

Auto-Calibração e Linearização de Sensores Utilizando Técnicas de Inteligência Computacional

Sílvia Grasiella Moreira Almeida

Dissertação submetida à
Escola de Engenharia
da Universidade Federal de Minas Gerais
para obtenção do título de Mestre em Engenharia Elétrica

*Dedico este trabalho aos meus pais, Gilvaldo e Amparo, ambos exemplos de coragem,
determinação e bondade para minha vida.*

Auto-Calibração e Linearização de Sensores Utilizando Técnicas de Inteligência Computacional

Resumo

Neste trabalho é proposto um sistema que seja capaz de realizar a calibração automática e linearização de sensores em um equipamento que une soluções em *hardware* e *software*. O *hardware* desenvolvido faz a leitura e condicionamento dos sinais dos sensores a serem linearizados. Já a solução implementada em *software* apresenta o treinamento multiobjetivo das redes neurais artificiais de funções de base radiais para realizar a linearização da curva sinais de entrada *versus* sinais de saída de sensores. Os pesos da rede neural são determinados por meio da técnica de mínimos quadrados multiobjetivo. Variando-se a largura das funções de base, diferentes conjuntos de Pareto são obtidos. Utiliza-se a técnica de decisão baseada em regressão linear sobre o conjunto de pontos não dominados para a escolha da solução que apresente a estrutura de rede mais adequada ao problema. A vantagem do treinamento multiobjetivo no contexto de linearização de sensores é determinar uma rede adequada para o problema e que apresente baixa complexidade estrutural, reduzindo, assim, o custo de implementação em *hardware*. São apresentados, em seguida, quatro experimentos realizados em laboratório para validação do algoritmo de treinamento da rede neural. Os três primeiros experimentos são realizados a partir da medição da variável temperatura em faixas distintas de operação e o quarto experimento é realizado a partir da medição do sinal de tensão gerado em uma balança capacitiva. São apresentadas também as soluções de treinamento mono-objetivo para os quatro experimentos e comparações entre as soluções mono-objetivo e multiobjetivo. Os resultados obtidos mostram que a metodologia proposta é adequada ao problema de linearização, permitindo a escolha de uma estrutura com menor custo de implementação.

Self-Calibration and Linearization of Sensors Using Computational Intelligence Techniques

Abstract

In this work, a general system for self-calibration and linearization of sensors is proposed, involving hardware and software solutions. The hardware is responsible for the data acquisition and signal conditioning. The software solution employs radial basis function neural networks for the linearization of the input-output relationship of a temperature sensor (thermocouple), trained with multiobjective least square method. By varying the width of the radial basis function, different Pareto sets are obtained. A decision-making strategy over the nondominated set is proposed based on linear regression, in order to choose the network with best structure for the problem. The advantage of multiobjective learning in the context of sensor linearization is providing an adequate network for the problem that also presents low structural complexity, reducing the hardware implementation cost. Four experiments are presented for the validation of the multiobjective learning algorithm. The three first experiments involve temperature sensors in different ranges of operation. The fourth experiment involves a capacitive balance, in which the voltage is related to the variation of the capacitance. The results show that the proposed methodology is suitable for the linearization problem, allowing the selection of a neural network structure with a low implementation cost.

Agradecimentos

Neste momento, em que páginas e mais páginas foram escritas sobre um tema científico, temo que este espaço não seja suficiente para que eu expresse o que me proponho neste momento: meus agradecimentos. Porque não são poucas as pessoas que nos ajudam em todos os momentos da nossa vida. Nós que não damos a devida atenção a todas, mas estão sempre ali, servindo de alicerce para que continuemos edificando nossa construção pessoal e profissional.

Não há, portanto, primeiros ou últimos agradecimentos. Há agradecimentos a todos que, igualmente, foram responsáveis pela conclusão deste trabalho.

Agradeço a *papai e mamãe*, que me ensinaram e me permitiram seguir o caminho que escolhesse, e tornaram a minha caminhada o mais suave possível, de todas as formas. Que são exemplos de perseverança e de que na vida não há limites além do que nós mesmos criamos.

Agradeço às minhas irmãs, *Giselle, Carla e Priscilla*, cheias de personalidade e que são capazes de enfrentar todas as adversidades com tranquilidade e, principalmente, objetividade.

Aos meus sobrinhos do coração, *Matheus, Bruna e João*, que me permitem trazer de volta as minhas lembranças de infância e adolescência e do quanto é bom viver.

Aos meus grandes mestres, hoje colegas do Instituto Federal de Minas Gerais, Ouro Preto, e que, desde a antiga Escola Técnica Federal de Ouro Preto, me ensinam que ser educador é mais do que simplesmente lecionar disciplinas, é ser amigo, companheiro, é ser um pouco pai. Sintam-se, cada um de vocês, homenageados aqui, em especial *Ronaldo e Paulinho*, sempre disponíveis para me ajudar com a minha falta de prática!

Aos meus alunos, a quem tanto estimo, respeito e com quem tanto me preocupo.

Vocês me fazem mudar a cada aula, tentar me reinventar para compreender e atender vocês.

A minha amiga *Denise*, uma irmã que encontrei ao longo da vida e que, com sua tranquilidade e paciência, me ampara nos momentos em que parece que o chão está se abrindo diante dos meus pés.

Ao meu grande amigo e co-orientador *Frederico*, que já assumiu o papel de me orientar pela vida há muito tempo, e o faz de forma que só tenho a agradecer por ter um amigo assim na minha vida. Fred, você é o cara!

Ao meu professor e orientador *Jaime Arturo Ramírez*, que conheci em uma aula de Programação Orientada a Objetos, no ano de 2000, e desde então tem sido o melhor orientador que eu poderia ter: sábio, sensato, educado, correto. E que, de forma sempre gentil, me ensina os caminhos da ciência e compartilha comigo seus conhecimentos.

Agradeço ao IFMG - Campus Ouro Preto, minha fonte de energia e minha segunda casa, pelo apoio aos meus estudos.

Agradeço ao PPGEE, secretárias *Arlete* e *Anete*, coordenador *Hani Camile Yehia*, que nunca mediram esforços para me ajudar em todas as minhas solicitações.

Agradeço muitíssimo a todos aqueles que, por falta de espaço, não consigo citar aqui: amigos, parentes, colegas e professores do CPDEE.

Finalizo agradecendo a Deus, que me deu a vida e ofereceu-me caminhos ao longo dela. Caminhos que sempre segui cercada de pessoas que amo e que tem me permitido escrever a minha própria história.

Meu *Muito Obrigada!*

Sumário

Lista de Figuras	xiii
Lista de Tabelas	xv
Nomenclatura	1
1 Introdução	3
1.1 Introdução	3
1.2 Justificativa	4
1.3 Objetivos	8
1.3.1 Aquisição de Dados	9
1.3.2 Implementação do treinamento multiobjetivo da Rede Neural	9
1.3.3 Decisão sobre a rede ótima a ser implementada	9
1.4 Revisão Bibliográfica	10
1.5 Organização do Texto	14
2 Medição de Temperatura por meio de Termopares	17
2.1 Medição de Temperatura	17
2.1.1 Escalas de Temperatura	18
2.1.2 Medidores de Temperatura	21

2.2	Termopares	22
2.2.1	Leis Fundamentais dos Circuitos Termoelétricos	25
2.2.2	Sistemas de Medição utilizando Termopares	27
2.2.3	Tipos e Características de Termopares Comerciais	29
2.3	Conclusão	29
3	Redes Neurais Artificiais	31
3.1	Redes Neurais Artificiais	31
3.1.1	Características de Redes Neurais Artificiais	32
3.2	Redes de Funções de Base Radiais	37
3.3	Treinamento das Redes de Funções de Base Radiais	40
3.3.1	Treinamento Supervisionado	40
3.3.2	Treinamento Semi-Supervisionado	41
3.3.3	Treinamento Multiobjetivo	43
3.4	Conclusão	46
4	Sistema de Linearização e Calibração de Sensores	47
4.1	Introdução	48
4.2	Aquisição dos Dados	49
4.3	Treinamento da Rede Neural	53
4.3.1	Topologia Série	53
4.3.2	Topologia Paralela	55
4.3.3	Treinamento da rede RBF	57
4.3.4	Critério de Decisão	59
4.4	Conclusão	62

5	Resultados	63
5.1	Introdução	63
5.2	Experimento 1: Termopar - Dados de benchmark	65
5.2.1	Aquisição de dados	66
5.2.2	Simulação	66
5.2.3	Resultados	67
5.2.4	Discussão	69
5.3	Experimento 2: Termopar - Medição de altas temperaturas	70
5.3.1	Montagem	70
5.3.2	Aquisição de dados	70
5.3.3	Resultados	71
5.3.4	Discussão	75
5.4	Experimento 3: Termopar - Medição de médias temperaturas	76
5.4.1	Montagem	76
5.4.2	Aquisição de dados	77
5.4.3	Resultados	78
5.4.4	Discussões	79
5.5	Experimento 4: Balança Capacitiva de Precisão	80
5.5.1	Montagem	80
5.5.2	Aquisição de dados	82
5.5.3	Resultados	82
5.5.4	Discussão	85
5.6	Conclusão	85
6	Conclusões	89

6.1	Conclusões	89
6.2	Trabalhos Futuros	93
A	Apêndice	95
A.1	Datasheets dos Circuitos Eletrônicos	95
A.1.1	Microcontrolador PIC 18F4550	95
A.1.2	Amplificador LM324	95
A.1.3	Módulo ECIO-40P	95
	Referências Bibliográficas	101

Lista de Figuras

1.1	Curvas características de termopares constituídos por Metais Nobres e Metais Base. 1.Pt vs Au-9Ni. 2.Mo-lat.Ru vs W-25Re. 3.Ni-10at.Ru vs W-25Re. 4.Re-20Ir vs Ir. 5.Re-10Ir vs Ir.	6
1.2	Curvas características de termopares constituídos por Metais Nobres e Platina, VII. 1.Pt vs Co-6Al. 2.Pt vs Co-40Ni. 3.Pt vs Co-25Ni. 4. Pt vs Co-30Fe. 5.Pt vs Co-15Fe.	6
1.3	Curvas características de termopares constituídos por Tungstênio e ligas Tungstênio-Molibdênio. 1.W-5Mo vs W. 2.W vs W-15Mo. 3.W vs W-25Mo. 4.W vs W-35Mo. 5.W vs W-50Mo.	7
2.1	Representação do Efeito Seebeck: (a) Circuito fechado. (b) Fem gerada pela diferença de temperatura.	23
2.2	Representação do Efeito Peltier	24
2.3	Representação do Efeito Thomson	24
2.4	Lei do Circuito Homogêneo	25
2.5	Lei dos Metais Intermediários	26
2.6	Lei da Temperatura Intermediária	27
3.1	Representação do neurônio biológico	33
3.2	Representação do neurônio artificial	34
3.3	Rede alimentada adiante ou acíclica com uma única camada de neurônios	36

3.4	Rede alimentada adiante ou acíclica totalmente conectada com uma camada oculta e uma camada de saída	37
3.5	Rede recorrente com realimentação	37
3.6	Arquitetura de uma rede RBF	38
3.7	Fluxograma do funcionamento do algoritmo K-Médias	43
3.8	Gráfico de Pareto	45
4.1	Esquemático do sistema implementado para auto-calibração e linearização de sensores	49
4.2	Sistema implementado para auto-calibração e linearização dos sensores .	50
4.3	Funcionamento do sistema durante a etapa de auto-calibração	50
4.4	Programa do microcontrolador para conversão Analógico-Digital	52
4.5	Especificações do Microcontrolador PIC18F4550	52
4.6	Topologia Série	54
4.7	Função Inversa	54
4.8	Topologia Paralela	55
4.9	Programa de treinamento da Rede RBF	60
4.10	Fluxograma do Treinamento da Rede Neural	61
4.11	Funcionamento do sistema durante a etapa de linearização	61
5.1	Dados do sensor a ser linearizado - Experimento 1	66
5.2	Soluções ótimas de treinamento mono-objetivo para valores de 10, 30 e 50 neurônios. Cada gráfico apresenta a melhor das dez soluções ótimas mono-objetivo, resultantes das dez variações das larguras σ das funções de base radiais.	67
5.3	Soluções ótimas de treinamento multiobjetivo	68
5.4	Rede linearizada escolhida pelo Decisor - Experimento 1	68

5.5	Experimento 2 - Leitura da temperatura em forno para queima de material	71
5.6	Dados do sensor a ser linearizado - Experimento 2	72
5.7	Soluções ótimas de treinamento mono-objetivo para valores de 10, 30 e 50 neurônios. Cada gráfico apresenta a melhor das dez soluções ótimas mono-objetivo, resultantes das dez variações das larguras σ das funções de base radiais.	73
5.8	Soluções ótimas de treinamento multiobjetivo	73
5.9	Rede linearizada escolhida pelo Decisor - Experimento 2	74
5.10	Soluções ótimas de treinamento multiobjetivo para 100 e 200 neurônios .	74
5.11	Sistema de aquecimento por estufa	76
5.12	Dados do sensor a ser linearizado - Experimento 3	77
5.13	Soluções ótimas de treinamento mono-objetivo para valores de 10, 30 e 50 neurônios. Cada gráfico apresenta a melhor das dez soluções ótimas mono-objetivo, resultantes das dez variações das larguras σ das funções de base radiais.	78
5.14	Soluções ótimas de treinamento multiobjetivo	79
5.15	Rede Linearizada escolhida pelo Decisor - Experimento 3	79
5.16	Balança de precisão capacitiva	81
5.17	Circuito eletrônico para medição da tensão	81
5.18	Pesos utilizados para medição no Experimento 4	82
5.19	Dados do sensor a ser linearizado - Experimento 4	83
5.20	Soluções ótimas de treinamento mono-objetivo para valores de 10, 30 e 50 neurônios. Cada gráfico apresenta a melhor das dez soluções ótimas mono-objetivo, resultantes das dez variações das larguras σ das funções de base radiais.	83
5.21	Soluções ótimas de treinamento multiobjetivo	84
5.22	Rede linearizada escolhida pelo Decisor - Experimento 4	84

A.1	Datasheet PIC 18F4550 - Página 1	96
A.2	Datasheet PIC 18F4550 - Página 2	97
A.3	Datasheet LM324 - Página 1	98
A.4	Datasheet LM324 - Página 2	99
A.5	Módulo ECIO - 40P	100

Lista de Tabelas

2.1	Principais pontos fixos de temperatura definidos pela ITS-90.	20
2.2	Classificação dos medidores de temperatura de acordo com o contato . . .	22
5.1	Comparação entre as soluções mono-objetivo para o Experimento 1	69
5.2	Comparação entre as soluções multiobjetivo para o Experimento 1	69
5.3	Comparação entre as soluções mono-objetivo para o Experimento 2	75
5.4	Comparação entre as soluções multiobjetivo para o Experimento 2	75
5.5	Comparação entre as soluções mono-objetivo para o Experimento 3	80
5.6	Comparação entre as soluções multiobjetivo para o Experimento 3	80
5.7	Comparação entre as soluções mono-objetivo para o Experimento 4	85
5.8	Comparação entre as soluções multiobjetivo para o Experimento 4	85

Nomenclatura

σ	Largura da função de base radial
μ	Centro da função de base radial
\mathbf{x}	Padrões de entrada da rede
\mathbf{t}	Padrões de saída da rede - valor a ser alcançado
$\mathbf{f}(\cdot)$	Saída da rede neural
$\mathbf{g}(\cdot)$	Função do sensor
$\mathbf{v}(\cdot)$	Função do sensor com ruído
\mathbf{m}	Quantidade de neurônios da camada escondida da RBF
λ	Variação do peso no método P- λ
N	Quantidade de padrões de entrada da rede
\mathbf{w}	Pesos da rede neural
Φ	Matriz de regressores
T	Temperatura a ser medida
T_R	Temperatura de referência
I	Matriz Identidade
ϵ	Valor mínimo de poda dos pesos
S_{AB}	coeficiente de <i>Seebeck</i>
ϵ_{AB}	tensão <i>Seebeck</i>
Φ_{AB}	Coeficiente de <i>Peltier</i>
\mathbf{I}	Corrente elétrica
\mathbf{Q}	Calor
σ_A	Coeficiente de <i>Thomson</i>

$C(w)$	Função de custo
$f_1(x)$	Função erro
$f_2(x)$	Função complexidade
δ_1	Ruído do sensor a ser linearizado
δ_2	Ruído do sensor de referência
$\varphi(\cdot)$	Função de ativação de um neurônio
ν	Potencial de ativação do neurônio
$\hat{f}(x)$	Função aproximada
ξ	Erro quadrático médio
Γ	Conjunto de pontos de treinamento
\mathbf{E}	Tensão gerada pelo termopar
fem	Força eletromotriz

Capítulo 1

Introdução

1.1 Introdução

A atuação da automação aplicada às indústrias de processo químico-metalúrgicas, químicas, petroquímicas, farmacêuticas e alimentícias tem por objetivo a otimização de cada um dos procedimentos que estas realizam, de forma a alcançarem uma produção em grandes quantidades com qualidade e eficiência.

Controlar as etapas produtivas da forma mais automática possível, desde a extração da matéria prima até a logística de escoamento da produção torna-se assim, condição para que os requisitos de produção sejam atendidos.

É cada vez maior a quantidade de trabalhos científicos que estudam formas viáveis de tornar os processos cada vez mais eficientes, agregando a estes processos tecnologias inovadoras ou consolidando de forma pragmática as já existentes.

Um dos pontos que afetam diretamente a qualidade da produção por estas indústrias é o conhecimento das diversas variáveis físicas que atuam em todas ou em algumas etapas do processo. Procura-se conhecer o comportamento daquelas que contribuem direta e indiretamente no processo produtivo e, a partir daí, monitorá-las e controlá-las de forma ótima.

Desta forma, variáveis tais como a temperatura, a umidade, a densidade, a pressão, a vazão, a velocidade, dentre tantas a serem citadas, são objetos de estudo constante.

Cada uma das variáveis existentes possui diversas formas de serem inferidas, a par-

tir de princípios físicos e matemáticos. O instrumento utilizado como objeto para a leitura destas variáveis, em sua forma mais primária, é o sensor. Um sensor pode ser definido como “um dispositivo que recebe um estímulo e responde com um sinal elétrico”, (Fraden 2003). O estímulo é a propriedade ou condição que é sentida pelo sensor e convertida em um sinal elétrico. Portanto, o propósito do sensor é responder a algum tipo de estímulo físico, convertendo-o em um sinal elétrico de saída que é compatível com circuitos eletrônicos.

Em razão desta diversidade de formas de se inferir o valor de uma variável, centenas de sensores estão disponíveis para que se faça a escolha daquele que melhor atenda à aplicação pretendida. Devem-se estabelecer a exatidão da medida a ser realizada, o material de construção do elemento sensor, a repetitividade e reprodutibilidade deste, as condições a que este elemento será submetido. A característica dos sensores a ser estudada neste trabalho é a relação existente entre o que ele efetivamente mede e o sinal que reproduz em sua saída. A grande maioria destas relações é não-linear.

O problema destas não linearidades resultantes das formas como as variáveis interagem fisicamente na natureza é o fato de que afetam diretamente o controle e monitoramento de processos, que são ajustados para operação em condições de processo específicas e conhecidas. Assim, quanto maior o conhecimento sobre as relações entre as variáveis que serão objeto de controle em um processo, melhor este será realizado.

Serão discutidas brevemente nas seções seguintes diversas técnicas de linearização propostas e utilizadas para medição de variáveis por meio de sensores.

Este trabalho pretende contribuir para o estudo de técnicas de linearização que unem desenvolvimento em *software* e em *hardware* e que possam ser aplicadas a quaisquer relações não-lineares de sensores.

1.2 Justificativa

Em um ambiente industrial, diversas operações ou sequências de operações envolvendo uma mudança de estado, de composição ou outras propriedades de um sistema são normalmente realizadas com o objetivo de geração de um produto. Variáveis que são constantemente monitoradas neste ambiente são a vazão, a viscosidade, a umidade, a pressão, o nível, o pH, a densidade, a temperatura dos processos, dentre outras, seja com o objetivo de monitorar, seja com o objetivo de controlar processos. Para que este con-

trole e monitoramento sejam realizados de forma ótima é de fundamental importância o conhecimento do comportamento dos sensores utilizados para medição destas variáveis.

Os processos industriais são controlados, em sua maior parte, por meio das chamadas malhas fechadas. Nestas, há um sensor medindo continuamente as variáveis de processo diretamente da linha de produção e realimentando um controlador que decidirá, baseando-se em algoritmos de controle específicos, sobre as ações a serem tomadas para ajuste da produção em caso de erro.

Cada sensor é único, uma vez que possui valores característicos para uma grande variedade de parâmetros, sejam eles: precisão, resolução, reprodutibilidade, estabilidade, linearidade, histerese, dentre outros. Entretanto, qualquer que seja o sensor, deseja-se que seu comportamento apresente linearidade entre seu sinal de entrada e saída. O problema é que grande parte dos princípios físicos que permitem a medição por meio de sensores não possuem esta relação linear. Além disto, os sinais produzidos pelos sensores estão na maior parte dos casos submetidos a condições de operação variáveis, degradação de componentes e ruídos de medição.

O objeto que motivou este estudo é o sensor conhecido como termopar. Existem muitos materiais utilizados para confecção de termopares, desde metais nobres até ametais. Assim, os gráficos da relação tensão de saída *versus* temperatura presentes nos termopares exibem as mais variadas funções, conforme Kinzie & Moore (1973) e Figuras 1.1, 1.2, 1.3.

Os termopares utilizados na indústria são escolhidos basicamente por meio das três características seguintes: apresentar a faixa de operação mais linear possível de sua relação tensão de saída *versus* temperatura, o material de que é confeccionado ser resistente ao processo a que será submetido e o custo do material do qual é confeccionado.

A menos da característica relativa à resistência do material do termopar ao processo a que é submetido, a linearização da relação tensão *versus* temperatura permite que as outras duas características, custo e faixa linear de operação, possam ser atendidas de modo que uma gama maior de termopares possa ser efetivamente utilizada para medição e controle de processo.

É comum o sensor, quando em operação, além da não-linearidade advinda do princípio físico, ter seu alcance e faixa de trabalho reduzidos, o que exige constante ajuste da relação de entrada e saída deste. Para verificação da linearidade do sensor, a calibração necessita ser realizada constantemente. Os ajustes desejados e/ou necessários na curva




Figura 1.1: Curvas características de termopares constituídos por Metais Nobres e Metais Base. 1.Pt vs Au-9Ni. 2.Mo-Ir vs W-25Re. 3.Ni-10at.Ru vs W-25Re. 4.Re-20Ir vs Ir. 5.Re-10Ir vs Ir.




Figura 1.2: Curvas características de termopares constituídos por Metais Nobres e Platina, VII. 1.Pt vs Co-6Al. 2.Pt vs Co-40Ni. 3.Pt vs Co-25Ni. 4. Pt vs Co-30Fe. 5.Pt vs Co-15Fe.

resultante da calibração devem ser, então, realizados.

De acordo com a International Standards Organization (ISO), ver INMETRO (2007), a calibração é definida como:




Figura 1.3: Curvas características de termopares constituídos por Tungstênio e ligas Tungstênio-Molibdênio. 1.W-5Mo vs W. 2.W vs W-15Mo. 3.W vs W-25Mo. 4.W vs W-35Mo. 5.W vs W-50Mo.

“... o conjunto de operações que estabelece, sob condições especificadas, a relação entre os valores indicados por um instrumento de medição ou sistema de medição ou valores representados por uma medida materializada ou um material de referência, os valores correspondentes das grandezas estabelecidas por padrões.”

Ao realizar-se uma medição deve-se considerar alguns aspectos, sejam eles: um nível mínimo de precisão a ser alcançada, o ruído advindo do ambiente e erros inerentes ao procedimento executado para realização desta medição. Portanto, diversas técnicas são utilizadas para minimizar estas características das medições, uma vez que elas estarão sempre presentes.

Há soluções propostas em *hardware*, que são implementações de circuitos eletrônicos analógicos compostos de amplificadores e condicionadores de sinais, como em (Williams 1988). Nestes casos, devem ser consideradas as dimensões dos componentes, além de seu custo e sensibilidade a interferências de ambiente.

Há também soluções propostas em *software*. Nestes casos, devem ser consideradas as variáveis custo de processamento, aproximações numéricas e resolução dos instrumentos/interfaces utilizadas.

