0201	0,00036	61%	2,78073
R0elm	0,7032	0,44202	76%	3,01127	0,56962	0,4414	68%	1,86451
Kc	0,89538	0,28954	68%	3,3366	0,5342	0,47612	77%	2,60656
Kelm	1,26031	0,00002	66%	3,16617	1,01973	0,00001	61%	2,78617
Kc-soft	0,30637	0,7569	85%	2,17052	0,27435	0,73095	87%	1,83405
	1-10-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c	1,26016	0,00009	66%	3,15299	1,02009	0,00035	61%	2,77799
R0elm	0,67543	0,46405	77%	3,06127	0,55849	0,45231	68%	1,9259
Kc	0,90561	0,28142	66%	3,1655	0,54416	0,46636	78%	2,63463
Kelm	1,26029	0,00001	66%	3,16868	1,01975	0,00001	61%	2,78868
Kc-soft	0,30632	0,75693	85%	2,17735	0,27402	0,73128	87%	1,83756
	1-15-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c	1,26018	0,00007	66%	3,15166	1,02009	0,00035	61%	2,77664
R0elm	0,69254	0,45048	77%	3,02929	0,56372	0,44718	68%	1,88546
Kc	1,00208	0,20487	68%	3,58408	0,63435	0,37792	75%	2,52039
Kelm	1,26029	0,00001	66%	3,16832	1,01974	0,00001	61%	2,78832
Kc-soft	0,3063	0,75695	85%	2,17503	0,27409	0,73121	87%	1,8347

Tabela 4.8 - Resultados de diferentes topologias com 2 parâmetros na entrada da rede

	2-3-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm	0,55203	0,56197	78%	2,84376	0,48867	0,52078	78%	2,19354
R0c_Kc	0,66253	0,4743	79%	2,78685	0,45483	0,55396	85%	2,75669
R0c_Kelm	1,15341	0,08479	66%	3,08295	0,95485	0,06362	71%	2,83358
R0c_Kc-soft	0,23579	0,8129	88%	1,66798	0,1995	0,80435	92%	1,18682
R0elm_Kc	0,55831	0,55699	79%	3,31938	0,34987	0,6569	78%	1,39692
R0elm_Kelm	0,7082	0,43806	76%	3,00319	0,57326	0,43881	67%	1,85629
R0elm_Kc-soft	0,24729	0,80377	88%	1,54219	0,2545	0,75742	90%	1,7327
Kc_Kelm	0,89428	0,29041	67%	3,31703	0,53623	0,47413	78%	2,62444
Kc_Kc-soft	0,30031	0,7617	86%	2,288	0,24273	0,76196	87%	1,36783
Kelm_Kc-soft	0,30628	0,75697	85%	2,17653	0,27414	0,73115	87%	1,83576
	2-5-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm	0,55443	0,56007	75%	2,82655	0,46948	0,5396	81%	2,33268
R0c_Kc	0,69792	0,44621	78%	3,08306	0,42663	0,58162	87%	2,72351
R0c_Kelm	1,15619	0,08259	66%	3,06401	0,9546	0,0639	71%	2,81329
R0c_Kc-soft	0,23327	0,81489	88%	1,66068	0,19848	0,80535	92%	1,16934
R0elm_Kc	0,45645	0,63781	83%	2,97432	0,34121	0,66539	81%	1,44859
R0elm_Kelm	0,69484	0,44865	77%	3,03682	0,56376	0,44714	68%	1,89141
R0elm_Kc-soft	0,24974	0,80183	87%	1,54617	0,25489	0,75004	90%	1,71135
Kc_Kelm	0,90119	0,28493	66%	3,24018	0,54128	0,46918	78%	2,61346
Kc_Kc-soft	0,27216	0,78404	87%	1,84084	0,22225	0,78205	90%	1,35291
Kelm_Kc-soft	0,30627	0,75697	85%	2,17596	0,27421	0,73109	87%	1,83626
	2-8-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm	0,54176	0,57012	77%	2,84912	0,47388	0,53528	81%	2,35586
R0c_Kc	0,68872	0,45351	79%	3,0654	0,43067	0,57766	86%	2,77289
R0c_Kelm	1,26017	0,00008	66%	3,1521	1,02008	0,00034	61%	2,77707
R0c_Kc-soft	0,23451	0,81392	88%	1,64941	0,1986	0,80524	92%	1,16859
R0elm_Kc	0,4293	0,65935	85%	2,34143	0,34508	0,66159	81%	1,46134
R0elm_Kelm	0,71103	0,43581	74%	3,04924	0,57652	0,43463	67%	1,89247
R0elm_Kc-soft	0,24975	0,80182	87%	1,53754	0,25523	0,7497	90%	1,68518
Kc_Kelm	0,90526	0,28169	66%	3,23294	0,54242	0,46807	78%	2,79804
Kc_Kc-soft	0,27308	0,78331	88%	1,81087	0,22466	0,77968	90%	1,35657
Kelm_Kc-soft	0,30641	0,75686	85%	2,18007	0,2738	0,73149	87%	1,84052
	2-10-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm	0,5539	0,56048	76%	2,82192	0,46867	0,54039	81%	2,33886
R0c_Kc	0,70228	0,44275	79%	3,09794	0,42999	0,57832	87%	2,73528
R0c_Kelm	1,26015	0,00001	66%	3,15435	1,02009	0,00035	61%	2,77933
R0c_Kc-soft	0,23594	0,81278	88%	1,68183	0,20043	0,80344	92%	1,18702
R0elm_Kc	0,47055	0,62662	82%	0,59751	0,33875	0,66781	81%	1,43501
R0elm_Kelm	0,70285	0,4423	76%	3,01031	0,56956	0,44145	68%	1,86508
R0elm_Kc-soft	0,25054	0,8012	87%	1,56106	0,25586	0,74908	90%	1,73923
Kc_Kelm	0,90418	0,28255	66%	3,18945	0,54442	0,4661	78%	2,62498
Kc_Kc-soft	0,27173	0,78438	87%	1,83333	0,22351	0,78081	90%	1,36568
Kelm_Kc-soft	0,30632	0,75693	85%	2,17712	0,27421	0,73109	87%	1,83803
	2-15-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm	0,60231	0,52207	76%	2,91091	0,51528	0,49468	76%	1,94553
R0c_Kc	0,68451	0,45685	77%	2,7706	0,4377	0,57076	85%	2,72947
R0c_Kelm	1,26014	0,00001	66%	3,15514	1,0201	0,00036	61%	2,78017
R0c_Kc-soft	0,23642	0,8124	88%	1,66939	0,19996	0,8039	92%	1,17831
R0elm_Kc	0,48514	0,61508	81%	2,72462	0,33314	0,6733	81%	1,42531
R0elm_Kelm	0,68267	0,45831	77%	3,04383	0,56047	0,45036	68%	1,90413
R0elm_Kc-soft	0,25125	0,80063	87%	1,54919	0,25541	0,74952	90%	1,69418
Kc_Kelm	0,90671	0,28054	66%	3,20842	0,5408	0,46966	78%	2,61722
Kc_Kc-soft	0,27101	0,78496	86%	1,82973	0,22607	0,77829	90%	1,37525
Kelm_Kc-soft	0,3063	0,75695	85%	2,18057	0,27384	0,73145	87%	1,8382

Tabela 4.9 - Resultados de diferentes topologias com 3 parâmetros na entrada da rede

	3-3-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc	0,3039	0,75885	92%	2,32071	0,21181	0,79228	91%	1,26392
R0c_R0elm_Kelm	0,56504	0,55165	80%	2,79031	0,47835	0,5309	80%	2,31158
R0c_R0elm_Kc-soft	0,20759	0,83527	91%	1,21685	0,22404	0,78029	91%	1,3805
R0c_Kc_Kelm	0,67568	0,46386	79%	3,00849	0,42285	0,58533	90%	2,7418
R0c_Kc_Kc-soft	0,23867	0,81062	90%	1,70626	0,23258	0,77191	88%	1,40271
R0c_Kelm_Kc-soft	0,23581	0,81288	88%	1,66989	0,1994	0,80445	92%	1,18618
R0elm_Kc_Kelm	0,5702	0,54756	79%	3,4741	0,34899	0,65776	78%	1,40557
R0elm_Kc_Kc-soft	0,23199	0,81592	88%	1,36594	0,20404	0,7999	92%	1,36932
R0elm_Kelm_Kc-soft	0,24812	0,80311	88%	1,53829	0,25385	0,75105	90%	1,67809
Kc_Kelm_Kc-soft	0,3014	0,76084	86%	2,27424	0,24207	0,7626	87%	1,34887
	3-5-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc	0,32973	0,73836	89%	2,37521	0,19994	0,80392	91%	1,04599
R0c_R0elm_Kelm	0,55913	0,55634	75%	2,80498	0,47158	0,53754	81%	2,3334
R0c_R0elm_Kc-soft	0,20286	0,83902	91%	1,17777	0,21233	0,79177	91%	1,31426
R0c_Kc_Kelm	0,67722	0,46263	79%	2,97711	0,42472	0,58349	87%	2,75564
R0c_Kc_Kc-soft	0,21663	0,8281	89%	1,34276	0,20158	0,80231	91%	1,05853
R0c_Kelm_Kc-soft	0,22897	0,81831	90%	1,55495	0,19784	0,80598	92%	1,14183
R0elm_Kc_Kelm	0,43756	0,6528	83%	2,32773	0,34271	0,66391	81%	1,46813
R0elm_Kc_Kc-soft	0,23155	0,81627	89%	1,41599	0,20386	0,80008	92%	1,35313
R0elm_Kelm_Kc-soft	0,24812	0,80311	88%	1,53829	0,25385	0,75105	90%	1,67809
Kc_Kelm_Kc-soft	0,27607	0,78094	88%	1,84614	0,23578	0,76877	87%	1,32268
	3-8-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc	0,33464	0,73446	90%	2,28164	0,23306	0,77144	90%	1,51006
R0c_R0elm_Kelm	0,55397	0,56043	75%	2,84018	0,46616	0,54285	80%	2,32012
R0c_R0elm_Kc-soft	0,21004	0,83333	92%	1,2406	0,2195	0,78474	91%	1,33329
R0c_Kc_Kelm	0,67676	0,463	79%	2,96903	0,42442	0,58378	87%	2,75271
R0c_Kc_Kc-soft	0,2544	0,79813	87%	1,95217	0,22791	0,77649	90%	1,41852
R0c_Kelm_Kc-soft	0,23392	0,81438	88%	1,60232	0,20004	0,80382	92%	1,16446
R0elm_Kc_Kelm	0,50883	0,59625	81%	2,7697	0,33731	0,66921	82%	1,43056
R0elm_Kc_Kc-soft	0,23497	0,81355	89%	1,37056	0,20495	0,799	92%	1,34408
R0elm_Kelm_Kc-soft	0,24975	0,80182	87%	1,54401	0,25558	0,74935	90%	1,71265
Kc_Kelm_Kc-soft	0,27192	0,78423	87%	1,82651	0,22452	0,77982	90%	1,36894
	3-10-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc	0,36328	0,71174	88%	2,51973	0,23182	0,77266	90%	1,17732
R0c_R0elm_Kelm	0,56481	0,55183	75%	2,79695	0,48019	0,52909	78%	2,32839
R0c_R0elm_Kc-soft	0,18811	0,85073	94%	1,02804	0,20284	0,80107	92%	1,24354
R0c_Kc_Kelm	0,67397	0,46522	79%	2,84876	0,43415	0,57424	88%	2,7614
R0c_Kc_Kc-soft	0,2044	0,83781	90%	1,32757	0,21565	0,78851	91%	1,53439
R0c_Kelm_Kc-soft	0,23532	0,81327	88%	1,6817	0,19952	0,80433	92%	1,17798
R0elm_Kc_Kelm	0,4268	0,66134	83%	2,40997	0,34026	0,66632	80%	1,41508
R0elm_Kc_Kc-soft	0,22799	0,81909	88%	1,40666	0,20598	0,798	92%	1,44998
R0elm_Kelm_Kc-soft	0,25115	0,80071	87%	1,545	0,25486	0,75006	90%	1,68873
Kc_Kelm_Kc-soft	0,2722	0,78401	88%	1,83156	0,2234	0,78091	90%	1,36057
	3-15-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc	0,36408	0,71111	85%	2,48939	0,2445	0,76022	87%	1,2796
R0c_R0elm_Kelm	0,55781	0,55739	75%	2,83344	0,4738	0,53536	80%	2,31641
R0c_R0elm_Kc-soft	0,21115	0,83245	92%	1,23522	0,22111	0,78316	91%	1,34664
R0c_Kc_Kelm	0,69481	0,44868	76%	2,97679	0,42316	0,58502	85%	2,76938
R0c_Kc_Kc-soft	0,28066	0,77729	88%	2,04523	0,23879	0,76583	88%	1,66291
R0c_Kelm_Kc-soft	0,23664	0,81222	88%	1,67531	0,20023	0,80364	92%	1,1886
R0elm_Kc_Kelm	0,55653	0,5584	79%	3,05698	0,34545	0,66122	80%	1,39787
R0elm_Kc_Kc-soft	0,23616	0,81261	89%	1,38686	0,20278	0,80113	93%	1,30815
R0elm_Kelm_Kc-soft	0,25185	0,80016	87%	1,55556	0,25617	0,74878	90%	1,72881
Kc_Kelm_Kc-soft	0,27083	0,7851	88%	1,85489	0,22296	0,78134	90%	1,36669

Tabela 4.10 - Resultados de diferentes topologias com 4 parâmetros na entrada da rede

	4-3-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm	0,32341	0,74338	90%	2,34089	0,2064	0,79758	91%	1,02555
R0c_R0elm_Kc_Kc-soft	0,18287	0,85489	92%	1,16514	0,18754	0,81608	95%	1,50338
R0c_R0elm_Kelm_Kc-soft	0,19656	0,84403	93%	1,13595	0,20787	0,79615	92%	1,27457
R0c_Kc_Kelm_Kc-soft	0,23787	0,81125	88%	1,61882	0,22777	0,77662	90%	1,23115
R0elm_Kc_Kelm_Kc-soft	0,23255	0,81547	88%	1,34728	0,20177	0,80213	92%	1,32051
	4-5-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm	0,33056	0,7377	89%	2,386	0,21599	0,78818	90%	1,05624
R0c_R0elm_Kc_Kc-soft	0,17791	0,85882	91%	1,22044	0,17954	0,82393	96%	1,31496
R0c_R0elm_Kelm_Kc-soft	0,18805	0,85078	93%	1,02885	0,21062	0,79345	92%	1,39109
R0c_Kc_Kelm_Kc-soft	0,20276	0,83911	90%	1,15464	0,19371	0,81003	92%	1,3432
R0elm_Kc_Kelm_Kc-soft	0,23402	0,8143	89%	1,35011	0,20546	0,79851	92%	1,37449
	4-8-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm	0,36875	0,7074	85%	2,41678	0,22228	0,78202	90%	1,15814
R0c_R0elm_Kc_Kc-soft	0,18479	0,85336	92%	1,20733	0,18312	0,82042	96%	1,41888
R0c_R0elm_Kelm_Kc-soft	0,19317	0,84671	93%	1,06662	0,18742	0,8162	92%	1,21535
R0c_Kc_Kelm_Kc-soft	0,2181	0,82694	90%	1,38899	0,20912	0,79491	90%	1,04625
R0elm_Kc_Kelm_Kc-soft	0,23137	0,8164	89%	1,39634	0,20234	0,80157	92%	1,3419
	4-10-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm	0,34646	0,72508	88%	2,42901	0,25077	0,75407	87%	1,55918
R0c_R0elm_Kc_Kc-soft	0,16463	0,86936	92%	1,22534	0,17654	0,82686	95%	1,40116
R0c_R0elm_Kelm_Kc-soft	0,19266	0,84712	94%	1,13127	0,21322	0,7909	92%	1,30438
R0c_Kc_Kelm_Kc-soft	0,21425	0,82999	90%	1,39319	0,20793	0,79609	91%	1,04683
R0elm_Kc_Kelm_Kc-soft	0,23331	0,81487	89%	1,42676	0,2046	0,79935	93%	1,3354
	4-15-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm	0,3349	0,73426	90%	2,37255	0,2381	0,7665	92%	1,52912
R0c_R0elm_Kc_Kc-soft	0,17376	0,86212	91%	1,16866	0,17967	0,82379	95%	1,30004
R0c_R0elm_Kelm_Kc-soft	0,20274	0,83913	92%	1,22406	0,21478	0,78937	91%	1,35759
R0c_Kc_Kelm_Kc-soft	0,22685	0,81999	88%	1,62889	0,23524	0,76931	90%	1,86779
R0elm_Kc_Kelm_Kc-soft	0,23448	0,81393	89%	1,36522	0,20336	0,80057	92%	1,31749

Tabela 4.11 - Resultados de diferentes topologias com 5 parâmetros na entrada da rede

	5-3-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm_Kc-soft	0,18656	0,85196	92%	1,24883	0,18761	0,81601	96%	1,56306
	5-5-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm_Kc-soft	0,17712	0,85945	92%	1,18347	0,17654	0,82686	95%	1,40116
	5-8-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm_Kc-soft	0,16549	0,86868	92%	0,97479	0,16495	0,83823	93%	1,25517
	5-10-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm_Kc-soft	0,18525	0,853	91%	1,29668	0,18571	0,81787	96%	1,44941
	5-15-1							
	Treinamento				Validação			
	MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
R0c_R0elm_Kc_Kelm_Kc-soft	0,17935	0,85768	92%	1,26363	0,18693	0,81667	96%	1,49718

Analisando os resultados do estudo dos dois conjuntos de dados, verifica-se que a combinação de parâmetros que apresenta o menor MSE e o melhor R^2 na validação é a mesma, ou seja, é a combinação utilizando todos os cinco parâmetros ajustáveis do modelo criado. Além disso, verifica-se que a topologia que apresenta o melhor resultado também é a mesma nos dois estudos, ou seja, a topologia 5-8-1.

