



UNESP – UNIV ESTADUAL PAULISTA
FACULDADE DE ENGENHARIA DE BAURU
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA



THIAGO MATHEUS GERONIMO

**ESTIMAÇÃO DO DIÂMETRO DE FUROS EM PROCESSO DE FURAÇÃO
UTILIZANDO SISTEMAS DE INTELIGÊNCIA ARTIFICIAL: UMA ANÁLISE
COMPARATIVA ENTRE DIFERENTES TÉCNICAS**

Bauru
2011

THIAGO MATHEUS GERONIMO

**ESTIMAÇÃO DO DIÂMETRO DE FUROS EM PROCESSO DE FURAÇÃO
UTILIZANDO SISTEMAS DE INTELIGÊNCIA ARTIFICIAL: UMA ANÁLISE
COMPARATIVA ENTRE DIFERENTES TÉCNICAS**

Dissertação apresentada à Faculdade de Engenharia de Bauru da Universidade Estadual Paulista Júlio de Mesquita Filho, para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Titular Paulo Roberto de Aguiar

Bauru
2011

Geronimo, Thiago Matheus.

Estimação do diâmetro de furos em processo de furação utilizando sistemas de inteligência artificial: uma análise comparativa entre diferentes técnicas / Thiago Matheus Geronimo, 2011
125 f.

Orientador: Paulo Roberto de Aguiar

Dissertação (Mestrado)-Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2011


1. Sistemas de inteligência artificial. 2. Monitoramento do processo de furação. 3. Diâmetro do furo usinado. I. Universidade Estadual Paulista. Faculdade de Engenharia. II. Título.

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE THIAGO MATHEUS GERONIMO, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DO(A) FACULDADE DE ENGENHARIA DE BAURU.


Aos 13 dias do mês de dezembro do ano de 2011, às 14:00 horas, no(a) ANFITEATRO DA SEÇÃO DE PÓS-GRADUAÇÃO DA FACULDADE DE ENGENHARIA, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos seguintes membros: Prof. Dr. PAULO ROBERTO DE AGUIAR do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. ERALDO JANNONE DA SILVA do(a) Departamento de Engenharia de Produção / Universidade de São Paulo - USP, Prof. Dr. JOSE ALFREDO COVOLAN ULSON do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, sob a presidência do primeiro, a fim de proceder a arguição pública da DISSERTAÇÃO DE MESTRADO de THIAGO MATHEUS GERONIMO, intitulado "ESTIMAÇÃO DO DIÂMETRO DE FUROS EM PROCESSO DE FURAÇÃO UTILIZANDO SISTEMAS DE INTELIGÊNCIA ARTIFICIAL: UMA ANÁLISE COMPARATIVA ENTRE DIFERENTES TÉCNICAS". Após a exposição, o discente foi arguido oralmente pelos membros da Comissão Examinadora, tendo recebido o conceito final: Aprovado. Nada mais havendo, foi lavrada a presente ata, que, após lida e aprovada, foi assinada pelos membros da Comissão Examinadora.



Prof. Dr. PAULO ROBERTO DE AGUIAR



Prof. Dr. ERALDO JANNONE DA SILVA



Prof. Dr. JOSE ALFREDO COVOLAN ULSON

DEDICATÓRIA

Dedico à minha esposa e ao meu filho que me ensinaram que o amor de uma família é capaz de tornar os sonhos realidade.

AGRADECIMENTOS

Agradeço primeiramente à minha esposa Christiane Calau Geronimo por participar ativamente deste trabalho através de sua amizade, amor e confiança. Ao meu filho Tales Calau Geronimo por me permitir compreender a imensidão do amor de um pai e por me motivar com seu sorriso e carinho.

Aos meus pais Francisco Maurício Geronimo Turato e Neusa Maria Matheus Geronimo por me ensinarem o caminho da persistência ao me apoiarem incondicionalmente em todas as minhas decisões e através de todo seu empenho em proporcionarem acesso à educação e ao trabalho. Aos meus irmãos Bruno Matheus Geronimo e Danilo Matheus Geronimo pela amizade e companheirismo.

Aos meus sogros Henrique Calau e Zenaide Amélia dos Santos Calau e aos meus queridos Tathiane Calau Ramos e Ivan Marcus Ramos, por nosso forte laço de amizade e amor.

Ao Prof. Titular Paulo Roberto de Aguiar pela confiança e orientação durante as atividades desta pesquisa e pelo exemplo, como pessoa e profissional, de como a firmeza de propósitos, a ética e o companheirismo aliados podem abrir as portas para a felicidade.

À Carlos Eduardo Dorigatti Cruz que realizou os ensaios e estudos iniciais que acabaram por gerar as idéias que incentivaram a elaboração desta dissertação.

Aos alunos de iniciação científica Frederico de Castro Neto e Sofia Viotto Brandão, que contribuíram no estudo e execução dos sistemas de inteligência artificial utilizados neste trabalho.

Àqueles que contribuem para a minha constante felicidade pela sua amizade João Henrique Vechetti Mantovani, Luiz Fernando Gomes, Luiz Henrique Correia Gatti, Margleide Domingues e Yves de Carvalho Souza.

Aos colegas do curso de mestrado Cesar Henrique Rossinoli Martins, Daniela Fernanda Grizzo Moia, Marcelo Marchi e Maurício E. Nakai pela amizade, aceitação e contribuição.

“Procure sempre uma ocupação; quando a
tiver não pense em outra coisa além de
procurar fazê-lo bem feito.”
Tales de Mileto

LISTA DE FIGURAS

Figura 1 – Representação do processo de furação. Adaptado de Walker (2006).	23
Figura 2 – Nomenclatura longitudinal de uma broca helicoidal. Klocke (2011)	24
Figura 3 - Geometria da ponta de uma broca helicoidal. Adaptada de Klocke (2011).	25
Figura 4 - Modelos de neurônios. (a) Neurônio biológico, adaptado de Negnevitsky (2005). (b) Neurônio artificial, adaptado de Haykin (1999).	29
Figura 5 - Arquitetura típica de uma rede perceptron com uma camada escondida. Adaptada de Haykin (1999).	31
Figura 6 - Modelo de uma RNA perceptron de múltiplas camadas. Adaptada de Haykin (1999).	31
Figura 7 - Dois fluxos de informação em uma RNA MLP: propagação dos sinais de entrada neurônio-a-neurônio e retropropagação camada-a-camada do erro.	32
Figura 8 - Etapas de um sistema de inferência <i>fuzzy</i> . Adaptado de Killing (2007).	37
Figura 9 - Classificação da condição da direção usando uma variável linguística. A variável linguística interpreta as mudanças no acelerador dentro de um período. Adaptado de Altrock (1995).	38
Figura 10 - Estrutura das regras <i>fuzzy</i> e sua relação com o sistema de inferência. O antecedente consiste nas entradas fuzzificadas em variáveis linguísticas e é usado para calcular a saída do consequente. Adaptado de Killing (2007).	38
Figura 11 - Exemplificação do processo em que as saídas das funções de pertinência do consequente são combinadas para calcular o valor numérico da saída. Adaptada de Killing (2007).	40
Figura 12 - <i>Defuzzificação</i> através da técnica da média ponderada. Adaptada de Killing (2007).	40
Figura 13 - Sistema ANFIS baseado no modelo TSK, com duas entradas e duas regras. Adaptada de Evsukoff; Almeida (2003).	41
Figura 14 - Rede com função de base radial com quatro funções de base e duas saídas. Adaptada de Jang et al. (1997).	46
Figura 15 - Parâmetros da curva gaussiana ajustados pelo processo de treinamento de uma rede com função de base radial (RBF).	47
Figura 16 - Representação do processo de medição. Adaptada de Ablameyko (2003).	52

Figura 17 - Efeito indesejável dos erros de medição no controle de qualidade industrial. Adaptada de Doebelin (2004).	53
Figura 18 - Conceitos de precisão e exatidão inerentes ao processo de medição. a) Alta precisão e baixa exatidão. b) Altas precisão e exatidão. c) Altos erros de precisão e exatidão. Adaptada de Figliola; Beasley (1995).....	54
Figura 19 - Método genérico para o desenvolvimento de um sistema de monitoramento inteligente para processos de usinagem. Adaptada de Abellan-Nebot e Subirón (2009).....	57
Figura 20 - Dimensões e configuração dos corpos-de-prova (dimensões em mm). Adaptado de CRUZ (2010).....	59
Figura 21 - Máquina-ferramenta e acessórios utilizados para a aquisição dos sinais, CRUZ (2010).	60
Figura 22 - Diagrama ilustrando a posição de montagem de cada sensor e a aquisição dos sinais, com o sistema de referência indicando o sentido das forças de corte, CRUZ (2010).	62
Figura 23 - Divisão dos sinais coletados de acordo com o material usinado, onde 2/5 corresponde à liga de titânio (em amarelo) e 3/5 correspondem à liga de alumínio (em branco), CRUZ (2010).	63
Figura 24 - Ilustração da irregularidade na circularidade do furo e processo de medição CRUZ (2010).	64
Figura 25 - Fluxograma representativo do algoritmo para o teste de arquitetura e parâmetros da rede MLP, proposto por CRUZ (2010).	65
Figura 26 - Fluxograma representativo do algoritmo desenvolvido para teste dos sinais.	66
Figura 27 - Fluxograma representativo do algoritmo utilizado para verificar a influência do número de épocas de treinamento.....	67
Figura 28 - Fluxograma representativo do algoritmo desenvolvido para teste de influência dos sinais e do suporte das gaussianas.....	68
Figura 29 - Representação da arquitetura da rede MLP utilizada para as duas ligas dos corpos-de-prova, utilizando os seis sinais disponíveis.	71
Figura 30 - Resultados da estimativa da rede MLP para a liga Ti6Al4V.	72
Figura 31 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de titânio, com todos os sinais na entrada, segundo a precisão do instrumento	

de medição utilizado (5µm) e às classes de tolerância da norma ABNT NBR 6158:1995.	73
Figura 32 - Resultados da estimativa da rede MLP para a liga Ti6Al4V.	74
Figura 33 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de alumínio, com todos os sinais na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e às classes de tolerância da norma ABNT NBR 6158:1995.	75
Figura 34 - Resultado do teste de influência dos sinais isolados e combinados em pares para a liga Ti6Al4V.	76
Figura 35 - Resultado do teste de influência dos sinais isolados e combinados em pares para a liga 2024-T3.	77
Figura 36 - Redes MLP com apenas o sinal da força no eixo Z aplicada na entrada, para cada material.	78
Figura 37 - Resultados da estimativa da rede MLP para a liga Ti6Al4V, com a força Z na entrada.	78
Figura 38 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de alumínio, com a força em Z na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e as classes de tolerância da norma ABNT NBR 6158:1995.	80
Figura 39 - Resultados da estimativa da rede MLP para a liga 2024-T3, com a força Z na entrada.	80
Figura 40 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de alumínio, com a força em Z na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e as classes de tolerância da norma ABNT NBR 6158:1995.	81
Figura 41 - Arquiteturas utilizadas para testes das redes MLP com dois sinais aplicados na entrada.	82
Figura 42 - Resultados da estimativa da rede MLP para a liga Ti6Al4V, com os sinais de emissão acústica e aceleração na entrada.	83
Figura 43 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de titânio, com a emissão acústica e a aceleração na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e as classes de tolerância da norma ABNT NBR 6158:1995.	84