Uma técnica clássica utilizada para linearização de sensores consiste em interpolação polinomial. Contudo, encontrar um polinômio interpolador que possa ser generalizado para diversas relações de entrada e saída de sensores não é tarefa trivial. Na maioria das vezes o ajuste por esta técnica deve ser realizado para partes específicas da faixa de medição do sensor. Além disso, problemas de oscilação numérica presentes devido ao aumento do grau do polinômio interpolador podem ocorrer. Uma consideração a ser feita é que o aumento do grau do polinômio não garante aumento de precisão na medição realizada.

Outra técnica que pode ser utilizada para linearização de sensores consiste nas Redes Neurais Artificiais, que são aproximadores universais de funções. As redes neurais, uma vez ajustadas e treinadas, possuem capacidade de adaptação a cenários não conhecidos. Estas características adequam-se, assim, a este estudo.

O uso de técnicas de Inteligência Computacional, tais como as redes neurais artificiais, permite a implementação também de uma funcionalidade a mais durante a linearização do sensor, que é a auto-calibração destes. Uma vez que os sensores em situações de uso necessitam ser calibrados periodicamente para verificação de sua resposta linear, é interessante utilizar um sistema que possa ser auto-calibrado por meio de valores reais de medição, de forma que a curva seja personalizada e adaptada ao sensor em questão. As redes neurais permitem esta auto-calibração, pois podem ser treinadas com os valores reais medidos do sistema a cada procedimento de calibração realizado.

1.3 Objetivos

A proposta deste trabalho é o estudo de técnicas de Inteligência Computacional objetivando a linearização de sensores de temperatura. É proposto, assim, um sistema que consiste na implementação da auto-calibração e linearização de sensores utilizando recursos de *software* e de *hardware*.

Para atingir a este objetivo principal, três objetivos específicos são propostos e implementados neste estudo:

1. Aquisição de dados.
2. Implementação do treinamento multiobjetivo da Rede Neural.
3. Decisão sobre a rede ótima a ser implementada em *hardware*.

1.3.1 Aquisição de Dados

Os dados para treinamento da rede neural são oriundos das medições realizadas pelos sensores a serem linearizados. Como estes sinais são analógicos e de amplitudes diversas devem, em uma primeira etapa, passar pelo processo de condicionamento. No escopo deste trabalho, o condicionamento consiste em preparar o sinal para ser utilizado no treinamento da rede neural.

Estes dados serão enviados ao computador por meio da interface USB, Universal Serial Bus, onde será realizado o treinamento *offline* da rede RBF.

1.3.2 Implementação do treinamento multiobjetivo da Rede Neural

Neste trabalho a proposta é treinar, por meio de otimização multiobjetivo, as redes RBF, redes de funções de base radiais. Ela será a responsável pela transformação linear entre os valores de entrada e saída dos sensores.

O treinamento da rede é realizado como uma otimização multiobjetivo devido ao desejo de obter-se estruturas simplificadas de rede neural para implementação da rede escolhida em *hardware*, além da minimização tradicional do erro. Tem-se, desta forma, dois objetivos a serem minimizados: o erro e a complexidade da rede.

Como estes são objetivos distintos e conflitantes, o uso de treinamento multiobjetivo da rede neural implementada surge como possível solução e é investigado neste trabalho.

1.3.3 Decisão sobre a rede ótima a ser implementada

A terceira etapa consiste na implementação de um decisor aplicado sobre todos os pontos não dominados da solução multiobjetivo que integram o conjunto denominado Pareto. Este decisor baseia-se em ajuste das curvas lineares geradas pelo sistema de linearização. O decisor será responsável pela escolha da melhor solução de linearização, que será efetivamente implementada em *hardware*.

1.4 Revisão Bibliográfica

Devido à importância da medição das diversas variáveis em ambientes industriais, são realizados inúmeros trabalhos para otimizar o funcionamento dos sensores que medem estas variáveis, envolvendo diferentes linhas de pesquisa.

O sensor que motivou esta pesquisa, o termopar, é um dos sensores de temperatura industrial mais utilizados no mercado, por sua grande faixa de utilização e resposta rápida. Desta forma, são citados aqui também alguns trabalhos específicos aplicados à variável temperatura.

Rosenberg (1994) discute a necessidade de medir-se temperatura com precisão em ambientes industriais. A partir do momento em que computadores lógicos programáveis são cada vez mais utilizados para controle e monitoramento de diversas variáveis industriais isto torna-se possível de forma mais efetiva. O autor levanta os avanços alcançados com a evolução de *hardware* disponível para construção destes computadores dedicados, sejam eles: aumento de memória e da velocidade de operação dos processadores. As questões que devem ser consideradas quando da leitura da temperatura em campo são detalhadas: isolamento, proteção contra sinais espúrios, proteção à interferência eletromagnética. Não se discute, entretanto, os efeitos causados nos medidores devido a degradações constantes que acontecem nestes quando em campo.

Bajzek (2005) apresenta um tutorial em instrumentação e medição onde discute os princípios físicos de funcionamento de um termopar. Drebuschak (2009) mostra as razões matemáticas fundamentais que tornam o ajuste polinomial da relação temperatura *versus* tensão impróprios. Esta desvantagem ocorre devido ao fenômeno de *Runger*, que ocorre em funções com uma potência negativa da variável que, ao serem derivadas e aproximadas por séries de Taylor, produzem equações fatoriais. As discussões são realizadas considerando-se aproximações por série de Taylor e afetam especificamente a técnica de se medir temperatura por meio de interpolação polinomial.

Em (Evans & Rowlands 1988), os autores propõem um sistema microprocessado portátil capaz de simular e calibrar termopares industriais (tipos B, E, J, K, R, S e T) e que realiza a compensação de junta fria automaticamente. Bethea & Rosenthal (1992) desenvolvem um sistema automático de calibração de termopares, especificamente para o tipo K, que opera na faixa da temperatura ambiente até 650 °C, podendo calibrar até 60 termopares simultaneamente no forno utilizado. Este sistema consiste em um computador pessoal, uma unidade de controle e aquisição de dados e um forno de calibração

de laboratório. Estes dois últimos trabalhos não investigam a não-linearidade dos sensores. Ambos utilizam como referência de calibração pontos disponíveis em tabelas de normas internacionais de temperatura, cada trabalho utilizando a norma vigente.

Já Hudoklin, Drnovsek, Pusnik & Bojkovski (2002) propõem um sistema capaz de calibrar diversos termopares simultaneamente e analisam as razões para ocorrência de erros em calibrações simultâneas. Otimizando estes erros, tem-se o tempo total de calibração e consequente custos para tal diminuído, atendendo a laboratórios que possuem grandes quantidades de sensores a serem calibrados.

Diante do fato da não-linearidade da relação sinal de entrada-saída medida pelos termopares, a necessidade da adoção de técnicas de linearização torna-se presente. Em (Pereira, Girao & Postolache 2001), os autores apresentam uma visão geral das técnicas clássicas de interpolação para linearização de dados e treinamento por meio de regressão de mínimos quadrados (LMS). É realizada uma comparação de performance entre a interpolação polinomial e as aproximações por meio de redes neurais artificiais para medição de dados, com especial atenção para a redução da dimensão do conjunto de pontos de calibração para obter-se determinada precisão. Os resultados apresentados neste artigo encorajam a investigação das redes neurais como técnicas de linearização, pois exibem ganhos de performance por esta técnica quando comparado às técnicas tradicionais.

Klopfenstein (1994) discute algoritmos de linearização para termopares, termistores e termorresistências. Cada um destes sensores possui questões para linearização específicas. No caso dos termopares, por exemplo, devem ser utilizadas técnicas para compensar, além da não-linearidade sinal de entrada-saída já citada anteriormente, os desvios na junção de referência destes. O autor discute separadamente técnicas próprias para termistores e para termorresistências e apresenta, ainda, polinômios de ordem reduzida com relação aos polinômios tradicionais de linearização utilizados para os termopares. Ele cita, no entanto, que há uma perda de precisão no valor de temperatura calculado, o que é contraditório com o trabalho apresentado por Drebushchak (2009).

Para otimizar características como precisão da medição, imunidade a ruídos de ambiente e aumento da faixa de medição, são propostos sistemas inteligentes de auto-calibração de sensores.

Ruppel (1990) desenvolveu um sistema computacional para simulação baseado em diferenças finitas capaz de reproduzir o comportamento termodinâmico de um termopar auto-calibrado que reconheça qual ponto da curva temperatura *versus* tempo é o ponto

de calibração ideal do termopar. A utilização do método de diferenças finitas para simular o comportamento dos sensores de temperatura ao longo do tempo é interessante e parece adequado a este problema, uma vez que os efeitos que regem o funcionamento dos termopares são baseados em gradientes de temperatura e diferenças entre ligas metálicas. Yang & Clarke (1997), propõem um modelo para um termopar auto-validado que seja capaz de detectar vários tipos de falhas internas, incluindo a perda de contato com o ambiente de medição, e mostra como os cálculos de incertezas associados podem ser realizados.

Há diversos estudos na tentativa de tornar os sensores efetivamente inteligentes, implementando métodos que realizem a linearização, a compensação de junta fria, a escolha de termopares para as faixas adequadas, a auto-calibração do sensor. Estes sistemas são compostos de implementações em *hardware* e *software*, de técnicas e métodos diversos conjugados, para que a finalidade de tornar o sistema todo automático e inteligente possa ser alcançada.

Em (Comisky, Drake & Dempsey 1995), os autores propõem um conversor analógico-digital baseado em redes neurais, já integrando os conceitos de *hardware* e *software*, ao implementar uma rede neural com amplificadores eletrônicos de baixo ganho representando cada neurônio desta rede. Weremczuk (1997) investiga o uso de algoritmos genéticos para calcular os pontos e a distribuição ótima para calibração de sensores inteligentes. As técnicas de algoritmos genéticos buscam uma melhora de desempenho na procura por pontos específicos de calibração.

Em (Patra & van den Bos 2000, Patra, Ang & Das 2004, Patra, Chakraborty & Meher 2008), verificam-se propostas de implementações em *hardware* de RNAs do tipo Perceptron de Múltiplas Camadas para compensação e linearização de sensores. Patra, Devi & Meher (2007) apresentam uma implementação em um chip FPGA (Field Programmable Gate Array) de uma rede de funções de base radiais (RBF) para compensação de sensores de pressão. Estes trabalhos mostram, em comum, o grande potencial da união entre as técnicas computacionais de redes neurais e sua integração ao *hardware*, no caso as FPGAs, *Field Programmable Gate Array* para realizar aproximações de funções e linearização de dados.

Chatterjee, Munshi, Dutta & Rakshit (2000) utilizam uma rede RBF para linearizar a característica estática de sensores de umidade capacitivos.

Reyneri (2003) apresenta uma visão geral das implementações de redes neurais artificiais e sistemas *fuzzy* em *hardware*. É feita a análise das limitações, vantagens e

desvantagens para os sistemas analógicos, digitais, sequência de pulsos e outras técnicas de implementação. São analisados os parâmetros de performance de *hardware* e as dificuldades inerentes a diversas metodologias de implementação.

Já as investigações sobre o treinamento de redes neurais são realizadas por Parma, Menezes & Braga (1998), onde é proposto um treinamento baseado em controle por modos deslizantes. Barreto (2003) propõe um algoritmo genético de mínimos quadrados ortogonal para realizar o treinamento de redes RBF. A investigação de técnicas mais eficientes de treinamento das redes, inclusive desenvolvendo-se as próprias técnicas, trazem novas possibilidades investigativas a respeito delas próprias e de suas aplicações.

Ainda no estudo de redes, desta vez a rede Perceptron de Múltiplas Camadas, xei ra, Braga, Takahashi & Saldanha (2000) investigam o treinamento multiobjetivo destas, realizando uma análise sobre o dilema entre polarização e variância existente na procura pelos pesos ótimos de ajuste da rede.

Jin & Sendhoff (2008) apresentam uma visão da pesquisa existente sobre otimização multiobjetivo de máquinas de aprendizagem, focando-se em aprendizagem supervisionada. Três aproximações para a geração do Pareto multiobjetivo são comparadas e discutidas em detalhes.

A abordagem multiobjetivo para o treinamento de redes neurais artificiais é apresentada e discutida em (Braga, Takahashi, Costa & R. A. Teixeira. In: . (Org.). . 1 ed. : 2006), (xei ra, Braga, Takahashi & Saldanha 2000), (Teixeira, Braga, Takahashi & Saldanha 2000), onde a rede apresentada é o Perceptron de Múltiplas Camadas.

Medrano-Marques & del Brio (2000) propõem um método geral de linearização para sensores quaisquer, baseado na implementação de uma rede neural artificial simples que faça a compensação das características não-lineares do sensor em questão. A rede neural utilizada é a Perceptron de Múltiplas Camadas e a entrada da rede é composta dos valores não-lineares de saída do sensor. Já os dados de saída da rede (os valores a serem alcançados) são a diferença entre o valor linear desejado para este e a saída do sensor. Introduzem, aqui, o cuidado que se deve ter com a topologia utilizada em implementações e a forma como os dados são fornecidos à rede para treinamento.

Em trabalhos mais recentes, Danisman, Dalkiran & Celebi (2006) descrevem um método para teste e calibração de diferentes tipos de termopares utilizando algoritmos baseados em redes neurais artificiais integrados com um instrumento virtual. Uma rede Perceptron de Múltiplas Camadas e uma placa de aquisição de dados com uma unidade

de condicionamento de sinal são implementadas neste artigo. Os dados de treinamento são obtidos de um calibrador de laboratório e as entradas da rede são as tensões medidas por um tipo de termopar equivalente. Embora utilizem técnicas de redes neurais, neste trabalho o objetivo não é linearizar o sensor, mas identificar sua curva e seu tipo.

Rivera, Carrillo, Chacón, Herrera & Bojorquez (2007) analisam diversas topologias de redes neurais e algoritmos de treinamento implementados para linearização de sensores. Realizam a comparação da técnica de rede neural com a interpolação polinomial. Em seguida implementam a rede neural treinada em um microcontrolador. Schoen (2007) apresenta algoritmos para melhorar a performance dinâmica de sensores e prever padrões de sinais de medições futuras. Para melhorar a performance dinâmica ele propõe dois filtros inversos. Um dos filtros incorpora uma constante ótima de ganho que reduz o custo computacional e melhora a precisão. Um método de identificação de sistema é utilizado para encontrar as propriedades dinâmicas do sensor e permitir a adaptação dos parâmetros do filtro inverso, que é um filtro adaptativo. É utilizado um algoritmo genético para escolha dos parâmetros ótimos do modelo da constante de ganho do sistema realimentado. O uso do algoritmo genético permite que a escolha dos parâmetros ótimos seja realizada de forma mais rápida, quando comparada a técnicas clássicas de otimização não-linear.

Wen, Qing & Qiang (2007) propõem combinar a tecnologia de um instrumento virtual com redes neurais para encontrar um modelo característico tensão *versus* temperatura do termopar e o algoritmo do gradiente descendente com um fator de momento é usado para ajustar os parâmetros de uma rede neural RBF. A implementação é realizada em *software* e em *hardware*.

1.5 Organização do Texto

O texto da dissertação encontra-se organizado da seguinte forma:

No Capítulo 2 são abordados conceitos relativos à medição e construção dos termopares, que são os sensores que motivaram este estudo. São descritos neste capítulo os efeitos e princípios físicos que permitem a medição de temperatura por pares termoeletrônicos e os cuidados que devem ser tomados quando da escolha destes sensores para utilização em controle de processos.

O Capítulo 3 trata da escolha e estudo da rede neural utilizada na implementação

deste trabalho, no caso a rede RBF. Nele, são apresentadas as particularidades da rede neural escolhida e o procedimento de treinamento desta com o objetivo de obter-se dados de saída linearizados. Também neste capítulo são estabelecidos e comparados os treinamentos supervisionado, semi-supervisionado e multiobjetivo da rede em questão. O procedimento de geração de diversas soluções ótimas de Pareto, por meio de um algoritmo de otimização multiobjetivo e da implementação de um decisor que seja capaz de selecionar a solução ótima estão descritos ao final deste capítulo.

No Capítulo 4 é realizado um detalhamento minucioso de todo o sistema implementado, desde a aquisição de dados a serem utilizados para o treinamento da rede neural até a saída já linearizada fornecida pelo microcontrolador após o ajuste *offline* dos pesos da rede neural em um computador pessoal. Faz-se uma discussão sobre as topologias possíveis para o treinamento a ser implementado e detalhes técnicos dos recursos utilizados na implementação do sistema são exibidos.

No Capítulo 5 são descritos quatro experimentos realizados para validação do algoritmo de treinamento multiobjetivo implementado. Além da descrição são apresentados resultados comparativos entre a otimização mono-objetivo e multiobjetivo e são realizadas as discussões e avaliações sobre estes resultados.

Capítulo 2

Medição de Temperatura por meio de Termopares

Neste capítulo são apresentadas noções que nos levam a definir a variável física temperatura. A partir desta definição, são esclarecidos os princípios físicos que regem e permitem a realização de medições de temperatura por sensores os mais diversos.

As escalas de temperatura utilizadas atualmente são revistas brevemente, esclarecendo-se especificamente como a norma internacional vigente ITS-90 define os pontos que são utilizados para calibração de todos os sensores de temperatura.

Os medidores de temperatura são, em seguida, classificados de acordo com o critério de contato direto ou indireto com o mensurando. Dentre os medidores, é dada especial atenção ao medidor do tipo par termoeletrico, o termopar, que é o sensor motivador deste trabalho. Os efeitos físicos que o descrevem e as leis fundamentais que regem seu funcionamento são descritos em detalhe.

Ao final do capítulo alguns tipos e características de termopares comerciais são descritos e uma breve conclusão e comentários são apresentados.

2.1 Medição de Temperatura

A noção intuitiva de temperatura é bastante familiar por lidarmos com esta variável em grande parte das situações cotidianas. Ela está relacionada à sensação de calor ou de frio, que ocorre quando tocamos um objeto, trocando calor com este.

Apesar desta familiaridade relativa ao conceito de temperatura, para que esta possa ter valor como medida científica faz-se necessário dar-lhe um significado preciso, pois a noção intuitiva de temperatura não é confiável. Algumas vezes os corpos frios podem parecer quentes e os corpos de materiais diferentes, que estão a mesma temperatura, parecem estar a temperatura diferentes.

Portanto, definir exatamente o que é temperatura não é tarefa simples, pois envolve conceitos físicos de termodinâmica e mecânica estatística, dentre outros.

Na tentativa de definir-se a temperatura, é necessário pensar em equilíbrio térmico entre sistemas. Quando ocorre equilíbrio, diz-se que os sistemas em contato possuem a mesma temperatura. Desta forma, pode-se dizer que, de acordo com Halliday, Resnick & Krane (1996), *a temperatura é a propriedade dos sistemas que permanece constante quando eles estão em equilíbrio térmico.*

A termodinâmica, baseada em leis estabelecidas experimentalmente, procura tornar os conceitos de temperatura passíveis de medições confiáveis.

São quatro as leis enunciadas pela termodinâmica. Segue enunciada a Lei Zero-ésima, que trata especificamente da medição da temperatura.

A Lei Zero-ésima da Termodinâmica

“Existe uma grandeza escalar chamada temperatura, que é uma propriedade de todos os sistemas termodinâmicos em equilíbrio térmico. Dois sistemas estão em equilíbrio térmico se, e somente se, suas temperaturas são iguais.”, conforme Halliday, Resnick & Krane (1996).

A Lei Zero-ésima define desta forma o conceito de temperatura como sendo a propriedade macroscópica de um sistema que será igual à de outro quando estiverem em equilíbrio térmico. É baseado nela que são construídos termômetros para medir a temperatura, pois sabemos que estes atingirão a mesma temperatura do sistema que medem quando estiverem em contato térmico.

2.1.1 Escalas de Temperatura

A dificuldade em se atribuir valores de forma padronizada à temperatura por meio de escalas reproduzíveis fez com que se levantassem pontos de referência nos quais se pudesse

reproduzir de forma bem definida os valores medidos, gerando a criação das escalas de temperatura.

Entre as mais importantes escalas desenvolvidas ao longo do tempo, tem-se as escalas Celsius, Fahrenheit e a Kelvin. A escala Fahrenheit é utilizada nos Estados Unidos e em parte da Europa. Em processos industriais é tendência o uso da escala Celsius em todo o mundo. Já a escala Kelvin, que define como seu ponto mínimo o zero absoluto, que é um conceito no qual um corpo não possui energia, é chamada escala de temperatura absoluta e bastante utilizada no meio científico.

Escala Internacional de Temperatura

Para melhor expressar as leis experimentais da termodinâmica, foi estabelecida internacionalmente uma escala baseada em fenômenos de mudança de estado físico de substâncias puras que ocorrem em condições únicas de temperatura e pressão, os pontos fixos de temperatura. Os pontos fixos são utilizados para interpolação em cálculos de fórmulas que relacionem as temperaturas às leituras de determinados termômetros.

A atual escala de temperatura adotada pelo Comitê Internacional de Pesos e Medidas é a ITS-90, International Temperature Scale, publicada em 1990.

A ITS-90 é uma escala prática que define pontos de calibração na faixa entre 0,65 K a aproximadamente 1.358,00 K (-272,5 °C a 1.084,85 °C), além de definir procedimentos de calibração que garantam qualidade e reprodutibilidade em medições para padronização internacional.

A ITS-90 também é utilizada como uma aproximação para medidas de temperaturas termodinâmicas em aplicações industriais e científicas.

Os principais pontos fixos definidos pela ITS-90 são descritos na Tabela 2.1. Em seguida, há um resumo das técnicas de interpolação utilizadas em cada faixa de medição.

Os meios disponíveis para medição e interpolação levam à divisão da escala de temperatura em quatro faixas, sejam elas:

- A primeira faixa, de -259,3467 a 0 °C é baseada nas medições com um termômetro de resistência de platina. Essa faixa é subdividida em 4 partes. Em cada uma, a diferença entre as razões das resistências medidas de um termômetro específico e a função de referência nos pontos fixos é usada para determinar as constantes em uma equação de interpolação polinomial especificada.

Principais Pontos Fixos	T(°C)
1) Ponto triplo (equilíbrio entre fases sólida, líquida e vapor) do hidrogênio	-259,3467
2) Ponto de vaporização (equilíbrio entre fases líquida e vapor) do hidrogênio à pressão de 250 mmHg	-256,1150
3) Ponto de vaporização normal (pressão de 1 atm) do hidrogênio	-252,8800
4) Ponto de vaporização normal de néon	-246,5939
5) Ponto triplo do oxigênio	- 218,7916
6) Ponto triplo da água	0,0100
7) Ponto de vaporização normal da água	100,00
8) Ponto de solidificação normal (equilíbrio entre as fases sólida e líquida à pressão de 1 atm) do zinco	419,5270
9) Ponto de solidificação normal da prata	961,780
10) Ponto de solidificação normal do ouro	1.064,180

Tabela 2.1: Principais pontos fixos de temperatura definidos pela ITS-90.

- A segunda faixa, de 0 a 630,74 °C (ponto normal de solidificação do antimônio, que é um ponto fixo secundário) também é baseada em um termômetro de resistência de platina. As constantes da equação de interpolação polinomial são determinadas por calibração nos três pontos fixos da faixa.
- A terceira faixa, de 630,74 a 1.064,18 °C é baseada em medições de um termopar padrão de platina e platina-ródio e uma equação de três termos que expressa a força eletromotriz como função de temperatura. As constantes são determinadas por uma medição com um termômetro de resistência de platina no ponto da solidificação do antimônio e por calibração nos dois pontos fixos principais da faixa.
- A quarta faixa, acima de 1.064,18 °C é baseada em medições de intensidade da radiação no espectro visível e comparada com aquela de mesmo comprimento de onda no ponto de fusão do ouro e na equação de Planck para radiação do corpo negro, medida por um pirômetro óptico.

Existem várias equações que relacionam a temperatura e a propriedade termométrica utilizada nestes instrumentos, sejam elas a resistência elétrica, a força eletromotriz e a

energia radiante. Por meio do uso destas equações pode-se determinar com precisão a temperatura em que se encontra um determinado corpo de prova.

Esta escala de temperatura é transferida para outros instrumentos de utilização mais simples, mantendo-se o erro dentro de faixas bastante estreitas.

Todo termômetro usado na prática deve ter a sua calibração relacionada à escala internacional de temperatura, ainda que de forma indireta, para ter sua medição validada.

2.1.2 Medidores de Temperatura

A temperatura não pode ser determinada diretamente, mas deve ser inferida a partir de seus efeitos elétricos ou físicos produzidos sobre uma substância cujas características são conhecidas. Os medidores de temperatura são construídos baseados nesses efeitos, conforme citado em SENAI & CST (1999).