Apesar de parecer que alguns parâmetros apresentam uma correlação muito pequena com a qualidade final da solda (R_{OC} e K_{ELM}), ao analisarmos os resultados obtidos com apenas um parâmetro na entrada da rede, verifica-se ao final que, em conjunto com os outros parâmetros, a contribuição desses leva a rede neural a estimar de forma mais precisa a qualidade final da solda.

As figuras 4.9 e 4.10 mostram o gráfico com os valores reais e os valores estimados da qualidade da solda dos testes com o conjunto de dados usado para validar a rede neural, utilizando os cinco parâmetros ajustáveis do modelo na topologia 5-8-1, para o primeiro e segundo conjunto de dados, respectivamente.




Figura 4.9 - Resultado da melhor combinação de parâmetros (5 parâmetros) e da melhor topologia entre as testadas (5-8-1) para o primeiro conjunto de dados

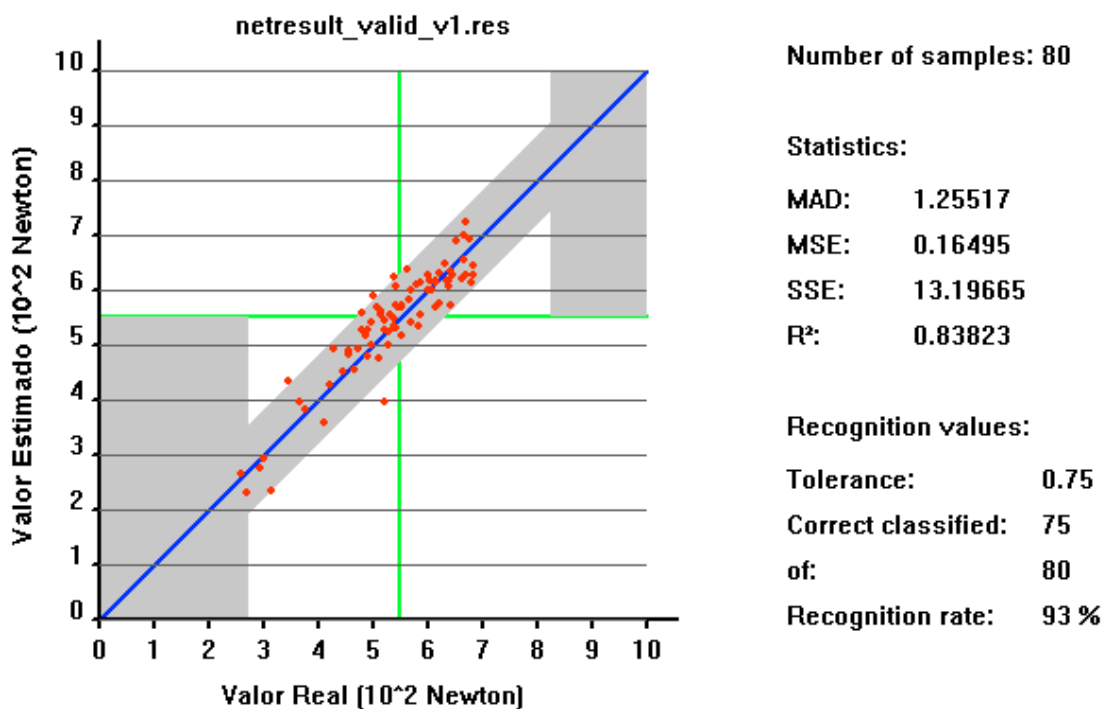


Figura 4.10 - Resultado da melhor combinação de parâmetros (5 parâmetros) e da melhor topologia entre as testadas (5-8-1) para o segundo conjunto de dados

Como resultado do primeiro conjunto de dados, tem-se um MSE de 9,68 N, um R² de 0,91114, uma taxa de reconhecimento de 100% e um MAD de 69,913 N. Como resultado do segundo conjunto de dados, tem-se um MSE de 16,495 N, um R² de 0,83823, uma taxa de reconhecimento de 93% e um MAD de 1,25517 N. Comparando os resultados, verifica-se que os resultados obtidos do primeiro conjunto de dados são melhores que os obtidos no segundo conjunto de dados. Essa diferença pode se dever ao fato de o segundo conjunto de dados ser mais abrangente que o primeiro, submetendo a rede a mais condições de perturbação do processo. Além disso, apesar de serem similares, o processo de produção da primeira máquina parece ser mais estável que o da segunda, provavelmente devido às características internas da máquina, como pode ser verificado pelas variações maiores da qualidade final da solda em condições normais no segundo processo quando comparadas ao primeiro (Anexo B).

Também, os resultados do segundo conjunto de dados podem ser considerados bons, uma vez que o MSE é de apenas 16,495 N em um processo ajustado para produzir soldas que suportem 550 N. Ainda, ao analisarem-se os dados da tabela B.2 do anexo B, observa-se que, no procedimento padrão de soldagem, a qualidade das soldas produzidas normalmente é superior a 600 N. Analisando-se o gráfico da figura 4.10, observa-se que entre os testes com a qualidade estimada fora da tolerância de 75 N, apenas a estimativa de um teste está realmente distante do limite. Os demais estão muito próximos a este limite.

4.4 Comparação com Sistemas Propostos na Literatura

No item 2.4 foram abordados os sistemas de monitoramento encontrados na literatura que utilizam características das variáveis elétricas (tensão e corrente) medidas durante o PSPR e redes neurais artificiais para estimar a qualidade final da solda.

Os sistemas apresentados nos trabalhos de Cho e Rhee (2002), Subramanian et al. (2004) e Ling et al. (2009) não são possíveis de serem aplicados no processo de produção de contatos elétricos investigado neste trabalho. Isso ocorre devido às características da curva de resistência dinâmica utilizada por estes autores serem típicas da soldagem de ligas de aço, tais como o pico de resistência dinâmica, o tempo para se atingir esse pico, o ângulo de inclinação durante o crescimento da resistência, que não são aplicáveis no processo investigado devido ao comportamento diferenciado da sua curva de resistência dinâmica.

O sistema proposto por Dilthey e Dichersbach (1999) é possível de ser reproduzido e testado com os conjuntos de dados desse trabalho, pois utiliza o valor da corrente máxima em cada meio ciclo senoidal e o respectivo valor de tensão neste mesmo tempo como dados de entrada da rede neural. Como estes valores também são usados no cálculo da resistência dinâmica utilizada neste trabalho, para reproduzir o sistema só foi necessário criar um *plug-in*

para unir as curvas de tensão e corrente em um único vetor. Esse *plug-in* foi chamado de “JoinVectors”. O tamanho do vetor resultante da aplicação deste *plug-in* nos dados no processo investigado é de 60 amostras. Este sistema foi testado utilizando as mesmas configurações de rede e os mesmos testes para treinamento e validação dos dois conjuntos de dados usados para analisar o sistema proposto neste trabalho. Só foi alterada a topologia, devido à diferença no tamanho do vetor de dados de entrada da rede, sendo testadas as topologias 60-20-1, 60-40-1, 60-60-1, 60-80-1 e 60-100-1. Os resultados obtidos para o primeiro conjunto de dados e para o segundo conjunto de dados são mostrados nas tabelas 4.12 e 4.13, respectivamente.

A melhor topologia entre as testadas para o primeiro conjunto de dados foi a 60-20-1. Os resultados da validação dessa topologia mostram um MSE de 0,10462 N, um R^2 de 0,90397, uma taxa de reconhecimento de 98% e um MAD de 0,81902 N. Estes resultados são ligeiramente inferiores aos obtidos com o sistema proposto neste trabalho.

Tabela 4.12 - Resultados do sistema proposto por Dilthey e Dichersbach (1999) aplicado no primeiro conjunto de dados com diferentes topologias de rede

60-20-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,11936	0,89209	95%	1,06716	0,10462	0,90397	98%	0,81902
60-40-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,1102	0,90037	97%	1,03535	0,11889	0,89087	96%	0,91397
60-60-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,10658	0,90365	97%	0,99871	0,11156	0,8976	96%	0,89752
60-80-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,11214	0,89862	97%	1,04407	0,13267	0,87822	96%	1,02338
60-100-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,10974	0,90079	97%	0,99264	0,12053	0,88936	96%	0,97631

Tabela 4.13 - Resultados do sistema proposto por Dilthey e Dichersbach (1999) aplicado no segundo conjunto de dados com diferentes topologias de rede

60-20-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,25616	0,79673	88%	1,36706	0,17343	0,82992	93%	1,07105
60-40-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,26697	0,78816	88%	1,39314	0,17818	0,82526	93%	1,18598
60-60-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,24034	0,80929	88%	1,37212	0,17736	0,82606	95%	0,94161
60-80-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,25274	0,79945	86%	1,28647	0,17753	0,82982	95%	1,01423
60-100-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,2414	0,80845	88%	1,27954	0,17452	0,82885	93%	1,1048

Para o segundo conjunto de dados, a melhor topologia entre as testadas também foi a 60-20-1. Os resultados da validação dessa topologia mostram um MSE de 0,17343 N, um R² de 0,82992, uma taxa de reconhecimento de 93% e um MAD de 1,07105 N. Estes resultados também são ligeiramente inferiores aos obtidos com o sistema proposto neste trabalho.

O sistema proposto por Aravinthan et al. (2001) também é possível de se reproduzir e testar neste trabalho, pois utiliza os pontos de máximo da corrente e tensão divididos um pelo outro, ou seja, a curva de resistência dinâmica, como entrada da rede neural. Testando este sistema com o mesmo procedimento utilizado para testar o proposto por Dilthey e Dichersbach (1999), só que alterando as topologias testadas para 30-10-1, 30-20-1, 30-30-1, 30-40-1 e 30-50-1, devido ao número de amostras da curva de resistência dinâmica que é de 30, os resultados obtidos para o primeiro conjunto de dados e para o segundo conjunto de dados são mostrados nas tabelas 4.14 e 4.15, respectivamente.

Tabela 4.14 - Resultados do sistema proposto por Aravinthan et al. (2001) aplicado no primeiro conjunto de dados com diferentes topologias de rede

30-10-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,10692	0,90334	98%	0,82309	0,10778	0,90106	98%	0,85088
30-20-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,11177	0,89895	98%	0,92838	0,10195	0,90641	98%	0,76874
30-30-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,12363	0,88824	97%	1,08535	0,10959	0,8994	95%	0,83142
30-40-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,12374	0,88695	96%	1,12374	0,10952	0,89946	98%	0,83256
30-50-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,12394	0,88795	96%	1,12504	0,10758	0,90125	96%	0,91933

Tabela 4.15 - Resultados do sistema proposto por Aravinthan et al. (2001) aplicado no segundo conjunto de dados com diferentes topologias de rede

30-10-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,25129	0,8006	87%	1,32252	0,17515	0,82823	96%	0,9444
30-20-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,24288	0,80728	87%	1,38727	0,17353	0,82982	96%	0,89773
30-30-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,24207	0,80791	87%	1,41391	0,17387	0,82948	95%	0,89675
30-40-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,24648	0,80442	87%	1,35962	0,17911	0,82435	95%	0,90526
30-50-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,25184	0,80016	86%	1,36184	0,18043	0,82305	96%	0,9556

A melhor topologia entre as testadas para o primeiro conjunto de dados foi a 30-20-1. Os resultados da validação dessa topologia mostram um MSE de 0,10195 N, um R^2 de 0,90641, uma taxa de reconhecimento de 98% e um MAD de 0,76874 N. Estes resultados são ligeiramente superiores aos obtidos com o sistema de Dilthey e Dichersbach (1999) mas ainda ligeiramente inferiores aos obtidos com o sistema proposto neste trabalho.

Para o segundo conjunto de dados, a melhor topologia entre as testadas também foi a 60-20-1. Os resultados da validação dessa topologia mostram um MSE de 0,17353 N, um R^2 de 0,82982, uma taxa de reconhecimento de 96% e um MAD de 0,89773 N. Analisando todos os itens, estes resultados também são ligeiramente superiores aos obtidos com o sistema de Dilthey e Dichersbach (1999), mas são ainda um pouco inferiores aos obtidos com o sistema proposto neste trabalho.

O trabalho de Márтин et al. (2006) utiliza como características do sistema o tempo de soldagem, o tipo de eletrodo e a curva de corrente de soldagem. Como os dois primeiros são valores fixos no processo investigado neste trabalho, não faz sentido testar a utilização somente da curva de corrente para estimar a qualidade final da solda. O sistema proposto por Wen, Zhang e outros (2009) utiliza quase as mesmas características que o trabalho de Márтин et al. (2006), mas, ao invés do tipo de eletrodo, utiliza como característica o valor final da curva de resistência dinâmica. Este sistema será reproduzido excluindo o tempo de soldagem das variáveis de entrada da rede, porque este é fixo neste processo investigado. Utilizando um *plug-in* chamado “Select Values”, foi selecionada a última amostra da curva de resistência dinâmica e, utilizando o *plug-in* “JoinVectors”, esta amostra foi adicionado ao final da curva de corrente.

Testando este sistema com o mesmo procedimento utilizado anteriormente, só que alterando as topologias testadas para 31-10-1, 31-20-1, 31-30-1, 31-40-1 e 31-50-1, devido ao número de amostras do vetor de entrada ser 31, os resultados obtidos para o primeiro

conjunto de dados e para o segundo conjunto de dados são mostrados nas tabelas 4.16 e 4.17, respectivamente.

Tabela 4.16 - Resultados do sistema proposto por Wen et al. (2009) aplicado no primeiro conjunto de dados com diferentes topologias de rede

31-10-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,11443	0,89655	97%	1,34046	0,14333	0,86843	95%	1,25811
31-20-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,121	0,89061	95%	1,29447	0,144	0,86782	93%	1,19801
31-30-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,12571	0,88635	97%	1,32601	0,1505	0,86185	93%	1,14618
31-40-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,12197	0,88973	96%	1,34853	0,14842	0,86376	93%	1,27685
31-50-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,12016	0,89137	96%	1,27507	0,14566	0,86629	95%	1,12894

Tabela 4.17 - Resultados do sistema proposto por Wen et al. (2009) aplicado no segundo conjunto de dados com diferentes topologias de rede

31-10-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,28204	0,7762	85%	1,54678	0,23814	0,76646	90%	1,04687
31-20-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,26788	0,78744	83%	1,54711	0,22294	0,78136	88%	1,00305
31-30-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,27568	0,78125	84%	1,58823	0,22964	0,77479	88%	1,03651
31-40-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,26962	0,78606	84%	1,54661	0,22845	0,77596	90%	1,04379
31-50-1							
Treinamento				Validação			
MSE	R ²	Recog %	MAD	MSE	R ²	Recog %	MAD
0,26899	0,78655	84%	1,54502	0,23238	0,7721	90%	1,06593

Analisando os resultados obtidos com o sistema proposto por Wen et al. (2009), verifica-se que são inferiores aos obtidos neste trabalho e também aos obtidos com os sistemas propostos por Dilthey e Dichersbach (1999) e Aravinthan et al. (2001). Esse resultado já era esperado tendo em vista que o sistema proposto por Wen et al. (2009) é baseado na curva de corrente e somente no valor final da curva de resistência dinâmica, sendo prejudicado pelo tipo de controle de alimentação utilizado no processo de soldagem de contatos elétricos em análise, que utiliza um controle de alimentação de corrente constante.