Figura 44 - Resultados da estimativa da rede MLP para a liga 2024-T3, com os sinais de potência elétrica e força no eixo Z na entrada.	85
Figura 45 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de alumínio, com a potência elétrica e a força no eixo Z, segundo a precisão do instrumento de medição utilizado (5µm) e as classes de tolerância da norma ABNT NBR 6158:1995.	86
Figura 46 - Resultado do teste de influência dos sinais isolados e combinados em pares para o sistema ANFIS desenvolvido para a liga Ti6Al4V.	87
Figura 47 - Resultado do teste de influência dos sinais isolados e combinados em pares para o sistema ANFIS desenvolvido para a liga 2024-T3.....	87
Figura 48 - Resultado do teste de influência do número de épocas nos sistemas ANFIS para cada liga do corpo-de-prova.	88
Figura 49 - Resultados da estimativa do sistema ANFIS para a liga Ti6Al4V, com o sinal da força no eixo Z na entrada.	89
Figura 50 - Classificação dos erros na estimativa dos diâmetros pelo sistema ANFIS para a liga de titânio, com a força em Z na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e as classes de tolerância da norma ABNT NBR 6158:1995.....	90
Figura 51 - Resultados da estimativa do sistema ANFIS para a liga 2024-T3, com o sinal da força no eixo Z na entrada.	91
Figura 52 - Classificação dos erros na estimativa dos diâmetros pelo sistema ANFIS para a liga de alumínio, com a força em Z na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e as classes de tolerância da norma ABNT NBR 6158:1995.....	92
Figura 53 - Resultados da estimativa do sistema ANFIS para a liga Ti6Al4V, com os sinais das forças nos eixos X e Z combinados na entrada.....	94
Figura 54 - Classificação dos erros na estimativa dos diâmetros pelo sistema ANFIS para a liga de titânio, com as forças em X e Z na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e as classes de tolerância da norma ABNT NBR 6158:1995.....	95
Figura 55 - Resultados da estimativa do sistema ANFIS para a liga 2024-T3, com os sinais da emissão acústica e da força no eixo Z combinados na entrada.	96
Figura 56 - Classificação dos erros na estimativa dos diâmetros pelo sistema ANFIS para a liga de alumínio, com a emissão acústica e a força em Z na entrada, segundo	

a precisão do instrumento de medição utilizado (5 μ m) e as classes de tolerância da norma ABNT NBR 6158:1995.	97
Figura 57 - Avaliação do erro absoluto com a variação do spread na rede RBF para a liga de titânio.	98
Figura 58 - Avaliação do erro absoluto com a variação do spread na rede RBF para a liga de alumínio.	98
Figura 59 - Resultados da estimativa da rede RBF para a liga Ti6Al4V, com todos os sinais aplicados na entrada.	99
Figura 60 - Classificação dos erros na estimativa dos diâmetros pela rede RBF para a liga de titânio, com todos os sinais na entrada, segundo a precisão do instrumento de medição utilizado (5 μ m) e as classes de tolerância da norma ABNT NBR 6158:1995.	100
Figura 61 - Resultados da estimativa da rede RBF para a liga 2024-T3, com todos os sinais aplicados na entrada, não exibindo generalização.	101
Figura 62 - Resultados do teste de influência dos sinais isolados e combinados em pares, mais o spread, no desempenho da rede RBF para a liga de titânio.	102
Figura 63 - Resultados do teste de influência dos sinais isolados e combinados em pares, mais o spread, no desempenho da rede RBF para a liga de alumínio.	102
Figura 64 - Classificação dos erros na estimativa dos diâmetros pela rede RBF para a liga de titânio, com a força Z na entrada, segundo a precisão do instrumento de medição utilizado (5 μ m) e as classes de tolerância da norma ABNT NBR 6158:1995.	104
Figura 65 - Resultados da estimativa da rede RBF para a liga 2024-T3, com todos os sinais aplicados na entrada, não exibindo generalização.	105
Figura 66 - Classificação dos erros na estimativa dos diâmetros pela rede RBF para a liga de alumínio, com a força Z na entrada, segundo a precisão do instrumento de medição utilizado (5 μ m) e as classes de tolerância da norma ABNT NBR 6158:1995.	106
Figura 67 - Resultados da estimativa da rede RBF para a liga Ti6Al4V, com os sinais da força em Y e da aceleração aplicados na entrada, não exibindo generalização.	106
Figura 68 - Resultados da estimativa da rede RBF para a liga 2024-T3, com os sinais da força em Y e da força em Z aplicados na entrada, não exibindo generalização.	107

LISTA DE TABELAS

Tabela 1 - Ângulos de hélice para furação de diversos materiais.	25
Tabela 2 – Valores numéricos para graus de tolerância padrão IT (International Tolerances) para dimensões nominais até 6mm.	26
Tabela 3 - Características que influenciam a qualidade do furo. (Stephenson; Agapiou, 2006).	27
Tabela 4 - Quatro operadores E/OU para uso com variáveis contínuas, disponíveis no MATLAB.	39
Tabela 5 - Dois passes do treinamento híbrido para ANFIS Jang (1993).	43
Tabela 6 - Cinco melhores resultados obtidos para a estimação do diâmetro na liga Ti6Al4V, pela rede MLP.	69
Tabela 7 - Cinco melhores resultados obtidos para a estimação do diâmetro na liga 2024-T3.	70
Tabela 8 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de titânio.	71
Tabela 9 - Comportamento da rede MLP na avaliação de controle de qualidade para a liga de titânio.	72
Tabela 10 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de titânio.	74
Tabela 11 - Comportamento da rede MLP na avaliação de controle de qualidade para a liga de alumínio.	75
Tabela 12 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de titânio, com a força Z na entrada.	79
Tabela 13 - Comportamento da rede MLP, com a força Z na entrada, na avaliação de controle de qualidade para a liga de titânio.	79
Tabela 14 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de alumínio, com a força Z na entrada.	81
Tabela 15 - Comportamento da rede MLP, com a força Z na entrada, na avaliação de controle de qualidade para a liga de alumínio.	81
Tabela 16 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de titânio, com os sinais de emissão acústica e aceleração na entrada.	83

Tabela 17 - Comportamento da rede MLP na avaliação de controle de qualidade para a liga de titânio.	83
Tabela 18 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de alumínio, com os sinais de potência elétrica e força no eixo Z na entrada.	85
Tabela 19 - Comportamento da rede MLP na avaliação de controle de qualidade para a liga de alumínio.	85
Tabela 20 - Parâmetros de influência dos centros de agrupamento definidos para o sistema ANFIS de estimativa para a liga de titânio.	89
Tabela 21 - Erro relativo percentual médio e erro absoluto médio do sistema ANFIS na estimativa dos diâmetros na liga de titânio, com a força Z na entrada.	90
Tabela 22 - Comportamento da rede MLP na avaliação de controle de qualidade para a liga de titânio.	90
Tabela 23 - Parâmetros de influência dos centros de agrupamento definidos para o sistema ANFIS de estimativa para a liga de alumínio.	91
Tabela 24 - Erro relativo percentual médio e erro absoluto médio do sistema ANFIS na estimativa dos diâmetros na liga de alumínio, com a força Z na entrada.	92
Tabela 25 - Comportamento do sistema ANFIS na avaliação de controle de qualidade para a liga de alumínio.	92
Tabela 26 - Parâmetros de influência dos centros de agrupamento definidos para o sistema ANFIS de estimativa para a liga de titânio, com duas entradas.	93
Tabela 27 - Erro relativo percentual médio e erro absoluto médio do sistema ANFIS na estimativa dos diâmetros na liga de titânio, com as forças X e Z na entrada.	94
Tabela 28 - Comportamento do sistema ANFIS na avaliação de controle de qualidade para a liga de titânio.	94
Tabela 29 - Parâmetros de influência dos centros de agrupamento definidos para o sistema ANFIS de estimativa para a liga de alumínio, com duas entradas.	95
Tabela 30 - Erro relativo percentual médio e erro absoluto médio do sistema ANFIS na estimativa dos diâmetros na liga de alumínio, com a emissão acústica e a força Z na entrada.	96
Tabela 31 - Comportamento do sistema ANFIS na avaliação de controle de qualidade para a liga de alumínio.	96
Tabela 32 - Erro relativo percentual médio e erro absoluto médio da rede RBF na estimativa dos diâmetros na liga de titânio, com todos os sinais na entrada.	99

Tabela 33 - Comportamento da rede RBF na avaliação de controle de qualidade para a liga de titânio.	100
Tabela 34 - Erro relativo percentual médio e erro absoluto médio da rede RBF, com a força Z na entrada, na estimativa dos diâmetros na liga de titânio.....	103
Tabela 35 - Comportamento da rede RBF, com a força Z na entrada, na avaliação de controle de qualidade para a liga de titânio.....	103
Tabela 36 - Erro relativo percentual médio e erro absoluto médio da rede RBF, com a força Z na entrada, na estimativa dos diâmetros na liga de alumínio.....	104
Tabela 37 - Comportamento da rede RBF, com a força Z na entrada, na avaliação de controle de qualidade para a liga de alumínio.	105
Tabela 38 - Comparativo final do desempenho dos três sistemas de inteligência artificial utilizados.	108

LISTA DE SÍMBOLOS

α_f : ângulo de incidência da broca

β : ângulo de cunha

γ_f : ângulo de saída

δ : ângulo de hélice

b_k : limiar de ativação, ou *bias*, do neurônio k

x_n : n -ésima entrada de um neurônio, ou de um sistema ANFIS

w : peso sináptico de um neurônio; peso de uma regra *fuzzy*; centro de agrupamento

u_k : saída do combinador linear k

$\phi(.)$: função de ativação; função de base radial

y : saída de um neurônio, ou, entrada de um sistema ANFIS

$v(n)$: campo induzido local de um neurônio, para a entrada n ; alvo, num conjunto de treinamento de uma rede RBF

$e(n)$: erro calculado na camada de saída, para a entrada n

$d(n)$: valor alvo de um conjunto de treinamento, para a entrada n

$\varepsilon(n)$: campo induzido local de um neurônio, para a entrada n

Δw : reajuste do peso sináptico

$\delta(n)$: gradiente local

α : momento, aplicado à regra delta generalizada

η : taxa de aprendizagem

μ, o : saída de uma função de pertinência, em um conjunto *fuzzy*

c : valor do consequente, em uma regra *fuzzy*

f : saída de uma regra *fuzzy*

θ : parâmetro do processo de adaptação *fuzzy*; vetor de pesos sinápticos, em uma rede RBF; parâmetro de otimização, em uma rede RBF

$\bar{w}$: saída normalizada de uma regra *fuzzy*

r : vizinhança do centro de um agrupamento

D : densidade de um agrupamento

ρ : centro da função gaussiana

σ : suporte da função gaussiana

T : conjunto de treinamento

J : erro quadrático médio, na saída de uma rede RBF

RESUMO

O monitoramento de processos de fabricação por usinagem tem se mostrado de extrema importância nas empresas que buscam um nível de excelência em qualidade, auxiliando na melhor alocação de recursos e redução de desperdícios oriundos de peças com problemas de qualidade. Abordagens multisensoriais têm sido empregadas no monitoramento desses processos com o objetivo de utilizar os sinais no treinamento de sistemas de inteligência artificial na tarefa de indicar desvios nas ferramentas ou no produto sendo fabricado. Neste trabalho, três sistemas de inteligência artificial foram utilizados com o objetivo de prover estimativas para o diâmetro de furos obtidos por processo de furação de precisão. Uma rede neural artificial perceptron de múltiplas camadas (RNA MLP), um sistema de inferência adaptável neuro-fuzzy (ANFIS) e uma rede neural artificial com função de base radial (RBF) foram treinados com os dados obtidos com os sensores para estimar os diâmetros dos furos para cada material do corpo-de-prova. A definição da melhor configuração para cada sistema de inteligência artificial foi obtida através de algoritmos desenvolvidos para verificar a influência dos sinais e dos parâmetros particulares de cada sistema sobre o resultado final da estimativa. Os resultados obtidos indicam que a RNA MLP apresenta maior robustez perante a variação nos dados apresentados. O sistema ANFIS e a rede RBF mostraram que seu resultado varia acentuadamente quando há variações nos dados apresentados no treinamento, requerendo que estes sistemas sejam treinados sempre com o conjunto de dados apresentados na mesma ordem. A análise de influência dos sinais mostrou que, embora a abordagem multisensorial apresente bons resultados na rede MLP, o mesmo não se repetiu para os demais sistemas que apresentaram erros durante o treinamento ou não apresentaram características de aprendizado. O sinal correspondente à força no eixo Z apresentado isoladamente aos sistemas produziu os melhores resultados.

Palavras-chave: ANFIS. Monitoramento de processo de furação. Sistemas de inteligência artificial. RBF. Redes neurais artificiais.

ABSTRACT

The supervision of manufacturing process by machining has been extremely important in companies which aim an excellence level in quality, helping on best assets allocation and waste reduction originated from pieces with quality problems. Multi-sensory approaches have been employed in the supervision of these processes aiming the use of signals in the training of artificial intelligence systems in order to indicate deviations in tools or in product being manufactured. Turning, grinding, milling and drilling have been the target of the application of these supervision intelligence systems. In this work three artificial intelligence systems were applied in order to provide estimations for the diameters of the holes obtained by precision drilling process. A Multilayer Perceptron Neural Network (ANN MLP), an adaptive neuro-fuzzy inference system (ANFIS) and an artificial neural network with radial basis function (RBF) were trained with the data obtained from the sensors to estimate the hole diameters for each material of the test pieces. The definition of the best configuration for each artificial intelligence system was obtained through algorithms developed to verify the signals influence and particular parameters of each system concerning the final estimation result. The tests results were analyzed under three criteria: the absolute and medium errors, the system capacity of obtaining correct results for each estimation – classifying them as approved or rejected – and the error analysis regarding the necessary tolerance classes to maintain process within the limits of precision mechanics. The results obtained indicate that the ANN MLP presents higher robustness before variation in the data presented. The ANFIS system and RBF network have shown that their result vary sharply when there are data variations presented in training, requiring these systems to be always trained with the data set presented in the same order. The signals influence analysis have shown that despite the multi-sensory approach has presented good results in MLP network; the same has not occurred to the other systems which presented errors during training or have not shown learning characteristics. The corresponding signal to force in Z axis presented separately to the intelligent systems has shown the best results.