Podem-se dividir os medidores de temperatura em dois grandes grupos:

1. Medidores de contato direto:
 - a. termômetros à dilatação de líquidos
 - b. termômetros à dilatação de sólidos
 - c. termômetros à pressão de líquido
 - d. termômetros à pressão de gás
 - e. termômetros à pressão de vapor
 - f. termômetros a par termoelétrico
 - g. termômetros à resistência elétrica.
2. Medidores de contato indireto:
 - a. pirômetros ópticos
 - b. pirômetros fotoelétricos
 - c. pirômetros de radiação.

A Tabela 2.2 faz uma comparação da utilização entre os medidores de contato direto e os medidores de contato indireto.

	Contato Direto	Contato Indireto
Condição necessária para medir com precisão	1) Estar em contato com o objeto a ser medido. 2) Praticamente não mudar a temperatura do objeto devido ao contato do detector.	1) A radiação do objeto medido tem que chegar até o detector.
Característica	1) É difícil medir a temperatura de um objeto pequeno, porque este tem tendência de mudança de temperatura quando em contato com um objeto cuja temperatura é diferente. 2) É difícil medir o objeto que está em movimento.	1) Não muda a temperatura do objeto porque o detector não está em contato direto com o mesmo. 2) Pode medir o objeto que está em movimento. 3) Geralmente mede a temperatura da superfície. 4) Depende da emissividade.
Faixa de Temperatura	É indicado para medir temperaturas menores que 1600° C.	É adequado para medir temperaturas elevadas (maior que -50 °C).
Precisão	Geralmente, $\pm 1\%$ da faixa.	Geralmente 3 a 10 °C.
Tempo de Resposta	Geralmente grande ($\geq 5min$).	Geralmente pequeno (0,3 a 3s.)

Tabela 2.2: Classificação dos medidores de temperatura de acordo com o contato

Neste estudo é dada especial atenção ao medidor de contato direto do tipo termômetro a par termoelétrico, o termopar.

2.2 Termopares

O sensor escolhido para estudo neste trabalho é o sensor conhecido como termopar, utilizado em medição de temperatura. Seu funcionamento é baseado em princípios físicos que demonstram a geração de força eletromotriz a partir da submissão de uma junção de materiais constituídos de diferentes ligas metálicas a gradientes de temperatura distintos.

Esses princípios físicos são especificamente os efeitos *Seebeck*, *Peltier*, e *Thomson*, ver Bajzek (2005).

O efeito *Seebeck*, representado na Figura 2.1 e descrito matematicamente pela Equação (2.1), acontece quando um circuito composto de dois metais distintos e com suas junções mantidas a temperaturas diferentes gera uma força eletromotriz correspondente.

Na Figura 2.1, tem-se os metais representados pelos fios A e B, a temperatura de referência T_R , também chamada junta fria e a temperatura a ser medida, também chamada junta quente. Uma corrente I circula pelo circuito quando este está fechado, ou seja, com as juntas soldadas.

$$S_{AB} = \lim_{\Delta T \rightarrow 0} \frac{\Delta \epsilon_{AB}}{\Delta T} = \frac{d\epsilon_{AB}}{dT} \quad (2.1)$$

em que ϵ_{AB} é a tensão *Seebeck*, T é a temperatura e S_{AB} é o coeficiente *Seebeck*.

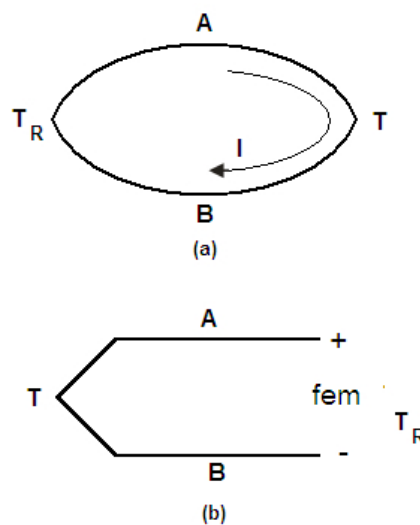


Figura 2.1: Representação do Efeito Seebeck: (a) Circuito fechado. (b) Fem gerada pela diferença de temperatura.

O efeito *Peltier*, descrito pela Equação (2.2), mede a mudança na quantidade de calor quando 1 Coloumb de carga atravessa uma junção formada por metais distintos:

$$\Phi_{AB}I = \frac{dQ}{dt} \quad (2.2)$$

onde Φ é o coeficiente de *Peltier* para os dois materiais, I é a corrente elétrica e dQ/dt é

a taxa de mudança em calor. Pode-se ver seu esquema de funcionamento na Figura 2.2.




Figura 2.2: Representação do Efeito Peltier

É possível, por meio das equações da termodinâmica, mostrar que os efeitos *Peltier* e *Seebeck* são reversíveis e energeticamente equivalentes.

No caso do efeito *Thomson*, conforme esquema na Figura 2.3, tem-se que, quando um material condutor é submetido à passagem de corrente elétrica e a temperaturas distintas em suas extremidades, há a absorção ou emissão de calor. Esta absorção ou emissão de calor depende da intensidade da corrente elétrica e da diferença de temperatura. O efeito *Thomson* descreve esta absorção ou emissão de calor, por meio da seguinte Equação (2.3):

$$\epsilon_{Th} = \int_{T_r}^T \sigma_A dT \quad (2.3)$$

onde σ_A é o coeficiente de *Thomson* para o material A, dT é o gradiente de temperatura, T é a temperatura a ser medida na junta quente e T_r é a temperatura na junta fria.




Figura 2.3: Representação do Efeito Thomson

A tensão *Seebeck* é o resultado da soma das tensões *Peltier* e *Thomson*, levando à

Equação (2.4), que é a equação fundamental dos termopares.

$$\epsilon_{AB} = (\Phi_{AB})_T - (\Phi_{AB})_{T_r} + \int_{T_r}^T (\sigma_A - \sigma_B) dT \quad (2.4)$$

2.2.1 Leis Fundamentais dos Circuitos Termoelétricos

A base da teoria termoelétrica em medições de temperatura utilizando termopares está fundamentada em três leis termoelétricas. Estas leis garantem a compreensão dos fenômenos que ocorrem ao se utilizar os sensores do tipo termopares na obtenção de valores instantâneos de temperatura em um processo industrial. São elas: a lei do Circuito Homogêneo, a lei dos Metais Intermediários e a lei da Temperatura Intermediária.

Lei do Circuito Homogêneo

A força eletromotriz termal desenvolvida em um circuito termoelétrico formado por dois metais homogêneos de naturezas diferentes depende apenas de duas características do circuito. Uma delas é a diferença de temperatura entre as junções dos metais. A outra característica é a composição química das ligas metálicas. Desta forma, não há interferência no valor de tensão gerado pelo circuito devido à distribuição ou ao gradiente de temperatura ao longo dos fios.

A Figura 2.4 apresenta esquematicamente esta lei.

Nota-se, em (b), que a liga A está submetida à temperatura T_3 e a liga B à temperatura T_4 . De acordo com a lei dos circuitos homogêneos, a tensão gerada em (b) será a mesma gerada em (a).




Figura 2.4: Lei do Circuito Homogêneo

Lei dos Metais Intermediários

Em um circuito constituído por condutores de vários metais diferentes, a força eletromotriz termal total será zero se todo o circuito estiver à mesma temperatura. Quando tem-se um circuito formado de dois fios de naturezas diferentes com suas junções em temperaturas diferentes e corta-se um dos fios introduzindo-se um terceiro fio de outra natureza, a força eletromotriz criada originalmente não é modificada, desde que as duas junções criadas pelo terceiro fio estejam à mesma temperatura, conforme mostra o esquema na Figura 2.5.

A tensão gerada em (b) será a mesma em (a), caso T_3 seja igual a T_4 , embora haja um fio C inserido na parte superior do circuito.




Figura 2.5: Lei dos Metais Intermediários

Assim, conclui-se que, se:

$$T_3 = T_4 \Rightarrow E_1 = E_2 \quad (2.5)$$

$$T_3 \neq T_4 \Rightarrow E_1 \neq E_2 \quad (2.6)$$

Um exemplo de aplicação prática desta lei é a utilização de contatos de latão ou cobre para interligação do termopar ao cabo de extensão no cabeçote, que é a peça onde será ligado o medidor que fará a leitura da força eletromotriz gerada pelo termopar.

Lei da Temperatura Intermediária

A tensão gerada em um termopar de metais homogêneos, com suas junções a temperaturas T_1 e T_2 , é igual a soma algébrica da tensão do termopar com uma junção na temperatura T_1 e a outra em uma temperatura qualquer T com a tensão do mesmo termopar com suas junções a T e T_2 . Assim, a tensão gerada depende somente da diferença entre a junta fria e a junta quente, independente de qualquer temperatura intermediária. O esquema desta lei pode ser visto na Figura 2.6.




Figura 2.6: Lei da Temperatura Intermediária

2.2.2 Sistemas de Medição utilizando Termopares

Em sistemas de controle automático, é interessante que os sensores sejam capazes de ter respostas lineares, por diversos motivos, já citados no Capítulo 1 deste trabalho. A relação tensão *versus* temperatura gerada pelos termopares, entretanto, é não-linear. Esta não-linearidade deve-se ao fato do coeficiente *Seebeck* variar com a temperatura, conforme Equação 2.1) e Figura 2.1.

Pelas equações dos efeitos físicos que regem o funcionamento dos termopares, entretanto, vê-se que relação tensão *versus* temperatura gerada pelos termopares é não-linear.

A norma ITS-90 fornece tabelas que linearizam esta relação. Estas tabelas são geradas empiricamente a partir da interpolação polinomial entre os pontos fixos que a própria norma ITS-90 estabelece. Para se medir temperatura com os termopares industriais, estes são integrados a circuitos eletrônicos que mantêm os valores tabelados em memória.

Outra forma de linearizar a relação temperatura *versus* tensão é por meio de interpolação, pois a variação da potência termoelétrica de um material com a temperatura

pode ser aproximada por um polinômio. Para um dado termopar é possível aproximar o polinômio resultante por uma relação linear se a variação de temperatura ficar dentro de uma faixa limitada.

O que diferencia as relações temperatura *versus* tensão entre os termopares são os coeficientes do polinômio da Equação (2.7) a seguir, além da quantidade de termos do polinômio. Para cada termopar são calculados coeficientes para um polinômio e a quantidade de termos que este deve possuir de forma a linearizar a relação temperatura *versus* tensão. O grau máximo do polinômio obtido para termopares industriais é 9.

$$T(x) = a_0 + a_1x^1 + a_2x^2 + a_3x^3 + a_4x^4 + a_5x^5 + a_6x^6 + a_7x^7 + a_8x^8 + a_9x^9 \quad (2.7)$$

onde:

T: temperatura [°C].

x: tensão gerada [mV].

Adotando esse procedimento para medição durante o uso do sensor, pode acontecer que a leitura de tensão não corresponda efetivamente à temperatura prevista nas tabelas da ITS-90, pois esta não é atualizada com as não-linearidades a que estão sujeitos os sensores quando instalados no processo.

Além disso, há um outro procedimento que deve ser realizado quando da medição da temperatura utilizando termopares, que é a compensação da junta fria. Como os valores tabelados pela ITS-90 são obtidos com a junta fria do termopar a zero grau, quando estes são instalados no processo faz-se necessária a correção do valor de tensão gerado nesta junta, pois este valor na junta fria passa a ser o valor de temperatura ambiente, ver NIST (1995).

Assim, para realizar a compensação de junta fria os instrumentos de medição trazem um outro sensor de referência de temperatura acoplado, ajustado para medir a temperatura ambiente. Este valor de temperatura ambiente corresponde a uma tensão tabelada e deve ser somada à tensão gerada pelo termopar. Outra forma de realizar a compensação de junta fria é medir a temperatura ambiente com termômetros de vidro e somar a tensão equivalente ao termopar de forma manual.

2.2.3 Tipos e Características de Termopares Comerciais

Quaisquer combinações de dois metais condutores podem, a princípio, operar como um termopar. Os termopares construídos para uso industrial devem possuir combinações de fios que apresentem uma relação razoavelmente linear entre a temperatura e a força eletromotriz. Além disto, é importante que gerem uma potência termoelétrica que seja detectável pelos equipamentos usuais de medição.

Dessa maneira, foram desenvolvidas diversas combinações de pares de ligas metálicas, desde as que atendem às indústrias até as mais sofisticadas para uso especial ou restrito a laboratório. Estas combinações foram feitas de modo a obter-se uma alta potência termoelétrica, aliando-se a estas combinações as melhores características possíveis dos elementos, como homogeneidade dos fios e resistência à corrosão na faixa de utilização.

Assim, cada tipo de termopar possui uma faixa de temperatura ideal de trabalho, que deve ser respeitada para que se tenha um maior rendimento e maior vida útil do mesmo. Podem-se dividir os termopares comerciais em dois grupos: os termopares básicos, que são dos tipos T, J, E, K e os termopares nobres, que são dos tipos S, R, B.

Os termopares denominados básicos são os de maior uso industrial, pois seus fios são de custo relativamente baixo e sua aplicação admite um limite de erro maior.

Os termopares denominados nobres são aqueles cujos pares são constituídos de platina. Embora possuam custo elevado e exijam instrumentos receptores de alta sensibilidade, devido à baixa potência termoelétrica, apresentam uma altíssima precisão, dada a homogeneidade e pureza dos fios termopares.

2.3 Conclusão

Neste capítulo foi apresentado o princípio geral que rege a medição de temperatura. As principais escalas utilizadas tanto na indústria quanto cientificamente foram citadas.

A importância da definição internacional dos pontos fixos de calibração, assim como os procedimentos desta realizados em faixas, foi apresentada por meio da norma ITS-90.

Em seguida, os medidores de temperatura foram classificados quanto ao contato e partiu-se para a definição dos conceitos físicos fundamentais para o funcionamento de sensores a par termoelétricos. A partir dos efeitos *Seebeck*, *Peltier* e *Thomson*, chegou-se

à equação fundamental dos termopares.

A utilização dos termopares na indústria também foi apresentada, assim como a padronização da utilização destes por meio da norma ITS-90.

Dois pontos são fundamentais para a compreensão de ter sido o termopar o sensor que motivou os estudos de linearização.

Primeiramente, pode-se perceber pela equação fundamental dos termopares, Equação (2.4), que não há uma expressão analítica fechada matemática que relacione temperatura com tensão. O modelo existente depende das variações dos efeitos físicos de acordo com as ligas escolhidas para a construção dos sensores. Assim, além desta relação ser não linear, as curvas que relacionam temperatura com tensão são obtidas empiricamente.

O segundo ponto é que a linearização nos sensores utilizados é realizada por meio de interpolação polinomial. Os problemas inerentes que surgem neste ponto são: os coeficientes estabelecidos em normas são capazes de manter a linearização somente para faixas de temperatura específicas; a quantidade de coeficientes não é a mesma para todos os termopares; o aumento do número de termos no polinômio interpolador não permite aumento da precisão da medição.

Desta forma, o termopar mostra-se um sensor no qual a aplicação da técnica de linearização proposta neste trabalho pode otimizar sua utilização, ao estender e generalizar sua faixa de operação linear. Além disto, há a possibilidade de diminuir o custo de sua construção, ao permitir que ligas mais baratas possam ser usadas para medição em faixas maiores.

Capítulo 3

Redes Neurais Artificiais

Este capítulo inicia-se com a descrição das características da técnica de Inteligência Computacional utilizada neste trabalho, as Redes Neurais Artificiais. Após explicar a estrutura de funcionamento e motivação para o uso desta técnica, trata especificamente da rede RBF, rede de funções de base radial, uma vez que esta é a rede neural implementada neste trabalho.

As formas tradicionais de treinamento das redes RBF são apresentadas e o treinamento multiobjetivo proposto no trabalho é descrito em detalhes.

Alguns comentários e conclusões sobre a utilização de otimização multiobjetivo para treinamento de redes neurais fecham o presente capítulo.

3.1 Redes Neurais Artificiais

O funcionamento do corpo humano sempre serviu como inspiração para o desenvolvimento de sistemas computacionais, por ser este um processo de alta complexidade onde cada um dos sistemas biológicos possui uma tarefa específica que contribui para o funcionamento do todo.

Diversas áreas de conhecimento surgem inspiradas neste funcionamento: inteligência computacional, computação evolucionária, sistemas imunes, entre outras.

A área de Inteligência Computacional, inspirada no funcionamento do cérebro humano, desenvolve técnicas que buscam reproduzir a inteligência humana. Estas técnicas

envolvem as ferramentas de lógica difusa, inteligência artificial simbólica, apoio às decisões com utilização de ferramentas estatísticas, modelos ocultos de Markov e redes neurais artificiais.

As Redes Neurais Artificiais são as técnicas computacionais investigadas neste trabalho.

Haykin (1998) define as redes neurais como:

“Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.”

As redes neurais são computacionalmente poderosas por serem estruturalmente paralelamente distribuídas e pela habilidade que possuem de aprender e, desta forma, tornarem-se capazes de generalizar.

3.1.1 Características de Redes Neurais Artificiais

As redes neurais artificiais possuem inspiração biológica, mais especificamente no comportamento das redes de neurônios biológicos e sua capacidade de entender estruturas de armazenamento e processar informações. Incluem-se nesta rede o cérebro e demais partes do sistema nervoso e os diversos sistemas sensoriais, sejam eles olfato, audição, visão, tato, paladar.

O cérebro humano é o centro do sistema nervoso, sendo estimulado continuamente com informações e tomando as decisões apropriadas baseado em suas percepções. Os neurônios são considerados os constituintes estruturais do cérebro. Um neurônio biológico pode ser visto na Figura 3.1.

Os elementos responsáveis pela interação entre os neurônios são as sinapses. De forma resumida, pode-se dizer que a criação de novas conexões sinápticas e a modificação das




Figura 3.1: Representação do neurônio biológico

conexões existentes fornecem ao cérebro as características de adaptação ao ambiente e consequente aprendizagem.

Esta aprendizagem em um sistema, seja ele biológico ou artificial, está ligada diretamente à capacidade deste em se adaptar ao ambiente e a novas situações; de corrigir erros cometidos no seu passado, de forma a não repetir estes mesmos erros no futuro; de melhorar sua performance, otimizando-a como um todo; de interagir com o meio, de forma a adquirir e trocar experiências; e de representar o conhecimento adquirido.

A proposta da rede neural artificial é criar um sistema que, assim como o cérebro humano, seja capaz de aprender.

Com este objetivo, apresenta-se à rede um conjunto de dados de treinamento. Estes dados representam padrões utilizados para treinamento da rede neural. Constituem um conjunto de pontos de entrada e respectiva saída desejada para aquela entrada apresentada à rede, conforme Equação (3.1).

$$\Gamma = x_i, t_{i=1}^N \quad (3.1)$$

sendo:

x : padrões de entrada fornecidos à rede.

t : saída desejada para cada padrão de entrada fornecido à rede.

N : quantidade de padrões existentes.

Após o treinamento da rede com padrões conhecidos, que consiste no ajuste dos pesos entre os neurônios baseado em algum critério, esta deve ser capaz de reconhecer padrões desconhecidos, para os quais não foi treinada. Feito isto estará caracterizada a desejada aprendizagem.

São características estruturais básicas que devem ser definidas em um projeto de construção de uma rede neural: as funções de ativação, uma técnica de aprendizagem e a definição de uma arquitetura.

A unidade básica de toda rede neural é o neurônio artificial, que pode ser visto na Figura 3.2. Nele, são representados os estímulos externos por meio das entradas x . Os pesos w de cada neurônio caracterizam um conjunto de sinapses. O somador presente no modelo realiza a soma dos sinais de entrada, ponderados pelas respectivas sinapses do neurônio. A função de ativação φ restringe a amplitude da saída do neurônio em um valor finito.

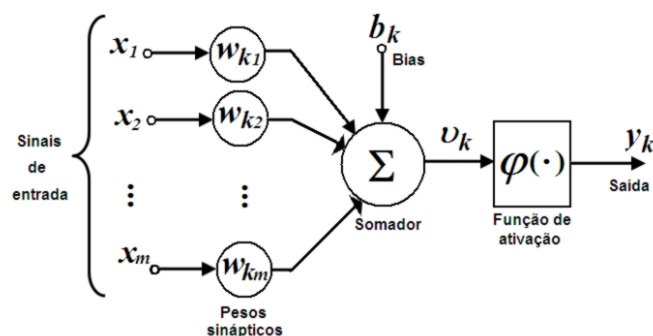


Figura 3.2: Representação do neurônio artificial

Funções de ativação

São funções usadas para restringir a amplitude de saída de um neurônio. Tipicamente, o intervalo normalizado da amplitude de saída de um neurônio é escrito como o intervalo unitário fechado $[0, 1]$ ou alternativamente $[-1, 1]$, (Haykin 1998).

As funções de ativação mais comumente utilizadas no processo de construção das redes são:

- Função de Limiar

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (3.2)$$

- Função linear por partes

$$\varphi(v) = \begin{cases} 1, & v \geq +\frac{1}{2} \\ v, & +\frac{1}{2} > v > -\frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases} \quad (3.3)$$

- Função Sigmóide

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (3.4)$$

onde v é o potencial de ativação do neurônio.

Técnicas de Aprendizagem

A aprendizagem de uma rede neural pode acontecer sob dois paradigmas.

O primeiro é conhecido como aprendizagem supervisionada, na qual existe um mentor ou professor capaz de fornecer à rede neural uma resposta desejada para um vetor de treinamento inicial. Isto ocorre quando padrões são apresentados à entrada e à saída da rede neural e o ajuste de pesos é realizado por meio do monitoramento do erro entre o valor alcançado e o valor desejado.

No segundo paradigma, a aprendizagem é dita não supervisionada e não há a figura do especialista capaz de supervisionar o processo. Esta aprendizagem é realizada quando se possuem apenas os padrões a serem apresentados na entrada da rede. Neste caso, é fornecida à rede condições para que seja realizada uma medida independente da qualidade da representação cuja rede deve aprender. Uma medida de qualidade da representação bastante utilizada é a distância Euclidiana entre os dados de entrada da rede.

Arquitetura

As possibilidades de interconexões entre neurônios na utilização das redes neurais permitem uma série de arquiteturas a serem implementadas, que atenderão às mais variadas aplicações. Embora cada arquitetura de rede possua uma quantidade de neurônios e uma forma própria de como estes se conectam, a unidade microscópica utilizada na construção de cada uma das redes neurais é o neurônio artificial, visto na Figura 3.2.

Assim, a arquitetura de uma rede neural descreve a forma como estes neurônios são interconectados. Podem-se identificar três classes distintas de arquiteturas de rede fundamentalmente diferentes, conforme citado em (Haykin 1998):

1. Redes alimentadas adiante com camada única, Figura 3.3: estas redes são constituídas aciclicamente e possuem uma camada de entrada de nós de fonte que se projeta sobre uma camada de saída de neurônios.
2. Redes alimentadas diretamente com múltiplas camadas, Figura 3.4: estas redes são constituídas aciclicamente e possuem uma camada de nós de entrada, uma ou múltiplas camadas de nós ocultos e uma camada de nós de saída.
3. Redes recorrentes, Figura 3.5: estas redes possuem pelo menos uma laço de realimentação e uma camada de nós.




Figura 3.3: Rede alimentada adiante ou acíclica com uma única camada de neurônios




Figura 3.4: Rede alimentada adiante ou acíclica totalmente conectada com uma camada oculta e uma camada de saída

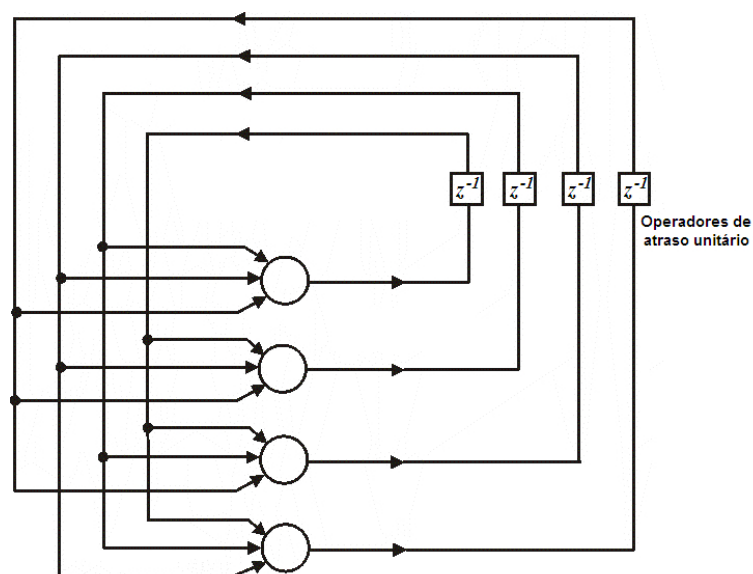


Figura 3.5: Rede recorrente com realimentação

3.2 Redes de Funções de Base Radiais

Neste trabalho, a rede implementada é a rede RBF, rede de funções de base radiais.