Embora os resultados dos trabalhos apresentados por outros autores, como visto acima, se aproximem dos resultados alcançados pela presente pesquisa, há que se ressaltar que o sistema de monitoramento proposto por aqueles não permite a identificação de possíveis causas para a degradação da qualidade da solda, característica importante do sistema proposto neste trabalho que será abordada no próximo item.

4.5 Identificação de Causas de Problemas no Processo

Outro objetivo do sistema proposto neste trabalho é o de identificar possíveis problemas que possam estar prejudicando a qualidade do processo, através da interpretação dos valores assumidos pelos parâmetros do modelo. Para o processo investigado, as principais perturbações são:

- Corrente de Soldagem: o valor real da corrente de soldagem no processo é diferente do valor selecionado pelo operador;
- Força de Soldagem: o valor real da força de soldagem no processo é diferente do valor selecionado pelo operador;
- “Welding Help”: ausência de “Welding Help” no material sendo soldado.

Inicialmente será feita uma análise de cada variável do modelo com relação à qualidade final do contato elétrico produzido (QC), ou seja, a força de cisalhamento suportada por este, em cada um dos conjuntos de dados, para estabelecer limites de valores para os parâmetros do modelo representativos das perturbações presentes no roteiro de testes dos conjuntos de dados.

A figura 4.11 mostra a relação entre QC e o parâmetro K_{C-SOFT} para o primeiro conjunto de dados.




Figura 4.11 - Relação entre QC e o parâmetro K_{C-SOFT} para o primeiro conjunto de dados

O parâmetro K_{C-SOFT} reflete o amolecimento do material durante o processo. Sendo assim, quanto maior o valor de K_{C-SOFT} , melhor a qualidade da solda, pois significa que mais calor foi concentrado na interface material-material durante a soldagem. Analisando os valores assumidos pelo parâmetro K_{C-SOFT} nas diferentes condições dos testes realizados, é possível tirar as seguintes conclusões:

- Se $K_{C-SOFT} < 0,543$, a qualidade da solda é ruim;

- Se $0,582 > K_{C-SOFT} > 0,543$, é necessário atenção pois o processo está operando com o valor de algum parâmetro diferente do definido no procedimento padrão de soldagem, mas a qualidade da solda ainda pode ser considerada boa;
- Se $K_{C-SOFT} > 0,582$, a solda é seguramente boa mesmo podendo haver pequeno desvio no valor de algum parâmetro com relação ao definido no procedimento padrão de soldagem.

A figura 4.12 mostra a relação entre QC e o parâmetro R_{OC} para o primeiro conjunto de dados.




Figura 4.12 - Relação entre QC e o parâmetro R_{OC} para o primeiro conjunto de dados

O parâmetro R_{OC} é relacionado com a resistência da interface material-material logo após o início da soldagem. Sendo assim, um valor mais alto de R_{OC} significa que o colapso da rugosidade entre as partes foi menor, o que pode ser causado por uma diminuição da força de soldagem ou pela diminuição da corrente de soldagem. Analisando os valores assumidos pelo parâmetro R_{OC} nas diferentes condições dos testes realizados, é possível tirar as seguintes conclusões:

- Se $R_{OC} > 0,241$, o processo está operando de acordo com o definido no procedimento padrão de soldagem ou o valor da corrente de soldagem está abaixo do definido;
- Se $R_{OC} < 0,241$, o processo está operando sem *welding help* ou com o valor da força de soldagem maior que o definido no procedimento padrão de soldagem.

A figura 4.13 mostra a relação entre QC e o parâmetro K_{ELM} para o primeiro conjunto de dados.




Figura 4.13 - Relação entre QC e o parâmetro K_{ELM} para o primeiro conjunto de dados

O parâmetro K_{ELM} é relacionado com a variação da resistência da interface eletrodo-material. Este parâmetro é diretamente proporcional a força de soldagem e inversamente proporcional a corrente de soldagem. Analisando os valores assumidos pelo parâmetro K_{ELM} nas diferentes condições dos testes realizados, é possível tirar as seguintes conclusões:

- Se $K_{ELM} > 8,55 \times 10^{-6}$, existe uma grande probabilidade de o processo estar operando com uma força de soldagem maior que a definida no procedimento padrão de soldagem e uma pequena probabilidade de estar operando sem *welding help*;

- Se $K_{ELM} < 8,55 \times 10^{-6}$, existe uma grande probabilidade de o processo estar operando sem *welding help* e uma pequena probabilidade de estar operando com uma força de soldagem maior que a definida no procedimento padrão de soldagem.

A figura 4.14 mostra a relação entre QC e o parâmetro R_{OELM} para o primeiro conjunto de dados.




Figura 4.14 - Relação entre QC e o parâmetro R_{OELM} para o primeiro conjunto de dados

O parâmetro R_{OELM} é relacionado com a resistência da interface eletrodo-material logo após o início da soldagem. Sendo assim, um valor mais alto de R_{OELM} significa um pior ajuste entre o eletrodo e as partes soldadas, o que pode ser causado por uma diminuição da força de soldagem ou pela diminuição da corrente de soldagem. Analisando os valores assumidos pelo parâmetro R_{OELM} nas diferentes condições dos testes realizados, é possível tirar as seguintes conclusões:

- Se $R_{OELM} > 0,063$, existe uma grande probabilidade de o processo estar operando sem *welding help* e uma pequena probabilidade de estar operando com uma força de soldagem maior que a definida no procedimento padrão de soldagem;

- Se $R_{OELM} < 0,063$, existe uma grande probabilidade de o processo estar operando com uma força de soldagem maior que a definida no procedimento padrão de soldagem e uma pequena probabilidade de estar operando sem *welding help*.

A figura 4.15 mostra a relação entre QC e o parâmetro K_C para o primeiro conjunto de dados.




Figura 4.15 - Relação entre QC e o parâmetro K_C para o primeiro conjunto de dados

O parâmetro K_C é relacionado com a variação da resistência da interface material-material. Este parâmetro é inversamente proporcional a força de soldagem e diretamente proporcional a corrente de soldagem. Analisando os valores assumidos pelo parâmetro K_C nas diferentes condições dos testes realizados, é possível tirar as seguintes conclusões:

- Se $K_C > 0,58$, o processo opera como no procedimento padrão de soldagem ou com desvio no valor de algum parâmetro, mas a qualidade da solda é aceitável;
- Se $K_C < 0,58$, o processo opera com o valor de algum parâmetro diferente do definido no procedimento padrão de soldagem com provável perda de qualidade por parte da solda.

Após esta análise foi possível estabelecer um procedimento para identificar a causa no caso de perda de qualidade por parte da solda. Este procedimento é mostrado no fluxograma da figura 4.16.

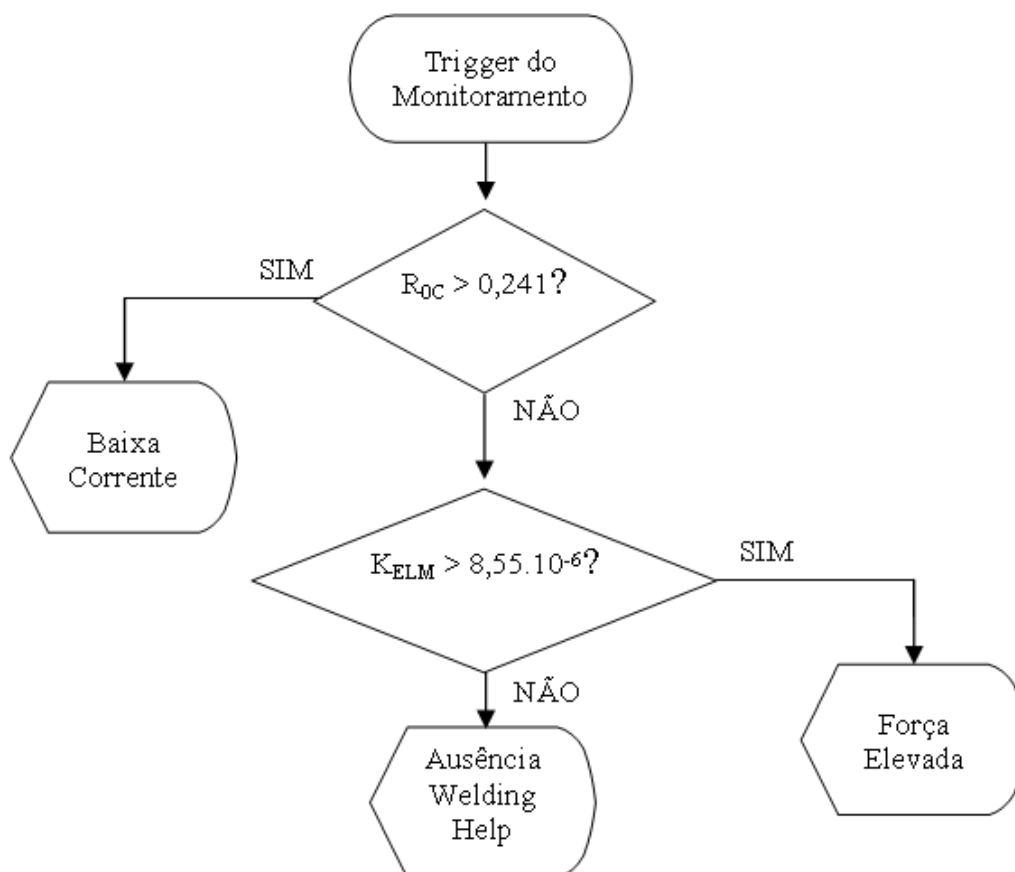


Figura 4.16 - Fluxograma do procedimento usado para identificar a causa no caso de perda de qualidade por parte da solda para o primeiro conjunto de dados

Ao estimar a qualidade de uma solda abaixo do mínimo exigido, o sistema inicia a execução do procedimento apresentado na figura 4.16. Este procedimento foi testado no primeiro conjunto de dados, usando como qualidade mínima exigida uma força de cisalhamento de 475N. De 39 amostras que tiveram a qualidade estimada abaixo de 475N somente 1 teve um diagnóstico errado da causa de perda de qualidade, obtendo o sistema uma taxa de acerto acima de 97,4%.

O mesmo estudo foi realizado no segundo conjunto de dados. As figuras 4.17, 4.18, 4.19, 4.20 e 4.21 mostram a relação entre QC e K_{C-SOFT} , R_{OC} , K_{ELM} , R_{OELM} e K_C , respectivamente.




Figura 4.17 - Relação entre QC e o parâmetro K_{C-SOFT} para o segundo conjunto de dados




Figura 4.18 - Relação entre QC e o parâmetro R_{OC} para o segundo conjunto de dados




Figura 4.19 - Relação entre QC e o parâmetro K_{ELM} para o segundo conjunto de dados




Figura 4.20 - Relação entre QC e o parâmetro R_{OELM} para o segundo conjunto de dados




Figura 4.21 - Relação entre QC e o parâmetro K_C para o segundo conjunto de dados

Após a análise dessas figuras foi possível estabelecer um procedimento para identificar a causa no caso de perda de qualidade por parte da solda para o segundo conjunto de dados. Este procedimento é mostrado no fluxograma da figura 4.22.

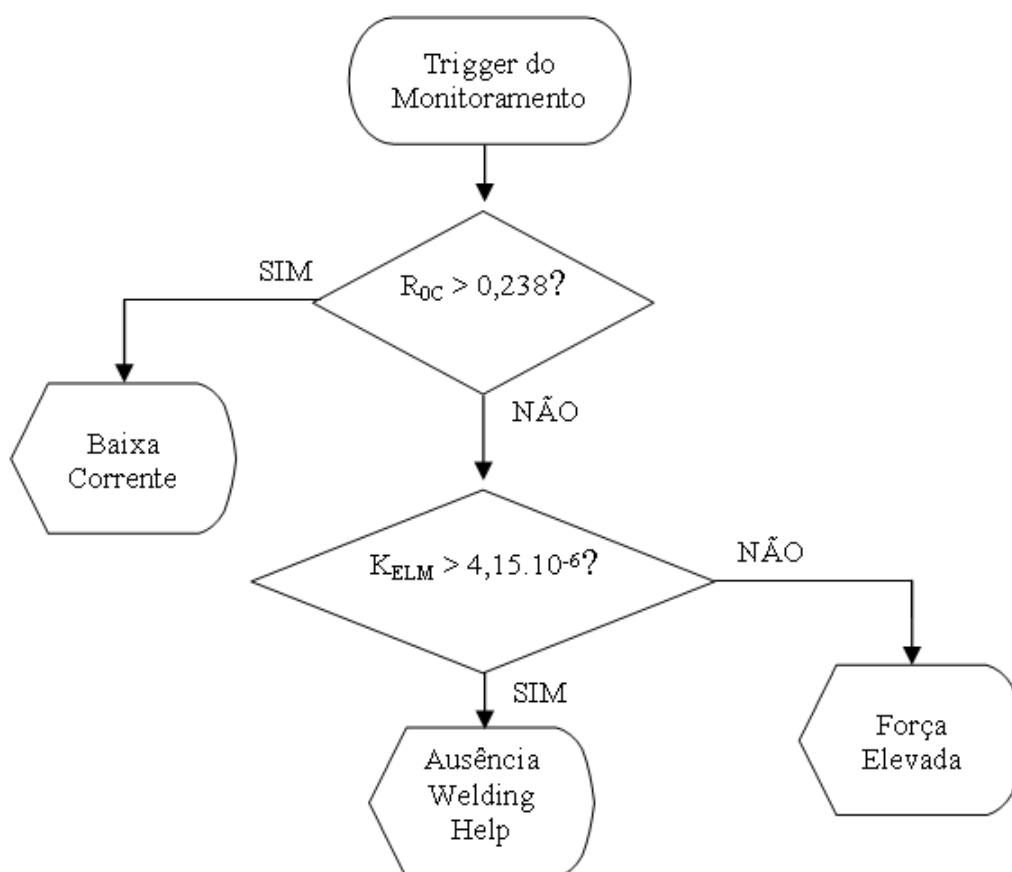


Figura 4.22 - Fluxograma do procedimento usado para identificar a causa no caso de perda de qualidade por parte da solda para o segundo conjunto de dados

Este procedimento foi testado no segundo conjunto de dados, usando como qualidade mínima exigida uma força de cisalhamento de 475N. De 37 amostras que tiveram a qualidade estimada abaixo de 475N somente 1 teve um diagnóstico errado da causa de perda de qualidade, obtendo o sistema uma taxa de acerto acima de 97,2%.

5 Conclusão

Neste trabalho foi apresentado um sistema de monitoramento baseado no reconhecimento de padrões através de redes neurais artificiais que se mostrou eficaz no monitoramento da qualidade do processo de solda a ponto resistiva.

Embora o sistema proposto tenha sido aplicado no PSPR, seus componentes são genéricos e podem ser aplicados também em outros processos produtivos, desde que alguma(s) grandeza(s) relacionada(s) com a qualidade possa(m) ser medida(s) e um modelo que incorpore essa(s) grandeza(s) seja concebível. É importante destacar que basta que o modelo reflita as propriedades da(s) grandeza(s) medida(s), não necessitando englobar todos os detalhes do processo, graças à capacidade de generalização das redes neurais que podem fornecer respostas coerentes para padrões desconhecidos. Esta é uma importante vantagem em processos não-determinísticos, onde não estão disponíveis modelos precisos e que englobem todas variáveis atuantes, o que ocorre com frequência no mundo industrial.

Baseado nos resultados obtidos, o sistema proposto foi capaz de monitorar a qualidade dos pontos de solda produzidos de forma não-destrutiva, não invasiva, individualizada, em tempo real, já que o tempo de processamento necessário para analisar cada solda, cerca de 31 ms, é suficiente para verificar cada ponto de solda produzido, mesmo em um processo com alta taxa de produção como o investigado neste trabalho.

Como os dados foram obtidos diretamente da linha de produção sem causar problemas a essa, e como o sistema proposto não necessita de dados diferentes dos obtidos, ou seja, tensão e corrente durante o processo de soldagem, pode-se dizer que o sistema proposto neste trabalho é capaz de operar em um ambiente industrial.