Keywords: ANFIS. Drilling process monitoring. Artificial intelligent systems. RBF. Artificial neural networks.

SUMÁRIO

1 INTRODUÇÃO	20
2 OBJETIVO	21
3 JUSTIFICATIVA PARA A REALIZAÇÃO DESTA PESQUISA	22
4 REVISÃO BIBLIOGRÁFICA	23
4.1 FABRICAÇÃO MECÂNICA POR PROCESSO DE FURAÇÃO	23
4.1.1 FERRAMENTA DE CORTE	24
4.1.2 PARÂMETROS DE CORTE E INFLUÊNCIA NA QUALIDADE	25
4.2 SISTEMAS DE INTELIGÊNCIA ARTIFICIAL	28
4.2.1 PERCEPTRON DE MÚLTIPLAS CAMADAS (MLP)	28
4.2.2 SISTEMA DE INFERÊNCIA ADAPTÁVEL NEURO-FUZZY (ANFIS)	36
4.2.2 REDES COM FUNÇÃO DE BASE RADIAL (RBF)	45
4.3 CONTROLE INTELIGENTE NA MANUFATURA	49
4.3.1 CONTROLE DE QUALIDADE ATUAL E NOVAS TECNOLOGIAS	51
4.3.2 ALGUNS SISTEMAS INTELIGENTES USADOS EM MONITORAMENTO DE PROCESSOS DE USINAGEM	55
5 MATERIAIS E MÉTODOS	58
5.1 ENSAIOS E MEDIÇÕES REALIZADAS	58
5.1.1 MÁQUINA-FERRAMENTA	58
5.1.2 CORPOS-DE-PROVA	58
5.1.3 FERRAMENTA E PARÂMETROS DE CORTE	59
5.1.4 ESTRATÉGIA DE MONITORAMENTO	60
5.1.5 TRATAMENTO DOS SINAIS	62
5.1.6 MEDIÇÃO DO DIÂMETRO	62
5.2 CONFIGURAÇÃO DOS SISTEMAS DE INTELIGÊNCIA ARTIFICIAL UTILIZADOS PARA A ESTIMATIVA DOS DIÂMETROS DOS FUROS USINADOS	64
5.2.1 REDE MLP	64
5.2.2 SISTEMA ANFIS	66
5.2.3 REDE RBF	67
6.1 DESEMPENHO DA REDE MLP COM TODOS OS SINAIS NA ENTRADA	69
6.1.1 REDE MLP PARA A LIGA Ti6AL4V	71
6.1.2 REDE MLP PARA A LIGA 2024-T3	74

6.2 DESEMPENHO DAS REDES MLP CONSIDERANDO A INFLUÊNCIA DOS SINAIS DE ENTRADA	76
6.2.1 REDES MLP COM O SINAL DA FORÇA Z APLICADO NA ENTRADA	77
6.2.2 REDE MLP COM DOIS SINAIS APLICADOS NA ENTRADA	82
6.3 DESEMPENHO DO SISTEMA ANFIS	86
6.3.1 SISTEMAS ANFIS COM O SINAL DA FORÇA Z APLICADO NA ENTRADA.....	89
6.3.2 SISTEMAS ANFIS COM DOIS SINAIS APLICADOS NA ENTRADA	93
6.4 DESEMPENHO DA REDE RBF.....	97
6.4.1 REDE RBF COM TODOS OS SINAIS NA ENTRADA.....	97
6.4.2 AVALIAÇÃO DA INFLUÊNCIA DOS SINAIS E DO SPREAD	101
6.4.3 REDE RBF COM O SINAL DA FORÇA Z NA ENTRADA.....	103
6.4.4 REDE RBF COM SINAIS COMBINADOS NA ENTRADA	106
6.5 COMPARAÇÃO DOS TRÊS SISTEMAS DE INTELIGÊNCIA ARTIFICIAL UTILIZADOS	107
7 CONCLUSÕES	109
APÊNDICE.....	115
A.1 AVALIAÇÃO DOS PARÂMETROS E ARQUITETURA DA RNA MLP	116
A.2 AVALIAÇÃO DA INFLUÊNCIA DOS SINAIS NA ENTRADA DA RNA MLP ..	118
A.3 AVALIAÇÃO DO NÚMERO DE ÉPOCAS NO TREINAMENTO E INFLUÊNCIA DAS ENTRADAS DO ANFIS	121
A.4 AVALIAÇÃO DO SPREAD E DA INFLUÊNCIA DOS SINAIS NA REDE RBF	

1 INTRODUÇÃO

O controle de processos industriais de fabricação por usinagem tem grande importância econômica devido à busca pela redução do desperdício de matéria-prima e mão-de-obra. Operações indiretas de fabricação, como o controle de qualidade dimensional, geram custos indiretos que podem ser evitados ou reduzidos através do emprego de sistemas de controle (Kamen,1999). O emprego de sistemas inteligentes de manufatura (SIM) é o próximo passo no monitoramento dos processos de fabricação e vem sendo pesquisado, através da aplicação de redes neurais artificiais (RNA), desde os anos 1980 (HUANG; ZHANG, 1994).

O emprego de sistemas automatizados de manufatura tem ganhado espaço na indústria, sendo aplicados em centros de usinagem ou máquinas CNC individualmente. Técnicas de automação aplicadas na manufatura dividem-se no processamento, montagem, inspeção e movimentação de produtos.

Na inspeção, diversos métodos de controle de qualidade auxiliado por computador (CAQC, na sigla em inglês) têm sido empregados na indústria. Dentre esses métodos há o controle por inspeção visual através da aplicação de sistemas inteligentes para detecção de defeitos (Matsushima et al., 2010), a análise de sinais de emissão acústica e vibração para determinação do desgaste de rebolos e estimativa da rugosidade superficial em processos de retificação (Aguilar et al., 2010).

O processo de furação por usinagem está entre os processos de fabricação mais utilizados na indústria em geral. Na busca por maior qualidade deste processo, RNA tem sido empregadas para o monitoramento do desgaste de brocas por meio da utilização de sensores. Dentre os tipos de sinais empregados estão os de esforços de usinagem obtidos por dinamômetro (Yang et al., 2009), corrente elétrica obtida pela aplicação de sensores de efeito Hall no motor elétrico (Li; Tso, 1999), vibrações (Abu-Mahfouz, 2003), e ainda, uma combinação destes e outros sensores como acelerômetros e de emissão acústica (Kandilli et al., 2007).

O uso de sistemas de inteligência artificial vem preenchendo uma lacuna existente na obtenção de modelos matemáticos para sistemas complexos. Durante esta pesquisa não foram encontrados modelos matemáticos, em artigos científicos ou livros, para a avaliação dinâmica do processo de furação visando à obtenção da geometria final do furo.

2 OBJETIVO

O objetivo deste trabalho é analisar o desempenho de três técnicas de inteligência artificial na estimação do diâmetro de furos no processo de furação de precisão, e contribui para a ratificação da aplicação de sistemas de inteligência artificial na tarefa de avaliar o resultado final de processos de fabricação por usinagem.

Esta pesquisa contribui também para a extensão da pesquisa iniciada por Cruz (2010), que analisou as relações entre os sinais resultantes do monitoramento da furação e os diâmetros obtidos, através de redes neurais artificiais (RNA) perceptron de múltiplas camadas (MLP).

Os sistemas de inteligência artificial são alimentados com conjuntos de dados compostos por: sinais de sensores utilizados no monitoramento da furação, combinados e isolados; os parâmetros de corte e os resultados obtidos na medição dos diâmetros.

Redes neurais artificiais perceptron de múltiplas camadas (RNA MLP), um sistema de inferência adaptável neuro-fuzzy (ANFIS) e uma rede com função de base radial (RBF) são as técnicas de inteligência artificial estudadas na função de estimar o diâmetro de furos usinados.

3 JUSTIFICATIVA PARA A REALIZAÇÃO DESTA PESQUISA

Processos de fabricação automatizados, como aqueles realizados em centros de usinagem, trazem uma elevação na capacidade de produção, reduzindo o ciclo de fabricação, devido ao menor número de equipamentos necessários para completar um produto, pouca necessidade de movimentação de materiais e menor mão-de-obra empregada. Entretanto, a manufatura caminha para uma automatização mais completa, partindo do princípio de que sistemas inteligentes estão entre as técnicas de automação mais confiáveis, visto que, procuram imitar o comportamento humano no que diz respeito à capacidade de tomar decisões. Desse modo, um sistema produtivo somente será completamente automatizado se requerer a mínima intervenção humana. A redução desta dependência contribui para a elevação da qualidade de vida dos trabalhadores da indústria, retirando-os do ambiente de trabalho agressivo e dando-lhes oportunidades de galgar melhores postos de trabalho.

Deste ponto de vista, este trabalho contribui para a popularização da aplicação de sistemas de inteligência artificial na manufatura, avaliando seu desempenho na tarefa de realizar o controle de qualidade utilizando tanto uma abordagem multisensorial, quanto uma aplicação com apenas um sensor, ou ainda, uma combinação em pares.

4 REVISÃO BIBLIOGRÁFICA

4.1 FABRICAÇÃO MECÂNICA POR PROCESSO DE FURAÇÃO

A fabricação de componentes obtida por processos que envolvem remoção mecânica de material por cisalhamento é conhecida como usinagem. A peça original possui um tamanho suficiente para que, após a remoção de material, a geometria desejada seja alcançada, atendendo às tolerâncias e ao acabamento superficial especificado (Walker, 2006). Neste tipo de processo, diversos métodos de obtenção de uma geometria especificada estão disponíveis como: furação, fresamento, torneamento e retificação. O material removido é chamado de cavaco. Os processos de usinagem representam uma grande parte dos processos de fabricação utilizados na indústria atualmente e, estima-se que cerca de 70% dos produtos manufaturados são produzidos por este tipo de processo e, desse percentual, 10% correspondem a processos de furação (Youssef; El-Hofy, 2008).

No processo de furação, exemplificado na Figura 1, geralmente a peça (P) é fixada à estrutura da máquina-ferramenta (E) e através do movimento da ferramenta (F), rotativo (R) e de translação (T) na direção do eixo do furo a ser obtido, o cavaco é removido dando forma à característica desejada para o produto. O movimento de translação da ferramenta é conhecido como avanço. A ferramenta utilizada em processos de furação é chamada broca helicoidal e possui geometria adequada para a retirada do cavaco.




Figura 1 – Representação do processo de furação. Adaptado de Walker (2006).

Os tipos de máquinas-ferramenta geralmente utilizadas consistem em: furadeiras de bancada, radiais, verticais dentre outros. Independente do tipo, as furadeiras devem apresentar resistência e rigidez suficientes para permitir a operação adequada durante a furação, quando os esforços de corte e torques surgem. Para se obter precisão na furação o mandril deve possuir mínima excentricidade na montagem com a broca e, para reduzir a tensão na ferramenta o mecanismo de avanço deve ser verificado contra folgas (Stephenson; Agapiou, 2006).

4.1.1 FERRAMENTA DE CORTE

A broca helicoidal é uma das ferramentas de corte mais complexas dentre aquelas utilizadas nos processos de usinagem de metais. Além dos gumes, necessários para cortar o metal, a broca deve possuir canais para conduzir o cavaco para fora da região de corte e uma haste para fixação no mandril, conforme a Figura 2.




Figura 2 – Nomenclatura longitudinal de uma broca helicoidal. Klocke (2011)

A geometria da ponta da broca é apresentada na Figura 3, onde α_f é o ângulo de incidência, β é o ângulo de cunha e γ_f é o ângulo de saída. O gume transversal tem a função de deformar plasticamente o metal, direcionando-o à aresta de corte maior que promove a separação do material excedente do restante da peça trabalhada.




Figura 3 - Geometria da ponta de uma broca helicoidal. Adaptada de Klocke (2011).

De acordo com as características do material a ser usinado o ângulo de hélice δ , igual ao ângulo de saída γ_f , varia. A tabela 1 indica a relação entre as características do material a ser usinado e o ângulo de hélice recomendado para a broca a ser utilizada na furação (Klocke, 2011 e Stephenson; Agapiou, 2006).

Tabela 1 - Ângulos de hélice para furação de diversos materiais.