A arquitetura de uma rede RBF envolve duas camadas distintas e os dados de entrada, conforme pode ser visto na Figura 3.6.

A primeira camada da rede, conectada aos dados de entrada, é a única camada oculta existente. Ela é responsável por aplicar uma transformação não-linear do espaço

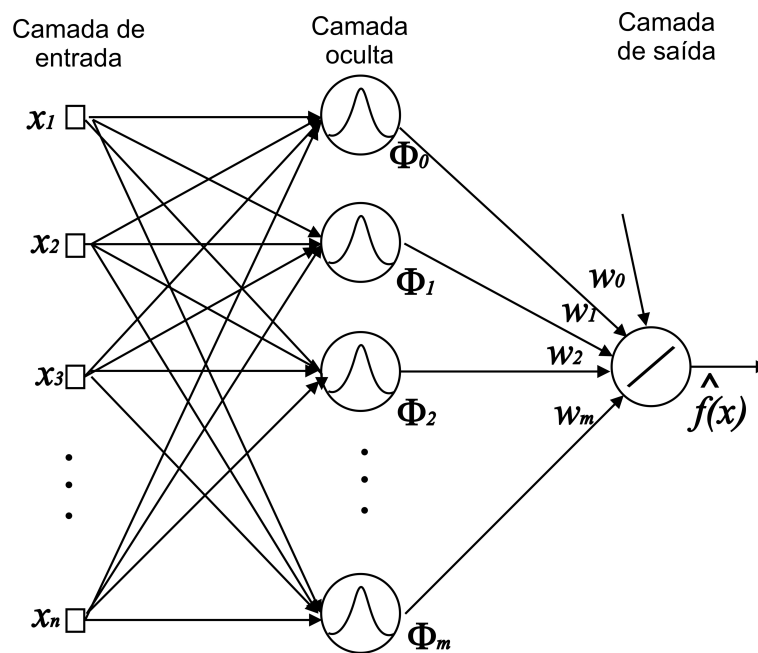


Figura 3.6: Arquitetura de uma rede RBF

de entrada para o espaço oculto. Em geral este espaço é de alta dimensionalidade.

A camada de saída da rede RBF é linear e fornece a resposta da rede ao padrão de entrada fornecido a ela em sua entrada.

No contexto de uma rede neural RBF, as unidades ocultas fornecem um conjunto de funções que constituem uma base arbitrária para os padrões de entrada, quando estes são expandidos sobre o espaço oculto. Este conjunto de funções da camada oculta são as funções de base radiais.

As funções de base radiais são funções não-lineares e seus valores crescem ou decrescem monotonicamente à medida que a distância a um ponto central aumenta. Este ponto é denominado o centro da função de base radiais.

Funções de base radial comumente utilizadas na rede RBF são as funções Gaussiana, Multiquadrática e Multiquadrática Inversa, representadas nas Equações (3.5), (3.6) e (3.7), respectivamente. De acordo com o *Teorema de Michelli*, ver Haykin (1998), elas garantem a não-singularidade da matriz de interpolação utilizada na transformação não-linear dos dados de entrada.

$$\theta_i(\mathbf{x}) = \exp\left(-\frac{(\|\mathbf{x} - \mathbf{c}_i\|)^2}{2\sigma_i^2}\right) \quad (3.5)$$

$$\theta_i(\mathbf{x}) = \sqrt{(\|\mathbf{x} - \mathbf{c}_i\|)^2 + \sigma_i^2} \quad (3.6)$$

$$\theta_i(\mathbf{x}) = \frac{1}{\sqrt{(\|\mathbf{x} - \mathbf{c}_i\|)^2 + \sigma_i^2}} \quad (3.7)$$

em que \mathbf{c}_i são os centros e σ as larguras das funções de base radiais e \mathbf{x} é o vetor de entrada.

Neste trabalho, foi utilizada a função Gaussiana, cujos centros são as médias μ e as larguras da função são os desvios σ .

Definida a função de base radial a ser utilizada nos neurônios da camada oculta, a função de saída, que é a função de aproximação da rede, é representada por:

$$\hat{f}(\mathbf{x}) = \sum_{i=0}^m w_i \theta_i(\|\mathbf{x} - \mathbf{c}_i\|), \quad \theta_0 = +1 \quad (3.8)$$

em que θ_i são as funções de base radiais cujos centros são \mathbf{c}_i , \mathbf{x} é o vetor de tamanho n dos padrões de entrada e w_i é o peso da rede. A rede possui $m + 1$ pesos e m neurônios.

Determinados os parâmetros das funções de base, centros μ e larguras σ , o problema de construção da função \hat{f} consistirá, então, na determinação dos pesos w_i . A partir dos dados de treinamento, é construído o sistema de equações:

$$\Theta \mathbf{w} = \mathbf{t} \quad (3.9)$$

em que Θ é a matriz com os valores das funções de base e \mathbf{t} são os valores de saída desejados. Se o número de pontos é igual a m e Θ for não singular, pode-se resolver o sistema simétrico assim obtido e encontrar \mathbf{w} . Se houver mais pontos do que funções de

base, então o sistema é sobredeterminado, e pode-se encontrar uma solução de mínimos quadrados.

3.3 Treinamento das Redes de Funções de Base Radiais

O treinamento de uma rede RBF consiste no processo pelo qual seus parâmetros serão ajustados de forma a reproduzir a função original. O objetivo não é apenas armazenar uma estrutura de dados conhecida, mas sim criar um mapeamento suave que seja capaz de realizar interpolação coerentemente em regiões onde não existam dados.

Assim, a rede será capaz de generalizar e aproximar a sua saída de forma correta para padrões de entrada que não foram apresentados a ela durante a etapa de treinamento.

A definição da arquitetura da rede RBF é realizada por meio da minimização da função de custo erro de treinamento, a média da soma dos erros quadráticos, Equação (3.10). Assim, o ajuste de pesos da rede RBF é realizado minimizando-se o erro quadrático médio durante o processo de aprendizagem. A arquitetura da rede será ajustada de acordo com um erro máximo estabelecido.

$$\xi_{MSE}(\{\mu_i\}, \sigma, \mathbf{w}) = \frac{1}{N} \sum_{n=1}^N \left[t_n - \hat{f}(\mathbf{x}_n) \right]^2 \quad (3.10)$$

onde $\{\mu_i\}$ são os centros das funções de base, σ é o vetor com as larguras das funções de base, e $N \geq m$ é o número de pontos do conjunto de treinamento.

3.3.1 Treinamento Supervisionado

No treinamento supervisionado da rede RBF, os centros μ e larguras σ das funções de base radiais não são fixados. Desta forma, o problema do treinamento torna-se um problema de otimização não-linear.

O treinamento supervisionado possui a desvantagem de tratar-se de um método de otimização não-linear computacionalmente caro, cuja convergência pode ser muito lenta, conforme (Barreto 2003).

Outra desvantagem deste treinamento é que não há nenhuma imposição quanto à

estrutura da rede e os centros podem assumir valores próximos, perdendo-se assim a propriedade de localidade destas redes.

Assim, pode-se realizar o treinamento da rede RBF de forma semi-supervisionada.

3.3.2 Treinamento Semi-Supervisionado

Para o caso onde os valores de centros μ e larguras σ das funções de base radiais são fixados, a otimização será realizada apenas para o parâmetro w . Este modelo é dito linear nos parâmetros. Entretanto, neste caso, é necessário que se estabeleça um critério para a definição dos parâmetros da função de base radial, centros μ e larguras σ .

O treinamento da rede é, então, dividido em duas etapas: a primeira não-supervisionada, para a escolha dos centros e larguras das funções de base radiais e a segunda, com os parâmetros da rede fixados, para encontrar os valores dos pesos w_i realizando o treinamento da rede RBF como uma rede linear.

A etapa não supervisionada será realizada, neste contexto, para a procura de valores que possam ser utilizados como os centros μ e larguras σ das funções de base radial, e não para o treinamento de toda a rede.

Existem diversas alternativas para a escolha dos centros e larguras das funções de base de forma não-supervisionada. Duas delas são as seguintes:

1. Auto-organizar os centros, agrupando-os de acordo com a distribuição dos dados de entrada.
2. Espalhar os centros uniformemente ao longo da região em que se encontram os dados.

Ambas as alternativas serão descritas nos itens seguintes.

Agrupamento de dados

Uma alternativa para a etapa de treinamento não supervisionado que utiliza a extração de características que revelem estruturas comuns em um conjunto de dados é o agrupamento de dados, também chamado *clusterização*.

A *clusterização* consiste em se particionar um conjunto de dados de n pontos dentro de um espaço m dimensional em K distintos clusters de forma a agrupar os dados similares, com relação a uma medida que, de forma geral, é uma medida de distância.

São características de algoritmos de *clusterização*:

- Sensibilidade à forma como a inicialização dos centros dos agrupamentos é gerada;
- É definido para dados contínuos;
- Não garante uma única solução para a *clusterização*, devido aos diferentes resultados obtidos com os valores iniciais dos centros dos clusters quando estes são escolhidos aleatoriamente.
- Os melhores resultados são obtidos quando as partições iniciais estão próximas das soluções finais.

Um algoritmo de *clusterização* amplamente utilizado na literatura é conhecido como *K-médias* e pode ser descrito por meio do fluxograma exibido na Figura 3.7.

Fixação dos centros μ e larguras σ das funções de base radiais

Um dos critérios estabelecido na literatura, ver Haykin (1998), para obtenção dos valores dos centros μ das funções de base radiais consiste em distribuir estes centros de forma uniforme ao longo da região onde encontram-se os dados de entrada da rede.

Já para o cálculo das larguras das funções de base radial, ainda que estas possam ser distintas e ajustáveis para cada centro, adota-se uma única largura para todos as funções. Estas dispersões são calculadas a partir da Equação (3.11).

$$\sigma = \frac{d_{max}}{\sqrt{2m}} \quad (3.11)$$

onde:

m é o número de centros;

d_{max} é a distância máxima entre os centros.

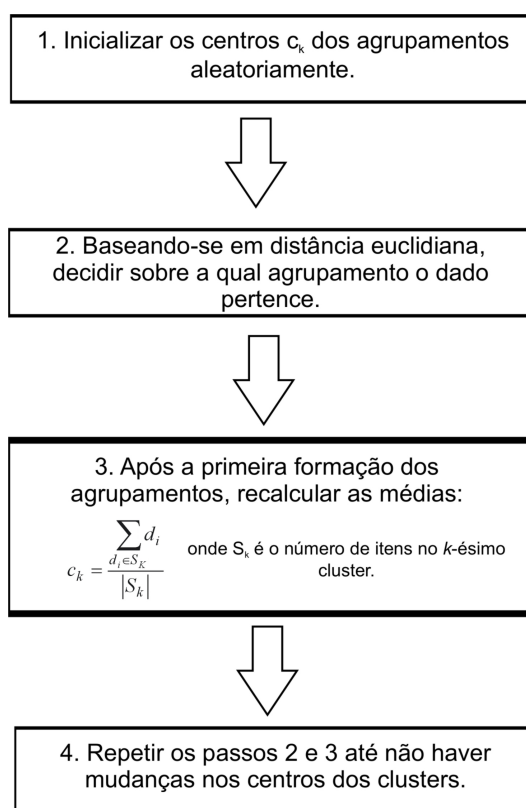


Figura 3.7: Fluxograma do funcionamento do algoritmo K-Médias

3.3.3 Treinamento Multiobjetivo

Os pesos que serão ajustados pela rede RBF são números reais e a representação destes em *hardware* é realizada em forma de ponto flutuante. Esta representação é feita no formato número x base^{expoente}. Dois parâmetros são variados nesta representação: a posição da vírgula e a potência à qual elevamos a base.

Quanto menor o valor encontrado para os pesos, mais espaço será necessário na memória do *hardware* para armazenar o valor do expoente deste peso. No contexto deste trabalho o *hardware* utilizado é um microcontrolador.

Os microcontroladores são projetados para realizar as operações aritméticas mais simples: adição e subtração. Portanto, não foram projetados para possuírem grande espaço em memória para armazenamento de dados. Parte da memória é utilizada na gravação das instruções de operação e não dos dados.

Desta forma, a possibilidade de descartar-se os pesos de menor valor fornece um ganho relevante com relação à diminuição do custo computacional da implementação

em um microcontrolador, economizando espaço em memória.

Para atender a esta implementação dos pesos em *hardware*, é proposto um treinamento para a rede neural diferente dos citados nos itens anteriores. Propõe-se, aqui, um treinamento que não otimize os parâmetros da rede apenas para a função erro quadrático médio. Os parâmetros da rede devem ser minimizados também para alguma medida que represente a memória a ser utilizada na implementação em *hardware*. Esta segunda avaliação pode ser realizada por meio da complexidade da rede, que é função da norma dos pesos ajustados.

Desta forma, tem-se um treinamento multiobjetivo a ser realizado, para as funções erro quadrático médio e complexidade da rede.

Segue, então, a formulação matemática do treinamento multiobjetivo proposto:

$$\min \left[f_1(\mathbf{w}) \quad f_2(\mathbf{w}) \right]^T \quad (3.12)$$

com

$$f_1(\mathbf{w}) = \frac{1}{2} [\mathbf{t} - \Theta \mathbf{w}]^T [\mathbf{t} - \Theta \mathbf{w}] \quad (3.13)$$

e

$$f_2(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} \quad (3.14)$$

Minimizar as funções $f_1(w)$ e $f_2(w)$ gera soluções conflitantes, onde a melhora em uma das funções representa necessariamente a piora na outra função. A representação destas soluções, chamadas Pareto-ótimas, pode ser vista na Figura 3.8. Os pontos que representam soluções não dominadas constituem, então, o gráfico de Pareto.

Como ambas as funções a serem otimizadas são convexas, pode-se adotar sua combinação convexa para geração da solução Pareto-ótima:

$$\min \lambda f_1(\mathbf{w}) + (1 - \lambda) f_2(\mathbf{w}) \quad (3.15)$$




Figura 3.8: Gráfico de Pareto

que possui solução de mínimos quadrados dada por:

$$\hat{\mathbf{w}} = \left[\mathbf{\Theta}^T \mathbf{\Theta} + N \frac{(1-\lambda)}{\lambda} I \right]^{-1} \mathbf{\Theta}^T t \quad (3.16)$$

Cada valor de λ , que deve estar entre $[0,1]$, gera um conjunto de pesos ótimos e um ponto no gráfico de Pareto. Será gerada como solução do treinamento multiobjetivo da rede, assim, um gráfico de Pareto com o número de pontos igual à quantidade de λ 's variados.

O Critério de Decisão

Uma vez que o gráfico de Pareto esteja construído, o próximo passo é decidir sobre qual ponto atende de forma mais satisfatória aos dois objetivos. O critério de decisão proposto é baseado na simulação das redes do conjunto Pareto usando os dados de teste.

Após simuladas as redes encontradas, faz-se uma regressão linear da relação entrada e saída do sensor integrado com a rede neural, obtendo-se uma relação linear. A rede que obtiver um menor erro entre seu valor estimado e os valores de regressão ajustados será escolhida como a rede a ser implementada.

3.4 Conclusão

Neste capítulo foram descritas e discutidas arquiteturas e técnicas de treinamento de redes neurais artificiais de forma geral. Existem diversas possibilidades de arquitetura e técnicas que podem ser utilizadas para os problemas a serem resolvidos pelas redes neurais, sejam eles de aproximação de funções, de regressão linear, de reconhecimento de padrões, de previsão de séries temporais.

Em seguida, o capítulo trata especificamente da rede RBF, rede de funções de base radiais e oferece especial atenção sobre sua arquitetura e treinamento por ter sido esta rede a escolhida para implementação neste trabalho.

A escolha da rede RBF torna-se interessante na medida em que esta rede possui arquitetura e treinamento simplificados, com grande capacidade de generalização, o que é desejado para este estudo.

As formas de treinamento possíveis para esta rede são discutidas e é proposto um treinamento multiobjetivo, o qual atenderá o objetivo de minimizar a complexidade estrutural da rede para que os pesos possam ser implementados em um microcontrolador de forma a otimizar o uso de memória deste *hardware*.

Para o problema proposto nesta dissertação, as características desta técnica específica da área de Inteligência Computacional, as redes neurais, mostram-se bastante adequadas.

Capítulo 4

Sistema de Linearização e Calibração de Sensores

Este capítulo descreve a implementação de cada etapa realizada para a criação de um sistema automático de calibração e linearização de sensores.

Na introdução são citados separadamente os equipamentos de *hardware* utilizados e suas funções no sistema e o algoritmo que constitui a realização em *software*.

As etapas estabelecidas no capítulo 1 como objetivos específicos deste trabalho são descritas em seguida, na ordem do fluxo que os sinais devem seguir para que seja realizada a sua calibração e linearização.

São exibidas as montagens realizadas, os programas e telas criados e características técnicas tanto do *hardware* quanto do *software*.

Uma discussão sobre a topologia do sistema a ser treinado, suas vantagens e desvantagens e a escolha realizada para implementação no sistema é apresentada em seguida.

Discutidas as topologias e as possíveis otimizações, o algoritmo implementado neste trabalho é detalhado, desde a leitura dos sinais para treinamento até a saída escolhida automaticamente por um módulo de decisão. A forma como este módulo é implementado também é apresentada.

O capítulo descreve ainda o funcionamento do sistema, de forma separada para as etapas de aquisição dos dados, implementação do treinamento da rede neural que lineariza e calibra automaticamente o sinal e a decisão sobre o sistema ótimo.

Por fim, discussões e conclusões são apresentadas sobre todos os aspectos abordados ao longo deste capítulo.

4.1 Introdução

Existem na literatura diversos estudos e na indústria diversas implementações de sistemas que unem *hardware* e *software* com o objetivo de realizar calibrações e ajustes *online* ou *offline* de equipamentos, de forma automática e confiável.

O sistema implementado neste trabalho, cujo esquema encontra-se na Figura 4.1 e montagem na Figura 4.2, integra *hardware* e *software* com a proposta de realizar a calibração e linearização automática de quaisquer sensores.

A parte pertinente ao *hardware*, na montagem da Figura 4.2, é constituída de um computador pessoal portátil padrão IBM, com 2Gbytes de memória RAM, 160 Gbytes de disco rígido, processador Intel Pentium Dual-Core e interfaces de comunicação USB; um microcontrolador PIC 18F4550 implementado em um módulo ECIO-40P; um circuito de amplificação de sinal e um display de 16 x 2 segmentos.

Os microcontroladores são circuitos eletrônicos programáveis extremamente versáteis com relação às implementações de sistemas, tanto por seu relativo baixo custo quanto por sua simplicidade de programação. Entretanto, possuem baixa resolução para manipulação numérica de dados em ponto flutuante e uma capacidade de memória limitada. Por estas últimas características, procura-se neste trabalho implementar um sistema que manipule uma quantidade de dados reduzida.

Já o *software* é implementado para treinamento da rede neural. Como o treinamento de uma rede neural artificial possui custo computacional elevado, decidiu-se neste momento pelo treinamento *offline* desta. Assim, o ajuste dos pesos da rede é realizado em um programa computacional desenvolvido no *software* Matlab com esta finalidade. O programa é executado em um computador padrão IBM, devido à sua arquitetura, que possui grande capacidade de processamento de dados.

Os padrões de entrada e saída utilizados para treinamento *offline* da rede são obtidos diretamente da leitura dos sinais dos sensores ajustados para este trabalho, durante um intervalo de tempo pré-determinado. Desta forma, garante-se que a calibração do sinal de saída do sensor corresponde efetivamente ao instrumento a ser ajustado.

Em seguida, os pesos ajustados durante o treinamento da rede são enviados por meio da interface USB do computador a um microcontrolador de 16 bits, juntamente com os parâmetros de largura σ e centro μ da função de base radial que constituem cada neurônio da camada escondida da rede RBF.

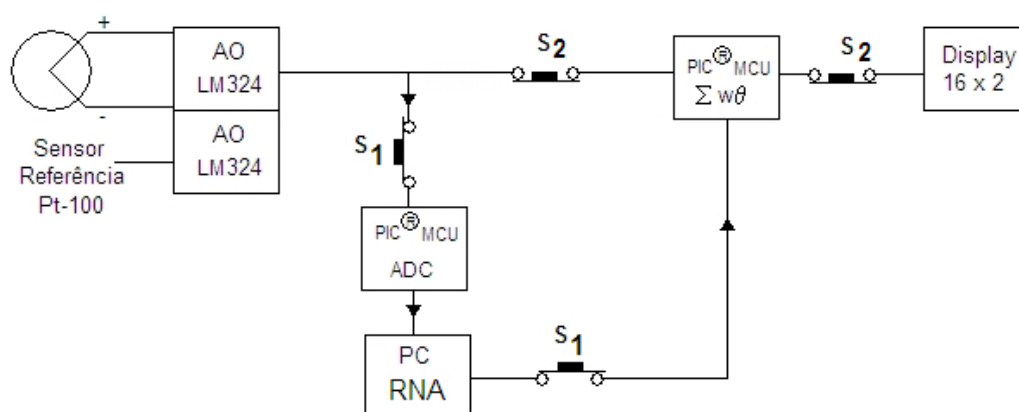


Figura 4.1: Esquemático do sistema implementado para auto-calibração e linearização de sensores

Assim, o funcionamento do sistema de auto-calibração é estabelecido em três etapas: aquisição dos dados, treinamento da rede neural e decisão sobre o sistema linear ótimo.

4.2 Aquisição dos Dados

O sistema de auto-calibração desenvolvido está ajustado fisicamente para linearizar sensores de temperatura do tipo termopar.

A aquisição de dados e o fluxo do sinal para esta configuração com termopares é realizada com os botões S_1 fechados e S_2 abertos, na Figura 4.1. Neste estágio, portanto, o sistema terá a configuração exibida na Figura 4.3.

Os dados a serem adquiridos para treinamento da rede são o valor de tensão gerado pelo termopar e o valor de temperatura medido por um sensor de referência.

Os valores de tensão gerados pelo termopar são lidos em conjunto com a resistência gerada pelo sensor termoresistivo Pt-100. O Pt-100 é um sensor baseado em variação de resistência com a temperatura e é utilizado como referência para valores de temperatura entre -200 a 850 °C, podendo medir além desta faixa de operação, porém com erros de



Figura 4.2: Sistema implementado para auto-calibração e linearização dos sensores

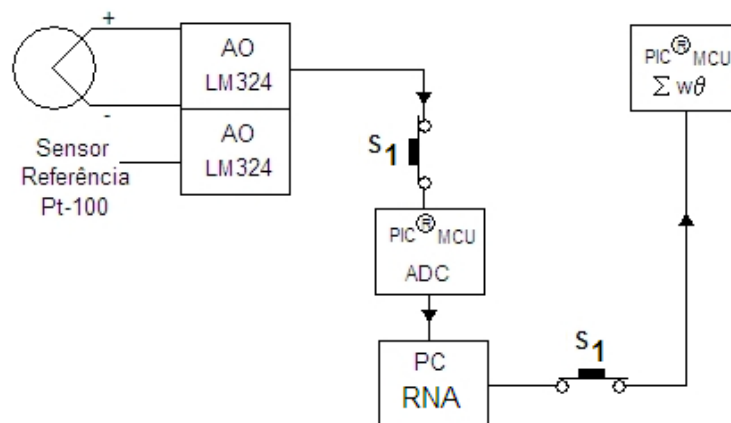


Figura 4.3: Funcionamento do sistema durante a etapa de auto-calibração

medições maiores. Os valores de resistência lidos são convertidos em temperatura no programa de computador desenvolvido.

Por serem valores analógicos de baixa amplitude, os sinais de tensão e resistência devem ser processados antes de serem enviados ao computador para treinamento *offline* da rede. São utilizados dois amplificadores operacionais de baixo custo para o estágio de

amplificação. Para a conversão analógico-digital dos sinais será utilizado um módulo específico do próprio microcontrolador que atua na etapa de auto-calibração e linearização do sinal.