Como previsto, os resultados mostraram que existe uma correlação entre as perturbações mais comuns que podem prejudicar a qualidade final da solda e os valores dos parâmetros do modelo. Dessa forma, o sistema proposto pode automaticamente analisar os

valores dos parâmetros obtidos, após o ajuste da curva do modelo com a curva real, e apontar a causa para soldas cuja qualidade estimada foi considerada baixa, com taxa de acerto acima de 97,2%. Esta característica do sistema é de grande valia para a manutenção do processo produtivo. Essa contribuição não foi encontrada nos sistemas propostos por outros autores. Embora estes sistemas, como mostrado, apresentem uma precisão na estimação da qualidade final da solda comparável com a obtida no sistema proposto neste trabalho, de cerca de 9,5 N para o primeiro conjunto de dados e 16,5 N para o segundo conjunto, não são capazes de apontar causas.

Após implementar todos os componentes do sistema no PSPR, ou seja, medir a tensão e corrente de soldagem, criar o modelo matemático parametrizável, treinar a rede neural usando os parâmetros ajustados do modelo e a força de cisalhamento obtida através de ensaio destrutivo, validar a rede treinada, interpretar os valores assumidos pelos parâmetros do modelo, encontrando os limites de valores que possibilitem identificar a causa de baixa qualidade, o sistema proposto está pronto para automaticamente estimar a força de cisalhamento suportada pelas soldas produzidas e identificar causas para soldas estimadas como sendo de baixa qualidade.

Como trabalhos futuros, pode-se investigar a utilização dos parâmetros ajustáveis do modelo criado como realimentação do processo em uma malha de controle ponto a ponto que ajuste os parâmetros do procedimento de soldagem. Outra sugestão é a implementação de um banco de dados com o histórico de produção no qual *Data Mining* pode ser aplicado para otimizar o procedimento de soldagem ao longo do tempo.

REFERÊNCIAS BIBLIOGRÁFICAS

ARAVINTHAN, A., SIVAYOGANATHAN, K., AL-DABASS, D., BALENDRAN, V., **A Neural Network System for Spot Weld Strength Prediction**, UKSIM2001, Conf. Proc. of the UK Simulation Society, 2001, pag. 156-160.

BISHOP, C. M., **Neural Networks for Pattern Recognition**, Oxford University Press, 1995.

BROOMHEAD, J.H.W., **Resistance Spot Welding Quality Assurance**, Welding and Metal Fabrication. vol. 58, No. 6, 1990, pag. 172-179.

BROWN, J.D., RODD, M.G., WILLIAMS, N.T., **Application of artificial intelligence techniques to resistance spot welding**, Ironmaking and Steelmaking, vol. 25, issue 3, 1998, pag. 199-204.

BROWN, L.J., SCHWABER, J.S., **Identifying operating conditions from pre-weld information for resistance spot welding**, Proceedings of the 2000 American Control Conference, vol. 3, 2000, pag. 1535-1539.

CHEN, X., ARAKI, K., **Fuzzy adaptive process control of resistance spot welding with a current reference model**, IEEE International Conference on Intelligent Processing Systems, 1997, ICIPS '97, vol.1, out. 1997, pag. 190-194.

CHEN, J., FARSON, D.F., ELY, K., FRECH, T., **Modeling small-scale resistance spot welding machine dynamics for process control**, The International Journal of Advanced Manufacturing Technology, volume 27, números 7-8, janeiro 2006, pag. 672-676.

CHO, Y., RHEE, S., **New technology for measuring dynamic resistance and estimating strength in resistance spot welding**, Measurement Science and Technology, n.11, pag. 1173-1178, 2000.

CHO, Y., RHEE, S., **Primary Circuit Dynamic Resistance Monitoring and its Application to Quality Estimation during Resistance Spot Welding**, Welding Journal, NEW YORK, junho 2002, pag.104-111.

CHO Y., RHEE, S., **Experimental Study of Nugget Formation in Resistance Spot Welding**, Welding Research – Supplement to the Welding Journal, n. 8, Agosto, 2003.

CHO, Y., RHEE, S., **Quality Estimation of Resistance Spot Welding by Using Pattern Recognition with Neural Networks**, IEEE Transactions on Instrumentation and Measurement, vol. 53, n.2, abril, 2004, pag. 330-334.

CULLEN, J.D., ATHI, N., AL-JADER, M., JOHNSON, P., AL-SHAMMA, A.I., **Multisensor fusion for on line monitoring of the quality of spot welding in automotive industry**, Measurement, volume 41, 2008, pag. 412–423.

DENISOV, A.A., SHAKARJI, C.M., LAWTFORD, B.B., MAEV, R., PAILLE, J.M., **Spot Weld Analysis With 2D Ultrasonic Arrays**, Journal of Research of the National Institute of Standards and Technology, Volume 109, Number 2, March-April, pag. 233-244, 2004.

DILTHEY, U., DICKERSBACH, J., **Application of neural networks for quality evaluation of resistance spot welds**, ISIJ International, vol. 39, n. 1, 1999, pag. 1061-1066.

DOYUM, A., SONAT M., **Ultrasonic examination of resistance spot weld**, Journal of Nondestructive Testing (NDT), vol.8, issue 12, 2003. Disponível em: <http://www.ndt.net/v08n12.htm>.

EISAZADEH, H, HAMED, M. HALVAEE A., **New parametric study of nugget size in resistance spot welding process using finite element method**, Materials and Design, volume 31, 2010, pag. 149–157.

EL-BANNA, M., FILEV, D., CHINNAM, R. B., **Intelligent Constant Current Control for Resistance Spot Welding**, IEEE International Conference on Fuzzy Systems'06, pag. 1570-1577, Julho, 2006.

EL-BANNA, M., FILEV D., CHINNAM. R.B., **Online qualitative nugget classification by using a linear vector quantization neural network for resistance spot welding**, International Journal Adv. Manuf. Technology, vol. 36, 2008, pag.237–248.

FURLANETTO, V., MOTOMURA, G. M., BATALHA, G. F., **Técnicas de Inteligência Artificial na Modelagem e Controle do Processo de Solda a Ponto por Resistência Elétrica**, V Congresso Nacional de Engenharia Mecânica – COBEM 2008, agosto, 2008.

GARZA, F. J., DAS, M., **Identification of time-varying resistance during welding**, Proceedings of the 17th IEEE Instrumentation and Measurement Technology Conference, vol. 3, pag. 1534-1539, 2000.

GARZA, F. J., DAS, M., **On Real time Monitoring and Control of Resistance Spot Welds using Dynamic Resistance Signatures**, Proceedings of the 44th IEEE Midwest Symposium on Circuits and Systems'01, vol. 1, pag. 41-44, 2001.

GONG, L., LIU, C.L, ZHA, X.F., **Model-Based Real-Time Dynamic Power Factor Measurement in AC Resistance Spot Welding With an Embedded ANN**, IEEE Transactions on Industrial Electronics, vol. 54, n. 3, junho 2007, pag. 1442-1448.

HARDT, M., **Welding**, Wikipedia, the free encyclopedia. Disponível em: <<http://en.wikipedia.org/wiki/Welding#Quality>>. Acessado em: 16 de julho de 2009.

HALMSHAW, R., **Introduction to the Non-Destructive Testing of Welded Joints**, The Welding Institute, Cambridge, UK, 1988.

HAYKIN, S., **Neural Networks. A Comprehensive Foundation**, Prentice Hall, New Jersey, 2a edição, 1999.

HIRSCH, R.B., **Tip Force Control Equals Spot Weld Quality**, Welding Journal, vol. 72, No. 3, pag. 57-60, 1993.

HOLDREN, R.L., **What Are the Causes of and Solutions to Weld Quality Control**, Welding Journal. vol. 72, No. 8, 1993.

IRVING, B., **Search Goes on for the Perfect Resistance Welding Control**, Welding Journal, vol. 75, No. 1, pag. 63-68, 1996.

IVEZIC, N., ALIEN, J.D., ZACHARIA JUNIOR, T., **Neural network-based resistance spot welding control and quality prediction**, Proceedings of the Second International Conference on Intelligent Processing and Manufacturing of Materials, 1999. IPMM '99., vol. 2, 1999, pag 989-994.

JOU, M., **Experimental Investigation of Resistance Spot Welding for Sheet Metals Used in Automotive Industry**, JSME International Journal, series C, vol. 44, n.2, 2001, pag. 544-552.

JOU, M., **Real time monitoring weld quality of resistance spot welding for the fabrication of sheet metal assemblies**, Journal of Materials Processing Technology, vol. 132, pag. 102–113, 2003.

KHOO, L.P., **A Prototype Fuzzy Resistance Spot Welding System**, Int. Journal Prod. Res., vol. 33, No. 7, pag. 2023-36, 1995.

KOON, W., **Current sensing for energy metering**, Conference Proceedings IIC-CHINA/ESC-CHINA'02, pag 321-324, 2002.

LEE, R.S., CHOO, Y. J., LEE, T. Y., KIM, M. H., CHOI, S. K., **A Quality Assurance Technique for Resistance Spot Welding Using a Neuro-Fuzzy Algorithm**, Journal of Manufacturing Systems, vol. 20, issue 5, 2001, pag. 320-328.

LI, W., HU, S. J., NI, J., **On-line Quality Estimation in Resistance Spot Welding**, J. Manuf. Sci. Eng., vol. 122, issue 3, agosto 2000, pag. 511-512.

LI, W., CHENG, S., HU, S.J., SHRIVER, J., **Statistical Investigation on Resistance Spot Welding Quality Using a Two-State Sliding-Level Experiment**, Journal of Manufacturing Science and Engineering, vol. 123, issue 3, agosto 2001, pag. 513-520.

LI, W., **Modeling and On-Line Estimation of Electrode Wear in Resistance Spot Welding**, Journal of Manufacturing Science and Engineering, vol. 127, novembro 2005, pag. 709-717.

LIANG, C., LIU, X., **Strength prediction of sheet to tube single sided resistance spot welding**, Materials and Design, vol. 30, n 10, dezembro 2009, p 4328-4334.

LING, S., WAN, L., WONG, Y., LI, D., **Input electrical impedance as quality monitoring signature for characterizing resistance spot welding**, NDT & E International, 2009.

MACHE, N., **Manual da Ferramenta de Simulação de Redes Neurais – SNNS**, Instituto para Sistemas Paralelos e Distribuídos de Alta Performance da Universidade de Stuttgart. Disponível em: <http://www.ra.cs.uni-tuebingen.de/SNNS/UserManual/UserManual.html>, 1995.

MANSOUR, T. M., **Ultrasonic Inspection of Spot Welds in Thin-Gage Steel**, Materials Evaluation, Vol. 46, n.5, Abril, 1988, pag. 640-658.

MARTÍN, O. , LÓPEZ, M. , MARTÍN, F., **Artificial neural networks for prediction of quality in resistance spot welding**, Revista de Metalurgia, volume 42, issue 5, setembro 2006, pag. 345-353.

MARTÍN, O., LÓPEZ, M., MARTÍN, F., **Artificial neural networks for quality control by ultrasonic testing in resistance spot welding**, Journal of Materials Processing Technology, n. 183, pag. 226-233, 2007.

MEOLA, C., SQUILLACE, A., MINUTOLO, F.M.C., MORACE, R.E., **Analysis of stainless steel welded joints: a comparison between destructive and non-destructive techniques**, Journal of Materials Processing Technology, vol. 155–156, pag.1893–1899, 2004.

MESSLER, R.W. Jr., **An Intelligent Control System for Resistance Spot Welding Using A Neural network and Fuzzy Logic**, IEEE Industry Applications Conference'95, vol. 2, pag. 1757-63, 1995.

MEWBORNE, M., **Advances made in resistance welding process control**, Practical Welding Today, May/June, Volume 3, n. 3, 1999.

MITCHELL, T. M., **Machine Learning**, McGraw-Hill Higher Education, 1997.

NEGNEVITSKY, M., **Artificial Intelligence: A Guide to Intelligent Systems**, Pearson Education Limited, 2002.

PENGXIAN, Z., HONGJIE, Z., JIANHONG, C., YUEZHOU, M., **Quality monitoring of resistance spot welding based on electrode displacement characteristics analysis**, Front. Mech. Eng. China, vol. 2, número 3, 2007, pag.330–335.

PODOLA, N.V., RUDENKO, P.M., GAVRISH, V.S., **Adaptive algorithm of quality control of resistance spot welding using neural networks**, Paton Welding Journal, no.1, 2002.

PODRZAJ, P., POLAJNAR, I., DIACI, J., KARIZ, Z., **Estimating the strength of resistance spot welds based on sonic emission**, Science and Technology of Welding and Joining, vol. 10, número 4, 2005, pag. 399-405.

PODRZAJ, P., POLAJNAR, J., DIACI, J., KARIZ, Z., **Overview of Resistance Spot Welding Control**, Science and Technology of Welding and Joining, vol.13, n.3, pag. 215-224, 2008.

PRESS, W. H., TEUKOLSKY, S. A., VETTERLING, W. T., FLANNERY, B. P., **NUMERICAL RECIPES IN C: THE ART OF SCIENTIFIC COMPUTING**, Cambridge University Press, second edition, 1992

RAMBOZ, J., **Machinable rogowski coil design and calibration**, IEEE Transactions on Instrumentation and Measurement, vol. 45, pag. 511-515, abril, 1996.

ROSENBLATT F., **The Perceptron: A probabilistic model for information storage and organization in the brain**, Psychological Review, vol. 68, pag. 386-408, 1958.

ROYE, W., **Nondestructive Inspection Methods in the automotive industry**, 8th ECNDT Conference, Barcelona (Spain), June 17-21, 2002.

RUISZ, J, BIBER, J, LOIPETSBERGER, M., **Quality evaluation in resistance spot welding by analyzing the weld fingerprint on metal bands by computer vision**, International Journal Adv Manuf. Technology, vol. 33, 2007, pag.952–960.

SAPP, MARK E., A History of Welding – from Hepheastus to Apollo. Disponível em: <<http://www.weldinghistory.org/whistoryfolder/welding/index.html>>. Acessado em: 01 de maio de 2009.

SHVIRER, J., PENG, H., HU, S.J., **Control of Resistance Spot Welding**, Proceedings of the American Control Conference '99, San Diego, California, pag. 187-191., Junho, 1999.

SONG, Q., ZHANG, W., BAY, N., **An Experimental Study Determines the Electrical Contact Resistance in Resistance Welding**, Welding Research – Supplement to the Welding Journal, volume 84, n.5, maio 2005, pag. 73-76.

STANWAY, J.D., **Technological Advances in Resistance Welding Control**, Welding and Metal Fabrication, Vol. 60, n. 4, pag. 159-164, 1992.

SUBRAMANIAN, D., DONGARKAR, G.K., DAS, M., V., FERNANDEZ, V., GRZADZINSKY, G., **Real time monitoring and quality control of resistance spot welds using voltage, current, and force data**, IEEE Electro/Information Technology Conference, 2004, EIT 2004, agosto 2004, pag. 211-220.

SUN, H., ZHANG, Y., LAI, X., CHEN, G., **On-line inspection of weld quality based on dynamic resistance curve in resistance spot welding and weld bonding**, Proc. of the Fourth International Symposium on Precision Mechanical Measurements, Vol. 7130, 2008.

TUOVINEN, L., LAURINEN, P., KOSKIMAKI, H., HAAPALAINEN, E., RUNING, J., **Building a Database to Support Intelligent Computational Quality Assurance of Resistance Spot Welding Joints**, IEEE International Symposium on Industrial Electronics - ISIE 2007, pag. 1980-1985, 2007.

VOGT, G., KÖHLER, C., RIEGER, D., **State of art in ultrasonic spotweld testing – offline & inline – new materials and coatings**, 9th European NDT Conference (ECNDT'06), 2006.

Disponível em: <<http://www.ndt.net/article/ecndt2006/doc/Th.3.4.5.pdf>>.

XINMIN, L., XIAOYUN, Z., YANSONG, Z., GUANLONG, C., **Weld Quality Inspection Based on Online Measured Indentation from Servo Encoder in Resistance Spot Welding**, IEEE Transactions on Instrumentation and Measurement, vol. 56, n. 4, Agosto, 2007, pag. 1501-1505.

WARD, D.A., EXON, T., **Using rogowski coil for transient current measurements**, Engineering Science and Education Journal, pag. 105-114, 1993.