Característica do material	Ângulo de hélice	Representação gráfica
Dúctil (Alumínio, magnésio, cobre, zinco, polímeros e aços de baixo carbono)	$35^\circ \leq \delta \leq 45^\circ$	
Normal (Ferro fundido, aço carbono, aço inoxidável, ligas de alumínio de alta dureza, etc.)	$18^\circ \leq \delta \leq 30^\circ$	
Elevada dureza e fragilidade (magnésio, ligas de alumínio, materiais com baixa usinabilidade)	$10^\circ \leq \delta \leq 15^\circ$	

4.1.2 PARÂMETROS DE CORTE E INFLUÊNCIA NA QUALIDADE

Por se tratar de um processo altamente não-linear, a qualidade do furo usinado é influenciada pelas condições do início do processo, quando a broca começa a cortar o material (Katz; Poustie, 2001). Os parâmetros de corte consistem das condições de operação: avanço e rotação da ferramenta (Hermann, 2003).

A determinação dos parâmetros adequados para a realização de uma operação de furação está relacionada às características do material a ser usinado e, ao tipo de broca a ser utilizado, e sua escolha determina o volume de material a ser removido, em forma de cavaco e, conseqüentemente, à magnitude das forças necessárias para sua remoção (Batzner et al., 1998).

4.1.2.1 TOLERÂNCIAS PARA FUROS

Segundo Walker (2006), para furos com diâmetros inferiores a 15mm, a tolerância estabelecida é de $\pm 0,3\text{mm}$. A norma técnica ABNT NBR 6158:1995 estabelece os valores padrão para tolerâncias de furos de até 3150mm. A tabela 2 contém os graus de tolerância para furos de até 6mm.

Tabela 2 – Valores numéricos para graus de tolerância padrão IT (International Tolerances) para dimensões nominais até 6mm.

Dimensão nominal (mm)		Graus de tolerâncias-padrão													
		IT1	IT2	IT3	IT4	IT5	IT6	IT7	IT8	IT9	IT10	IT11	IT12	IT13	IT14
Acima	Até e inclusive	Tolerância													
		(μm)											(mm)		
-	3	0,8	1,2	2	3	4	6	10	14	25	40	60	0,1	0,14	0,25
3	6	1	1,5	2,5	4	5	8	12	18	30	48	75	0,12	0,18	0,3
		Mecânica extraprecisa													
		Mecânica corrente ou precisa													
		Mecânica grosseira													

Os graus de tolerância-padrão ainda são classificados de acordo com a precisão requerida para o diâmetro do furo, o que depende de cada aplicação e do tipo de ajuste desejado, entre o furo e a peça a ser montada ao longo do diâmetro. Para as peças fabricadas na indústria, de um modo geral, aquelas que serão utilizadas em montagens para transmissão de potência ou para fixação de componentes estruturais recebem tolerâncias da mecânica de precisão, ou seja, entre os graus IT5 e IT10. Tolerâncias na faixa da mecânica extraprecisa são empregadas na fabricação de instrumentos de medição e calibradores dos tipos passa e não-passa.

4.1.2.2 FATORES QUE AFETAM A QUALIDADE NA FURAÇÃO

A importância de se garantir a qualidade dos furos obtidos por processo de furação se justifica devido ao grande número de componentes, cuja fabricação termina com a construção de um ou mais furos, o que indica um grande prejuízo se algum problema ocorre nesta etapa (Strenkowski et al., 2004). De acordo com Zhao (1994), a qualidade desejada para o furo obtido no processo de furação por usinagem é avaliada de acordo com a exatidão dimensional e o acabamento superficial, que dependem do uso de ferramentas de longa vida e de baixa potência e força de corte.

A formação de uma base de conhecimento, oriunda da experiência obtida através da aplicação dos processos de furação, é importante para a determinação adequada das condições de operação, que influenciam a qualidade do furo usinado em conjunto com o material e geometria da ferramenta utilizada, o mecanismo de fixação da broca e a utilização de fluido de corte (Stephenson; Agapiou, 2006). A tabela 3 resume as características que influenciam a qualidade do furo para cada fator de projeto do processo.

Tabela 3 - Características que influenciam a qualidade do furo. (Stephenson; Agapiou, 2006).

Fatores de projeto	Características
Material da peça trabalhada	Microestrutura, dureza, elongação, estrição, usinabilidade, tratamento térmico aplicado, condição inicial da superfície.
Seleção do tipo de máquina-ferramenta	Rigidez estrutural e dos mecanismos de fixação e avanço da broca, número de eixos, orientação da ferramenta, tipo da mesa, disponibilidade de fluido de corte, exatidão e repetibilidade dos eixos disponíveis.
Seleção da ferramenta de corte	Tipo e estilo, material, geometria (ângulos), diâmetro, dureza, revestimento, desempenho quanto à remoção de cavacos, máximo avanço, rotação, forças e torque permitidos.
Seleção do tipo de mandril	Tipo, tipos de ferramentas que podem ser acopladas, rigidez e amortecimento em função da relação comprimento/diâmetro do furo a ser usinado.
Seleção do fluido de corte	Necessidade de remoção do cavaco e de refrigeração da peça, forma de aplicação.

Youssef e El-Hofy (2008) ainda identificam outros parâmetros que têm influência nas tolerâncias dimensionais resultantes:

- A afiação da ferramenta afeta a exatidão do diâmetro e a retilidade dos furos.
- O uso de guias ou buchas na montagem da broca evita a formação de rebarbas nos furos bem como a distorção no tamanho do furo.
- Expansão térmica do material, causado por variações na temperatura durante o processo.
- Distorção, na fixação, da peça a ser furada.

4.2 SISTEMAS DE INTELIGÊNCIA ARTIFICIAL

Definir inteligência artificial é uma tarefa árdua, pois, não há um consenso sobre quais habilidades um ser considerado inteligente deve possuir. Entretanto, algumas características podem ser associadas à inteligência, como a capacidade de aprender com uma experiência ou pela apresentação de informações ou, ainda, pela capacidade de se comunicar.

Apesar de não ser possível delimitar o significado de inteligência, alguns sistemas computacionais têm sido desenvolvidos sob o rótulo de sistemas inteligentes. Esses sistemas são capazes de classificar um conjunto de dados, aproximar funções e adaptar um sistema de controle, dentre outras aplicações.

4.2.1 PERCEPTRON DE MÚLTIPLAS CAMADAS (MLP)

A primeira tentativa de se compreender o funcionamento de uma rede neural biológica foi feita pelos pesquisadores Warren S. McCulloch e Walter H. Pitts – um neurofisiologista e um matemático, respectivamente – em 1943, que criaram um modelo matemático para o funcionamento de um neurônio, onde uma soma ponderada dos estímulos de entrada foi comparada a um limite de ativação, que leva o neurônio a emitir um estímulo de saída. O modelo de McCulloch-Pitts mostrou-se capaz de realizar qualquer cálculo aritmético ou lógico (Hagan et al., 1996).

Em 1949, Donald O. Hebb, um neuropsicólogo, postulou uma regra de aprendizado baseado no comportamento do neurônio e de suas conexões

(sinapses). A regra hebbiana, como ficou conhecida, foi utilizada por Frank Rosenblatt, um cientista da computação, em 1958, no desenvolvimento do modelo do perceptron (Haykin, 1999).

O perceptron consiste de um algoritmo elaborado para imitar o comportamento de um neurônio de McCulloch-Pitts com a finalidade de classificar padrões linearmente separáveis. A Figura 4 apresenta o neurônio biológico (Negnevitsky, 2005) e seu modelo matemático (Haykin, 1999). Assim como o neurônio biológico, o perceptron recebe estímulos em suas conexões de entrada (sinapses) e, se as condições necessárias são satisfeitas, um sinal é emitido na saída (axônio). As entradas recebidas são multiplicadas por pesos sinápticos, que correspondem à força de determinada entrada para a emissão da saída e uma soma ponderada é calculada. O resultado da soma é comparado a um limite de ativação do neurônio.




Figura 4 - Modelos de neurônios. (a) Neurônio biológico, adaptado de Negnevitsky (2005). (b) Neurônio artificial, adaptado de Haykin (1999).

Um neurônio artificial k pode ser descrito pelas seguintes expressões matemáticas Haykin (1999):

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

$$y_k = \varphi(u_k + b_k) \quad (2)$$

onde $x_1, x_2, \dots, x_n$ são os sinais de entrada; $w_1, w_2, \dots, w_n$ são os pesos sinápticos; u_k é a saída do combinador linear; b_k é o limiar de ativação (bias); $\varphi(.)$ é a função de ativação e y_k é a saída do neurônio.

A função de ativação define a saída de um neurônio em termos do potencial de ativação. Os tipos mais comuns de função de ativação utilizadas são listadas abaixo:

- ❖ Função de Heaviside ou Degrau: a saída do neurônio assume o valor 1 se o potencial de ativação for positivo, caso contrário, assume o valor 0.
- ❖ Função Rampa: pode assumir valores entre 0 e 1, ou, entre -1 e 1.
- ❖ Função Sigmóide: é a forma mais comumente utilizada e apresenta uma transição suave entre os comportamentos linear e não-linear. Ao contrário das anteriores, esta função é diferenciável. Pode assumir valores entre 0 e 1, ou, entre -1 e 1.

Geralmente, a utilização de apenas um neurônio não é suficiente para resolver problemas complexos (Hagan et al., 1996). Assim como na estrutura biológica, faz-se necessário organizar os neurônios em uma rede neural. A rede neural mais simples consiste em um conjunto de perceptrons, agrupados em uma camada escondida, entre a de entrada e a de saída, conforme Figura 5, onde cada nó nas camadas escondida e de saída corresponde a um neurônio. O número de nós, na entrada, depende do número de variáveis do problema, assim como os neurônios da camada de saída.




Figura 5 - Arquitetura típica de uma rede perceptron com uma camada escondida. Adaptada de Haykin (1999).

A estrutura apresentada acima para uma rede neural artificial (RNA) não é única e pode conter mais de uma camada escondida. A definição da arquitetura de uma RNA depende do tipo de problema a ser solucionado e, das características dos sinais apresentados na entrada. Além disso, também podemos definir o número de neurônios em cada uma delas. Cada camada escondida possui sua própria matriz de pesos sinápticos, um vetor de limiar de ativação, um vetor de entrada líquida e um vetor de saída (Hagan et al., 1996). A Figura 6 exibe uma arquitetura da RNA perceptron de múltiplas camadas (MLP).




Figura 6 - Modelo de uma RNA perceptron de múltiplas camadas. Adaptada de Haykin (1999).

Para que uma RNA possa apresentar características identificadas com a inteligência é necessário que ela aprenda com sua experiência anterior, chegando aos resultados esperados, ou, classificando as entradas com base nas características dos sinais apresentados (Davim, 2008).

Duas categorias de treinamento podem ser aplicadas: aprendizado supervisionado e não-supervisionado. Para que o aprendizado supervisionado seja possível, dois fluxos de sinais devem existir numa rede MLP, segundo Haykin (1999) (ver Figura 7): um fluxo através das camadas ocultas e da camada de saída, levando informações sobre os sinais e suas características e outro no sentido contrário, retornando informações sobre o erro estimado na tarefa incumbida à RNA, com o objetivo de ajustar os pesos sinápticos.




Figura 7 - Dois fluxos de informação em uma RNA MLP: propagação dos sinais de entrada neurônio-a-neurônio e retropropagação camada-a-camada do erro.