Assim, nesta etapa, o sinal é submetido a dois circuitos de condicionamento, sejam eles:

- Amplificador
- Conversor Analógico/Digital

No estágio de amplificação dos valores de tensão gerados pelo termopar e resistência do sensor de referência, ambos terão seus sinais aumentados em 100 vezes. Utiliza-se um amplificador operacional LM324, devido a duas características importantes que possui: seu ganho de tensão contínua, de 100 dB, que atende ao trabalho proposto e sua alimentação, que pode ser realizada entre 3 e 30V de forma assimétrica. A maioria dos amplificadores operacionais é alimentado de forma simétrica. Entretanto, estas fontes possuem construção mais complexa. O uso do amplificador com alimentação assimétrica permite que a própria interface USB faça a alimentação dos circuitos eletrônicos durante a fase de treinamento da rede, pois esta fornece +5V de tensão e até 100mA de corrente contínua.

Em seguida à leitura e amplificação do sinal de tensão e do sinal de resistência, estes são enviados ao microcontrolador, onde serão convertidos em sinais digitais, conforme a programação do microcontrolador, realizada no programa FlowCode, da Microchip e vista na Figura 4.4.

O microcontrolador utilizado neste sistema é o PIC 18F4550, que opera com resolução de 16 bits. A escolha do 18F4550 deu-se por sua integração com a interface USB e capacidade de memória, que é de 32kbytes. Esta capacidade de memória é considerada alta se comparada à capacidade de outros microcontroladores. Suas principais especificações podem ser vista na Figura 4.5.

Após a digitalização dos sinais pelo microcontrolador, estes são enviados ao computador por meio da interface USB, o que garante rapidez na transmissão dos dados e flexibilidade, por ser esta interface um padrão bastante presente nos computadores atuais e promissor com relação a utilizações futuras. A escolha da interface USB, portanto, torna o sistema flexível quanto à sua utilização.

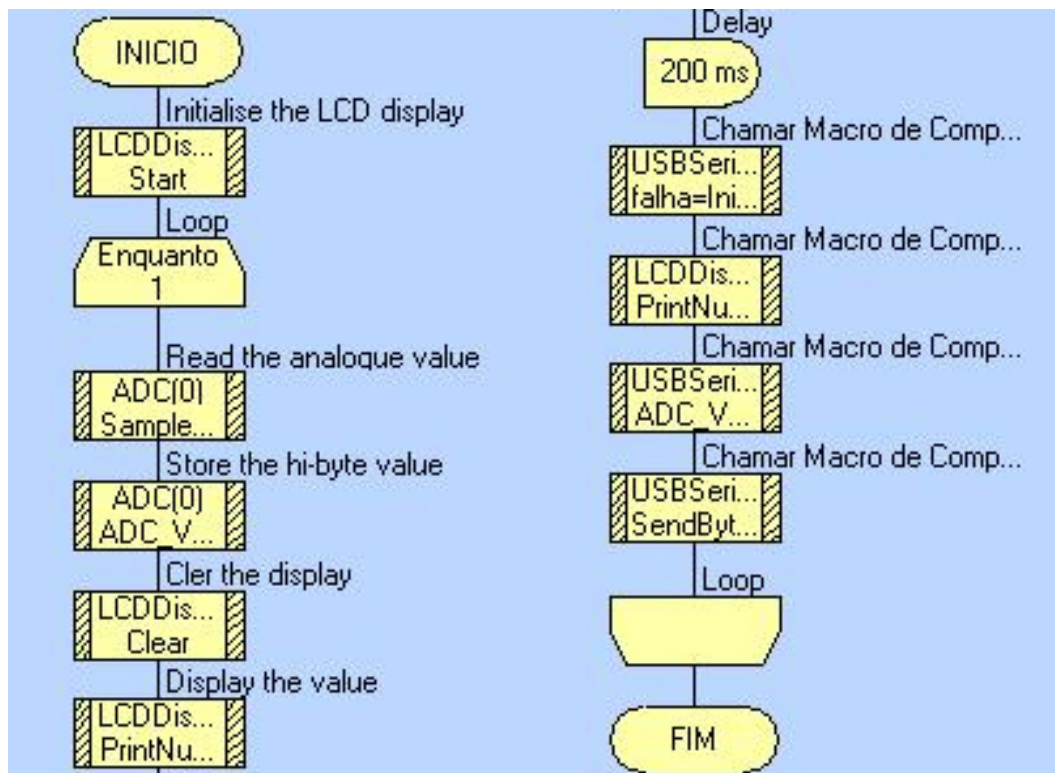


Figura 4.4: Programa do microcontrolador para conversão Analógico-Digital

Device	Program Memory		Data Memory		I/O	10-Bit A/D (ch)	CCP/ECCP (PWM)	SPP	MSSP		EAUSART	Comparators	Timers 8/16-Bit
	Flash (bytes)	# Single-Word Instructions	SRAM (bytes)	EEPROM (bytes)					SPI	Master I ² C™			
PIC18F2455	24K	12288	2048	256	24	10	2/0	No	Y	Y	1	2	1/3
PIC18F2550	32K	16384	2048	256	24	10	2/0	No	Y	Y	1	2	1/3
PIC18F4455	24K	12288	2048	256	35	13	1/1	Yes	Y	Y	1	2	1/3
PIC18F4550	32K	16384	2048	256	35	13	1/1	Yes	Y	Y	1	2	1/3

Figura 4.5: Especificações do Microcontrolador PIC18F4550

Realizado o treinamento da rede neural, que é a próxima etapa descrita, os sinais relativos aos pesos ajustados, centros e larguras estabelecidos para cada neurônio são enviados novamente ao microcontrolador.

4.3 Treinamento da Rede Neural

A escolha do algoritmo de treinamento da rede neural deve ser precedida pela definição do problema a ser aproximado e da topologia do sistema implementado.

Problema: encontrar uma relação linear entre entrada e saída de um sensor qualquer, por meio de uma rede neural.

Sejam:

x : valor lido pelo sensor.

$g(x)$: função do sensor, não-linear.

$v(x) = g(x) + \delta$: função do sensor com ruído.

$f(\cdot)$: saída da rede neural, não-linear. Definida pela topologia escolhida.

$y = kx$: saída do sistema, linear, onde k é uma constante.

Definido o problema, serão discutidas duas topologias para implementação do algoritmo de treinamento da rede, de forma a obter-se uma relação entrada-saída linear no contexto deste trabalho. A configuração dos sinais de entrada e saída do sistema, assim como a posição do sensor e da rede definem as topologias série e paralela.

4.3.1 Topologia Série

O sistema implementado em topologia série é exibido na Figura 4.6. A estrutura estabelecida neste caso consiste em uma ligação em série do sensor à rede neural. Deseja-se um sinal linear entre a saída da rede neural e a entrada do sensor.

Desta forma, o sinal primário x é lido pelo sensor, que gera um sinal $g(x)$. Esta relação x *versus* $g(x)$ é a relação não-linear a ser linearizada.

Ao sinal $g(x)$ é acrescentado ruído, representando os ruídos a que estão sujeitos os sensores, de forma geral: térmicos, sonoros, eletromagnéticos. Esta função com ruído é representada por $v(x)$.

A função $v(x)$ é a entrada da rede neural e a saída será a função $f(v(x))$, que estabelece a relação linear desejada x *versus* $f(x)$.

A rede neural deve modelar a função inversa $g^{-1}(x)$. Entretanto, há casos em que




Figura 4.6: Topologia Série

a função inversa pode não existir. A Figura 1.2 exibe um exemplo de função que não possui inversa.

Dada uma função $f: A \rightarrow B$, se f é bijetora, então existirá a função inversa f^{-1} como sendo a função de B em A , tal que $f^{-1}(y) = x$, conforme visto na Figura 4.7.




Figura 4.7: Função Inversa

Conclui-se que a função a ser linearizada deve possuir inversa para que o sistema proposto tenha solução.

As equações que são estabelecidas para esta topologia são as seguintes:

$$y = f(g) + \delta_2 \quad (4.1)$$

$$y = f[g(x) + \delta_1] + \delta_2 \quad (4.2)$$

onde δ_1 é o ruído do sinal lido pelo sensor e δ_2 é o ruído do sensor de referência.

Para δ_1 próximo de zero, tem-se que:

$$f[g(x) + \delta_1] \approx f[g(x)] + \delta_1 \frac{df}{dg}, \quad (4.3)$$

que é uma aproximação por série de Taylor.

Utilizando a topologia série, desta forma, a rede neural deve modelar a função inversa $g^{-1}(x)$ para ter em sua saída a relação linear desejada. O ruído inserido no sistema devido ao sensor a ser modelado, pode ser adicionado ao ruído do sensor de referência. Desta forma, este não é, necessariamente, gaussiano. Ainda assim, é possível aproximá-lo por um ruído gaussiano, pois é de baixo valor.

Esta topologia é capaz de solucionar o problema de linearização do sensor, pois sua entrada é o sinal gerado pelo sensor e sua saída deve ser o sinal primário que é função do sinal lido na saída do sensor.

4.3.2 Topologia Paralela

Na topologia em paralelo do sistema, como pode ser visto na Figura 4.8, o valor x lido pelo sensor é também a entrada da rede neural a ser treinada.

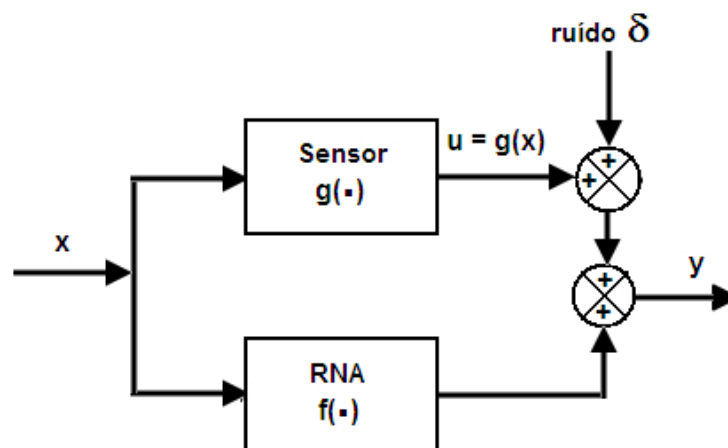


Figura 4.8: Topologia Paralela

O ruído, assim como na topologia em série, é acrescentado ao sinal $g(x)$, que é a saída do sensor. A diferença para a topologia em série está no fato de que o sinal entregue à saída da rede como valor desejado é $(x - v(x))$. Portanto, o ruído está acrescentado ao sinal de saída da rede neural e não à sua entrada.

As relações estabelecidas para a topologia paralela são:

$$y = g(x) + \delta + f(x) = x. \quad (4.4)$$

Portanto, a saída desejada para a rede é:

$$f(x) = x - (g(x) + \delta) \quad (4.5)$$

O treinamento da rede neural, nesta topologia, modela o desvio não linear do sensor em relação a reta. Assim, a topologia em paralelo do sensor com a rede neural permite, sem perder a capacidade de representação do ruído existente, que a função aproximada pela rede seja modelada de forma correta. Neste caso, a função a ser modelada não precisa ter inversa.

Ela foi investigada por ter sido utilizada, com sucesso, em trabalhos de compensação de não-linearidades em sensores provocadas por variáveis externas. Patra & van den Bos (2000), Patra, Ang & Das (2004), Patra, Chakraborty & Meher (2008) implementam esta topologia para realizar, por meio da rede neural perceptron de múltiplas camadas, a compensação em sensores capacitivos provocada pela variação da temperatura ambiente.

Para o caso deste trabalho, entretanto, esta topologia não se mostra adequada, uma vez que o foco não é a compensação de variáveis externas. Deve ser feita a linearização de relações entrada/saída em sensores inerentemente não-lineares. Desta forma, o sistema deve ser capaz de fornecer como resposta uma relação linear entre a entrada fornecida a este, x e a saída y .

Se esta é a relação a ser fornecida pelo sistema implementado, a entrada do sensor não pode ser enviada diretamente a rede neural, pois é ela que desejamos encontrar por meio da modelagem. O sinal a ser utilizado como entrada para a rede neural deve ser a saída do sensor, que é função da entrada, $f(x) = u$.

Este é o motivo pelo qual a topologia paralela não se mostrou adequada para resolver o problema proposto, como um todo, de auto-calibração e linearização de sensores, embora existam contextos nos quais a sua implementação é justificada e adequada.

A topologia adequada e que deve ser utilizada neste trabalho é, assim, a topologia série. O treinamento da rede RBF é realizado, portanto, para o sistema implementado com esta topologia.

4.3.3 Treinamento da rede RBF

Embora o sistema implemente o treinamento multiobjetivo, é realizado também um treinamento mono-objetivo neste trabalho, para fins de comparação e estudo.

A função de base radial utilizada na camada escondida da rede RBF foi a Gaussiana.

O treinamento da rede RBF consiste na otimização da função de custo MSE - Erro Quadrático Médio, conforme descrito no Capítulo 3, Equação (3.10).

O algoritmo de treinamento da rede utilizado realiza o ajuste dos pesos da camada de saída da rede RBF e fixa os valores dos centros μ e larguras σ baseados no critério descrito no capítulo 3, onde os valores dos centros μ são obtidos a partir dos dados de entrada e o valor de largura σ é obtido por meio da distância máxima entre os centros e a quantidade de dados disponíveis para treinamento, conforme Equação (3.11). O modelo é, assim, linear nos parâmetros e, desta forma, realiza-se o treinamento semi-supervisionado.

Assim, na primeira parte do treinamento da rede, estabelecem-se os valores de largura σ e centros μ em uma etapa não-supervisionada, conforme Equação (3.11).

Este critério de cálculo direto dos parâmetros das funções de base radiais foi escolhido em detrimento da *clusterização* dos dados por garantir a distribuição dos centros μ ao longo dos dados de entrada, evitando perda da propriedade de localidade destas redes, o que pode acontecer se os centros no procedimento de *clusterização* forem iniciados aleatoriamente.

Na segunda etapa do treinamento, a etapa supervisionada, utiliza-se o Método dos Mínimos Quadrados para solucionar o problema de otimização da função de custo erro quadrático médio, Equação (3.10).

Treinamento Mono-objetivo

No treinamento mono-objetivo da rede neural, apenas uma função de custo será otimizada com relação ao parâmetro peso w . Esta função é o erro quadrático médio, Equação (3.10). Assim, o problema pode ser formulado matematicamente como:

$$\min_w C(\mathbf{w}) \quad (4.6)$$

com a função de custo

$$C(\mathbf{w}) = \frac{1}{2} [\mathbf{t} - \Theta \mathbf{w}]^T [\mathbf{t} - \Theta \mathbf{w}] \quad (4.7)$$

que possui solução de mínimos quadrados dada por:

$$\hat{\mathbf{w}} = (\Theta^T \Theta)^{-1} \Theta^T \mathbf{t} \quad (4.8)$$

em que Θ_i é a matriz de funções de base radiais, \mathbf{t} é o vetor de valores desejados e \mathbf{w} é o vetor de pesos da rede.

Treinamento Multiobjetivo

No treinamento multiobjetivo da rede RBF, conforme já citado Capítulo 3, item 3.2.2, uma segunda função de custo deve ser otimizada em conjunto com a minimização do erro quadrático médio. Esta função mede a complexidade da rede, por meio do cálculo da norma dos pesos desta. Quanto maior o valor da norma, mais complexa é a estrutura da rede. No caso da rede RBF, isto significa maior quantidade de neurônios.

A maior complexidade da rede e conseqüente maior quantidade de neurônios na camada escondida, significa um valor de erro quadrático médio menor. Nesta otimização procura-se estabelecer um equilíbrio entre o erro e a complexidade da rede, que são objetivos conflitantes. Minimizar o erro é aumentar a complexidade da estrutura e minimizar a complexidade é aumentar o erro. Assim, são geradas soluções ótimas de Pareto, que fornecerão opções para a escolha desejada para o equilíbrio entre erro e

complexidade.

Assim, tem-se como resultado do treinamento da rede possíveis estruturas neuronais simplificadas com um erro mínimo.

Para que haja uma maior diversidade de soluções para o treinamento multiobjetivo da rede neural, o algoritmo não gera apenas um conjunto de Pareto pelo método P- λ , gera k conjuntos. Assim, opta-se pela seguinte implementação para a geração dos k Paretos:

1. Os centros μ de cada função de base radial são gerados a partir de uma distribuição uniforme dos dados de entrada.
2. O valor da largura σ da função de base radial será variado para cada treinamento multiobjetivo realizado, embora seja fixo para o treinamento corrente.
3. São gerados dez valores para a largura σ , escolhidos de forma aleatória entre 0 e o valor calculado pela Equação (3.11).
4. Mantidos os centros μ da redes de funções de base radiais calculados em 1, para cada um dos 10 valores de largura σ realiza-se então o treinamento multiobjetivo da rede, gerando uma solução de Pareto para cada largura σ .
5. Tem-se, ao final de todo o processo de treinamento multiobjetivo, 10 Paretos gerados.
6. Um algoritmo de não dominância de pontos estabelece entre todos os pontos de todos os Paretos gerados, aqueles que constituem o Pareto ótimo.

Desta forma, aumenta-se a quantidade de soluções possíveis, aumentando o espaço de busca.

Tanto a etapa semi-supervisionada quanto a supervisionada são realizadas em um *software* elaborado em Matlab especificamente para este fim e disponível em um micro-computador. A Figura 4.9 exhibe a interface principal do *software* criado.

Já o fluxograma descrito na Figura 4.10 especifica as etapas de treinamento da rede neural e em seguida sua validação por meio dos pontos de teste.

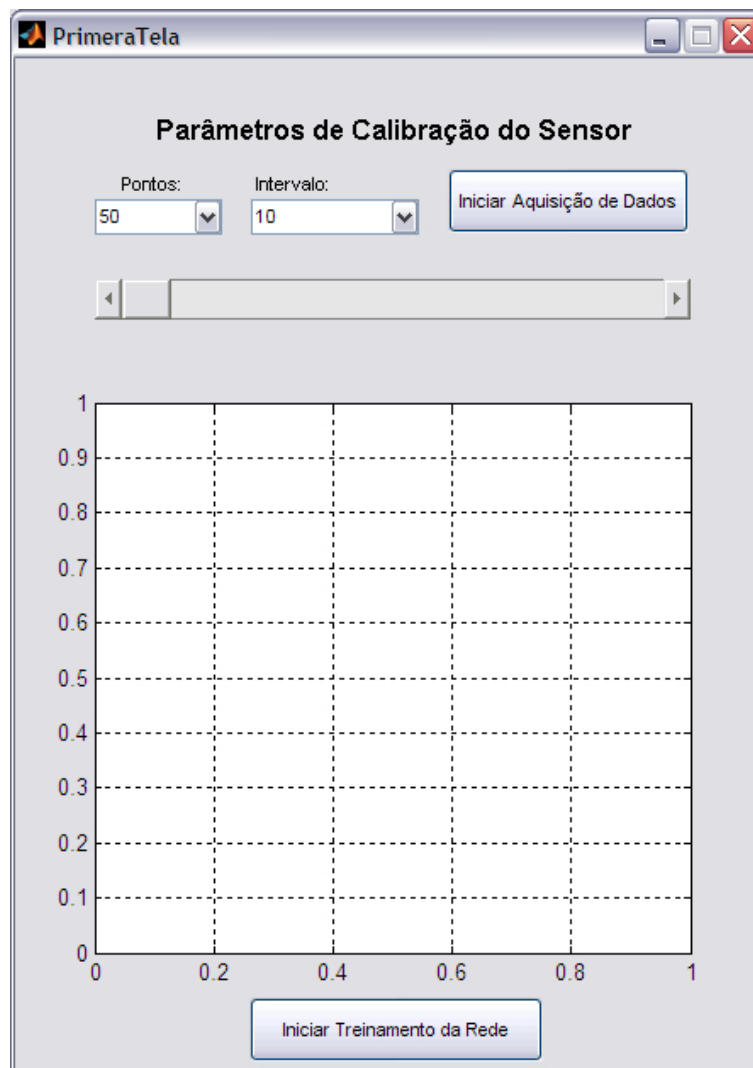


Figura 4.9: Programa de treinamento da Rede RBF

4.3.4 Critério de Decisão

Como o treinamento multiobjetivo é utilizado neste trabalho, o resultado da otimização será um gráfico de Pareto. As soluções de Pareto são ótimas em um contexto multi-objetivo, mas deve-se escolher dentre elas aquela que será enviada ao microcontrolador, concluindo o processo de linearização em *hardware*.

A decisão a ser tomada é sobre qual rede resultante do treinamento multiobjetivo possui o menor erro quadrático médio para a reta linear ($ax + b$) desejada gerada por regressão linear dos dados de teste.

Esta decisão é gerada automaticamente, mas o programa implementado permite que

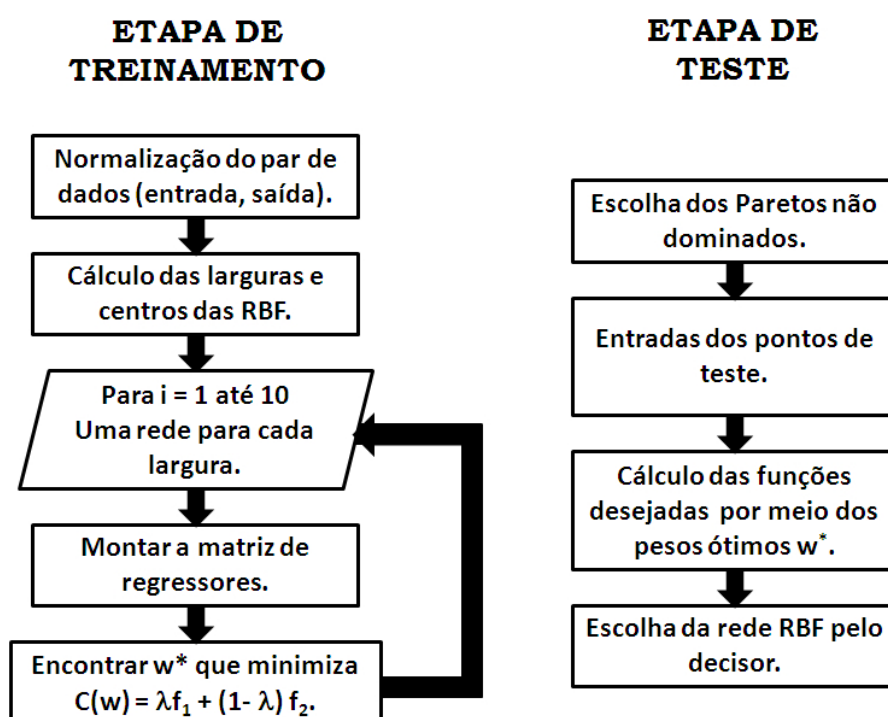


Figura 4.10: Fluxograma do Treinamento da Rede Neural

outros pontos do gráfico de Pareto possam ser escolhidos manualmente e, desta forma, a rede definida pela escolha manual tenha seus parâmetros entregues ao microcontrolador para o processo de linearização.

Escolhida uma rede ótima a ser implementada, que possua uma relação erro *versus* complexidade adequada, os parâmetros da rede largura σ , centro μ e pesos ótimos são entregues ao microcontrolador via interface USB.

O diagrama do funcionamento desta etapa está descrito na Figura 4.11. As chaves S_2 devem estar fechadas e as chaves S_1 abertas, o que pode ser visto na Figura 4.1.




Figura 4.11: Funcionamento do sistema durante a etapa de linearização

O microcontrolador receberá os dados lidos pelo sensor em tempo real e, a partir das médias μ , desvios σ e pesos ajustados, exibirá o resultado da saída do sensor linearizado em um display de 16 x 2 segmentos.

4.4 Conclusão

O sistema de auto-calibração e linearização de sensores exibido neste estudo está adaptado à linearização de sensores de temperatura por dois motivos: o primeiro é que o sensor de referência que fornecerá os valores de saída para a rede neural que deve ser treinada é uma termoresistência, o Pt100. O segundo motivo é que os circuitos eletrônicos condicionadores do sinal estão adaptados para amplificação de sinais de tensão, gerados pelo termopar, e de sinais de resistência, gerados pelo sensor de referência.

Escolher a topologia adequada para a solução do problema é fundamental para que a função aproximada pela rede neural não modele o ruído. Assim, mostra-se que a topologia a ser implementada deve ser a série.

A escolha dos componentes eletrônicos que compõem os circuitos de condicionamento é realizada de forma que o sistema possa funcionar nas duas etapas da forma mais independente possível. Na etapa de auto-calibração, ele é alimentado por meio da interface USB do computador ao qual está conectado. Na etapa de linearização, quando lê os sinais não-lineares e exibe o valor linearizado no display de 16 segmentos pode ser alimentado por uma bateria de 9V.