WEN, J., WANG, C. S., XUI G.S.AND ZHANGI, X. Q., **Real Time Monitoring Weld Quality of Resistance Spot Welding for Stainless Steel**, ISIJ International, vol. 49, número 4, 2009, pag. 553–556.

WEN, J., ZHANG, X., XU, G., WANG, C., ZHANG, X., HE, S., **Quality estimation of resistance spot welding of stainless steel based on BP neural network**, China Welding (English Edition), volume 18, issue 3, setembro 2009, pag. 16-20.

WILLIAMS, N. T., PARKER, J. D., **Review of resistance spot welding of steel sheets - Part 1 Modelling and control of weld nugget formation**, International Materials Reviews, Maney Publishing, vol. 49, número 2, abril 2004a, pag. 45-75.

WILLIAMS, N. T., PARKER, J. D., **Review of resistance spot welding of steel sheets - Part 2 Factors influencing electrode life**, International Materials Reviews, Maney Publishing, vol. 49, número 2, abril 2004b, pag. 77-108.

YANG, Y. P., BABU, S. S., ORTH, F. AND PETERSON, W., **Integrated computational model to predict mechanical behavior of spot weld**, Science and Technology of Welding and Joining, vol. 13, número 3, 2008, pag. 232-233.

ZHANG, C., DI, L., AN, Z., **Welding quality monitoring and management system based on data mining technology**, Proceedings of the Second International Conference on Machine Learning and Cybernetics, Xi'an, novembro, 2003.

ZHANG, P., ZHANG, H., MA, Y., CHEN, J., **On-line quality estimation of resistance spot welding based on extraction of signals feature**, Transactions of the China Welding Institution, volume 26, issue 9, setembro 2005, pag. 52-57.

ZHANG, Y. S., WANG, H., CHENG, L., ZHANG, X. Q., **Monitoring and intelligent control of electrode wear based on a measured electrode displacement curve in resistance spot welding**, Meas. Sci. Technol., n.18, pag. 867–876, 2007.

ZHANG, H., HOU, Y., **Quality evaluation of the resistance spot welding based on PCA-SVM**, Hanjie Xuebao/Transactions of the China Welding Institution, volume 30, issue 4, abril 2009, pag. 97-100.

ANEXO A - REDES NEURAIS ARTIFICIAIS

A.1 FUNDAMENTOS DE REDES NEURAIS ARTIFICIAIS

Haykin descreveu uma rede neural como sendo uma máquina adaptável ou, mais especificamente: “Uma rede neural é um processador altamente paralelo e distribuído que possui uma propensão natural para armazenar conhecimento através de experiência e disponibilizá-lo para uso. Assemelha-se ao cérebro de duas formas: o conhecimento é adquirido pela rede através um processo de aprendizado e o peso entre as conexões entre neurônios, chamadas de sinapses, são utilizados para armazenar esse conhecimento” (HAYKIN, 1999).

Redes Neurais podem ser definidas como um modelo de raciocínio baseado no cérebro humano. O cérebro consiste em grupo de células nervosas, denso e altamente interconectado ou, basicamente, unidades de processamento chamados neurônios. O cérebro humano é formado por aproximadamente 10 bilhões de neurônios e 6 trilhões de conexões entre eles (NEGNEVITSKY, 2002). Desta forma, utilizando um processamento altamente paralelo, o cérebro tem condições de executar funções e atividades mais rápido que o mais poderoso computador existente atualmente.

Apesar de cada neurônio, individualmente, apresentar uma estrutura extremamente simples, o conjunto de tais elementos constitui um enorme poder de processamento. O neurônio consiste do corpo da célula, chamada soma, um número de fibras chamadas dendritos, e uma única e longa fibra chamada de axônio. Enquanto os dendritos alcançam regiões ao redor da soma, os axônios alcançam os dendritos e somas de outros neurônios. A Figura A.1 compara as conexões de um neurônio biológico e um neurônio artificial, e a Tabela A.1 apresenta uma analogia entre neurônios biológicos e neurônios artificiais.




Figura A.1. Conexões de um Neurônio (a) Neurônio Biológico; (b) Neurônico Artificial

Tabela A.1 - Analogia entre Rede Neural Biológica e Artificial

Rede Neural Biológica	Rede Neural Artificial
Soma	Neurônio
Dendrito	Entrada
Axônio	Saída
Sinapse	Pesos

Sinais são propagados de um neurônio a outro através de complexas reações eletroquímicas. Substâncias químicas liberadas pelas sinapses causam uma mudança no potencial elétrico do corpo da célula. Quando esse potencial atinge um limite, um pulso elétrico, chamado de potencial de ação, é enviado através do axônio. O pulso espalha-se e eventualmente atinge as sinapses, fazendo com que as sinapses aumentem ou diminuam seus potenciais. De qualquer forma, o ponto mais interessante é que a rede neural apresenta plasticidade. Em resposta ao padrão de estímulo, os neurônios demonstram, ao longo tempo, mudanças no peso entre suas conexões. Neurônios também podem formar novas conexões com outros neurônios. Até mesmo grupos inteiros de neurônios podem em alguns casos migrar de um lugar para outro. Esses mecanismos formam a base para o aprendizado no cérebro.

Nosso cérebro pode ser considerado um sistema de processamento de informações altamente complexo, paralelo e não-linear. Informações são armazenadas e processadas em

uma rede neural simultaneamente através de toda a rede, ao invés de um local específico, ou seja, em redes neurais, ambos dados e processamento são globais ao invés de locais.

Devido à plasticidade, conexões entre neurônios que tendem à resposta correta à solicitação são fortalecidas, enquanto aquelas que levam à resposta errada são enfraquecidas. Como resultado, a rede neural tem a habilidade de aprender através de experiência. Aprendizado é uma característica fundamental e essencial de uma rede neural biológica. A tranquilidade e naturalidade na qual as redes neurais podem aprender levaram à tentativa de simular uma rede neural biológica em um computador.

Apesar de atualmente as RNA não se parecerem muito com as redes neurais biológicas, isso por si só já é um grande avanço. As RNAs são capazes de aprender, ou seja, elas utilizam a experiência para aprimorar sua performance. Quando expostas a um número suficiente de amostras, as RNAs podem generalizar outras informações que não foram encontradas ou fornecidas. Uma RNA consiste de um número de processadores extremamente simples, porém altamente interconectados, também chamados de neurônios, análogos aos neurônios biológicos do cérebro. Os neurônios são conectados através de conexões com pesos, transmitindo sinais de um neurônio para outro. Cada neurônio recebe um número de sinais de entrada através dessas conexões. Apesar disso, o neurônio nunca produz mais de um único sinal de saída. O sinal de saída é transmitido através da conexão de saída do neurônio, correspondente ao axônio do neurônio biológico. A conexão de saída, por sua vez, é dividida em um ramo em que cada ramificação transmite o mesmo sinal. É importante observar que o sinal não é dividido entre os ramos e sim mantido para cada um. Esses ramos de saída terminam nas conexões de entrada de outros neurônios na rede. A Figura A.2 apresenta as conexões típicas de uma RNA.




Figura A.2 - Arquitetura de uma RNA típica

A.2 O Neurônio como um Simples Elemento Computacional

Um neurônio recebe vários sinais das conexões de entrada, calcula um novo nível de ativação e envia o novo sinal para a saída através das conexões de saída. Os sinais de entrada podem ser dados externos ou saídas de outros neurônios. A Figura A.3 mostra um neurônio típico:

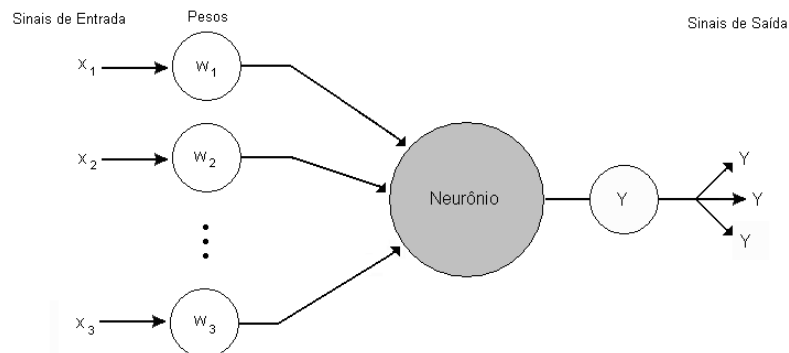


Figura A.3 - Diagrama de um neurônio

Em 1943, Warren McCulloch e Walter Pitts propuseram uma idéia simples e que ainda hoje é a base para a maioria das RNAs. O neurônio calcula a soma das entradas influenciadas pelo peso de cada conexão e compara o resultado com o valor de ativação, θ . Se o valor da entrada do neurônio for menor que o de ativação, a saída do neurônio é -1. Porém, se o valor

da entrada do neurônio for igual ou maior que o de ativação, o neurônio é ativado e sua saída atinge o valor +1.

Em outras palavras, o neurônio utiliza as seguintes funções de ativação:

$$X = \sum_{i=1}^n x_i w_i$$

$$Y = \begin{cases} +1 & \text{se } X \geq \theta, \\ -1 & \text{se } X < \theta \end{cases} \quad (\text{A.1})$$

onde: X é a entrada do neurônio influenciada pelo peso das conexões, x_i é o valor da entrada i , w_i é o peso da entrada i , n é o número de entradas do neurônio e Y é a saída do neurônio. Este tipo de função de ativação é chamado de função sinal.

Assim, a atual saída do neurônio com função de ativação sinal pode ser representada da seguinte forma:

$$Y = \text{sign} \left[\sum_{i=1}^n x_i w_i - \theta \right] \quad (\text{A.2})$$

Várias funções de ativação foram testadas, mas somente algumas apresentaram aplicações práticas. Quatro tipos são ilustrados na Figura A.4: degrau, sinal, linear e sigmoidal.

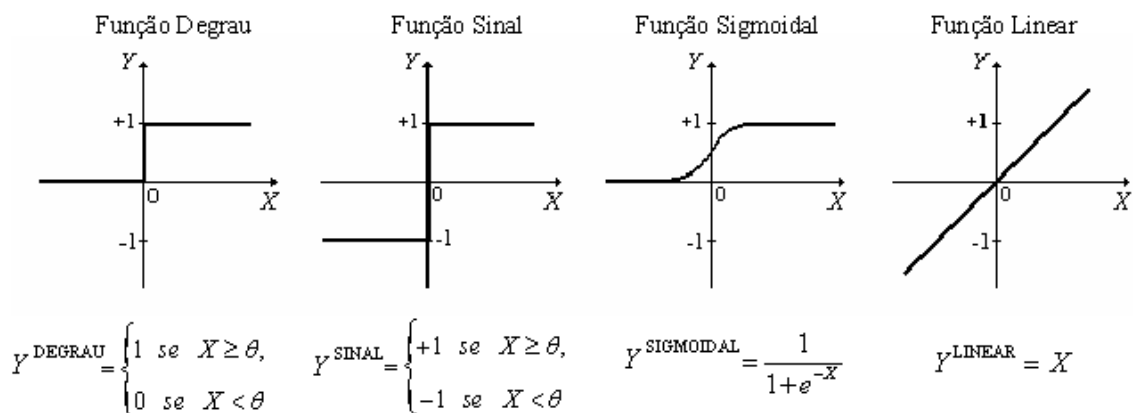


Figura A.4 - Funções de Ativação de um Neurônio

A função sigmoïdal transforma a entrada, a qual pode variar entre menos e mais infinito, em um valor razoável entre 0 e 1. Neurônios com essa função são utilizados em redes com algoritmo *back-propagation*.

A função linear proporciona uma saída igual à entrada do neurônio. Neurônios com essa função são geralmente utilizados para aproximação linear.

A.3 O Perceptron

Em 1958, Frank Rosenblatt introduziu o primeiro algoritmo que proporcionou um procedimento para um treinamento de uma RNA, o perceptron, que consiste na forma de RNA mais simples possível. É constituído de um único neurônio com pesos ajustáveis e o valor de ativação.

O funcionamento do Perceptron é baseado no modelo de McCulloch e Pitts e consiste de uma combinação linear seguido pelo valor de ativação. A soma das entradas multiplicadas por seus respectivos pesos é comparada com o valor de ativação, que produz uma saída igual a +1 se essa soma for positiva e -1 se a soma for negativa. O objetivo do Perceptron é classificar as entradas, ou seja, estímulos externos x_1, x_2, \dots, x_n , entre, por exemplo, duas classes A_1 e A_2 . Assim, no caso de um Perceptron simples, o espaço n-dimensional é dividido por um hiperplano em duas regiões. Esse hiperplano é definido pela função linearmente separável:

$$\sum_{i=1}^n x_i \cdot w_i - \theta = 0 \quad (\text{A.3})$$

onde n é o número de entradas e θ é o valor de ativação aplicado no neurônio.

Para o caso de duas entradas, x_1 e x_2 , a fronteira tem a forma de uma linha reta, mostrada na Figura A.5(a). O ponto 1 localizado acima da fronteira, pertence à classe A_1 e o

ponto 2, localizado abaixo da fronteira, pertence à classe A_2 . O valor de ativação θ pode ser utilizado para mover essa fronteira.

Com três entradas, o hiperplano ainda pode ser observado. A Figura A.5(b) mostra as três dimensões para o Perceptron com três entradas. Neste caso, a função é definida por:

$$x_1 \cdot w_1 + x_2 \cdot w_2 + x_3 \cdot w_3 - \theta = 0 \quad (\text{A.4})$$

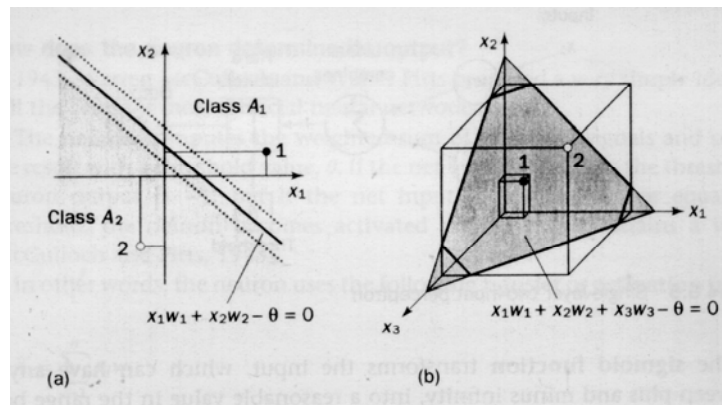


Figura A.5 - Separação Linear no Perceptron: (a) Perceptron com duas entradas; (b) Perceptron com três entradas

O Perceptron aprende a tarefa que foi designado a realizar através de pequenos ajustes nos pesos para reduzir a diferença entre a saída atual e a desejada. Inicialmente, os pesos são determinados de forma aleatória, normalmente entre $[-0.5, 0.5]$, e assim atualizados para obter a saída através de exemplos para treinamento. A determinação do erro entre a saída atual e a desejada faz-se da seguinte forma, considerando que o Perceptron está na iteração p :

$$e(p) = Y_d(p) - Y(p) \quad (\text{A.5})$$

onde: $Y(p)$ = saída atual;

$Y_d(p)$ = saída desejada em $p = 1, 2, 3 \dots$

Se o erro $e(p)$ for positivo, é necessário aumentar a saída $Y(p)$, porém se for negativo, é necessário diminuir $Y(p)$. Levando em consideração que uma entrada do Perceptron

contribui $x_i(p) \times w_i(p)$ para a entrada total $X(p)$, pode-se notar que se o valor da entrada $x_i(p)$ for positivo, um incremento no peso $w_i(p)$ tende a aumentar a saída do Perceptron $Y(p)$, enquanto se $x_i(p)$ for negativo, um aumento $w_i(p)$ tende a diminuir $Y(p)$. Desta forma, a regra de aprendizado do Perceptron pode ser determinada como:

$$w_i(p+1) = w_i(p) + \alpha \times x_i(p) \times e(p) \quad (\text{A.6})$$

onde α é a taxa de aprendizado, uma constante positiva menor que 1.

A regra de aprendizado do Perceptron foi proposta inicialmente por Rosenblatt em 1960. Através dessa regra pode-se chegar a um conjunto de tarefas para o treinamento do Perceptron:

I) Inicialização

Determinar os pesos iniciais w_1, w_2, \dots, w_n e o valor de ativação θ . Normalmente os pesos são determinados aleatoriamente, entre valores de $[-0.5, 0.5]$.