O método de retropropagação dos erros (*backpropagation*) é o mais poderoso em termos de eficácia no treinamento, apesar do tempo para convergência ser alto, requerendo alto desempenho computacional Hagan et al. (1996). O algoritmo deste método consiste em duas etapas, correspondentes aos fluxos da Figura 7. Na etapa de propagação dos sinais os pesos sinápticos não são atualizados e a saída de cada neurônio é calculada por Haykin (1999):

$$y_j(n) = \varphi_j[v_j(n)] \quad (3)$$

onde, $v_j(n)$ é o campo induzido local do neurônio j , definido por

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (4)$$

onde, m é o número de entradas do neurônio j , $w_{ji}(n)$ é o peso sináptico da conexão entre os neurônios i e j e $y_i(n)$ é o sinal de saída do neurônio i . Na camada de saída, o sinal de erro $e_j(n)$ a cada iteração é calculado pela comparação com o valor desejado $d_j(n)$:

$$e_j(n) = d_j(n) - y_j(n) \quad (5)$$

Com o erro calculado é possível definir uma função de energia do erro médio $\mathcal{E}(n)$ que deve ser minimizada para que a MLP convirja para o resultado desejado. A energia do erro depende apenas dos parâmetros da rede, como os pesos e dos limiares de ativação. O reajuste dos pesos sinápticos $\Delta w_{ji}(n)$ é proporcional ao gradiente local da função custo, que pode ser expressa pela regra da cadeia como:

$$\frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} = \frac{\partial \mathcal{E}(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (6)$$

Cada termo da equação 6 pode ser obtido através da efetuação das diferenciais em 7, 8, 9 e 10:

$$\frac{\partial \mathcal{E}(n)}{\partial e_j(n)} = \frac{\partial [1/2 \sum_{j \in C} e_j^2(n)]}{\partial e_j(n)} = e_j(n) \quad (7)$$

onde C é o conjunto que contém todos os neurônios da camada de saída.

$$\frac{\partial e_j(n)}{\partial y_j(n)} = \frac{\partial [d_j(n) - y_j(n)]}{\partial y_j(n)} = -1 \quad (8)$$

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \frac{\partial \{\varphi_j[v_j(n)]\}}{\partial v_j(n)} = \varphi_j'[v_j(n)] \quad (9)$$

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = \frac{\partial [w_{ji}(n)y_i(n)]}{\partial w_{ji}(n)} = y_i(n) \quad (10)$$

Substituindo as equações de 7 a 10 em 6, temos:

$$\frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} = -e_j(n)\varphi_j'[v_j(n)]y_i(n) \quad (11)$$

A correção do peso sináptico é definida pela regra delta:

$$\Delta w_{ji} = -\eta \frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} \quad (12)$$

onde o sinal negativo indica a intenção de minimizar $\mathcal{E}(n)$ e η é a taxa de aprendizagem, parâmetro relacionado à velocidade da apresentação dos sinais. Usando a equação 11 em 12, obtém-se a regra delta para atualização dos pesos:

$$\Delta w_{ji} = -\eta \delta(n)y_i(n) \quad (13)$$

onde o gradiente local $\delta(n)$ é definido na equação 14:

$$\delta(n) = -e_j(n)\varphi_j'[v_j(n)] \quad (14)$$

Pode-se verificar, por inspeção da equação 14, que a função de ativação φ_j deve ser diferenciável, sendo que duas são mais utilizadas (Davim, 2008): a função sigmóide ou logística (equação 15) e a função tangente hiperbólica (equação 16), onde C é uma constante.

$$f(t) = \frac{1}{1 + e^{-Ct}} \quad (15)$$

$$f(t) = \tanh\left(\frac{Ct}{2}\right) \quad (16)$$

Os pesos sinápticos são ajustados de acordo com a regra delta generalizada (equação 17).

$$\Delta w_{ji} = \alpha \Delta w_{ji}(n-1) + \eta \delta(n) y_i(n) \quad (17)$$

Enquanto a taxa de aprendizagem η permite definir a quantidade da alteração feita nos pesos sinápticos, o momento α evita a instabilidade do processo quando η assume um alto valor (Haykin, 1999).

O algoritmo de retropropagação dos erros pode ainda ser otimizado para reduzir o esforço computacional. Um algoritmo otimizado muito utilizado e, que foi utilizado neste trabalho é o de Levenberg-Marquardt, que consiste numa variação do método de Newton (Hagan; Menhaj, 1994). Este algoritmo busca a minimização da função custo, em relação a um vetor de parâmetros n , cuja modificação segue a equação 18:

$$\Delta n = -[\nabla^2 \mathcal{E}(n)]^{-1} \nabla \mathcal{E}(n) \quad (18)$$

onde, $\nabla \mathcal{E}(n)$ é o gradiente e $\nabla^2 \mathcal{E}(n)$ é a matriz Hessiana e, como a função custo é uma função quadrática do erro (ver equação 7), podem ser escritos como nas equações 19 e 20, respectivamente.

$$\nabla \mathcal{E}(n) = J^T(n) e(n) \quad (19)$$

$$\nabla^2 \mathcal{E}(n) = J^T(n) J(n) + S(n) \quad (20)$$

onde, a matriz Jacobiana $J(n)$ é determinada por

$$J(n) = \begin{bmatrix} \frac{\partial e_1(n)}{\partial n_1} & \frac{\partial e_1(n)}{\partial n_2} & \cdots & \frac{\partial e_1(n)}{\partial n_n} \\ \frac{\partial e_2(n)}{\partial n_1} & \frac{\partial e_2(n)}{\partial n_2} & \cdots & \frac{\partial e_2(n)}{\partial n_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(n)}{\partial n_1} & \frac{\partial e_N(n)}{\partial n_2} & \cdots & \frac{\partial e_N(n)}{\partial n_n} \end{bmatrix} \quad (21)$$

e

$$S(n) = \sum_{i=1}^N e_i(n) \nabla^2 e(n) \quad (22)$$

Portanto, a modificação Levenberg-Marquardt no método Gauss-Newton pode ser descrita, considerando $S(n) \approx 0$, por

$$\Delta n = [J^T(n)J(n) + \mu I]^{-1} J^T(n) \mathcal{E}(n) \quad (23)$$

4.2.2 SISTEMA DE INFERÊNCIA ADAPTÁVEL NEURO-FUZZY (ANFIS)

4.2.2.1 INTERPRETAÇÃO DE VARIÁVEIS LINGUÍSTICAS

Uma rede neural artificial do tipo MLP é capaz de apresentar características associadas ao aprendizado humano. Porém, esse sistema de inteligência artificial não é capaz de solucionar problemas, quando variáveis linguísticas estão disponíveis, o que é uma tarefa comum para o ser humano. Um exemplo de variável linguística pode ser retirado de um automóvel em movimento. Geralmente, ao observar o automóvel, pode-se inferir se a velocidade é baixa, moderada ou alta, sem informações precisas sobre os limites entre cada classe.

Em 1965, Lotfi A. Zadeh elaborou a teoria dos conjuntos nebulosos (*fuzzy*, em inglês). Distintamente da teoria clássica, que estabelece limites explícitos para definir se um dado pertence ou não a um conjunto, a teoria *fuzzy* estabelece funções com valores entre 0 e 1 para averiguar o grau de pertinência de certo dado em um conjunto (Zadeh, 1965).

O uso de informações qualitativas por um sistema de inteligência artificial requer um tipo de conversão dos dados de entrada através do uso de uma função de pertinência que transforme informações como “avanço baixo”, “velocidade de corte mediana”, “alta força de corte”, etc. em um número que representa o quanto uma informação pertence a determinado conjunto. Essa informação é utilizada em um conjunto de regras do tipo SE-ENTÃO cujo resultado é convertido em dados numéricos (Chandrasekaran et al., 2009).

O conjunto de processamentos descrito acima é conhecido como sistema de inferência *fuzzy* e pode ser resumido como apresentado na Figura 8.




Figura 8 - Etapas de um sistema de inferência *fuzzy*. Adaptado de Killing (2007).

4.2.2.2 FUZZIFICAÇÃO DAS ENTRADAS

Fuzzificação é o termo geralmente utilizado para definir o grau de pertinência de uma variável a um conjunto *fuzzy*. Em um processo de fuzzificação, por exemplo, um especialista pode definir a velocidade da ferramenta como baixa, média ou alta, dependendo do valor definido para o processo, como variável lingüística, enquanto que sensores podem indicar a magnitude da velocidade da ferramenta com um valor numérico.

Um exemplo da aplicação de um sistema de inferência *fuzzy* pode ser dado pelo controle de eficiência em um automóvel com câmbio automático, relacionando variáveis lingüísticas como o número de vezes que o acelerador foi acionado à marcha que deve ser selecionada para o menor consumo de combustível, avaliando o comportamento do motorista (Altrock, 1995).

Considerando um conjunto clássico, o valor de 27 mudanças no acelerador seria considerado como moderado (Figura 9). Contudo, em se tratando de variáveis lingüísticas, de acordo com a interpretação humana, o valor pode ser considerado tanto moderado como alto. Um conjunto *fuzzy* pode capturar esse conceito através da superposição de dois ou mais conjuntos, possibilitando que o valor de 27 mudanças do exemplo possa ser considerado como pertencendo tanto a um valor médio de mudanças quanto a um valor alto. No caso, o valor de 27 pertenceria em 0,8 ao conjunto “médio” e 0,2 ao conjunto “alto”.




Figura 9 - Classificação da condição da direção usando uma variável linguística. A variável linguística interpreta as mudanças no acelerador dentro de um período. Adaptado de Altrock (1995).

4.2.2.3 EFETUAÇÃO DAS REGRAS

Na segunda etapa do sistema de inferência *fuzzy*, as variáveis linguísticas são utilizadas para compor regras do tipo SE-ENTÃO, conforme exemplo da Figura 10.




Figura 10 - Estrutura das regras *fuzzy* e sua relação com o sistema de inferência. O antecedente consiste nas entradas fuzzificadas em variáveis linguísticas e é usado para calcular a saída do consequente. Adaptado de Killing (2007).

No exemplo de uma transmissão automática, um conjunto de regras para definir as condições da condução poderia ser:

- ❖ Se o número de mudanças no acelerador for médio e, se o automóvel estiver em quarta marcha então, mudar para a quinta marcha.
- ❖ Se o número de mudanças no acelerador for alto e o automóvel estiver em quinta marcha, então mudar para a quarta marcha.

As regras podem ser formuladas com o auxílio dos operadores E e OU, como na lógica booleana. Entretanto, como as variáveis assumem valores diferentes de 0 e 1, diversos operadores foram formulados para corresponder à lógica booleana. A tabela 4 exibe alguns dos operadores disponíveis no MATLAB.

Tabela 4 - Quatro operadores E/OU para uso com variáveis contínuas, disponíveis no MATLAB.

E	OU
Mínimo $MIN(\mu_A(x), \mu_B(x))$	Máximo $MAX(\mu_A(x), \mu_B(x))$
Produto algébrico $\mu_A(x)\mu_B(x)$	Soma algébrica $\mu_A(x) + \mu_B(x) - \mu_A(x)\mu_B(x)$

Cada regra *fuzzy* efetuada pode satisfazer totalmente ou parcialmente as condições do problema. O nível de atendimento é definido pela força de disparo. O conseqüente é composto por um conjunto de ações gerado pelo disparo da regra, definindo a resposta do sistema de inferência (Rezende, 2003).

4.2.2.4 DEFUZZIFICAÇÃO

O processo de *defuzzificação* combina as saídas de cada regra em um valor de saída para toda a rede. A produção da saída pode seguir algumas técnicas como:

- ❖ Maximização: quando o máximo valor da saída é selecionado;
- ❖ Média ponderada: a média ponderada da saída das regras é calculada;
- ❖ Centróide: quando o centro de área abaixo da função de pertinência final é calculado.

A Figura 11 exemplifica o processo de *defuzzificação* pelo cálculo do centróide da função de pertinência.




Figura 11 - Exemplificação do processo em que as saídas das funções de pertinência do consequente são combinadas para calcular o valor numérico da saída. Adaptada de Killing (2007).

A técnica que utiliza a média ponderada considera apenas o peso de cada regra, o que reduz significativamente o esforço computacional, em comparação com o método do centróide. A Figura 12 exemplifica a técnica.




Figura 12 - Defuzzificação através da técnica da média ponderada. Adaptada de Killing (2007).

4.2.2.5 ANFIS (ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM)

Embora os sistemas *fuzzy* possam trazer benefícios para o controle de processos industriais pela introdução do conhecimento qualitativo, não são capazes de se adaptar a mudanças no processo. Para contornar esse problema o uso de sistemas híbridos, conhecidos como *neuro-fuzzy*, têm sido estudados desde 1980 (Evsukoff; Almeida, 2003).

Dentre diversos sistemas neuro-*fuzzy* desenvolvidos, o sistema ANFIS tem sido largamente pesquisado em uma ampla gama de aplicações como modelagem, tomada de decisões, processamento de sinais e controle (Jang et al., 1997).

O sistema ANFIS é baseado no sistema *fuzzy* TSK proposto por Sugeno, M.; Kang (1988) e Takagi; Sugeno (1985), onde as conclusões das regras não são defuzzificadas, mas obtidas através de uma função das entradas do sistema. O modelo ANFIS baseado no modelo TSK é ilustrado na Figura 13.




Figura 13 - Sistema ANFIS baseado no modelo TSK, com duas entradas e duas regras. Adaptada de Evsukoff; Almeida (2003).