Tanto o uso do microcontrolador PIC 18F4550 quanto o de um computador pessoal para realizar o treinamento *offline* da rede neural tornam o sistema bastante flexível, pois não limitam o seu uso a equipamentos específicos. Qualquer computador que possua a interface USB pode executar a auto-calibração do sensor. Especificamente com relação ao PIC 18F4550, é possível utilizá-lo para outras tarefas em caso de *upgrade* em implementações futuras, tais como o armazenamento de parâmetros que se façam necessários ou outras medições que podem ser lidas em suas entradas analógicas.

Desta forma, cada uma das etapas descritas exige um ajuste específico, tanto para o *hardware* quanto para o *software*, de forma que o sistema linearize a relação desejada de forma adequada a partir dos dados reais, sendo flexível o suficiente em termos de sua implementação.

Capítulo 5

Resultados

Este capítulo apresenta e descreve em detalhes os quatro experimentos realizados para a aquisição de dados de sensores não-lineares que foram utilizados para teste e validação do algoritmo implementado para treinamento da rede RBF.

Para cada experimento são descritos sua montagem, aquisição dos dados e resultados.

São exibidos, para fins de comparação, resultados de treinamento mono-objetivo e multiobjetivo da rede neural. O sistema implementado, entretanto, utiliza o treinamento multiobjetivo, por ser esta a solução proposta neste trabalho para realizar, além da calibração e linearização automática dos sensores, a escolha de uma rede de menor complexidade a ser implementada em *hardware*.

As discussões são apresentadas para cada experimento e uma conclusão geral finaliza o capítulo.

5.1 Introdução

Durante o estudo das técnicas de inteligência computacional utilizadas para calibração e linearização automática de sensores foram realizados quatro experimentos que envolvem relações não-lineares de sensores.

No primeiro experimento foram utilizados para linearização dados de *benchmark* relativos à medição de temperatura. O segundo, terceiro e quarto experimentos tiveram suas montagens realizadas no Laboratório de Instrumentação Eletrônica e Controle de

Processos do Instituto Federal de Minas Gerais, campus Ouro Preto.

Tanto o segundo quanto o terceiro experimentos consistiram em medições de temperatura por meio de termopares realizados em dois fornos disponíveis no laboratório do Instituto Federal de Minas Gerais, campus Ouro Preto. Os fornos operam em faixas de temperatura distintas. O forno utilizado no segundo experimento produz temperaturas até 1.200 °C. Devido a estes valores de temperatura, este experimento é referido neste trabalho como Altas Temperaturas. Já o forno utilizado no terceiro experimento alcança uma temperatura máxima de 400 °C. Devido aos valores obtidos por este forno, este experimento é chamado no trabalho de Médias Temperaturas.

Um sensor capacitivo foi objeto do quarto experimento, implementado como uma balança. A relação medida foi, assim, a amplitude da tensão gerada *versus* o peso colocado na balança capacitiva.

A estrutura utilizada para o treinamento da rede foi a topologia série. Para comparação entre o treinamento mono-objetivo e multiobjetivo, em todos os experimentos foram geradas as seguintes soluções:

- Três soluções mono-objetivo, testando diferentes quantidades de neurônios: 10, 20 e 50 neurônios.
- Uma solução multiobjetivo, onde a estrutura inicial da rede possui 50 neurônios. Após o treinamento, os valores de pesos de baixa magnitude são retirados da solução final, diminuindo a quantidade de neurônios necessária para realizar a linearização entre os valores lidos pelos sensores e a saída linear desejada.
- O algoritmo de treinamento, tanto para o caso mono-objetivo quanto para o caso multiobjetivo, foi executado dez vezes e os valores apresentados nas tabelas são as médias destas execuções. Isto porque a escolha dos centros μ das redes RBF é aleatória.

No caso do treinamento multiobjetivo, a poda dos valores de baixa magnitude das soluções de pesos encontradas foi realizada por meio da seguinte relação, Equação (5.1):

$$\epsilon = \frac{w_{maior}}{100} \quad (5.1)$$

onde w_{maior} é o peso de maior valor dentre os pesos calculados.

Todos os dados de entrada e saída utilizados para treinamento da rede neural foram normalizados.

Para cada par de dados medidos pelos sensores, um polinômio de *enésima* ordem foi ajustado para aumentar a quantidade de pontos disponíveis para o treinamento e teste da rede neural, uma vez que estas medições possuem, de forma geral, poucos pontos.

São apresentadas tabelas com os valores de erro para o caso mono-objetivo e multi-objetivo.

Os dados que deverão ser enviados e manipulados pelo microcontrolador, com m sendo a quantidade de neurônios, são:

- Pesos ajustados ótimos: $m+1$ valores representados por números reais em ponto flutuante, com sinal.
- Desvio ótimo: 1 valor representado em ponto flutuante, sem sinal.
- Médias dos neurônios: m valores representados por números reais em ponto flutuante, sem sinal.

5.2 Experimento 1: Termopar - Dados de benchmark

Neste experimento, foram utilizados dados disponíveis no sítio Sensorland¹. O arquivo de dados disponível consiste na leitura de tensão *versus* temperatura para os seguintes termopares:

- Termopar tipo T: 16 pares de pontos.
- Termopar tipo J: 22 pares de pontos.
- Termopar tipo S: 22 pares de pontos.

¹<http://www.sensorland.com/HowPage017.html>, endereço acessado em Março de 2009.

5.2.1 Aquisição de dados

A partir dos dados de temperatura disponibilizados no sítio, foi escolhido o termopar que apresentou uma maior não-linearidade para a faixa disponibilizada de medições, no caso o termopar tipo S. A relação temperatura *versus* tensão deste pode ser vista na Figura 5.1.

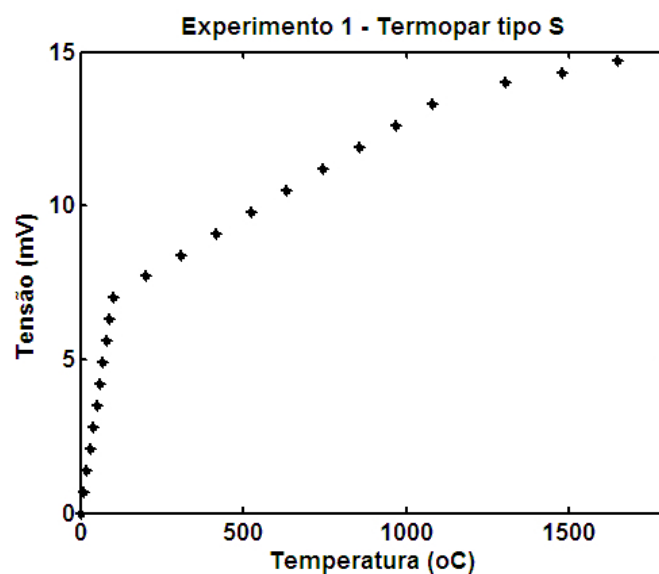


Figura 5.1: Dados do sensor a ser linearizado - Experimento 1

5.2.2 Simulação

A partir dos pontos medidos pelo termopar tipo S, foi gerado um polinômio de 3a. ordem que representa a relação tensão *versus* temperatura e permite que se gere uma quantidade de pontos para treinamento da rede por meio deste polinômio ajustado.

O sensor escolhido foi usado para medições na faixa de temperatura entre 0 e 1700 °C. Assim, os pontos foram gerados para esta faixa.

Após a normalização dos dados, somou-se ruído Gaussiano de média zero e desvio padrão 1% ao valor de tensão $u(t)$ gerado pelo sensor.

Neste experimento foram utilizados 681 pontos para treinamento mono-objetivo e multiobjetivo da rede e 171 pontos para teste. O número de neurônios estabelecido foi de $m = 50$, pois para este experimento os valores de treinamento mono-objetivo com mais de 50 neurônios apresentou mal condicionamento.

Foram escolhidos m centros μ e dez desvios σ a partir dos dados normalizados de temperatura, segundo o critério estabelecido no Capítulo 3, Equação (3.11).

5.2.3 Resultados

A Figura 5.2, apresenta o resultado ótimo do treinamento da rede realizado minimizando-se somente o MSE, Equação (3.10).

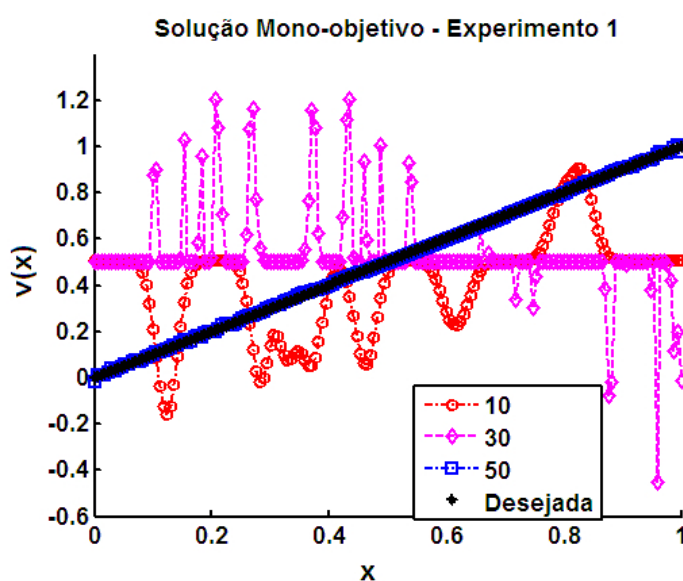


Figura 5.2: Soluções ótimas de treinamento mono-objetivo para valores de 10, 30 e 50 neurônios. Cada gráfico apresenta a melhor das dez soluções ótimas mono-objetivo, resultantes das dez variações das larguras σ das funções de base radiais.

Na Figura 5.3 podem ser vistos os conjuntos de Pareto gerados na solução de treinamento multiobjetivo da rede RBF. Para dez valores distintos de desvio da rede RBF, foram gerados conjuntos de Pareto por meio do método $P-\lambda$. Destes conjuntos, que se entrelaçam devido às variações de desvio, foi gerado um Pareto único, destacado na Figura 5.3.

Entre as possíveis 90 soluções geradas após o treinamento, nove soluções para cada um dos dez Pareto, o decisor implementado no algoritmo escolheu automaticamente a solução exibida na Figura 5.4.

Nas Tabelas 5.1 e 5.2 são apresentados os resultados numéricos para a otimização

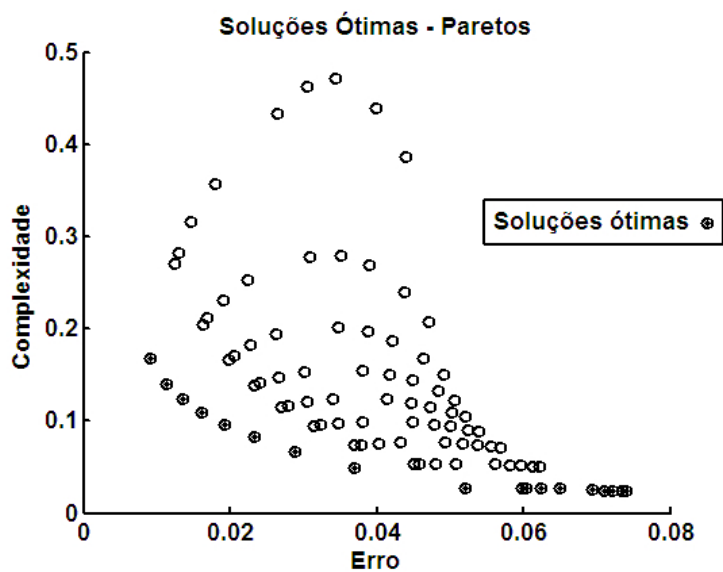


Figura 5.3: Soluções ótimas de treinamento multiobjetivo

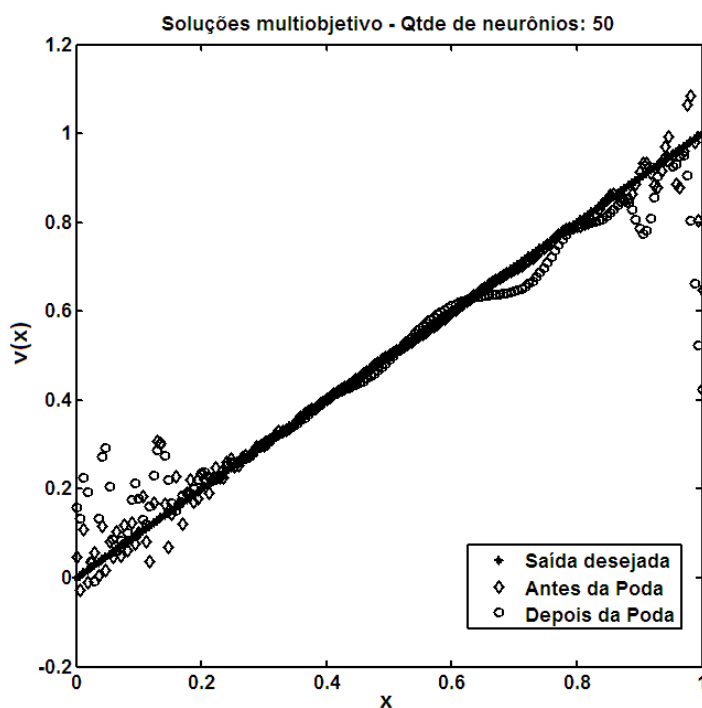


Figura 5.4: Rede linearizada escolhida pelo Decisor - Experimento 1

mono-objetivo e multiobjetivo para os melhores casos, respectivamente. Neste último caso, a complexidade está representada pela quantidade de neurônios utilizados na rede após a poda de pesos de menor magnitude.

No caso da otimização mono-objetivo, os valores de erro apresentados são as médias dos valores dos erros das dez soluções obtidas ao variar-se a largura σ .

No caso da otimização multiobjetivo, são apresentados os valores de erro para a redução de quantidade de neurônios mais significativa e o valor de erro para 50 neurônios, que foi o valor máximo utilizado durante o treinamento para comparação com o treinamento mono-objetivo.

A solução multiobjetivo para o dobro de neurônios também é exibida. Pode-se notar que o erro diminui com o aumento de neurônios utilizados.

	Mono-objetivo
Neurônios	MSE
10	0,1608
30	0,0884
50	0,0080

Tabela 5.1: Comparação entre as soluções mono-objetivo para o Experimento 1

	Multiobjetivo	
Neurônios	MSE	Descrição
15	0,0444	Maior redução de neurônios por meio da poda
49	0,0111	Menor erro após a poda
50	0,0058	Menor erro antes da poda
100	0,0036	Erro para o dobro de neurônios comparado

Tabela 5.2: Comparação entre as soluções multiobjetivo para o Experimento 1

5.2.4 Discussão

É possível obter-se a linearização dos dados de entrada *versus* saída utilizando as redes RBF tanto para a otimização mono-objetivo, onde procura-se o erro mínimo, quanto para a otimização multiobjetivo, onde procura-se o erro mínimo e a estrutura simplificada da rede, com a menor quantidade de neurônios possível.

O tempo de execução do algoritmo de treinamento, em ambos os casos, é similar. Desta forma, é vantajoso utilizar o treinamento multiobjetivo, pois este permite uma escolha entre erro e complexidade que atenda à linearização desejada de menor complexidade para implementação computacional, conforme Tabelas 5.1 e 5.2, onde as soluções apresentadas são ótimas.

É possível diminuir o valor de erro da rede, mas por meio do treinamento multiobjetivo. Nota-se que, com o aumento dos neurônios, este erro diminui. Já o treinamento mono-objetivo apresenta mal condicionamento para valores de neurônio maiores que 50.

5.3 Experimento 2: Termopar - Medição de altas temperaturas

5.3.1 Montagem

Este experimento consistiu na medição de temperatura de um forno industrial localizado no Laboratório de Instrumentação Eletrônica e Controle de Processos do IFMG - Campus Ouro Preto, utilizado em conjunto com a Universidade Federal de Ouro Preto para teste de queima de madeira. A montagem pode ser vista na Figura 5.5. O destaque **1** mostra os termopares inseridos no forno. O destaque **2** apresenta o esquema de aquecimento do forno, que é realizado por meio do ar. O destaque **3** apresenta o forno em operação e o destaque **4** apresenta o circuito eletrônico que manipula a vazão de ar para o forno.

O forno produz temperaturas na faixa ambiente até cerca de 1.200 °C. Ele é instrumentado com seis termopares, distribuídos igualmente ao longo deste.

5.3.2 Aquisição de dados

O forno possui seis termopares instalados para leitura de sua temperatura, todos do tipo S. Para este experimento, utilizamos outros 2 termopares, um do tipo K e outro do tipo J, e ambos foram inseridos no mesmo ponto para medição e comparação.

As leituras foram realizadas por uma placa de aquisição de dados montada em laboratório.




Figura 5.5: Experimento 2 - Leitura da temperatura em forno para queima de material

O termômetro utilizado para referência foi um pirômetro óptico, que forneceu a leitura de temperatura simultaneamente às leituras de tensão pela placa de aquisição de dados.

Os valores lidos para ambos os termopares estão disponíveis na Figura 5.6. O termopar tipo K foi escolhido para linearização devido à sua potência termoelétrica menor se comparada ao termopar tipo J. Desta forma, testa-se o treinamento da rede para uma situação de maior dificuldade durante a medição por este instrumento.

Estes dados foram aproximados por um polinômio de 3ª ordem e, a partir do polinômio, foram gerados 301 pontos de treinamento e 76 pontos para teste.

5.3.3 Resultados

As Figuras 5.7 e 5.9 apresentam o resultado do treinamento mono-objetivo e multi-objetivo, respectivamente, para a linearização dos dados de temperatura medidos pelo termopar tipo K.

As soluções para o treinamento multiobjetivo podem ser vistas na Figura 5.8. São 90

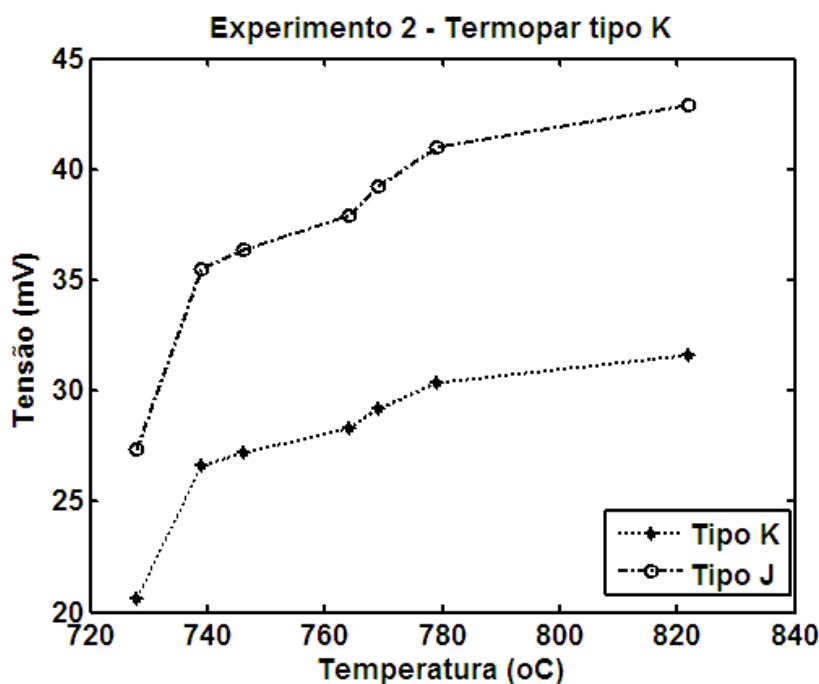


Figura 5.6: Dados do sensor a ser linearizado - Experimento 2

soluções de redes possíveis, e o Pareto que gerou as melhores soluções estão em destaque nesta figura.

A saída da rede selecionada pelo decisor implementado é exibida na Figura 5.9, antes e após a poda dos valores de pesos de baixa magnitude.

Neste experimento, foi gerado um gráfico com a saída do sistema para os valores de 100 e 200 neurônios, pois a quantidade de 50 neurônios para que se faça a comparação com o resultado do experimento mono-objetivo não apresentou grande diferença entre os valores de erro obtidos. Este gráfico pode ser visto na Figura 5.10. Entretanto, o treinamento mono-objetivo foi realizado apenas para 50 neurônios, pois acima deste valor a o problema apresenta mal-condicionamento no cálculo dos pesos.

As Tabelas 5.3 e 5.4 sintetizam os resultados por meio de treinamento mono-objetivo e multiobjetivo obtidos para este experimento, para 50 neurônios.

No caso da otimização mono-objetivo, os valores de erro apresentam os mínimos encontrados entre as dez soluções obtidas ao variar-se a largura σ .

No caso da otimização multiobjetivo, são apresentados os valores que obtiveram redução de quantidade de neurônios mais significativa para cada poda de pesos realizados

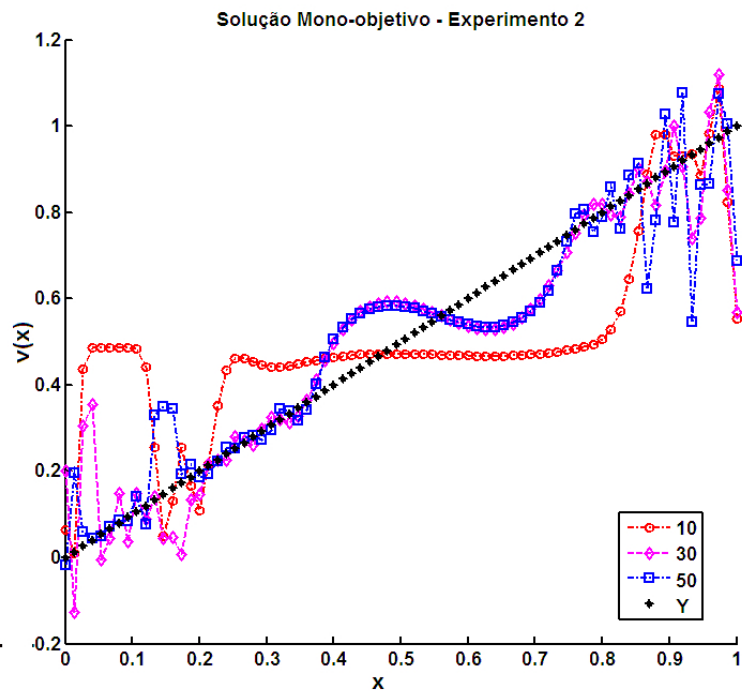


Figura 5.7: Soluções ótimas de treinamento mono-objetivo para valores de 10, 30 e 50 neurônios. Cada gráfico apresenta a melhor das dez soluções ótimas mono-objetivo, resultantes das dez variações das larguras σ das funções de base radiais.




Figura 5.8: Soluções ótimas de treinamento multiobjetivo




Figura 5.9: Rede linearizada escolhida pelo Decisor - Experimento 2




Figura 5.10: Soluções ótimas de treinamento multiobjetivo para 100 e 200 neurônios

e o valor para 50, 100 e 200 neurônios, que foi o valor máximo utilizado durante o treinamento.

	Mono-objetivo
Neurônios	MSE
10	0,0980
30	0,0768
50	0,0078

Tabela 5.3: Comparação entre as soluções mono-objetivo para o Experimento 2

	Multiobjetivo	
Neurônios	MSE	Descrição
39	0,0292	Maior redução de neurônios por meio da poda
50	0,0097	Menor erro após a poda
51	0,0097	Menor erro antes da poda
100	0,0023	Erro para o dobro de neurônios comparado
200	0,0017	Erro para o quádruplo de neurônios comparado

Tabela 5.4: Comparação entre as soluções multiobjetivo para o Experimento 2

5.3.4 Discussão

Neste experimento pode-se ver que a linearização por meio de treinamento multiobjetivo foi possível. Entretanto, uma aproximação razoável foi obtida com um número maior de neurônios, com o erro diminuindo à medida que a norma de pesos aumenta.

O valor de erro para 50 neurônios na solução mono-objetivo apresenta valor relativamente menor ao da solução multiobjetivo. Já para os valores de 100 e 200 neurônios, o treinamento mono-objetivo não pode ser realizado por problemas de mal-condicionamento. Desta forma, a solução é realizar o treinamento multiobjetivo e realizar a poda dos pesos de menor magnitude.

5.4 Experimento 3: Termopar - Medição de médias temperaturas

5.4.1 Montagem

O terceiro experimento realizado também tratou da variável temperatura, mas desta vez para uma faixa de medição entre 25 e 400 °C. Os valores de temperatura medidos, neste caso, são menores do que os dos experimentos 1 e 2.