II) Ativação

Ativar o Perceptron aplicando as entradas $x_1(p), x_2(p), \dots, x_n(p)$ e a saída desejada $Y_d(p)$. Calcular a saída atual na iteração $p=1$.

$$Y(p) = \text{step} \left[\sum_{i=1}^n x_i(p) * w_i(p) - \theta \right] \quad (\text{A.7})$$

onde n é o número de entradas do Perceptron e step é a função de ativação.

III) Treinamento dos Pesos

Atualizar os pesos do Perceptron.

$$w_i(p+1) = w_i(p) + \Delta w_i(p) \quad (\text{A.8})$$

onde $\Delta w_i(p)$ é a correção do peso na iteração p .

A correção do peso é realizada através da regra do delta:

$$\Delta w_i(p) = \alpha \times x_i(p) \times e(p) \quad (\text{A.9})$$

IV) Iteração

Incrementar uma vez p , voltar ao passo de Ativação e repetir todo processo até convergir ao valor desejado.

O Perceptron com camada única pode classificar somente padrões linearmente separáveis, independente da função de ativação utilizada. Pode-se perceber claramente as limitações do Perceptron ao treinar uma rede para realizar as operações lógicas E, OU e Ou exclusivo. A tabela verdade de cada operação lógica é mostrada na Tabela A.2. A tabela apresenta todas as possíveis combinações para duas variáveis de entrada, x_1 e x_2 , e o resultado das operações. O Perceptron deve ser treinado para classificar os padrões de entrada.

Tabela A.2. Tabela Verdade para as operações lógicas básicas

Input Variables		Resultados		
x1	x2	E	OU	OU Exclusivo
0	0	0	0	0
0	1	0	1	1
1	0	0	1	1
1	1	1	1	0

Considerando inicialmente a operação lógica E, após realizar a inicialização, o Perceptron é ativado pela seqüência de quatro padrões de entrada, que representa uma época. Os pesos do Perceptron são atualizados após cada ativação, repetindo-se esse processo até todos os pesos convergirem para um grupo de valores uniformes. Os resultados são mostrados na Tabela A.3, Valor de ativação $\theta = 0.2$ e a taxa de aprendizado $\alpha = 0.1$.

Tabela A.3. Exemplo de treinamento do Perceptron: operação lógica E

Época	Entradas		Saída Desejada Yd	Pesos Iniciais		Saída Atual Y	Erro e	Pesos Finais	
	x1	x2		W1	W2			W1	W2
1	0	0	0	0.3	-0,1	0	0	0.3	-0,1
	0	1	0	0.3	-0,1	0	0	0.3	-0,1
	1	0	0	0.3	-0,1	1	-1	0.2	-0,1
	1	1	1	0.2	-0,1	0	1	0.3	0.0
2	0	0	0	0.3	0.0	0	0	0.3	0.0
	0	1	0	0.3	0.0	0	0	0.3	0.0
	1	0	0	0.3	0.0	1	-1	0.2	0.0
	1	1	1	0.2	0.0	1	0	0.2	0.0
3	0	0	0	0.2	0.0	0	0	0.2	0.0
	0	1	0	0.2	0.0	0	0	0.2	0.0
	1	0	0	0.2	0.0	1	-1	0.1	0.0
	1	1	1	0.1	0.0	0	1	0.2	0.1
4	0	0	0	0.2	0.1	0	0	0.2	0.1
	0	1	0	0.2	0.1	0	0	0.2	0.1
	1	0	0	0.2	0.1	1	-1	0.1	0.1
	1	1	1	0.1	0.1	1	0	0.1	0.1
5	0	0	0	0.1	0.1	0	0	0.1	0.1
	0	1	0	0.1	0.1	0	0	0.1	0.1
	1	0	0	0.1	0.1	0	0	0.1	0.1
	1	1	1	0.1	0.1	1	0	0.1	0.1

De maneira muito similar, o Perceptron pode aprender a operação lógica OU. Porém, um Perceptron com camada única não pode ser treinado para executar a operação lógica OU exclusivo.

A Figura A.6 representa as funções E, OU e OU exclusivo como gráficos bi-dimensionais baseados nos valores das duas entradas. Os pontos no espaço de entrada onde a saída da função é 1 são representados por pontos pretos e àqueles que a saída é 0, pontos brancos.




Figura A.6 - Gráficos bi-dimensionais de operações lógicas básicas: (a) E ($x_1 \cap x_2$); (b) OU ($x_1 \cup x_2$); (c) OU-exclusivo ($x_1 \oplus x_2$)

Nas Figuras A.6(a) e (b), pode-se separar os pontos pretos dos brancos através de uma linha. Porém os pontos na Figura A.6(c) não podem ser separados por uma linha. O Perceptron só pode representar funções que podem ser separadas linearmente. Porém, as limitações do Perceptron proposto por Rosenblatt podem ser superadas com a utilização de formas mais avançadas de RNA, como Perceptrons com várias camadas treinados com o algoritmo *back-propagation*.

A.4 Redes Neurais Multicamadas

Um Perceptron multicamadas é uma rede neural direta com uma ou mais camadas escondidas. Tipicamente, a rede consiste em uma camada de neurônios de interface como entrada, no mínimo uma camada escondida de neurônios computacionais e uma camada de neurônios computacionais de saída. Os sinais de entrada são propagados diretamente camada por camada. Um Perceptron multicamadas com duas camadas escondidas é mostrado na Figura A.7.




Figura A.7 - Perceptron com duas camadas

Cada camada em uma rede neural artificial multicamadas tem sua própria função específica. A camada de entrada recebe os sinais de entrada do mundo externo e redistribui

esses sinais para todos os neurônios na camada escondida. Na verdade, neurônios na camada de entrada raramente possuem um valor ou influência computacional. A camada de saída aceita sinais de saída, ou em outras palavras padrões de estímulos provenientes das camadas escondidas e determina o padrão de saída de toda a rede neural

Os neurônios da camada escondida detectam as características. Os pesos dos neurônios representam as características escondidas nos padrões de entrada. Essas características são então utilizadas pelo neurônio de saída na determinação dos padrões de saída. Concluindo: os pesos da rede neural representam justamente o conhecimento acumulado através do treinamento

Com uma camada escondida, pode-se representar qualquer função contínua nos sinais de entrada e, com duas camadas escondidas, até mesmo funções descontínuas podem ser representadas

Em relação ao aprendizado de redes neurais multicamadas, centenas de algoritmos de aprendizados diferentes estão disponíveis, porém o método mais popular é o *back-propagation* que será descrito na seção A.5 a seguir

A.5 Algoritmo de Aprendizado Back-Propagation

Esse método foi inicialmente proposto em 1969 por A. E. Bryson e Y. O. Ho, mas foi ignorado devido à sua demanda computacional e, desta forma, foi redescoberto somente nos meados de 1980.

O aprendizado em uma rede multicamadas procede da mesma maneira que um Perceptron. Um conjunto de padrões de entrada é apresentado para a rede para treinamento. A rede computa seu próprio padrão e na existência de um erro, ou seja, se a diferença entre a saída atual e a desejada for maior que um valor desejado, os pesos são ajustados para diminuir esse erro. Em um Perceptron, existe apenas um peso para cada entrada e apenas uma saída.

Em uma rede multicamadas, porém, existem muitos pesos, cada qual contribui para mais de uma saída.

O algoritmo *back-propagation* possui duas fases para o aprendizado da rede. Inicialmente, um conjunto de padrões de entrada é apresentado para a rede para treinamento. A rede então propaga os padrões de entrada de camada em camada até que um padrão de saída é gerado pela camada de saída. Se esse padrão for diferente da saída desejada, um erro é calculado e então propagado para trás, da camada de saída até a camada de entrada através da rede. Os pesos são modificados à medida que o erro é propagado.

Assim como qualquer outra rede neural, a que utiliza o algoritmo *back-propagation* para aprendizado é determinada pela arquitetura da rede, pelas funções de ativação utilizadas pelos neurônios e pelo algoritmo de aprendizado, que especifica o procedimento para o ajuste dos pesos. Tipicamente, a rede que utiliza um algoritmo *back-propagation* é multicamadas e possui três ou quatro camadas. As camadas são completamente conectadas, ou seja, todos neurônios em cada camada são conectados em todos outros neurônios na camada seguinte.

O neurônio determina sua saída de maneira similar ao Perceptron de Rosenblatt (ROSENBLATT, 1958). Primeiro, ele computa as entradas influenciadas pelos pesos, conforme mostrado anteriormente na equação A.3.

A seguir, esse valor de entrada é passado através da função de ativação. Porém, diferentemente do Perceptron, os neurônios na rede que utiliza *back-propagation* utilizam a função de ativação sigmoideal. A derivada dessa função é fácil de se realizar e também garante que a saída do neurônio seja limitada entre 0 e 1.

$$Y^{sigmoideal} = \frac{1}{1 + e^{-x}} \quad (\text{A.10})$$

Para demonstrar a regra de aprendizado *back-propagation*, pode-se considerar uma rede com três camadas mostrada na Figura A.8. Os índices i , j e k são referentes aos neurônios de entrada, escondidos e de saída respectivamente.

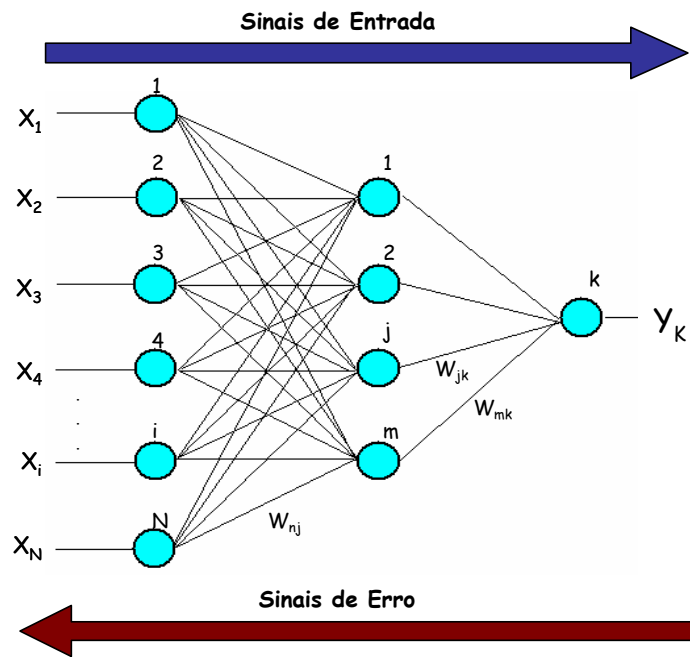


Figura A.8 - Rede Neural que utiliza *back-propagation* com três camadas

Os sinais de entrada, $x_1(p), x_2(p), \dots, x_n(p)$, são propagados através da rede da esquerda para a direita, e os sinais de erro, e_1, e_2, \dots, e_l , da direita para a esquerda. O símbolo w_{ij} denota o peso da conexão entre o neurônio i da camada de entrada e o neurônio j da camada escondida. Já o símbolo w_{jk} representa o neurônio j da camada escondida e o neurônio k da camada de saída.

Para propagar o sinal de erro, é necessário começar na camada de saída e seguir para trás, na camada escondida. O sinal de erro no neurônio de saída k na iteração p é definido por:

$$e_k(p) = y_{d,k}(p) - y_k(p) \quad (\text{A.11})$$

onde $y_{d,k}(p)$ é o valor de saída desejado do neurônio k na iteração p .

O neurônio k , que é localizado na camada de saída, possui o próprio valor de saída desejado. Desta forma, pode-se utilizar o procedimento direto para atualizar o peso w_{jk} . Na

verdade, a regra para atualizar o peso de neurônios de saída é similar à regra de aprendizado do Perceptron na equação A.8 como mostra a equação A.12:

$$w_{jk}(p+1) = w_{jk}(p) + \Delta w_{jk}(p) \quad (\text{A.12})$$

onde $\Delta w_{jk}(p)$ é a correção do peso.

Ao determinar a correção de erro para o Perceptron, foi utilizado o sinal de entrada x_i . Porém na rede multicamadas, os neurônios de entrada na camada de saída são diferentes dos neurônios de entrada da camada de entrada. Utiliza-se agora a saída do neurônio j na camada escondida, $y_j(p)$. A correção do peso na rede multicamadas é computado através de:

$$\Delta w_{jk}(p) = \alpha \times y_j(p) \times \delta_k(p) \quad (\text{A.13})$$

onde $\delta_k(p)$ é o gradiente de erro no neurônio k na camada de saída na iteração p .

O gradiente de erro é determinado como a derivada da função de ativação sigmoidal, F' , multiplicado pelo erro do neurônio de saída. Assim, obtém-se para o neurônio k na camada de saída:

$$\delta_k(p) = F'[X_k(p)] \times e_k(p) \quad (\text{A.14})$$

onde $X_k(p)$ é a entrada influenciada pelos pesos do neurônio k na iteração p :

$$X_k(p) = \sum_{j=1}^m x_{jk}(p) \times w_{jk}(p) - \theta_k \quad (\text{A.15})$$

onde m é o número de neurônios na camada escondida.

Assim, a equação A.14 pode ser representada por:

$$\delta_k(p) = y_k(p) \times [1 - y_k(p)] \times e_k(p) \quad (\text{A.16})$$

onde $y_k = \frac{1}{1 + e^{-X_k(p)}}$.

Para calcular a correção dos pesos para a camada escondida, pode-se aplicar as mesmas equações para a camada de saída:

$$\Delta w_{ij}(p) = \alpha \times x_i(p) \times \delta_j(p) \quad (\text{A.17})$$

onde $\delta_j(p)$ representa o gradiente de erro no neurônio j na camada escondida:

$$\delta_j(p) = y_j(p) \times [1 - y_j(p)] \times \sum_{k=1}^l \delta_k(p) \cdot w_{jk}(p) \quad (\text{A.18})$$

onde l é o número de neurônios na camada de saída, $y_j = \frac{1}{1 + e^{-X_j(p)}}$,

$$X_j(p) = \sum_{i=1}^n x_i(p) \times w_{ij}(p) - \theta$$

e n é o número de neurônios na camada de entrada.

Desta forma, pode-se determinar o algoritmo de treinamento *back-propagation*:

I) Inicialização

Determinar os pesos iniciais w_1, w_1, \dots, w_n e o valor de ativação θ .

II) Ativação

Ativar a rede neural com o algoritmo *back-propagation* aplicando as entradas $x_1(p), x_2(p), \dots, x_n(p)$ e as saídas desejadas $y_{d,1}(p), y_{d,2}(p), \dots, y_{d,n}(p)$.

a. Calcular a saída atual dos neurônios na camada escondida:

$$y_j(p) = \text{sigmoidal} \left[\sum_{i=1}^n x_i(p) \times w_{ij}(p) - \theta_j \right] \quad (\text{A.19})$$

onde n é o número de entradas do neurônio j na camada escondida e sigmoidal é a função de ativação.

b. Calcular as saídas atuais dos neurônios da camada de saída:

$$y_k(p) = \text{sigmoidal} \left[\sum_{i=1}^m x_{jk}(p) \times w_{jk}(p) - \theta_k \right] \quad (\text{A.20})$$

onde m é o número de entradas do neurônio k na camada de saída.

III) Treinamento dos Pesos

Atualizar os pesos na rede que utiliza o *back-propagation* propagando para trás os erros associados com os neurônios de saída.

- a. Calcular o gradiente de erro para os neurônios na camada de saída:

$$\delta_k(p) = y_k(p) \times [1 - y_k(p)] \times e_k(p) \quad (\text{A.21})$$

onde

$$e_k(p) = y_{d,k}(p) - y_k(p) \quad (\text{A.22})$$

Calcular as correções dos pesos:

$$\Delta w_{jk}(p) = \alpha \times y_j(p) \times \delta_k(p) \quad (\text{A.23})$$

Atualizar os pesos nos neurônios de saída:

$$w_{jk}(p+1) = w_{jk}(p) + \Delta w_{jk}(p) \quad (\text{A.24})$$

- b. Calcular o gradiente de erro para os neurônios na camada escondida:

$$\delta_i(p) = y_j(p) \times [1 - y_j(p)] \times \sum_{k=1}^l \delta_k(p) \cdot w_{jk}(p) \quad (\text{A.25})$$

Calcular a correção dos pesos:

$$\Delta w_{ij}(p) = \alpha \times x_i(p) \times \delta_j(p) \quad (\text{A.26})$$

Atualizar os pesos na camada escondida:

$$w_{ij}(p+1) = w_{ij}(p) + \Delta w_{ij}(p) \quad (\text{A.27})$$

IV) Iteração

Incrementar uma vez p , voltar ao passo de Ativação e repetir todo processo até que o critério de erro selecionado seja satisfeito.