As regras de um sistema ANFIS, baseado em um modelo TSK de primeira ordem são formuladas pelas equações 18.

$$\begin{cases} \text{if } x = A_1 \text{ and } y = B_1 \text{ then } f_1 = \theta_{11}x + \theta_{12}y + \theta_{13} \\ \text{if } x = A_2 \text{ and } y = B_2 \text{ then } f_2 = \theta_{21}x + \theta_{22}y + \theta_{23} \end{cases} \quad (24)$$

Onde x e y são as entradas do modelo; A_1 , A_2 , B_1 e B_2 são os conjuntos *fuzzy* determinados por funções de pertinência; f_1 e f_2 são as saídas de cada regra que dependem dos parâmetros θ_{ii} (definido pelo processo de adaptação) e das variáveis de entrada. Cada uma das camadas do modelo ANFIS desempenha uma função específica no processo de inferência (Evsukoff; Almeida, 2003), como detalhado abaixo.

- Camada 1: são definidas as funções de pertinência – geralmente gaussianas. Nesta etapa os valores de pertinência são obtidos para cada conjunto *fuzzy*. No treinamento do sistema, o centro e o suporte das funções de pertinência, chamados de parâmetros de premissa, são ajustados.

$$\begin{cases} o_{11} = \mu_{A_1}(x) \\ o_{12} = \mu_{A_2}(x) \\ o_{13} = \mu_{B_1}(x) \\ o_{14} = \mu_{B_2}(x) \end{cases} \quad (25)$$

No caso de uma função gaussiana, o centro e o suporte correspondem, respectivamente, à média e ao desvio-padrão.

- Camada 2: o número de regras estabelecido define o número de unidades desta camada, que agregam as saídas da camada 1 pelo operador Π . Para que os parâmetros possam ser otimizados, garantindo que o sistema seja continuamente diferenciável, o operador produto é empregado.

$$\begin{cases} o_{21} = w_1 = \mu_{A_1}(x)\mu_{B_1}(y) \\ o_{22} = w_2 = \mu_{A_2}(x)\mu_{B_2}(x) \end{cases} \quad (26)$$

- Camada 3: as saídas de cada unidade são normalizadas, em relação aos valores de ativação das regras.

$$\begin{cases} o_{31} = \bar{w}_1 = \frac{w_1}{w_1 + w_2} \\ o_{32} = \bar{w}_2 = \frac{w_2}{w_1 + w_2} \end{cases} \quad (27)$$

- Camada 4: os parâmetros dos conseqüentes ocorrem linearmente na saída de cada regra, o que permite sua adaptação pelo método dos mínimos quadrados. A saída das regras é obtida pela equação 28

$$\begin{cases} o_{41} = \bar{w}_1 f_1 \\ o_{42} = \bar{w}_2 f_2 \end{cases} \quad (28)$$

- Camada 5: as saídas são somadas e a saída total é produzida pela equação 29.

$$o_{51} = \sum \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad (29)$$

A popularidade do sistema ANFIS se deve, em parte, à sua disponibilidade no MATLAB®. Porém, possuem algumas restrições em relação ao modelo apresentado, como: peso unitário para cada regra; somente uma saída é gerada para cada sistema com *defuzzificação* pela média ponderada; a customização de funções de pertinência não é possível.

Durante o treinamento do sistema ANFIS são adaptados os parâmetros das funções de pertinência e das funções de saída, conforme a tabela 5.

Tabela 5 - Dois passes do treinamento híbrido para ANFIS Jang (1993).

	Passe de avanço	Passe de retorno
<i>Parâmetros de premissa</i>	Fixo	Gradiente descendente
<i>Parâmetros do consequente</i>	Estimador por mínimos quadrados	Fixo
<i>Sinais</i>	Nós de saída	Taxas de erro

4.2.2.5.1 CONFIGURAÇÃO INICIAL DE UM SISTEMA ANFIS

O número de funções de pertinência e, consequentemente, o número de regras de um sistema de inferência *fuzzy* é de fundamental importância, pois, definem características dos dados apresentados. Cada função representa um agrupamento de dados (*cluster*) e por esse motivo devem apresentar algum afastamento em relação aos centros dos agrupamentos, mas com alguma superposição, como o exemplo da Figura 9, apresentado anteriormente. Caso

contrário, o algoritmo de treinamento pode apresentar problemas para distinguir qual conjunto de dados uma função representa, além de adequar regras distintas para os mesmos dados (Killing, 2007).

Métodos para a geração de funções de pertinência para um conjunto de dados de entrada, como o agrupamento subtrativo (*subtractive clustering*) podem ser utilizados (Chiu, 1994). Métodos de agrupamento de dados são eficazes para agregar dados similares e baseiam-se no comportamento humano de classificar informações para facilitar a análise. Além do método de agrupamento subtrativo outros foram desenvolvidos, como k-médias, *fuzzy* c-médias e o método da montanha (*mountain method*), sendo este último a base para o desenvolvimento do agrupamento subtrativo (Jang et al., 1997).

Os quatro processos citados acima foram comparados em Hammouda e Karray (2000). Os resultados indicam que, embora k-médias e c-médias resultem em maior exatidão, não podem ser usados quando o número de agrupamentos não é conhecido. Os outros dois processos – montanha e subtrativo – podem ser aplicados quando não se possui essa informação. Entretanto, o método subtrativo foi recomendado em virtude do menor esforço computacional requerido, em comparação com o da montanha.

O método subtrativo baseia-se no da montanha onde o centro do agrupamento é escolhido pela densidade de pontos de uma malha (Jang et al., 1997). O algoritmo subtrativo utiliza os pontos dos dados de entrada, e cada ponto x_i é candidato a centro de agrupamento tendo uma medida de densidade associada, calculada por

$$D_i = \sum_{j=1}^n \exp\left(-\frac{\|x_i - x_j\|^2}{(r_a/2)^2}\right) \quad (30)$$

onde r_a é uma constante positiva que define uma vizinhança para o centro do agrupamento, fora da qual os dados contribuem fracamente para a medida de densidade.

Após o cálculo para cada ponto, aquele com a maior medida de densidade é escolhido como o primeiro centro de agrupamento e, definido por x_{c1} com densidade

D_{c1} . A densidade de cada ponto é novamente calculada, mas com a equação seguinte

$$D_i = D_i - D_{c1} \exp\left(-\frac{\|x_i - x_{c1}\|^2}{(r_b/2)^2}\right) \quad (31)$$

A atualização da medida de densidade reduz o potencial dos pontos próximos ao centro do agrupamento de serem escolhidos como centros. A equação 31 é aplicada a cada escolha de um novo centro até cobrir todo o conjunto dos dados de entrada. Os centros de agrupamento definidos pelo método subtrativo serão usados como centros para as funções de pertinência das regras do sistema de inferência *fuzzy*.

4.2.3 REDES COM FUNÇÃO DE BASE RADIAL (RBF)

As redes neurais artificiais com função de base radial (RBF) são semelhantes a uma rede MLP com três camadas, sendo uma de entrada, uma escondida e uma de saída. Porém, as duas redes são distintas nos seguintes aspectos (Haykin, 1999; Hopgood, 2000):

- ❖ Uma rede RBF tem uma única camada oculta, enquanto que uma MLP pode ter uma ou mais camadas ocultas.
- ❖ Os nós computacionais de uma MLP, localizados em uma camada oculta ou em uma camada de saída, compartilham um modelo neural comum. Por outro lado, os nós computacionais na camada oculta de uma rede RBF são bem diferentes e servem a um propósito diferente daqueles da camada de saída da rede.
- ❖ A camada oculta de uma rede RBF é não-linear, enquanto que a camada de saída é linear. No entanto, as camadas ocultas e de saída de uma MLP usada como classificador de padrões são normalmente todas não-lineares.
- ❖ O argumento da função de ativação de cada unidade oculta em uma rede RBF calcula a norma euclidiana entre o vetor de entrada e o centro daquela unidade. Enquanto isso, a função de ativação de cada

unidade oculta em uma MLP calcula o produto interno do vetor de entrada pelo vetor de peso sináptico daquela unidade.

- ❖ As MLPs constroem aproximações globais de um mapeamento de entrada-saída não-linear. Por outro lado, as redes RBF utilizando não-linearidades localizadas com decaimento exponencial constroem aproximações locais para mapeamentos de entrada-saída não-lineares.

A dimensão do espaço de dados oculto em uma rede RBF é alta, pois, segundo (COVER, 1985 *apud* HAYKIN, 1999) um problema de classificação de dados tende a ser linearmente separável quanto maior a dimensão desse espaço.

A arquitetura de uma rede RBF pode ser visualizada na Figura 14, onde duas saídas são obtidas.




Figura 14 - Rede com função de base radial com quatro funções de base e duas saídas. Adaptada de Jang et al. (1997).

A configuração da camada intermediária pode conter diversas funções de base radial, contanto que o ponto de máximo seja situado na origem (Haykin, 1999), sendo que a função gaussiana é a mais empregada (Evsukoff; Almeida, 2003) e pode ser calculada pela equação 32.

$$\varphi(x(t)) = \exp \left[-\frac{\|x(t) - \rho_i\|^2}{\sigma_i^2} \right] \quad (32)$$

onde $\|x(t) - \rho_i\|$ é a distância euclidiana entre os valores de entrada x para o exemplo, t é o centro da função gaussiana da unidade i , ρ_i , e σ_i define o suporte da mesma função. Um exemplo de uma função simétrica pode ser visualizado na Figura 15.

O cálculo para a saída da rede utiliza funções de ativação lineares e obedece a equação vetorial 33.

$$y(t) = u(t)\theta = \varphi(x(t))\theta \quad (33)$$




Figura 15 - Parâmetros da curva gaussiana ajustados pelo processo de treinamento de uma rede com função de base radial (RBF).

onde $\varphi(x(t))$ define as saídas das funções da camada escondida e θ é o vetor com os pesos de cada conexão.

Considerando que uma RNA pode ser desenvolvida como um problema de aproximação em um espaço de alta dimensão, a definição do aprendizado em uma rede RBF visa encontrar uma superfície nesse espaço que melhor se adapte aos dados de treinamento, num tratamento estatístico, sendo que a generalização é equivalente à interpolação dos dados de teste pela superfície (Azevedo et al., 2000).

Os algoritmos de treinamento realizam o ajuste dos centros e dos suportes das funções de base radial, na camada escondida, geralmente por um algoritmo de

agrupamento de dados como o k-médias, em uma primeira etapa. O segundo passo consiste em ajustar os pesos sinápticos, na camada de saída, com o método backpropagation (Azevedo et al., 2000).

Segundo Chandrasekaran et al. (2009), uma rede RBF tem treinamento mais rápido que a MLP, embora necessite de mais dados.

A adaptação dos pesos sinápticos é necessária para que o mapeamento do conjunto de treinamento $T = \{(x(t), v(t)), t = 1..N\}$ (Evsukoff; Almeida, 2003); onde $x(t)$ é o vetor com as t entradas e $v(t)$ é o alvo associado à entrada t , que podem ser relacionados pela função de erro quadrático médio (equação 34), considerando apenas uma saída.

$$J(\theta) = \frac{1}{N} \sum_{t=1..N} [y(t) - v(t)]^2 \quad (34)$$

Utilizando o problema de otimização por mínimos quadrados para obter o conjunto de parâmetros θ^* (equação 35) que minimiza a equação 34:

$$\theta^* = \min_{\theta} (\|W \cdot \theta - V\|) \quad (35)$$

onde V é o vetor com todos os alvos e W é a matriz de regressores (equação 36), com as saídas de cada unidade da camada escondida para os N pontos de treinamento:

$$W = \begin{bmatrix} u_1(1) & \cdots & u_M(1) \\ \vdots & \ddots & \vdots \\ u_1(N) & \cdots & u_M(N) \end{bmatrix} = \begin{bmatrix} \varphi_1(x(1)) & \cdots & \varphi_M(x(1)) \\ \vdots & \ddots & \vdots \\ \varphi_1(x(N)) & \cdots & \varphi_M(x(N)) \end{bmatrix} \quad (36)$$

O problema de minimização pode ser resolvido pelo sistema linear (equação 37):

$$\theta^* = (W^T W)^{-1} W^T V \quad (37)$$

O objetivo de conseguir que a rede generalize o conhecimento apresentado consiste nas seguintes definições: assumindo uma rede com o número de unidades

de base radial $M < N$, com conjunto de treinamento com M colunas linearmente independentes, para uma função gaussiana.

Neste trabalho foi utilizada a rede RBF disponível no MATLAB®, como rede com função de base radial exata.