A montagem realizada consiste em um bloco de pedra sabão funcionando como uma estufa, destacada na Figura 5.11 como o item (1) e cuja temperatura será medida.

O aquecimento do bloco é realizado no interior deste, tendo como atuador um ferro de solda, destacado como (2) da Figura 5.11. A potência entregue ao ferro de solda é comandada manualmente por um *dimmer*, marcado como (3) na Figura 5.11.



Figura 5.11: Sistema de aquecimento por estufa

5.4.2 Aquisição de dados

Durante a medição, a faixa de temperatura foi variada entre a temperatura ambiente de aproximadamente 25 °C e 373 °C, que foi o valor máximo alcançado pelo experimento.

O sensor de referência, neste caso, foi um termopar tipo J calibrado para esta faixa e que faz parte do conjunto de medição do multímetro. O multímetro realizou, desta forma, a medição da temperatura de referência para o experimento.

Foram realizadas medições com três termopares distintos, além do sensor de referência: tipos K, T e J.

A tensão dos termopares foi medida com três multímetros. Estes foram ligados em um computador e os dados de tensão foram adquiridos do *software* do próprio multímetro, por meio da interface RS-232 do computador.

O termopar escolhido para linearização foi o termopar tipo T, por ter apresentado a curva que apresentou maior não-linearidade. Seus dados estão exibidos na Figura 5.12.

O polinômio que melhor ajustou-se aos dados deste experimento foi de 5a. ordem. A partir dele, foram gerados 376 pontos para treinamento e 38 pontos para teste.




Figura 5.12: Dados do sensor a ser linearizado - Experimento 3

5.4.3 Resultados

Os resultados obtidos para o treinamento mono-objetivo estão exibidos na Figura 5.13. Em seguida, são exibidos os Paretos resultantes da otimização multiobjetivo na Figura 5.14, e a saída da rede escolhida por meio do decisor implementado na Figura 5.15, antes e depois da poda dos pesos de menor magnitude, conforme a Equação 5.1.

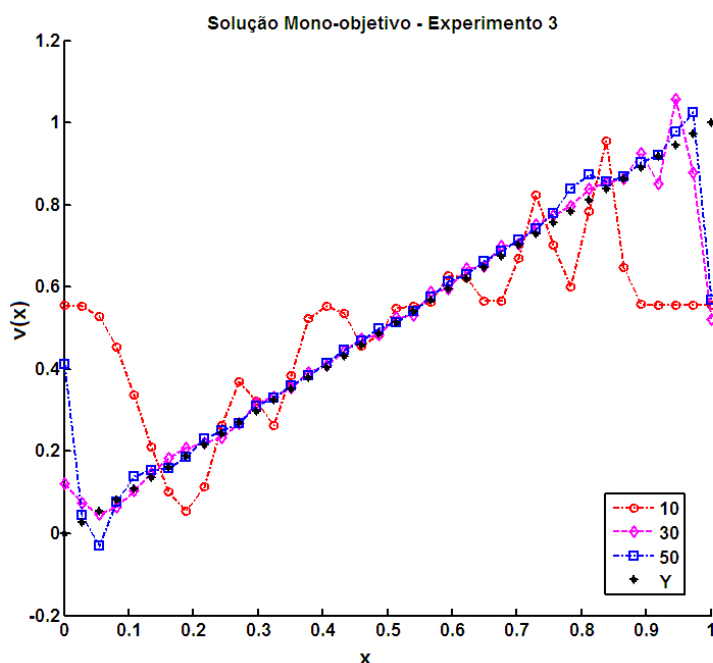


Figura 5.13: Soluções ótimas de treinamento mono-objetivo para valores de 10, 30 e 50 neurônios. Cada gráfico apresenta a melhor das dez soluções ótimas mono-objetivo, resultantes das dez variações das larguras σ das funções de base radiais.

As Tabelas 5.5 e 5.6 apresentam de forma resumida os resultados por meio de treinamento mono-objetivo e multiobjetivo obtidos para este experimento.

No caso da otimização mono-objetivo, os valores de erro apresentados são as médias dos valores entre as dez soluções obtidas ao variar-se a largura σ .

No caso da otimização multiobjetivo, são apresentados os valores de erro para uma redução de quantidade de neurônios mais significativa e o valor para 50 neurônios, para comparação com a solução mono-objetivo.




Figura 5.14: Soluções ótimas de treinamento multiobjetivo

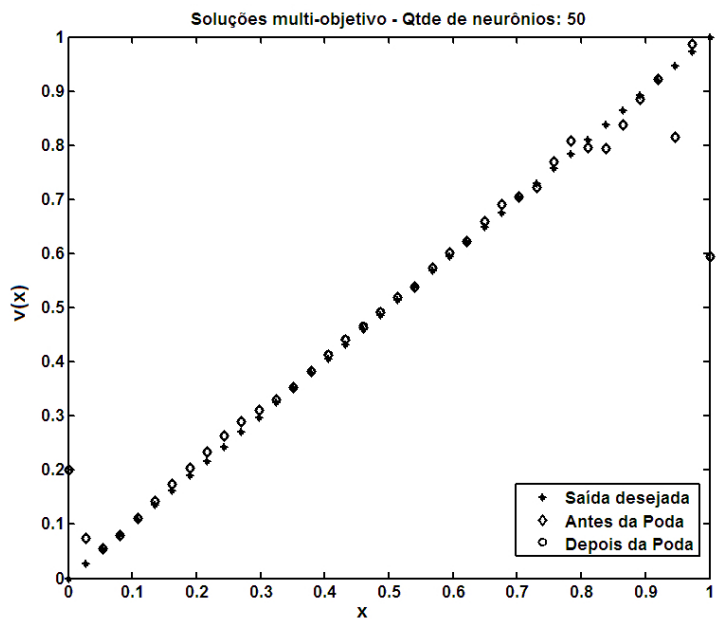


Figura 5.15: Rede Linearizada escolhida pelo Decisor - Experimento 3

5.4.4 Discussões

Este experimento apresenta resultados de erro adequados ao problema de linearização.

O treinamento mono-objetivo para grandes quantidades de neurônios (no caso foram testados para valores acima de aproximadamente 100 neurônios), mostrou-se mal-con-

	Mono-objetivo
Neurônios	MSE
10	0,0594
30	0,0111
50	0,0064

Tabela 5.5: Comparação entre as soluções mono-objetivo para o Experimento 3

	Multiobjetivo	
Neurônios	MSE	Descrição
43	0,0238	Maior redução de neurônios por meio da poda
49	0,0048	Menor erro após a poda
50	0,0042	Menor erro antes da poda
100	0,0036	Erro para o dobro de neurônios comparado

Tabela 5.6: Comparação entre as soluções multiobjetivo para o Experimento 3

dicionado e no treinamento multiobjetivo o erro não variou de forma significativa para valores mais elevados da norma de pesos. Percebe-se pela tabela das soluções multiobjetivo que, para a rede com o dobro de neurônios, o erro diminuiu muito pouco.

Isto deve-se ao fato de o sinal utilizado neste experimento já ser praticamente linear.

5.5 Experimento 4: Balança Capacitiva de Precisão

5.5.1 Montagem

Neste experimento as variáveis cuja relação não-linear foram avaliadas são o peso e a tensão, medidos em uma balança de precisão.

Foi confeccionado para tal uma balança capacitiva de precisão que possui sua capacitância alterada com o peso.

O capacitor, que no caso é a balança de precisão, foi confeccionado com duas placas de fenolite de dimensão 5x5 cm e cujo dielétrico entre as placas é o ar.

Nas extremidades das placas foram soldados fios e montado um ressonador. Esta

montagem pode ser vista na Figura 5.16.




Figura 5.16: Balança de precisão capacitiva

A frequência de ressonância f_R encontrada para o circuito tanque, Figura 5.17 foi de 831,05 KHz.

Após o ajuste da frequência de ressonância do circuito de medição, que pode ser visto na Figura 5.17, os pesos e tensões foram medidos à esta frequência.

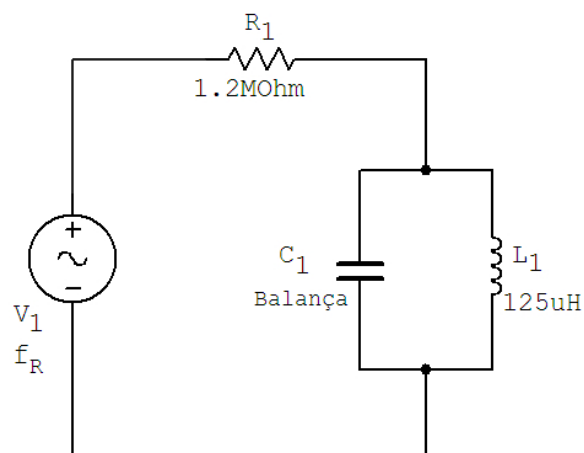


Figura 5.17: Circuito eletrônico para medição da tensão

5.5.2 Aquisição de dados

Com a frequência de ressonância fixa, os pesos foram colocados sobre o capacitor, que é a balança em nosso circuito. A amplitude do sinal de saída foi medida, então, no osciloscópio.

Foram utilizados pesos calibrados pelo INMETRO, conforme Figura 5.18, do Laboratório de Química do IFMG - Campus Ouro Preto. Combinando os pesos, foram realizadas medições entre 0 e 100 g.



Figura 5.18: Pesos utilizados para medição no Experimento 4

Os sinais medidos a partir desta montagem estão disponíveis na Figura 5.19.

5.5.3 Resultados

Os resultados para a linearização são descritos nas figuras seguintes.

Para o treinamento mono-objetivo da rede, a solução encontra-se na Figura 5.20.

Para o treinamento multiobjetivo da rede, as soluções de Pareto estão na Figura 5.21 e a saída da rede ótima escolhida pelo decisor é apresentada na Figura 5.22, tanto para




Figura 5.19: Dados do sensor a ser linearizado - Experimento 4

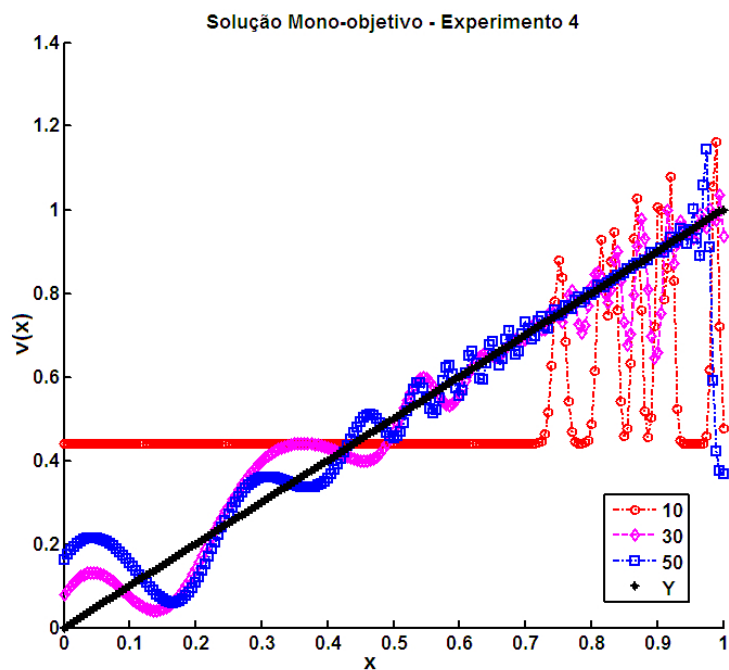


Figura 5.20: Soluções ótimas de treinamento mono-objetivo para valores de 10, 30 e 50 neurônios. Cada gráfico apresenta a melhor das dez soluções ótimas mono-objetivo, resultantes das dez variações das larguras σ das funções de base radiais.

a escolha antes da realização da poda dos valores de peso de menor magnitude quanto para a escolha após a poda.




Figura 5.21: Soluções ótimas de treinamento multiobjetivo

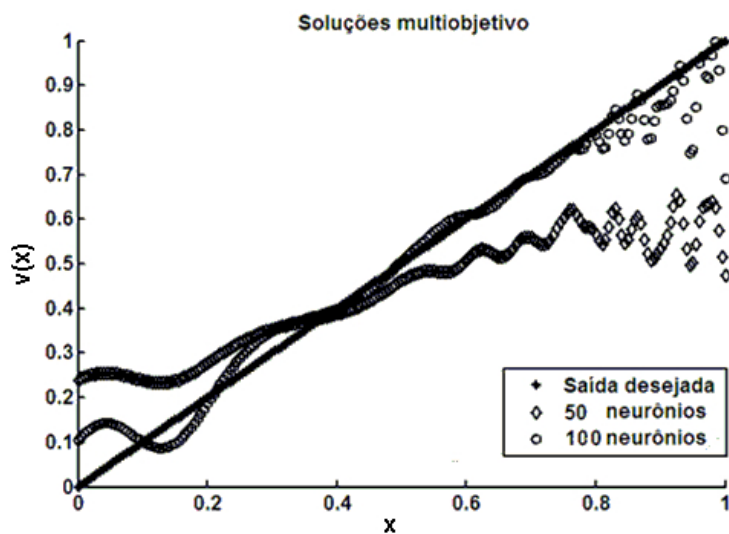


Figura 5.22: Rede linearizada escolhida pelo Decisor - Experimento 4

As Tabelas 5.7 e 5.8 apresentam de forma resumida os resultados por meio de treinamento mono-objetivo e multiobjetivo obtidos para este experimento.

No caso da otimização mono-objetivo, os valores de erro apresentados são as médias calculadas entre as dez soluções obtidas ao variar-se a largura σ .

No caso da otimização multiobjetivo, são apresentados os valores de redução de quantidade de neurônios mais significativa para o valor de poda implementado e o valor

de erro para 50 neurônios a fim de que possam ser comparados com o treinamento mono-objetivo.

	Mono-objetivo
Neurônios	MSE
10	0,2043
30	0,0879
50	0,0048

Tabela 5.7: Comparação entre as soluções mono-objetivo para o Experimento 4

	Multiobjetivo	
Neurônios	MSE	Descrição
–	–	Maior redução de neurônios por meio da poda
–	–	Menor erro após a poda
50	0,0076	Menor erro antes da poda
100	0,0053	Erro para o dobro de neurônios comparado

Tabela 5.8: Comparação entre as soluções multiobjetivo para o Experimento 4

5.5.4 Discussão

No caso deste experimento, onde a relação entre os sinais a serem linearizados decresce, nota-se que a linearização foi parcialmente alcançada pelo treinamento multiobjetivo. O resultado mais próximo utiliza praticamente todos os neurônios gerados, não permitindo a eliminação de muitos neurônios ao otimizar a complexidade. O erro só diminui, neste caso, com o aumento de neurônios. A otimização mono-objetivo, neste caso, obteve um melhor resultado para 50 neurônios.

5.6 Conclusão

Os quatro experimentos apresentados utilizados para validação do algoritmo de treinamento da rede neural implementado no sistema de auto-calibração e linearização de

sensores obtiveram os resultados esperados. Ou seja, a rede neural treinada foi capaz de linearizar as relações não-lineares a que foi submetida.

Cada um dos quatro experimentos apresentou diferenças entre si, em termos de dados a serem linearizados e tipos de sensores estudados.

No caso dos três primeiros experimentos, embora todos tenham trabalhado com termopares para medir temperatura, tanto o tipo de termopar quanto os dados de medição utilizados correspondem a situações distintas.

No primeiro e segundo experimentos, que trabalharam em faixas similares, de altas temperaturas, embora para termopares diferentes, notam-se valores que apresentam maior não-linearidade, como é de se esperar para estes sensores.

Já no terceiro experimento, também com um termopar diferente dos outros dois experimentos, a relação utilizada para o treinamento já é praticamente linear. Outras técnicas de linearização poderiam ter obtido resultados melhores. Prova disto é que os resultados para o treinamento multiobjetivo não apresentaram grande diferença de erro nem de quantidade de neurônios no processo de auto-calibração e linearização. Isto deve-se ao fato da faixa de trabalho, entre cerca de 25 a 400 °C. Esta faixa, em um contexto de termopares, é parte de uma faixa maior de medição. Quando se trata de termopares, se for possível dividir as medições por faixas lineares, a regressão linear pode ser realizada como técnica mais simples e eficiente.

Já o caso do quarto experimento é totalmente diferente. Primeiro, foi realizada a linearização para uma relação decrescente. Segundo, o sensor analisado é capacitivo. O resultado obtido foi o desejado, uma vez que a relação linear foi encontrada. Entretanto, vê-se nos valores de resultados ótimos apresentados para o treinamento multiobjetivo, que o sistema utilizou todos os neurônios e ainda obteve um valor de erro elevado se comparado aos outros experimentos.

Assim, os quatro experimentos realizados, cada um com sua especificidade, possibilitam a validação do treinamento multiobjetivo da rede neural que foi implementado como parte de um sistema de auto-calibração e linearização que envolve também uma parte implementada em *hardware*.

Já para os resultados mono-objetivo obtidos com um número de neurônios maior que 50 há mal-condicionamento da matriz de regressores, o que gera não permitiu uma análise para uma quantidade maior de neurônios. Os valores de largura σ utilizados para gerar os dez treinamentos da rede variam entre zero e uma distância máxima entre

os centros μ , e estes últimos são calculados a partir dos dados de entrada da rede. À medida em que as larguras aumentam e a distância entre os centros diminui (quanto maior a quantidade de neurônios, maior a quantidade de centros para o mesmo conjunto de pontos de entrada), a função de base radial, que é exponencial, tende a 1 e a matriz de regressores passa a apresentar valores de linhas muito próximos uns dos outros. Quando é realizada a inversão desta matriz para solução do problema de otimização ocorre, então, o mal-condicionamento.

Ao se gerar dados para treinamento e teste da rede neural a partir da aproximação por polinômios, foi acrescentado ao experimento os problemas numéricos que ocorrem em polinômios. Em todos os experimentos foram testados diversos valores para a ordem de aproximação do polinômio gerado. Para o terceiro e o quarto experimentos o polinômio foi capaz de realizar uma boa aproximação. Já para o primeiro e segundo experimentos os dados foram ajustados por meio de regressão utilizando o método dos mínimos quadrados.

Capítulo 6

Conclusões

6.1 Conclusões

Uma vez proposto este estudo na forma como se apresenta, possuindo caráter teórico e prático, diversas questões foram levantadas para que uma implementação unindo *hardware* e *software* fosse possível no sentido de obter-se um equipamento que realize a calibração e linearização automática de sensores.

O motivador deste trabalho foi o sensor do tipo termopar. Este sensor é um dos mais utilizados para medição de temperatura em ambientes industriais. Existem mais de trinta construções de termopares estudadas, com as mais diversas ligas metálicas e, no entanto, industrialmente e cientificamente, para medição de temperatura, utilizam-se apenas cerca de sete tipos: os tipos T, J, E, K, R, S e B. Quais seriam as limitações que não permitem a utilização dos outros termopares?

Algumas limitações encontradas levam ao desenvolvimento deste estudo.

A primeira delas é a falta de uma relação matematicamente estabelecida para a relação temperatura medida e tensão gerada pelo termopar. Isto deve-se ao fato de que os efeitos físicos que regem estes sensores são dependentes das características físico-químicas dos materiais que constituem os termopares.

Outra limitação é que as combinações de condutores de menor custo apresentam baixa potência termoelétrica, o que dificulta a medição dos valores de tensão e torna o sinal lido mais sensível a ruídos diversos. Os pares metálicos que apresentam maior potência termoelétrica são constituídos de metais nobres. O problema passa a ser então

o custo elevado.

A vida útil dos termopares depende do ambiente e faixa de temperatura a que estão submetidos. Em muitos casos, um termopar realiza somente algumas poucas medições e já não está mais apto a realizar medidas. É comum, também, o termopar continuar apto a realizar medidas, mas necessitar de calibração e ajuste para continuar operando na faixa correta.

Na tentativa de melhorar o desempenho dos sensores, estes são construídos com ligas que procuram melhorar a homogeneidade do material, a potência termoelétrica gerada, a resistência a ambientes hostis, tais como atmosferas oxidantes, redutoras, sulfurosas, inertes, entre outras.

Desta forma, a partir da questão levantada sobre os fatores que limitam a utilização dos outros sensores do tipo termopar surgiu o tema deste trabalho: utilizar técnicas de inteligência computacional e *hardware* de baixo custo para calibrar e linearizar automaticamente os sensores.

A escolha de uma técnica de inteligência computacional tornou-se adequada devido ao fato de não haver um modelo matemático que defina esta relação temperatura *versus* tensão. A técnica escolhida precisava, então, ser capaz de aprender a partir de dados medidos.

Como desejava-se uma técnica que tenha como característica a capacidade de aprender e generalizar, a escolha recaiu naturalmente sobre a implementação de uma rede neural. Além da proposta de resolver este problema, trouxe outra característica interessante para o sistema proposto: permitiu que se estendesse o trabalho de calibração e linearização automática para sensores dos tipos mais diversos.

Neste trabalho, pelo caráter prático, não procurou-se apenas treinar um rede neural que seja capaz de realizar a transformação não-linear desejada. Procurou-se uma rede neural de menor complexidade, para que sua estrutura, uma vez treinada, pudesse ser implementada em *hardware*.

Surgiu então o treinamento multiobjetivo da rede neural, onde foram dois os objetivos a serem alcançados: encontrar o menor erro e a menor complexidade estrutural da rede para implementação em *hardware*.

A rede de funções de base radiais, a rede RBF, já possui uma estrutura simplificada, por apresentar somente uma camada oculta e como função de ativação dos neurônios

desta camada oculta, as funções de base radiais. Sabe-se que uma rede RBF é capaz de aproximar localmente quaisquer funções, desde que seja projetada com a quantidade de neurônios adequada.

Duas topologias foram propostas para implementação do treinamento da rede RBF: a topologia em série e a topologia em paralelo. O trabalho apresentou alguns problemas e soluções da topologia em série e em paralelo. Embora a topologia paralela tenha apresentado-se promissora, por permitir que funções que não possuam inversa pudessem ser utilizadas, esta mostrou-se inadequada para este trabalho. Desta forma, o treinamento foi realizado com a topologia em série.

Após a definição da topologia a ser utilizada, o algoritmo de treinamento multiobjetivo foi implementado. Foram geradas diversas soluções ótimas como resultado do treinamento multiobjetivo, as soluções de Pareto. Como as funções a serem otimizadas durante o treinamento da rede neural são convexas, o método escolhido para gerar o gráfico de Pareto foi o método $P-\lambda$.

Cada uma das soluções do gráfico de Pareto representou uma rede que apresenta uma relação ótima entre erro e complexidade.

Como a proposta do trabalho era implementar a calibração e linearização em *hardware*, houve a necessidade de se escolher uma dentre as redes ótimas geradas. Foi implementado um decisor baseado em regressão linear que escolhe, automaticamente, a partir dos pontos de teste com as redes ótimas, qual rede fornece o menor erro.

A existência do decisor é importante porque a escolha automática evita que o operador precise escolher entre as redes geradas, o que pode levar muito tempo e exigir também um critério visual bem estabelecido. Entretanto, o programa implementado oferece a opção de escolha da rede que se deseja implementar, o que flexibiliza o sistema.

Os quatro experimentos apresentados como resultados no Capítulo 5 para validação de todo o treinamento multiobjetivo da rede neural e posterior escolha automática da solução ótima, são interessantes porque cada um deles leva a uma função diferente.

No primeiro experimento, um sensor foi testado em uma faixa bastante ampla de temperatura. Neste experimento procurou-se resolver o problema da falta de modelo matemático de termopares para uma faixa tão ampla de medição.

Já o segundo experimento apresentou um sensor termopar com baixa potência termelétrica para a faixa de medição, também variada.

O terceiro experimento tratou de um termopar que, para a faixa de medição, já possuía característica praticamente linear.

Enfim, o quarto experimento apresentado tratou de uma relação não-linear decrescente, ao contrário dos outros três experimentos.

Para todos os experimentos foi realizado treinamento multiobjetivo e mono-objetivo. O treinamento mono-objetivo foi realizado para fins de comparação. Notou-se, no treinamento mono-objetivo, que o sinal é linearizado em todas as situações, mas apresentou erros grandes para pequenas quantidades de neurônios na camada escondida da rede RBF.

Como era esperado, à medida que o número de neurônios que constituem a camada escondida da rede aumentou, o erro diminuiu. Entretanto, para valores muito maiores de neurônios, apresentou mal-condicionamento, devido ao método utilizado para fixar os valores de centros μ e larguras σ das funções de base radiais da camada oculta da rede.