Como um exemplo, pode-se considerar a rede que utiliza o *back-propagation* de três camadas mostrada na Figura A.9. Suponha que a rede tenha que realizar a operação lógica OU exclusivo. Redes com uma única camada não são capazes de realizar tal operação.




Figura A.9 - Rede Neural de três camadas para solucionar a operação OU exclusivo

Os neurônios 1 e 2 na camada de entrada recebem sinais através das entradas x_1 e x_2 , respectivamente, e redistribui essas entradas para os neurônios na camada escondida sem qualquer processamento: $x_{13} = x_{14} = x_1$ e $x_{23} = x_{24} = x_2$.

O efeito do valor de ativação aplicado a um neurônio da camada escondida ou de saída é representado pelos seus pesos, θ , conectado a uma entrada fixa de -1 .

Os pesos iniciais e valores de ativação são determinados aleatoriamente, conforme segue:

$$w_{13} = 0.5, w_{14} = 0.9, w_{23} = 0.4, w_{24} = 1.0, w_{35} = -1.2, w_{45} = 1.1, \\ \theta_3 = 0.8, \theta_4 = -0.1, \theta_5 = 0.3.$$

Considere um grupo de treinamento onde as entradas x_1 e x_2 são iguais a 1 e a saída desejada $y_{d,5}$ é 0 . A saída atual dos neurônios de saída na camada escondida são calculados por:

$$y_3 = \text{sigmoidal}(x_1 w_{13} + x_2 w_{23} - \theta_3) = \frac{1}{1 + e^{-(1 \times 0.5 + 1 \times 0.4 - 1 \times 0.8)}} = 0.5250$$

$$y_4 = \text{sigmoidal}(x_1 w_{14} + x_2 w_{24} - \theta_4) = \frac{1}{1 + e^{-(1 \times 0.9 + 1 \times 1.0 + 1 \times 0.1)}} = 0.8808$$

Agora, a saída atual do neurônio de saída 5 na camada de saída é determinado por:

$$y_5 = \text{sigmoidal}(x_3 w_{35} + x_4 w_{45} - \theta_5) = \frac{1}{1 + e^{-(0.5250 \times 1.2 + 0.8808 \times 1.1 - 1 \times 0.3)}} = 0.5097$$

Desta forma, o seguinte erro é obtido:

$$e = y_{d,5} - y_5 = 0 - 0.5097 = -0.5097$$

O próximo passo é o treinamento dos pesos. Para atualizar os pesos e os valores de ativação na rede, propaga-se o erro, e , da camada de saída para trás, até a camada de entrada.

Inicialmente, calcula-se o gradiente de erro para o neurônio 5 na camada de saída:

$$\delta_5 = y_5 \cdot (1 - y_5) \cdot e = 0.5097 \times (1 - 0.5097) \times (-0.5097) = -0.1274$$

Então, determina-se as correções dos erros assumindo que a taxa de aprendizado, α , é igual a 0,1:

$$\Delta w_{35} = \alpha \times y_3 \times \delta_5 = 0.1 \times 0.5250 \times (-0.1274) = -0.0067$$

$$\Delta w_{45} = \alpha \times y_4 \times \delta_5 = 0.1 \times 0.8808 \times (-0.1274) = -0.0112$$

$$\Delta \theta_5 = \alpha \times (-1) \times \delta_5 = 0.1 \times (-1) \times (-0.1274) = -0.0127$$

Após isso, calcula-se o gradiente de erro para os neurônios 3 e 4 na camada escondida:

$$\delta_3 = y_3 \cdot (1 - y_3) \times \delta_5 \times w_{35} = 0.5250 \times (1 - 0.5250) \times (-0.1274) \times (-1.2) = 0.0381$$

$$\delta_4 = y_4 \cdot (1 - y_4) \times \delta_5 \times w_{45} = 0.8808 \times (1 - 0.8808) \times (-0.1274) \times 1.1 = -0.0147$$

Determina-se então as correções dos erros:

$$\Delta w_{13} = \alpha \times x_1 \times \delta_3 = 0.1 \times 1 \times 0.0381 = 0.0038$$

$$\Delta w_{23} = \alpha \times x_2 \times \delta_3 = 0.1 \times 1 \times 0.0381 = 0.0038$$

$$\Delta \theta_3 = \alpha \times (-1) \times \delta_3 = 0.1 \times (-1) \times 0.0381 = -0.0038$$

$$\Delta w_{14} = \alpha \times x_1 \times \delta_4 = 0.1 \times 1 \times (-0.0147) = -0.0015$$

$$\Delta w_{24} = \alpha \times x_2 \times \delta_4 = 0.1 \times 1 \times (-0.0147) = -0.0015$$

$$\Delta \theta_4 = \alpha \times (-1) \times \delta_4 = 0.1 \times (-1) \times (-0.0147) = 0.0015$$

Finalmente, os pesos e valores de ativação são atualizados:

$$w_{13} = w_{13} + \Delta w_{13} = 0.5 + 0.0038 = 0.5038$$

$$w_{14} = w_{14} + \Delta w_{14} = 0.9 - 0.0015 = 0.8985$$

$$w_{23} = w_{23} + \Delta w_{23} = 0.4 + 0.0038 = 0.4038$$

$$w_{24} = w_{24} + \Delta w_{24} = 1.0 + 0.0015 = 0.9985$$

$$w_{35} = w_{35} + \Delta w_{35} = -1.2 - 0.0067 = -1.2067$$

$$w_{45} = w_{45} + \Delta w_{45} = 1.1 - 0.0112 = 1.0888$$

$$\theta_3 = \theta_3 + \Delta \theta_3 = 0.8 - 0.0038 = 0.7962$$

$$\theta_4 = \theta_4 + \Delta \theta_4 = -0.1 + 0.0015 = -0.0985$$

$$\theta_5 = \theta_5 + \Delta \theta_5 = 0.3 + 0.0127 = 0.3127$$

O processo de treinamento é repetido até a soma dos erros quadráticos atingirem um valor menor que 0.001. A soma dos erros quadráticos é um indicador muito prático referente à performance da rede neural. O algoritmo de treinamento *back-propagation* se esforça em minimizar esse critério.

Quando o valor do erro quadrático for suficientemente pequeno após a influência dos grupos de treinamento ou épocas, é considerado que a rede convergiu. No exemplo acima, esse valor suficientemente pequeno do erro quadrático é definido como sendo menor que 0,001. A Figura A.10 representa a curva de aprendizado: a soma dos erros quadráticos versus o número de épocas usadas no treinamento. A curva de aprendizado mostra quão rápido é o aprendizado da rede neural.




Figura A.10 - Curva de treinamento para a operação OU exclusivo.

Pode-se observar que demorou 224 épocas ou 896 iterações para treinar a rede, para que ela pudesse assim realizar a operação OU exclusivo. A seguir são mostrados os pesos e valores de ativação que satisfazem o critério de erro escolhido:

$$w_{13} = 4,7621, w_{14} = 6.3917, w_{23} = 4.7618, w_{24} = 6.3917, w_{35} = -10.3788,$$

$$w_{45} = 9.7691, \theta_3 = 7.3061, \theta_4 = 2.8441, \theta_5 = 4.5589$$

Agora, após a rede neural ter convergido, pode-se testar a rede apresentando o grupo de treinamento e calculando as saídas da rede. Os resultados são apresentados na Tabela A.4.

Tabela A.4. Resultados finais do aprendizado da rede de três camadas: a operação lógica OU exclusivo

Entradas		Saídas Desejadas	Saída Atual	Erro e	Soma dos Erros Quadráticos
x1	x2	yd	y5		
1	1	0	0.0155	-0,0155	0.001
0	1	1	0.9849	0.0151	
1	0	1	0.9849	0.0151	
0	0	0	0.0175	-0,0175	

A rede obtém pesos e valores de ativação diferentes quando começa com condições iniciais diferentes. De qualquer forma, sempre se resolve o problema, alterando apenas o número de iterações necessárias para a rede convergir.

A Figura A.11 mostra as regiões separadas agora por mais de uma linha. Desta forma, isolou-se o padrão de saída referente ao padrão de entrada, e a rede multicamadas provou ser capaz de representar funções linearmente inseparáveis.




Figura A.11 - Limites de decisão construída pela rede neural: (a) E ($x_1 \cap x_2$); (b) OU ($x_1 \cup x_2$); (c) OU-exclusivo ($x_1 \oplus x_2$)

O aprendizado de uma rede neural artificial costuma ser muito rápido, porém pode-se acelerar esse aprendizado incluindo um termo momento na regra Delta da equação A.9:

$$\Delta w_{jk}(p) = \beta \times \Delta w_{jk}(p-1) + \alpha \times y_j(p) \times \delta_k(p) \quad (\text{A.28})$$

onde β é um número positivo ($0 \leq \beta \leq 1$), chamado de constante momento. Normalmente, essa constante tem o valor de 0,94. A equação A.28 é chamada de regra Delta generalizado. No caso especial em que $\beta = 0$, obtém a equação A.9.

A utilização do momento tem um efeito estabilizador, ou seja, acelera quando o erro tende a cair, e diminui o processo quando a superfície do aprendizado apresenta um pico e vales.

Outro método muito utilizado e muito eficaz para acelerar a convergência do aprendizado via *back-propagation* é através de ajustes na taxa de aprendizado durante o treinamento da rede. Uma taxa de aprendizado α pequena causa pequenas variações nos pesos da rede de uma iteração para outra. Porém, se essa taxa for muito grande, a variação dos pesos pode ser muito grande, gerando instabilidade e, como consequência, a rede pode se tornar oscilatória.

ANEXO B

Tabela B.1 – Detalhamento dos Testes do Primeiro Conjunto de Dados

Número do Teste	Nome do Arquivo	Corrente usada [kA]	Força usada (mm da mola)	Welding Help 0=Sim/1=Não	Uso Eletrodo (pontos)	Força Cisalham. [N]	Notas
1	000100002001	3.7	15,8	0	640	551	
2	000100003001	3.7	15,8	0	641	655	
3	000100004001	3.7	15,8	0	74	659	
4	000100005001	3.7	15,8	0	75	628	
5	000100006001	3.7	15,8	0	76	605	
6	000100007001	3.7	15,8	0	77	646	
7	000100008001	3.7	15,8	0	78	613	
8	000100009001	3.7	15,8	0	79	622	
9	000100010001	3.7	15,8	0	80	611	
10	000100011001	3.7	15,8	0	81	652	
11	000100012001	3.7	15,8	0	82	587	
12	000100013001	3.7	15,8	0	83	629	
13	000100014001	3.7	15,8	0	84	614	
14	000100015001	3.7	15,8	0	85	581	
15	000100016001	3.7	15,8	0	86	570	
16	000100031001	3.7	14,8	0	142	515	
17	000100032001	3.7	14,8	0	143	599	
18	000100033001	3.7	14,8	0	144	544	
19	000100034001	3.7	14,8	0	145	616	
20	000100035001	3.7	14,8	0	146	552	
21	000100036001	3.7	14,8	0	147	570	
22	000100037001	3.7	14,8	0	148	588	
23	000100038001	3.7	14,8	0	149	600	
24	000100039001	3.7	14,8	0	150	536	
25	000100040001	3.7	14,8	0	151	555	
26	000100041001	3.7	14,8	0	152	617	
27	000100042001	3.7	14,8	0	153	618	
28	000100043001	3.7	14,8	0	154	565	
29	000100044001	3.7	14,8	0	155	563	
30	000100045001	3.7	14,8	0	156	616	
31	000100061001	3.7	14,3	0	157	558	
32	000100062001	3.7	14,3	0	158	582	
33	000100063001	3.7	14,3	0	159	507	
34	000100064001	3.7	14,3	0	160	536	
35	000100065001	3.7	14,3	0	161	526	
36	000100066001	3.7	14,3	0	162	577	
37	000100067001	3.7	14,3	0	163	518	
38	000100068001	3.7	14,3	0	164	597	
39	000100069001	3.7	14,3	0	165	494	
40	000100070001	3.7	14,3	0	166	560	
41	000100071001	3.7	14,3	0	167	551	
42	000100072001	3.7	14,3	0	168	604	
43	000100073001	3.7	14,3	0	169	505	

44	000100074001	3.7	14,3	0	170	517	
45	000100075001	3.7	14,3	0	171	531	
46	000100091001	3.7	13,8	0	172	451	
47	000100092001	3.7	13,8	0	173	505	
48	000100093001	3.7	13,8	0	174	544	
49	000100094001	3.7	13,8	0	175	530	
50	000100095001	3.7	13,8	0	176	529	
51	000100096001	3.7	13,8	0	177	535	
52	000100097001	3.7	13,8	0	178	553	
53	000100098001	3.7	13,8	0	179	520	
54	000100099001	3.7	13,8	0	180	526	
55	000100100001	3.7	13,8	0	181	444	
56	000100101001	3.7	13,8	0	182	496	
57	000100102001	3.7	13,8	0	183	448	
58	000100103001	3.7	13,8	0	184	535	
59	000100104001	3.7	13,8	0	185	546	
60	000100105001	3.7	13,8	0	186	488	
61	000100121001	3.7	13,3	0	187	557	
62	000100122001	3.7	13,3	0	188	493	
63	000100123001	3.7	13,3	0	189	557	
64	000100124001	3.7	13,3	0	190	496	
65	000100125001	3.7	13,3	0	191	503	
66	000100126001	3.7	13,3	0	222	448	
67	000100127001	3.7	13,3	0	223	538	
68	000100128001	3.7	13,3	0	224	528	
69	000100129001	3.7	13,3	0	225	491	
70	000100130001	3.7	13,3	0	226		falha
71	000100131001	3.7	13,3	0	227	530	
72	000100132001	3.7	13,3	0	228	520	
73	000100133001	3.7	13,3	0	229		falha
74	000100134001	3.7	13,3	0	230	480	
75	000100135001	3.7	13,3	0	231	519	
76	000100151001	3.7	15,8	0	232	572	
77	000100152001	3.7	15,8	0	233	598	
78	000100153001	3.7	15,8	0	234	649	
79	000100154001	3.7	15,8	0	235	588	
80	000100155001	3.7	15,8	0	236	596	
81	000100156001	3.7	15,8	0	237	629	
82	000100157001	3.7	15,8	0	238	628	
83	000100158001	3.7	15,8	0	239	609	
84	000100159001	3.7	15,8	0	240	575	
85	000100160001	3.7	15,8	0	241	645	
86	000100161001	3.7	15,8	0	242	573	
87	000100162001	3.7	15,8	0	243	632	
88	000100163001	3.7	15,8	0	244	565	
89	000100164001	3.7	15,8	0	245	606	
90	000100165001	3.7	15,8	0	246	572	
91	000100181001	3.5	15,8	0	247	514	
92	000100182001	3.5	15,8	0	248	558	
93	000100183001	3.5	15,8	0	249	575	
94	000100184001	3.5	15,8	0	250	582	
95	000100185001	3.5	15,8	0	251	548	
96	000100186001	3.5	15,8	0	252	554	
97	000100187001	3.5	15,8	0	253	559	