4.3 CONTROLE INTELIGENTE NA MANUFATURA

Seja qual for o ramo de atividade de uma indústria, objetivos comuns como a maximização da produtividade aliada à minimização dos custos operacionais e à redução dos custos indiretos de fabricação, são aplicados amplamente na definição de objetivos e metas para os processos. Custos indiretos podem ser identificados: a depreciação de máquinas e equipamentos utilizados na produção, o salário de supervisores, a energia consumida pelos processos (elétrica, pneumática, etc.) e o controle de qualidade. Este último contribui com os custos da mão-de-obra e de aquisição e manutenção – inclui-se aferição e reparo – de instrumentos de medição. Assim como a movimentação dos materiais, o tempo de seu armazenamento e de espera para a próxima operação, a atividade de inspeção é considerada como uma operação que não agrega valor ao produto final (Kamen, 1999).

A fim de se obter uma redução dos custos, referentes às atividades de inspeção, sistemas de controle têm sido empregados na indústria para corrigir os parâmetros de operação, mediante o monitoramento de sinais, para manter as características do produto dentro dos limites considerados aceitáveis. Em se tratando de controle, monitoramento e diagnóstico de processos industriais, MONOSTORI et al. (2006) os identifica como campos que se sobrepõem, no que diz respeito às técnicas utilizadas, como processamento de sinais para detecção de condições anormais durante a operação.

O monitoramento dos processos de fabricação pode ser aplicado na forma da verificação do desgaste da ferramenta, durante o processo, por meio da análise de sinais, para medir e estimar as variáveis do processo. Tal abordagem é conhecida como monitoramento da condição da ferramenta (TCM, na sigla em inglês). Outras abordagens consistem na determinação da integridade superficial, ou, da exatidão dimensional da peça. LIANG et al. (2004) apresenta o estado da arte do controle e monitoramento de processos industriais e relaciona as características monitoradas, aos tipos de sinais utilizados em várias aplicações.

O controle de um processo depende do conhecimento de um modelo, que relaciona os parâmetros e variáveis desse processo aos resultados esperados e, de uma arquitetura, que definirá os ajustes necessários para o atendimento das características desejadas. O modelo de um processo pode ser obtido por duas estratégias: formulação matemática por equações diferenciais, ou, se uma grande quantidade de dados estiver disponível, um sistema de inteligência artificial pode ser empregado para aproximação (Davim, 2008). Modelos matemáticos são desenvolvidos quando se conhece bem a relação entre os componentes envolvidos, mas a alta complexidade aliada a não-linearidades referentes ao comportamento da ferramenta e da peça, durante o processo, dificultam sua aplicação e a determinação de uma solução analítica. Além disso, a simulação de modelos complexos requer um alto desempenho computacional.

Para ser classificado como inteligente, um sistema precisa apresentar características que são relacionadas à inteligência humana como: memorização, uso do conhecimento (dados) na resolução de problemas e capacidade de aprender com a experiência (Haykin, 1999). Sistemas especialistas e redes neurais artificiais (RNA) são duas ferramentas de inteligência artificial que podem ser usadas no controle de processos e, segundo Wilamowski e Irwin (2010), o conhecimento contido em uma RNA não está disponível em uma forma compreensível, enquanto que, um sistema especialista, pode fornecer informações sobre como e por que determinada solução foi obtida.

De acordo com Huang e Zhang (1994), a manufatura integrada por computador (CIM, na sigla em inglês) se apresenta em fase de evolução, sendo a aplicação de sistemas inteligentes o próximo passo no controle da produção, como pode ser verificado através do expressivo acréscimo no número de artigos científicos publicados a partir dos anos 1980. Os autores apresentam um levantamento das aplicações de RNA na fabricação no auxílio às atividades de projeto do produto, planejamento do processo, programação da produção, modelagem e controle, monitoramento e diagnóstico, controle de qualidade, classificação de peças e robótica.

O termo computação leve (*soft computing*, em inglês) definido por Zadeh (1994) traduz a necessidade de se considerar a imprecisão e a incerteza, que são parte do processo de tomada de decisões do ser humano, na análise de problemas reais por sistemas inteligentes incorporados às máquinas. A justificativa se deve ao

fato de que o ser humano toma decisões melhores quando as informações são imprecisas, do que com informações meticulosamente detalhadas, como no momento de estacionar um automóvel, quando a decisão de que a tarefa de estacionar o carro foi concluída baseada apenas na percepção das tolerâncias do espaço reservado.

A computação leve consiste na fusão da lógica *fuzzy* com redes neurais artificiais e computação evolutiva, resultando em um sistema inteligente, capaz de agrupar as características de cada componente como: imprecisão, aprendizado e incerteza, respectivamente (Zadeh, 1994).

Aplicações da computação leve na indústria foram levantadas por DOTE e OVASKA (2001) e incluem o ramo aeronáutico, sistemas de comunicação, eletrodomésticos, sistemas de potência, automação da fabricação e robótica, eletrônica de potência e controle de movimento, engenharia de processos e transportes. Assim, sistemas inteligentes são bastante eficazes quando aplicados aos problemas reais, quando a abordagem tradicional é difícil de ser aplicada devido à necessidade de melhores modelos.

4.3.1 CONTROLE DE QUALIDADE ATUAL E NOVAS TECNOLOGIAS

O controle de qualidade, aplicado na indústria, consiste em se verificar as características desejadas para determinado produto, de forma a analisar se os requisitos de projeto foram atendidos de maneira adequada, de acordo com as tolerâncias especificadas. Para se atingir este objetivo o emprego de técnicas de inspeção foram desenvolvidas de acordo com a característica que se deseja monitorar, e cada técnica emprega diferentes instrumentos de medição para extração das características desejadas no produto.

O trabalho metrológico consiste em comparações entre certas quantidades de uma mesma grandeza, sendo necessário o envolvimento de cinco agentes para caracterização de um processo de medição (Ablameyko 2003), cuja relação pode ser observada na Figura 16.

Segundo Ablameyko (2003), cada um dos cinco agentes contribui para a inexatidão do processo de medição, pois, o produto possui um modelo que não é completamente verdadeiro; o padrão apenas representa a grandeza a ser medida e tem precisão limitada em relação ao valor teórico determinado; o instrumento de

medição possui diversos mecanismos internos que produzem alguma interferência no resultado e são influenciados pelas condições do ambiente, onde a medição ocorre; o método de medição pode não levar em consideração todos os fenômenos associados à grandeza examinada e, por fim, o operador pode contribuir para a inexatidão da medição através de uma leitura (paralaxe) ou manuseio incorreto do instrumento.




Figura 16 - Representação do processo de medição. Adaptada de Ablameyko (2003).

O método empregado a obtenção da medição consiste de um procedimento científico, que envolve o conhecimento dos processos físicos associados à grandeza a ser medida e que deve ser controlado e padronizado para que possa ser replicado por outros inspetores (Balbinot; Brusamarello, 2010).

Um controle de qualidade bem implementado pode ser definido pela eficácia em detectar produtos fora de conformidade e segregá-los, para que não cheguem até o cliente. Sua eficácia passa pela capacidade de um sistema de medição em rejeitar produtos não-conformes e, aceitar aqueles que atendem às especificações.

Segundo Doebelin (2004), se as variações de processos e de medição forem assumidas como distribuições gaussianas o percentual de produtos que serão classificados de forma incorreta pode ser estimado segundo critério definido por Juran, um dos gurus da qualidade, que estabeleceu um desvio-padrão inferior a 4% como aceitável. Supondo uma medição de uma variável qualquer de um processo, cuja especificação nominal é de 10, com tolerância que permite a aceitação do

produto na faixa de 4 a 16, poderia levar a uma rejeição de um produto bom ou uma aceitação de um produto não-conforme, devido aos erros inerentes ao processo de medição, conforme exemplificado na Figura 17, onde um desvio-padrão de 4,2% foi calculado.




Figura 17 - Efeito indesejável dos erros de medição no controle de qualidade industrial. Adaptada de Doebelin (2004).

Dois termos de uso corrente na indústria, para definir a capacidade de um instrumento de medição de apresentar o valor real de uma grandeza medida, são a precisão, ou repetibilidade, e a exatidão. O primeiro termo pode ser interpretado como a capacidade do instrumento de medição apresentar resultados sequenciais dentro de certa faixa de valores enquanto que, a exatidão, é a capacidade de um instrumento indicar o valor exato da grandeza (Lira, 2002). Em ambos os casos, um erro de medição é sempre incorporado. A Figura 18 exemplifica os conceitos acima através de uma analogia com um jogo de tiro ao alvo.

Redes neurais artificiais são muito úteis quando se trabalha com o controle de qualidade reativo que, segundo HUANG e ZHANG (1994), inclui o planejamento de amostragem, a análise de lotes de aceitação e a análise de retrabalhos. O autor levanta trabalhos publicados entre 1990 e 1991, cuja tecnologia foi aplicada na análise de motores elétricos, inspeção de moldes de injeção, alto-falantes e montagem de componentes eletrônicos.




Figura 18 - Conceitos de precisão e exatidão inerentes ao processo de medição. a) Alta precisão e baixa exatidão. b) Altas precisão e exatidão. c) Altos erros de precisão e exatidão. Adaptada de Figliola; Beasley (1995).

Chinnam et al. (2000) propõe um método de controle de qualidade on-line baseado no controle dos processos durante a operação de fabricação, onde uma rede neural artificial Multilayer Perceptron (MLP), com três camadas ocultas, é utilizada para construir uma relação entre as saídas obtidas e os parâmetros do processo.

O uso de um sistema, conhecido como memória associativa *fuzzy* adaptável (AFAM, na sigla em inglês), é utilizado por Shahir (2003) para substituir a inspeção visual de um brasão da maçaneta da porta de um automóvel.

Killing (2007) identifica a vantagem da aplicação de métodos de inspeção automatizados na realização do controle de qualidade como a possibilidade de avaliar 100% do lote, mantendo-se alta taxa de produção, enquanto que, controlada manualmente, a inspeção total resulta em uma diminuição da produtividade, requerendo a verificação apenas de amostras do lote. Em seu trabalho, desenvolve um sistema automatizado para averiguar, por meio de imagens, uma viga utilizada na indústria automobilística, mais especificamente para verificar a posição de grampos, onde serão montados parafusos, e as imagens capturadas por uma câmera são analisadas por um sistema inteligente neuro-fuzzy.

No trabalho de Matsushima et al. (2010), uma rede neural artificial com uma camada oculta é utilizada para inspeção das juntas soldadas de componentes eletrônicos. A RNA é treinada através da apresentação de modelos de juntas aceitáveis e defeituosas, utilizando o método backpropagation.

4.3.2 ALGUNS SISTEMAS INTELIGENTES USADOS EM MONITORAMENTO DE PROCESSOS DE USINAGEM

Segundo Davim (2008), os sistemas inteligentes aplicados na manufatura são comparados a um operador qualificado que emprega seus órgãos sensoriais e seu cérebro para operar uma máquina-ferramenta. Assim, é necessário o emprego de sensores com boa precisão e exatidão, com baixo custo de implantação, e ferramentas computacionais eficientes, desenvolvidas através de algoritmos otimizados que possam reproduzir o processo de tomada de decisões do operador.

No monitoramento de operações de usinagem, o conhecimento do modelo matemático do processo é utilizado no controle, baseado na física de suas interações. Geralmente, esse modelo é aproximado através de equações diferenciais que podem ser aplicadas em softwares de simulação pelo método dos elementos finitos para viabilizar a análise do comportamento do processo, com grande esforço computacional. Porém, modelos matemáticos precisos dificilmente podem ser obtidos devido à complexidade da interação entre a ferramenta de trabalho e a peça. Métodos de computação leve – como RNA e algoritmos genéticos, podem ser utilizados para modelar o processo, baseado em dados coletados. A vantagem do uso desta classe de solução está na sua capacidade de relacionar as saídas às entradas, mesmo diante de dados imprecisos, faltantes ou incertos (Davim, 2008).

Um sistema de monitoramento da condição da ferramenta é proposto por Abu-Mahfouz (2003) para possibilitar o uso mais eficiente e econômico da broca, em um processo de furação a seco em aço 1040. Um acelerômetro foi utilizado para captar as vibrações da mesa, desconsiderando os transientes de entrada e saída da broca na peça de trabalho. Uma RNA MLP foi treinada utilizando o avanço, a rotação da ferramenta e mais quatro parâmetros estatísticos resultantes do processamento do sinal de aceleração, para detectar cinco tipos de desgaste na broca. A rede MLP foi capaz de detectar o desgaste em todos os conjuntos de treinamento e obteve 80% de sucesso em classificar o tipo de desgaste, demonstrando que o sinal de aceleração tem boa capacidade para o monitoramento de processos de fabricação.

O desgaste e evidências da quebra em pequenas brocas foram monitorados e uma RNA MLP foi treinada com o método *backpropagation* para identificar ambos,

através dos sinais de emissão acústica, vibração e força de avanço em Hermann (2003). O monitoramento on-line foi realizado em uma fresadora convencional e o reconhecimento adequado do desgaste da broca foi analisado em relação às entradas apresentadas à rede MLP. Os melhores resultados na detecção do desgaste da broca foram obtidos através da combinação das médias dos sinais de emissão acústica e da força de avanço.