Já o treinamento multiobjetivo apresentou baixos valores de erro e simplificou a estrutura inicial, que para todos os casos foi de 50 neurônios.

Quanto ao *hardware*, o objetivo a ser alcançado era a implementação de um sistema de baixo custo e, no entanto, flexível e eficiente.

O treinamento da rede neural, que exige maior esforço computacional elevado, foi realizado em um computador pessoal de baixo custo e acessível.

A leitura e aquisição dos dados foi realizada em um circuito eletrônico com amplificadores operacionais que consomem pouca energia, sendo alimentados por tensões assimétricas, entre 3 a 30V. A escolha dos amplificadores com alimentação assimétrica foi realizada para que na etapa de aquisição de dados pelo computador para treinamento da rede, o circuito pudesse ser alimentado pela interface USB, que fornece 5V e até 100mA de corrente. Além do mais, esta interface está disponível em grande parte dos sistemas computacionais utilizados.

O uso de microcontroladores é bastante adequado para ter-se um sistema simples e eficiente. Os microcontroladores são mais simples e baratos que as FPGAs, *Field Programmable Gate Array* e também são reprogramáveis, além de possuírem memória para armazenamento de dados, circuitos para conversão analógico-digital e controle por largura de pulso que podem ser utilizados para comando de atuadores. Seu grande prob-

lema é a manipulação de grandes quantidades de dados, que exige memória do *hardware* e os microcontroladores não possuem muita memória disponível. Daí a necessidade de uma rede neural simplificada para ser implementada em *hardware*.

6.2 Trabalhos Futuros

Seguem sugestões de trabalhos futuros que podem ser realizados em todas as etapas que constituíram o desenvolvimento deste trabalho.

- Para a etapa de aquisição de dados:
 1. Investigar um circuito de condicionamento de sinais de baixo custo que possa ser utilizado para a leitura de diversos sensores, principalmente os que envolvem variáveis elétricas, tais como corrente, tensão, campo magnético, capacitância, reatância, resistência.
 2. Investigar a implementação da programação do microcontrolador em linguagem Assembler, pois permite extrair deste máxima eficiência, por se tratar de linguagem de máquina.
 3. Implementar um módulo que envie o sinal linearizado gerado pela rede neural ajustada escolhida para um dispositivo de controle de processos, equivalente aos transmissores utilizados industrialmente.
- Para a etapa de treinamento multiobjetivo da rede RBF:
 1. Investigar a eliminação de uma quantidade maior de neurônios, a partir de comparação entre os valores máximo e mínimo dos pesos gerados no treinamento.
 2. Investigar a utilização de algoritmo de *clusterização* para escolha dos parâmetros fixos da função de base radial, estabelecendo um critério para a escolha dos centros do algoritmo.
 3. Implementar, para solução do problema multiobjetivo, o Método de Mínimos Quadrados Recursivo, eliminando, desta forma, a necessidade do cálculo *on-line* da inversa da matriz de regressores e diminuindo os problemas que surgem a partir deste cálculo.
- Para a etapa de decisão:

1. Investigar técnicas de decisão que possam utilizar informação *a priori*.
 2. Investigar técnicas de decisão estatísticas.
 3. Implementar a compensação de temperatura ambiente para sensores quaisquer.
- Para o sistema, de forma geral:
 1. Implementar o treinamento *online* da rede RBF, distribuindo os neurônios entre agrupamentos de microcontroladores.
 2. Investigar os custos das aproximações realizadas por outras redes neurais, tais como o Perceptron de Múltiplas Camadas.
 3. Realizar experimentos com sensores em ambientes industriais.

O uso de técnicas de Inteligência Computacional para resolver o problema de linearização de sensores mostrou-se bastante promissor. Integrar estas técnicas a implementações em *hardware* permite o desenvolvimento de equipamentos programáveis e adaptáveis para outras finalidades além da investigada neste estudo.

Foi importante, durante o desenvolvimento do trabalho, pesquisar formas que tornem o sistema proposto o mais eficiente possível a um custo de implementação mínimo, uma vez que é objetivo utilizar este sistema em laboratórios onde se realizem calibração de sensores ou, ainda, em ambientes industriais.

Apêndice A

Apêndice

A.1 Datasheets dos Circuitos Eletrônicos

Esta seção traz parte dos datasheets que descreve as principais especificações dos circuitos eletrônicos utilizados no desenvolvimento do *hardware* para auto-calibração e linearização de sensores.

Os datasheets completos podem ser encontrados nos sítios dos fabricantes.

A.1.1 Microcontrolador PIC 18F4550

Acesse o sítio <http://www.microchip.com>, para visualizar o *datasheet* completo do microcontrolador PIC 18F4550.

A.1.2 Amplificador LM324

No sítio <http://www.datasheetcatalog.com/>, pode-se acessar o *datasheet* completo do Amplificador Operacional LM324.

A.1.3 Módulo ECIO-40P

Acesse o sítio <http://www.matrixmultimedia.com>, para mais informações sobre o módulo ECIO-40P.

PIC18F2455/2550/4455/4550

1.0 DEVICE OVERVIEW

This document contains device-specific information for the following devices:

- PIC18F2455
- PIC18F2550
- PIC18F4455
- PIC18F4550
- PIC18LF2455
- PIC18LF2550
- PIC18LF4455
- PIC18LF4550

This family of devices offers the advantages of all PIC18 microcontrollers – namely, high computational performance at an economical price – with the addition of high endurance, Enhanced Flash program memory. In addition to these features, the PIC18F2455/2550/4455/4550 family introduces design enhancements that make these microcontrollers a logical choice for many high-performance, power sensitive applications.

1.1 New Core Features

1.1.1 nanoWatt TECHNOLOGY

All of the devices in the PIC18F2455/2550/4455/4550 family incorporate a range of features that can significantly reduce power consumption during operation. Key items include:

- **Alternate Run Modes:** By clocking the controller from the Timer1 source or the internal oscillator block, power consumption during code execution can be reduced by as much as 90%.
- **Multiple Idle Modes:** The controller can also run with its CPU core disabled but the peripherals still active. In these states, power consumption can be reduced even further, to as little as 4% of normal operation requirements.
- **On-the-Fly Mode Switching:** The power-managed modes are invoked by user code during operation, allowing the user to incorporate power-saving ideas into their application's software design.
- **Low Consumption in Key Modules:** The power requirements for both Timer1 and the Watchdog Timer are minimized. See **Section 28.0 "Electrical Characteristics"** for values.

1.1.2 UNIVERSAL SERIAL BUS (USB)

Devices in the PIC18F2455/2550/4455/4550 family incorporate a fully featured Universal Serial Bus communications module that is compliant with the USB Specification Revision 2.0. The module supports both low-speed and full-speed communication for all supported data transfer types. It also incorporates its own on-chip transceiver and 3.3V regulator and supports the use of external transceivers and voltage regulators.

1.1.3 MULTIPLE OSCILLATOR OPTIONS AND FEATURES

All of the devices in the PIC18F2455/2550/4455/4550 family offer twelve different oscillator options, allowing users a wide range of choices in developing application hardware. These include:

- Four Crystal modes using crystals or ceramic resonators.
- Four External Clock modes, offering the option of using two pins (oscillator input and a divide-by-4 clock output) or one pin (oscillator input, with the second pin reassigned as general I/O).
- An internal oscillator block which provides an 8 MHz clock ($\pm 2\%$ accuracy) and an INTRC source (approximately 31 kHz, stable over temperature and VDD), as well as a range of 6 user-selectable clock frequencies, between 125 kHz to 4 MHz, for a total of 8 clock frequencies. This option frees an oscillator pin for use as an additional general purpose I/O.
- A Phase Lock Loop (PLL) frequency multiplier, available to both the High-Speed Crystal and External Oscillator modes, which allows a wide range of clock speeds from 4 MHz to 48 MHz.
- Asynchronous dual clock operation, allowing the USB module to run from a high-frequency oscillator while the rest of the microcontroller is clocked from an internal low-power oscillator.

Besides its availability as a clock source, the internal oscillator block provides a stable reference source that gives the family additional features for robust operation:

- **Fail-Safe Clock Monitor:** This option constantly monitors the main clock source against a reference signal provided by the internal oscillator. If a clock failure occurs, the controller is switched to the internal oscillator block, allowing for continued low-speed operation or a safe application shutdown.
- **Two-Speed Start-up:** This option allows the internal oscillator to serve as the clock source from Power-on Reset, or wake-up from Sleep mode, until the primary clock source is available.

PIC18F2455/2550/4455/4550

1.2 Other Special Features

- **Memory Endurance:** The Enhanced Flash cells for both program memory and data EEPROM are rated to last for many thousands of erase/write cycles – up to 100,000 for program memory and 1,000,000 for EEPROM. Data retention without refresh is conservatively estimated to be greater than 40 years.
- **Self-Programmability:** These devices can write to their own program memory spaces under internal software control. By using a bootloader routine, located in the protected Boot Block at the top of program memory, it becomes possible to create an application that can update itself in the field.
- **Extended Instruction Set:** The PIC18F2455/2550/4455/4550 family introduces an optional extension to the PIC18 instruction set, which adds 8 new instructions and an Indexed Literal Offset Addressing mode. This extension, enabled as a device configuration option, has been specifically designed to optimize re-entrant application code originally developed in high-level languages such as C.
- **Enhanced CCP Module:** In PWM mode, this module provides 1, 2 or 4 modulated outputs for controlling half-bridge and full-bridge drivers. Other features include auto-shutdown for disabling PWM outputs on interrupt or other select conditions and auto-restart to reactivate outputs once the condition has cleared.
- **Enhanced Addressable USART:** This serial communication module is capable of standard RS-232 operation and provides support for the LIN bus protocol. Other enhancements include Automatic Baud Rate Detection and a 16-bit Baud Rate Generator for improved resolution. When the microcontroller is using the internal oscillator block, the EUSART provides stable operation for applications that talk to the outside world without using an external crystal (or its accompanying power requirement).
- **10-Bit A/D Converter:** This module incorporates programmable acquisition time, allowing for a channel to be selected and a conversion to be initiated, without waiting for a sampling period and thus, reducing code overhead.
- **Dedicated ICD/ICSP Port:** These devices introduce the use of debugger and programming pins that are not multiplexed with other microcontroller features. Offered as an option in select packages, this feature allows users to develop I/O intensive applications while retaining the ability to program and debug in the circuit.

1.3 Details on Individual Family Members

Devices in the PIC18F2455/2550/4455/4550 family are available in 28-pin and 40/44-pin packages. Block diagrams for the two groups are shown in Figure 1-1 and Figure 1-2.

The devices are differentiated from each other in six ways:

1. Flash program memory (24 Kbytes for PIC18FX455 devices, 32 Kbytes for PIC18FX550).
2. A/D channels (10 for 28-pin devices, 13 for 40/44-pin devices).
3. I/O ports (3 bidirectional ports and 1 input only port on 28-pin devices, 5 bidirectional ports on 40/44-pin devices).
4. CCP and Enhanced CCP implementation (28-pin devices have two standard CCP modules, 40/44-pin devices have one standard CCP module and one ECCP module).
5. Streaming Parallel Port (present only on 40/44-pin devices).

All other features for devices in this family are identical. These are summarized in Table 1-1.

The pinouts for all devices are listed in Table 1-2 and Table 1-3.

Like all Microchip PIC18 devices, members of the PIC18F2455/2550/4455/4550 family are available as both standard and low-voltage devices. Standard devices with Enhanced Flash memory, designated with an "F" in the part number (such as PIC18F2550), accommodate an operating V_{DD} range of 4.2V to 5.5V. Low-voltage parts, designated by "LF" (such as PIC18LF2550), function over an extended V_{DD} range of 2.0V to 5.5V.

Low power quad op amps

LM124/224/324/324A/ SA534/LM2902

DESCRIPTION

The LM124/SA534/LM2902 series consists of four independent, high-gain, internally frequency-compensated operational amplifiers designed specifically to operate from a single power supply over a wide range of voltages.

UNIQUE FEATURES

In the linear mode, the input common-mode voltage range includes ground and the output voltage can also swing to ground, even though operated from only a single power supply voltage.

The unity gain crossover frequency and the input bias current are temperature-compensated.

FEATURES

- Internally frequency-compensated for unity gain
- Large DC voltage gain: 100 dB
- Wide bandwidth (unity gain): 1 MHz (temperature-compensated)
- Wide power supply range Single supply: $3 V_{DC}$ to $30 V_{DC}$ or dual supplies: $\pm 1.5 V_{DC}$ to $\pm 15 V_{DC}$
- Very low supply current drain: essentially independent of supply voltage (1 mW/op amp at $+5 V_{DC}$)
- Low input biasing current: $45 nA_{DC}$ (temperature-compensated)
- Low input offset voltage: 2 mV_{DC} and offset current: 5 nA_{DC}
- Differential input voltage range equal to the power supply voltage
- Large output voltage: $0V_{DC}$ to $V_{CC}-1.5 V_{DC}$ swing

PIN CONFIGURATION

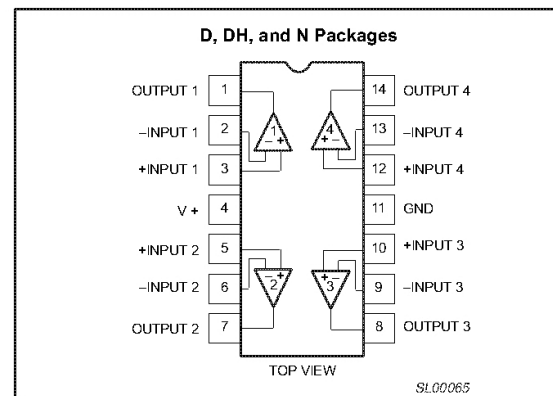


Figure 1. Pin configuration.

ORDERING INFORMATION

DESCRIPTION	TEMPERATURE RANGE	ORDER CODE	DWG #
14-Pin Plastic Dual In-Line Package (DIP)	-55 °C to +125 °C	LM124N	SOT27-1
14-Pin Plastic Small Outline (SO) Package	-25 °C to +85 °C	LM224D	SOT108-1
14-Pin Plastic Dual In-Line Package (DIP)	-25 °C to +85 °C	LM224N	SOT27-1
14-Pin Plastic Small Outline (SO) Package	0 °C to +70 °C	LM324D	SOT108-1
14-Pin Plastic Thin Shrink Small Outline Package (TSSOP)	0 °C to +70 °C	LM324DH	SOT402-1
14-Pin Plastic Dual In-Line Package (DIP)	0 °C to +70 °C	LM324N	SOT27-1
14-Pin Plastic Small Outline (SO) Package	0 °C to +70 °C	LM324AD	SOT108-1
14-Pin Plastic Dual In-Line Package (DIP)	0 °C to +70 °C	LM324AN	SOT27-1
14-Pin Plastic Small Outline (SO) Package	-40 °C to +85 °C	SA534D	SOT108-1
14-Pin Plastic Dual In-Line Package (DIP)	-40 °C to +85 °C	SA534N	SOT27-1
14-Pin Plastic Small Outline (SO) Package	-40 °C to +125 °C	LM2902D	SOT108-1
14-Pin Plastic Dual In-Line Package (DIP)	-40 °C to +125 °C	LM2902N	SOT27-1
14-Pin Plastic Thin Shrink Small Outline Package (TSSOP)	-40 °C to +125 °C	LM2902DH	SOT402-1

Philips Semiconductors

Product data

Low power quad op amps

LM124/224/324/324A/
SA534/LM2902**ABSOLUTE MAXIMUM RATINGS**

SYMBOL	PARAMETER	RATING	UNIT
V_{CC}	Supply voltage	32 or ± 16	V_{DC}
V_{IN}	Differential input voltage	32	V_{DC}
V_{IN}	Input voltage	-0.3 to +32	V_{DC}
P_D	Maximum power dissipation, $T_{amb} = 25\text{ }^\circ\text{C}$ (still-air) ¹ N package D package DH package	1420 1040 762	mW mW mW
	Output short-circuit to GND one amplifier ² $V_{CC} < 15\text{ }V_{DC}$ and $T_{amb} = 25\text{ }^\circ\text{C}$	Continuous	
I_{IN}	Input current ($V_{IN} < -0.3\text{ V}$) ³	50	mA
T_{amb}	Operating ambient temperature range LM324/324A LM224 SA534 LM2902 LM124	0 to +70 -25 to +85 -40 to +85 -40 to +125 -55 to +125	$^\circ\text{C}$ $^\circ\text{C}$ $^\circ\text{C}$ $^\circ\text{C}$ $^\circ\text{C}$
T_{stg}	Storage temperature range	-65 to +150	$^\circ\text{C}$
T_{slid}	Lead soldering temperature (10 sec max)	230	$^\circ\text{C}$

NOTES:

- Derate above 25 $^\circ\text{C}$ at the following rates:
N package at 11.4 mW/ $^\circ\text{C}$
D package at 8.3 mW/ $^\circ\text{C}$
DH package at 6.1 mW/ $^\circ\text{C}$
- Short-circuits from the output to V_{CC+} can cause excessive heating and eventual destruction. The maximum output current is approximately 40 mA, independent of the magnitude of V_{CC} . At values of supply voltage in excess of +15 V_{DC} continuous short-circuits can exceed the power dissipation ratings and cause eventual destruction.
- This input current will only exist when the voltage at any of the input leads is driven negative. It is due to the collector-base junction of the input PNP transistors becoming forward biased and thereby acting as input bias clamps. In addition, there is also lateral NPN parasitic transistor action on the IC chip. This action can cause the output voltages of the op amps to go to the $V+$ rail (or to ground for a large overdrive) during the time that the input is driven negative.

Figura A.4: Datasheet LM324 - Página 2




Figura A.5: Módulo ECIO - 40P

Referências Bibliográficas

- Bajzek, T. J. (2005). Thermocouples: a sensor for measuring temperature, *IEEE Instrumentation & Measurement Magazine* **8**(1): 35–40.
- Barreto, A. M. S. (2003). *Algoritmo genético dos mínimos quadrados ortogonal para o treinamento de redes RBF*, Master's thesis, COPPE, UFRJ.
- Bethea, M. D. & Rosenthal, B. N. (1992). An automated thermocouple calibration system, *IEEE Transactions on Instrumentation and Measurement* **41**.
- Braga, A. P., Takahashi, R. H. C., Costa, M. A. & R. A. Teixeira. In: . (Org.). . 1 ed. :, v. p. . (2006). Multi-objective algorithms for neural network learning, *in* Y. Jin (ed.), *Multi-Objective Machine Learning*, 1st edn, Springer, Berlin, pp. 151–171.
- Chatterjee, A., Munshi, S., Dutta, M. & Rakshit, A. (2000). An artificial neural linearizer for capacitive humidity sensor, *Proceedings of the 17th IEEE Instrumentation and Measurement Technology Conference, IEEE IMTC*, Vol. 1, pp. 313–317.
- Comisky, D. A., Drake, J. M. & Dempsey, G. L. (1995). A neural analog-to-digital converter with resolution enhancement, *IEEE* .
- Danisman, K., Dalkiran, I. & Celebi, F. (2006). Design of a high precision temperature measurement system based on artificial neural network for different thermocouple types, *Measurement* **39**: 695–700.
- Drebushchak, V. A. (2009). Approximation of the emf of a thermocouple - part i. the polynomials of temperature and runge's phenomenon, *Journal of Thermal Analysis and Calorimetry* **96**(1): 315320.
- Evans, W. A. & Rowlands, S. L. (1988). Design of a portable thermocouple calibrator, *IEEE Proceedings* **135**.

- Fraden, J. (2003). *Handbook of Modern Sensors: Physics, Designs, and Applications*, Springer- Berlin.
- Halliday, D., Resnick, R. & Krane, K. (1996). *Física 2*, John Wiley & Sons.
- Haykin, S. (1998). *Neural Networks: A Comprehensive Foundation*, 2nd edn, Prentice Hall.
- Hudoklin, D., Drnovsek, J., Pusnik, I. & Bojkovski, J. (2002). Simultaneous calibration of a large number of thermocouples, *IEEE Transactions on Instrumentation and Measurement* **51**.
- INMETRO (2007). *Vocabulário internacional de termos de metrologia legal: portaria INMETRO no. 163 de 06 de setembro de 2005*, INMETRO, Rio de Janeiro.
- Jin, Y. C. & Sendhoff, B. (2008). Pareto-based multiobjective machine learning: An overview and case studies, *IEEE Transactions on Systems, Man, and Cybernetics, Part C - Applications and Reviews* **38**(3): 397–415.
- Kinzie, P. & Moore, R. D. (1973). *Thermocouple Temperature Measurement*, John Wiley & Sons.
- Klopfenstein, L. R. (1994). Software linearization techniques for thermocouples, thermistors, and RTDS, *ISA Transactions* **33**(3): 293–305.
- Medrano-Marques, N. J. & del Brio, B. M. (2000). A general method for sensor linearization based on neural networks, *Proceedings of the IEEE International Symposium on Circuits and Systems, ISCAS 2000*, Vol. 2, Geneva, Switzerland, pp. 497–500.
- NIST (1995). NIST ITS-90 thermocouple database. available at the url <http://srdata.nist.gov/its90/main/>.
- Parma, G., Menezes, B. & Braga, A. (1998). Sliding mode algorithm for training multilayer artificial neural networks, *Electronic Letters* **34**(1): 97–98.
- Patra, J. C., Ang, E. L. & Das, A. (2004). Neural network-based intelligent sensor operating in harsh environment, *Proceedings of the Intelligent Sensors, Sensor Networks and Information Processing Conference*, pp. 137–142.
- Patra, J. C., Chakraborty, G. & Meher, P. K. (2008). Neural-network-based robust linearization and compensation technique for sensors under nonlinear environmental influences, *IEEE Transactions on Circuits and Systems I* **55**(5): 1316–1327.

- Patra, J. C., Devi, T. A. & Meher, P. K. (2007). Radial basis function implementation of intelligent pressure sensor on field programmable gate array, *Proceedings of the 6th International Conference on Information, Communications & Signal Processing*.
- Patra, J. C. & van den Bos, A. (2000). Auto-calibration and compensation of a capacitive pressure sensor using multilayer perceptrons, *ISA Transactions* **39**: 175–190.
- Pereira, J. M. D., Girao, P. M. B. S. & Postolache, O. (2001). Fitting transducer characteristics to measured data, *IEEE Instrumentation & Measurement Magazine* **4**(4): 26–39.
- Reyneri, L. M. (2003). Implementation issues of neuro-fuzzy hardware: Going toward hw/sw codesign, *IEEE Transactions on Neural Networks* **14**(1): 176–194.
- Rivera, J., Carrillo, M., Chacón, M., Herrera, G. & Bojorquez, G. (2007). Self-calibration and optimal response in intelligent sensors design based on artificial neural networks, *Sensors* **7**: 1509–1529.
- Rosenberg, R. J. (1994). Temperature measurement on the job site using rtds and thermocouples, *ISA Transactions* .
- Ruppel, F. R. (1990). Modeling a self-calibrating thermocouple for use in a smart temperature measurement system, *IEEE Transactions on Instrumentation and Measurement* **39**.
- Schoen, M. P. (2007). Dynamic compensation of intelligent sensors, *IEEE Transactions on Instrumentation and Measurement* **56**(5): 1992–2001.
- SENAI & CST (1999). Instrumentação básica ii - vazão, temperatura e analítica, *Technical report*, SENAI - ES.
- Teixeira, R. A., Braga, A. P., Takahashi, R. H. C. & Saldanha, R. R. (2000). A multi-objective optimization approach for training artificial neural networks, *Proceedings of the 6th Brazilian Symposium on Neural Networks*, Vol. 1, Rio de Janeiro.
- Wen, D., Qing, L. & Qiang, L. (2007). Calibration system for thermocouple application based on technology of virtual instrument and neural network, *The Eighth International Conference on Electronic Measurement and Instruments* **7**(1): 268–273.
- Weremczuk, J. (1997). Genetic algorithm for smart sensors calibration under disturbing condition, *Proceedings of the Instrumentation and Measurement Technology Conference, IEEE IMTC*, Vol. 1, Ottawa, Canada, pp. 214–217.

- Williams, J. (1988). Thermocouple measurement, *Technical report*, Linear Technology.
- xei ra, R. A. T., Braga, A. P., Takahashi, R. H. C. & Saldanha, R. R. (2000). Improving generalization of MLPs with multi-objective optimization, *Neurocomputing (Amsterdam)* **35**(4): 189–194.
- Yang, J. C.-Y. & Clarke, D. W. (1997). A self-validating thermocouple, *IEEE Transactions on Control Systems Technology* **5**.