98	000100188001	3.5	15,8	0	254	575	
99	000100189001	3.5	15,8	0	255	567	
100	000100190001	3.5	15,8	0	256	530	
101	000100191001	3.5	15,8	0	272	601	
102	000100192001	3.5	15,8	0	273	568	
103	000100193001	3.5	15,8	0	274	543	
104	000100194001	3.5	15,8	0	275	570	
105	000100195001	3.5	15,8	0	276	534	
106	000100211001	3.2	15,8	0	277	484	
107	000100212001	3.2	15,8	0	278	479	
108	000100213001	3.2	15,8	0	279	450	
109	000100214001	3.2	15,8	0	280	493	
110	000100215001	3.2	15,8	0	281	481	
111	000100216001	3.2	15,8	0	282	453	
112	000100217001	3.2	15,8	0	283	439	
113	000100218001	3.2	15,8	0	284	458	
114	000100219001	3.2	15,8	0	285	502	
115	000100220001	3.2	15,8	0	286	456	
116	000100221001	3.2	15,8	0	287	462	
117	000100222001	3.2	15,8	0	288	495	
118	000100223001	3.2	15,8	0	289	452	
119	000100224001	3.2	15,8	0	290	485	
120	000100225001	3.2	15,8	0	291	476	
121	000100241001	2.8	15,8	0	292		falha
122	000100242001	2.8	15,8	0	293	383	
123	000100243001	2.8	15,8	0	294	364	
124	000100244001	2.8	15,8	0	295	338	
125	000100245001	2.8	15,8	0	296	405	
126	000100246001	2.8	15,8	0	297	367	
127	000100247001	2.8	15,8	0	298	383	
128	000100248001	2.8	15,8	0	299	340	
129	000100249001	2.8	15,8	0	300	415	
130	000100250001	2.8	15,8	0	301	364	
131	000100251001	2.8	15,8	0	322	356	
132	000100252001	2.8	15,8	0	323	347	
133	000100253001	2.8	15,8	0	324	353	
134	000100254001	2.8	15,8	0	325	355	
135	000100255001	2.8	15,8	0	326	376	
136	000100271001	2.4	15,8	0	327	226	
137	000100272001	2.4	15,8	0	328	240	
138	000100273001	2.4	15,8	0	329	302	
139	000100274001	2.4	15,8	0	330	287	
140	000100275001	2.4	15,8	0	331	268	
141	000100276001	2.4	15,8	0	332	227	
142	000100277001	2.4	15,8	0	333	284	
143	000100278001	2.4	15,8	0	334	266	
144	000100279001	2.4	15,8	0	335	211	
145	000100280001	2.4	15,8	0	336	228	
146	000100281001	2.4	15,8	0	337	225	
147	000100282001	2.4	15,8	0	338	293	
148	000100283001	2.4	15,8	0	339	250	
149	000100284001	2.4	15,8	0	340	256	
150	000100285001	2.4	15,8	0	341	235	
151	000100301001	3.7	15,8	0	342	593	

152	000100302001	3.7	15,8	0	343	568
153	000100303001	3.7	15,8	0	344	548
154	000100304001	3.7	15,8	0	345	613
155	000100305001	3.7	15,8	0	346	618
156	000100306001	3.7	15,8	0	347	566
157	000100307001	3.7	15,8	0	348	576
158	000100308001	3.7	15,8	0	349	641
159	000100309001	3.7	15,8	0	350	602
160	000100310001	3.7	15,8	0	351	562
161	000100311001	3.7	15,8	0	352	574
162	000100312001	3.7	15,8	0	353	591
163	000100313001	3.7	15,8	0	354	576
164	000100314001	3.7	15,8	0	355	604
165	000100315001	3.7	15,8	0	356	616
166	000100331001	3.7	15,8	1	357	580
167	000100332001	3.7	15,8	1	358	465
168	000100333001	3.7	15,8	1	359	502
169	000100334001	3.7	15,8	1	360	526
170	000100335001	3.7	15,8	1	361	536
171	000100336001	3.7	15,8	1	362	591
172	000100337001	3.7	15,8	1	363	575
173	000100338001	3.7	15,8	1	364	539
174	000100339001	3.7	15,8	1	365	502
175	000100340001	3.7	15,8	1	366	565
176	000100341001	3.7	15,8	1	367	465
177	000100342001	3.7	15,8	1	368	496
178	000100343001	3.7	15,8	1	369	461
179	000100344001	3.7	15,8	1	370	458
180	000100345001	3.7	15,8	1	371	427
181	000100346001	3.7	15,8	1	372	455
182	000100347001	3.7	15,8	1	373	431
183	000100348001	3.7	15,8	1	374	439
184	000100349001	3.7	15,8	1	375	405
185	000100350001	3.7	13,8	1	376	420

Tabela B.2 – Detalhamento dos Testes do Segundo Conjunto de Dados

Número do Teste	Nome do Arquivo	Corrente usada [kA]	Força usada (mm da mola)	Welding Help 0=Sim/1=Não	Uso Eletrodo (pontos)	Força Cisalham. [N]	Notas
1	00100002001	3,7	15,8	1	1	654	
2	00100003001	3,7	15,8	1	2	711	
3	00100004001	3,7	15,8	1	3	679	
4	00100005001	3,7	15,8	1	4	589	
5	00100006001	3,7	15,8	1	5	733	
6	00100007001	3,7	15,8	1	6	665	
7	00100008001	3,7	15,8	1	7	643	
8	00100009001	3,7	15,8	1	8	664	
9	00100010001	3,7	15,8	1	9	669	
10	00100011001	3,7	15,8	1	10	693	
11	00100012001	3,7	15,8	1	11	605	
12	00100013001	3,7	15,8	1	12	615	
13	00100014001	3,7	15,8	1	13	577	
14	00100015001	3,7	15,8	1	14	728	
15	00100016001	3,7	15,8	1	15	642	
16	00100044001	3,7	14,8	1	43	624	
17	00100045001	3,7	14,8	1	44	618	
18	00100046001	3,7	14,8	1	45	514	
19	00100047001	3,7	14,8	1	46	594	
20	00100048001	3,7	14,8	1	47	652	
21	00100049001	3,7	14,8	1	48	622	
22	00100050001	3,7	14,8	1	49	555	
23	00100051001	3,7	14,8	1	50	549	
24	00100052001	3,7	14,8	1	51		falha
25	00100053001	3,7	14,8	1	52	571	
26	00100054001	3,7	14,8	1	53	630	
27	00100055001	3,7	14,8	1	54	529	
28	00100056001	3,7	14,8	1	55	546	
29	00100057001	3,7	14,8	1	56	617	
30	00100058001	3,7	14,8	1	57	615	
31	00100070001	3,7	14,3	1	69	475	
32	00100071001	3,7	14,3	1	70	594	
33	00100072001	3,7	14,3	1	71	574	
34	00100073001	3,7	14,3	1	72	539	
35	00100074001	3,7	14,3	1	73	533	
36	00100075001	3,7	14,3	1	74	609	
37	00100076001	3,7	14,3	1	75	584	
38	00100077001	3,7	14,3	1	76	516	
39	00100078001	3,7	14,3	1	77	463	
40	00100079001	3,7	14,3	1	78	514	
41	00100080001	3,7	14,3	1	79	615	
42	00100081001	3,7	14,3	1	80	561	
43	00100082001	3,7	14,3	1	81	542	
44	00100083001	3,7	14,3	1	82	515	
45	00100084001	3,7	14,3	1	83	622	
46	00100096001	3,7	13,8	1	95	428	

47	00100097001	3,7	13,8	1	96	513
48	00100098001	3,7	13,8	1	97	524
49	00100099001	3,7	13,8	1	98	542
50	00100100001	3,7	13,8	1	99	509
51	00100101001	3,7	13,8	1	100	443
52	00100102001	3,7	13,8	1	101	543
53	00100103001	3,7	13,8	1	102	583
54	00100104001	3,7	13,8	1	103	530
55	00100105001	3,7	13,8	1	104	482
56	00100106001	3,7	13,8	1	105	462
57	00100107001	3,7	13,8	1	106	517
58	00100108001	3,7	13,8	1	107	539
59	00100109001	3,7	13,8	1	108	555
60	00100110001	3,7	13,8	1	109	486
61	00100122001	3,7	13,3	1	121	498
62	00100123001	3,7	13,3	1	122	482
63	00100124001	3,7	13,3	1	123	431
64	00100125001	3,7	13,3	1	124	488
65	00100126001	3,7	13,3	1	125	518
66	00100127001	3,7	13,3	1	126	508
67	00100128001	3,7	13,3	1	127	492
68	00100129001	3,7	13,3	1	128	411
69	00100130001	3,7	13,3	1	129	521
70	00100131001	3,7	13,3	1	130	554
71	00100132001	3,7	13,3	1	131	496
72	00100133001	3,7	13,3	1	132	492
73	00100134001	3,7	13,3	1	133	456
74	00100135001	3,7	13,3	1	134	508
75	00100136001	3,7	13,3	1	135	514
76	00100148001	3,7	16,8	1	147	669
77	00100149001	3,7	16,8	1	148	688
78	00100150001	3,7	16,8	1	149	658
79	00100151001	3,7	16,8	1	150	648
80	00100152001	3,7	16,8	1	151	640
81	00100153001	3,7	16,8	1	152	653
82	00100154001	3,7	16,8	1	153	624
83	00100155001	3,7	16,8	1	154	698
84	00100156001	3,7	16,8	1	155	615
85	00100157001	3,7	16,8	1	156	666
86	00100158001	3,7	16,8	1	157	679
87	00100159001	3,7	16,8	1	158	643
88	00100160001	3,7	16,8	1	159	643
89	00100161001	3,7	16,8	1	160	657
90	00100162001	3,7	16,8	1	161	653
91	00100174001	3,7	15,8	1	173	543
92	00100175001	3,7	15,8	1	174	582
93	00100176001	3,7	15,8	1	175	645
94	00100177001	3,7	15,8	1	176	602
95	00100178001	3,7	15,8	1	177	643
96	00100179001	3,7	15,8	1	178	575
97	00100180001	3,7	15,8	1	179	638
98	00100181001	3,7	15,8	1	180	667
99	00100182001	3,7	15,8	1	181	633
100	00100183001	3,7	15,8	1	182	615

101	00100184001	3,7	15,8	1	183	583	
102	00100185001	3,7	15,8	1	184	607	
103	00100186001	3,7	15,8	1	185	633	
104	00100187001	3,7	15,8	1	186	639	
105	00100188001	3,7	15,8	1	187	571	
106	00100200001	3,5	15,8	1	199	571	
107	00100201001	3,5	15,8	1	200	570	
108	00100202001	3,5	15,8	1	201	538	
109	00100203001	3,5	15,8	1	202	500	
110	00100204001	3,5	15,8	1	203	585	
111	00100205001	3,5	15,8	1	204		falha
112	00100206001	3,5	15,8	1	205	578	
113	00100207001	3,5	15,8	1	206	490	
114	00100208001	3,5	15,8	1	207	539	
115	00100209001	3,5	15,8	1	208	602	
116	00100210001	3,5	15,8	1	209	638	
117	00100211001	3,5	15,8	1	210	550	
118	00100212001	3,5	15,8	1	211	532	
119	00100213001	3,5	15,8	1	212	528	
120	00100214001	3,5	15,8	1	213	578	
121	00100226001	3,2	15,8	1	225	434	
122	00100227001	3,2	15,8	1	226	499	
123	00100228001	3,2	15,8	1	227	527	
124	00100229001	3,2	15,8	1	228	468	
125	00100230001	3,2	15,8	1	229	450	
126	00100231001	3,2	15,8	1	230	446	
127	00100232001	3,2	15,8	1	231	470	
128	00100233001	3,2	15,8	1	232	512	
129	00100234001	3,2	15,8	1	233	441	
130	00100235001	3,2	15,8	1	234	434	
131	00100236001	3,2	15,8	1	235	522	
132	00100237001	3,2	15,8	1	236	521	
133	00100238001	3,2	15,8	1	237	489	
134	00100239001	3,2	15,8	1	238	456	
135	00100240001	3,2	15,8	1	239	415	
136	00100252001	2,8	15,8	1	251	368	
137	00100253001	2,8	15,8	1	252	366	
138	00100254001	2,8	15,8	1	253	404	
139	00100255001	2,8	15,8	1	254	363	
140	00100256001	2,8	15,8	1	255	412	
141	00100257001	2,8	15,8	1	256	364	
142	00100258001	2,8	15,8	1	257	352	
143	00100259001	2,8	15,8	1	258	378	
144	00100260001	2,8	15,8	1	259	412	
145	00100261001	2,8	15,8	1	260	378	
146	00100262001	2,8	15,8	1	261	347	
147	00100263001	2,8	15,8	1	262	269	
148	00100264001	2,8	15,8	1	263	363	
149	00100265001	2,8	15,8	1	264	422	
150	00100266001	2,8	15,8	1	265	367	
151	00100278001	2,4	15,8	1	277	258	
152	00100279001	2,4	15,8	1	278	300	
153	00100280001	2,4	15,8	1	279	235	
154	00100281001	2,4	15,8	1	280	260	

155	00100282001	2,4	15,8	1	281	315	
156	00100283001	2,4	15,8	1	282	303	
157	00100284001	2,4	15,8	1	283	291	
158	00100285001	2,4	15,8	1	284	260	
159	00100286001	2,4	15,8	1	285	269	
160	00100287001	2,4	15,8	1	286	266	
161	00100288001	2,4	15,8	1	287	296	
162	00100289001	2,4	15,8	1	288	222	
163	00100290001	2,4	15,8	1	289	242	
164	00100291001	2,4	15,8	1	290	269	
165	00100292001	2,4	15,8	1	291	257	
166	00100304001	4	15,8	1	303	661	
167	00100305001	4	15,8	1	304	666	
168	00100306001	4	15,8	1	305	761	
169	00100307001	4	15,8	1	306	615	
170	00100308001	4	15,8	1	307	603	
171	00100309001	4	15,8	1	308	657	
172	00100310001	4	15,8	1	309	689	
173	00100311001	4	15,8	1	310	684	
174	00100312001	4	15,8	1	311	610	
175	00100313001	4	15,8	1	312	600	
176	00100314001	4	15,8	1	313	683	
177	00100315001	4	15,8	1	314	672	
178	00100316001	4	15,8	1	315	603	
179	00100317001	4	15,8	1	316	604	
180	00100318001	4	15,8	1	317	615	
181	00100330001	3,8	15,8	1	329	572	
182	00100331001	3,8	15,8	1	330	565	
183	00100332001	3,8	15,8	1	331	588	
184	00100333001	3,8	15,8	1	332	593	
185	00100334001	3,8	15,8	1	333	607	
186	00100335001	3,8	15,8	1	334	547	
187	00100336001	3,8	15,8	1	335	551	
188	00100337001	3,8	15,8	1	336	615	
189	00100338001	3,8	15,8	1	337	620	
190	00100339001	3,8	15,8	1	338	594	
191	00100340001	3,8	15,8	1	339	555	
192	00100341001	3,8	15,8	1	340	594	
193	00100342001	3,8	15,8	1	341	597	
194	00100343001	3,8	15,8	1	342	637	
195	00100344001	3,8	15,8	1	343	574	
196	00100360001	3,8	15,8	0	359	599	
197	00100361001	3,8	15,8	0	360	522	
198	00100362001	3,8	15,8	0	361	586	
199	00100363001	3,8	15,8	0	362	562	
200	00100364001	3,8	15,8	0	363	481	
201	00100365001	3,8	15,8	0	364	413	
202	00100366001	3,8	15,8	0	365	533	
203	00100367001	3,8	15,8	0	366		falha
204	00100368001	3,8	15,8	0	367	507	
205	00100369001	3,8	15,8	0	368	601	
206	00100370001	3,8	15,8	0	369	521	
207	00100371001	3,8	15,8	0	370	578	
208	00100372001	3,8	15,8	0	371	390	

209	00100373001	3,8	15,8	0	372	529	
210	00100374001	3,8	15,8	0	373	546	
211	00100420001	3,8	15,8	1	419	533	
212	00100421001	3,8	15,8	1	420	534	
213	00100422001	3,8	15,8	1	421	562	
214	00100423001	3,8	15,8	1	422	572	
215	00100424001	3,8	15,8	1	423	552	
216	00100425001	3,8	15,8	1	424	508	
217	00100426001	3,8	15,8	1	425	520	
218	00100427001	3,8	15,8	1	426	543	
219	00100428001	3,8	15,8	1	427		falha
220	00100429001	3,8	15,8	1	428		falha
221	00100430001	3,8	15,8	1	429		falha
222	00100431001	3,8	15,8	1	430	577	
223	00100432001	3,8	15,8	1	431	590	
224	00100433001	3,8	15,8	1	432	566	
225	00100434001	3,8	15,8	1	433	538	
226	00102960001	3,8	15,8	1	2959	570	
227	00102961001	3,8	15,8	1	2960	587	
228	00102962001	3,8	15,8	1	2961	567	
229	00102963001	3,8	15,8	1	2962	585	
230	00102964001	3,8	15,8	1	2963	680	
231	00102965001	3,8	15,8	1	2964	629	
232	00102966001	3,8	15,8	1	2965	552	
233	00102967001	3,8	15,8	1	2966	538	
234	00102968001	3,8	15,8	1	2967	679	
235	00102969001	3,8	15,8	1	2968	574	
236	00102970001	3,8	15,8	1	2969	587	
237	00102971001	3,8	15,8	1	2970	536	
238	00102972001	3,8	15,8	1	2971	561	
239	00102973001	3,8	15,8	1	2972	682	
240	00102974001	3,8	15,8	1	2973	606	