O uso de sensores e técnicas de sensoriamento, estratégias de controle e os softwares abertos disponíveis para o monitoramento de processos de fabricação foram levantados em LIANG et al. (2004). Os avanços devem caminhar na direção do uso dos dados para controlar a formação de cavacos e de rebarbas. As informações do processo serão coletadas de forma mais abrangente com mais sensores monitorando diversas variáveis.

O monitoramento on-line de um processo de retificação foi realizado com a finalidade de se obter estimativas para a rugosidade superficial pelo uso de um sistema de inferência adaptável neuro-fuzzy (ANFIS, na sigla em inglês) por Samhour; Surgenor (2005). Um acelerômetro piezelétrico foi utilizado para captar as vibrações do processo e a densidade espectral da potência serviu como entrada para o sistema ANFIS, bem como o avanço do rebolo e a força de avanço. O erro percentual na estimativa da rugosidade superficial, em comparação com valores obtidos através de medições, foi de apenas 9%.

Uma abordagem no controle de processos de usinagem consiste no monitoramento da condição da ferramenta. Tal abordagem consiste na coleta de dados, geralmente utilizando múltiplos sensores, para determinar o nível de desgaste indicando o momento mais econômico para realizar a troca. Os processos de furação e fresamento foram monitorados em tempo real em Kandilli et al. (2007) através de sensores de força (x, y e z), aceleração, corrente e emissão acústica instalados em um centro de usinagem CNC com quatro eixos. A média, o desvio-padrão e o RMS dos sinais coletados foram apresentados a uma RNA MLP com o objetivo de apontar o desgaste.

Uma revisão dos sistemas de monitoramento de processos de usinagem baseados em inteligência artificial é apresentada em Abellan-Nebot e Subirón (2009). O levantamento foi feito considerando-se: os diferentes tipos de sensores utilizados, as técnicas de processamento de sinais, as características dos sinais utilizadas, bem como os métodos utilizados para sua extração, o projeto de

experimentos para utilização da menor quantidade de dados e, por fim, as características das técnicas de inteligência artificial aplicadas para relacioná-los às saídas dos processos. A Figura 19 exhibe a proposta para a implantação do monitoramento inteligente de um processo de fabricação.



Figura 19 - Método genérico para o desenvolvimento de um sistema de monitoramento inteligente para processos de usinagem. Adaptada de Abellan-Nebot e Subirón (2009).

A capacidade da previsão de uma RNA MLP foi analisada por Aguiar et al. (2010) em relação à qualidade superficial de uma peça de aço doce trabalhada em um processo de retificação. Os parâmetros de qualidade avaliados foram a rugosidade média superficial, a detecção da queima da superfície e a micro-dureza, diante de variações nos parâmetros do processo. Como entradas das redes neurais foram utilizados o sinal RMS de emissão acústica, a potência de corte, o avanço e os parâmetros estatísticos DPKS e DPO, apresentados de forma distinta a três arquiteturas. O melhor desempenho encontrado corresponde a um erro médio de 5,54%, cujas entradas da rede foram o parâmetro RMS da emissão acústica, o avanço e a potência de corte.

Uma rede bayesiana foi utilizada para a previsão da rugosidade superficial de furos feitos em peças de aço por Bustillo e Correa (2011). Os resultados foram divididos em classes de rugosidade, sendo que a rede classificou de forma precisa 86% das estimativas.

Apesar dos bons resultados encontrados na aplicação de sistemas de inteligência artificial no monitoramento de processos de usinagem, trabalhos voltados para a estimação do resultado final do processo são escassos.

5 MATERIAIS E MÉTODOS

A implementação dos sistemas de inteligência artificial, bem como a metodologia utilizada para a definição das configurações serão abordadas neste capítulo. Um breve relato do método empregado para a obtenção dos dados utilizados para treinamento dos sistemas será fornecido com o objetivo de proporcionar maior entendimento do problema abordado.

Todas as informações obtidas sobre os ensaios e aquisição e processamento dos sinais foram obtidos de Cruz (2010), cujo trabalho encontra-se resumido no item 5.1 e subtópicos. Os demais testes e algoritmos, constantes do tópico 5.2 em diante, foram desenvolvidos no trabalho corrente, com exceção do algoritmo para a configuração otimizada da rede MLP (arquitetura da rede e melhores parâmetros).

5.1 ENSAIOS E MEDIÇÕES REALIZADAS

5.1.1 MÁQUINA-FERRAMENTA

O processo de furação foi realizado em uma fresadora universal U-30 marca Zocca, de propriedade do Laboratório de Tecnologia da Usinagem (LATTUS), do campus da UNESP de Bauru. Trata-se de um equipamento de configuração manual, com potência instalada de 6cv no motor principal, faixa de rotação da ferramenta de 45 a 2800rpm e avanço vertical de 4 a 250 mm/min, com IHM para controle de posição dos eixos. A fresadora ainda possui réguas eletrônicas de precisão micrométrica em cada eixo e foram utilizadas para garantir a padronização das coordenadas dos furos nos corpos-de-prova Zocca (2011).

5.1.2 CORPOS-DE-PROVA

Os dados utilizados no treinamento dos sistemas de inteligência artificial consistem do resultado do monitoramento de um processo de furação por usinagem, sem o uso de fluido de corte. Corpos-de-prova (Figura 20), compostos por uma chapa de liga de titânio Ti6Al4V unida, por selante de interface, a uma chapa de liga de alumínio 2024-T3, foram submetidos ao processo de furação.

Um total de 54 corpos-de-prova foi usinado com o objetivo de obter furos sob condições de usinagem distintas, sendo seis para cada conjunto de condições de usinagem, com nove conjuntos no total.




Figura 20 - Dimensões e configuração dos corpos-de-prova (dimensões em mm). Adaptado de CRUZ (2010).

5.1.3 FERRAMENTA E PARÂMETROS DE CORTE

A broca utilizada para a realização dos ensaios consiste em uma ferramenta especial para a usinagem de ligas utilizadas na indústria aeronáutica, fabricada pela OSG Sulamericana de Ferramentas Ltda.

Cada broca de metal duro, num total de nove, foi identificada com um número sequencial e foi utilizada exclusivamente para a usinagem dos corpos-de-prova correspondentes a uma das nove condições de usinagem escolhidas. No total, cada broca foi utilizada na usinagem de 162 furos. Com este número de furos foi esperado o desgaste da ferramenta afetando, assim, os sinais coletados.

O diâmetro externo de cada broca foi medido em projetor de perfil e a média de cinco medições foi armazenada para utilização no treinamento dos sistemas de inteligência artificial.

Os parâmetros de corte selecionados foram determinados com o objetivo de representar diversas condições de usinagem utilizadas na indústria. Assim, três

rotações (500, 1000 e 2000 rpm) e três velocidades de avanço (22,4; 90 e 250 mm/min) foram combinadas, resultando em nove conjuntos distintos.

5.1.4 ESTRATÉGIA DE MONITORAMENTO

Para monitoramento do processo de furação foram instalados quatro sensores sendo: um sensor de emissão acústica, um acelerômetro unidimensional, um sensor de efeito Hall e um dinamômetro tridimensional. Os sinais foram enviados a um computador através de uma placa de aquisição de sinais do fabricante National Instruments, modelo PCI-6035E de 16 bits, com taxa de aquisição de 2kS/s. A montagem dos módulos de aquisição de sinais com o computador e a máquina-ferramenta são apresentados na Figura 21.




Figura 21 - Máquina-ferramenta e acessórios utilizados para a aquisição dos sinais, CRUZ (2010).

Cada sensor utilizado capturou uma característica do processo de furação através da medição de variáveis, conforme é detalhado a seguir:

- A emissão acústica em um material consiste na propagação de ondas elásticas transientes geradas pela liberação rápida de energia em fontes localizadas no material. O sensor foi acoplado em um banco de ensaios utilizado para fixar o

dinamômetro ao corpo-de-prova e, à mesa da máquina-ferramenta com o objetivo de captar a emissão acústica gerada: pela deformação, cisalhamento e/ou ruptura do material usinado.

- As vibrações em uma máquina são decorrentes dos esforços empregados na transmissão e na usinagem de uma peça, embora também possam surgir devido a falhas em rolamentos ou engrenagens. Nos ensaios, um acelerômetro foi utilizado para medir a aceleração proveniente das vibrações causadas pelo corte dos materiais dos corpos-de-prova devido às variações nas forças de corte durante o processo.
- O sensor de efeito Hall foi utilizado para medir a corrente e a tensão elétrica do motor de indução. Ambos os sinais são multiplicados e filtrados resultando em um sinal correspondente à potência elétrica consumida.
- Os esforços necessários em um processo de usinagem estão relacionados à resistência do material ao cisalhamento e ao escoamento e estão relacionados à escolha dos parâmetros de corte. Um dinamômetro tridimensional foi instalado para coletar informações sobre os esforços no plano xy e a força efetiva de corte no eixo z. Para a montagem deste sensor foi necessária a instalação de um banco de ensaios para garantir a rigidez do conjunto corpo-de-prova/sensor/mesa, fundamental para a qualidade da furação.

O diagrama da Figura 22 ilustra a posição de montagem de cada sensor utilizado.

5.1.5 TRATAMENTO DOS SINAIS

Os sinais coletados foram analisados por rotinas computacionais no MATLAB® para a eliminação dos trechos coletados onde a ferramenta não estava em contato com a peça, antes e depois de executar a operação de corte.

A força no eixo z foi utilizada para determinar o início e fim da operação, pois, dentre os sinais coletados foi o que mais evidenciou as duas etapas. As regiões de inatividade foram desprezadas, bem como o trecho do sinal correspondente à retirada da broca do furo usinado.




Figura 22 - Diagrama ilustrando a posição de montagem de cada sensor e a aquisição dos sinais, com o sistema de referência indicando o sentido das forças de corte, CRUZ (2010).

Cada material do qual o corpo-de-prova foi composto apresenta características de resistência diferentes, o que acarreta em desvios dimensionais distintos, assim como as características dos sinais sofrem variação conforme a broca passa pelas duas ligas. Devido a essas considerações, os sinais foram divididos em duas partes sendo, 2/5 para a liga de titânio e 3/5 para a liga de alumínio. A Figura 23 ilustra a divisão dos sinais.

Por fim, a média aritmética dos valores absolutos de cada sinal foi calculada, obtendo-se um valor médio de cada sinal para cada furo usinado nos corpos-de-prova.

5.1.6 MEDIÇÃO DO DIÂMETRO

O diâmetro dos furos foi mensurado com o auxílio de um relógio comparador com resolução de $\pm 0,005\text{mm}$, da marca Mahr, modelo 1087B. Para evitar a influência das limalhas e cavacos resultantes do processo de furação, os corpos-de-prova foram limpos com ar comprimido e panos.




Figura 23 - Divisão dos sinais coletados de acordo com o material usinado, onde 2/5 corresponde à liga de titânio (em amarelo) e 3/5 correspondem à liga de alumínio (em branco), CRUZ (2010).

Devido às diferenças nas propriedades das ligas utilizadas o comportamento dimensional varia de forma distinta para cada uma. De qualquer forma, o diâmetro dos furos obtidos não é perfeitamente circular e foi aproximado por uma elipse apontando dimensões mínima e máxima, conforme Figura 24.

Devido ao procedimento adotado na medição, para cada furo medido quatro valores de diâmetro foram registrados sendo os diâmetros mínimos e máximos de cada uma das ligas. Os registros obtidos foram utilizados para compor o conjunto de treinamento dos sistemas de inteligência artificial, com respeito às saídas desejadas.

5.2 CONFIGURAÇÃO DOS SISTEMAS DE INTELIGÊNCIA ARTIFICIAL UTILIZADOS PARA A ESTIMATIVA DOS DIÂMETROS DOS FUROS USINADOS

5.2.1 REDE MLP

Neste trabalho foram utilizadas RNA MLP cuja configuração e execução foi realizada através do *toolbox* de RNA do MATLAB®. A configuração da MLP foi obtida com o uso de um algoritmo, proposto por Cruz (2010), cuja finalidade é variar a arquitetura da rede neural e dois parâmetros, conforme Figura 25.




Figura 24 - Ilustração da irregularidade na circularidade do furo e processo de medição CRUZ (2010).

Após a obtenção dos resultados, a escolha da configuração da rede MLP foi feita pela classificação do erro médio obtido para a estimativa do diâmetro mínimo e, para o diâmetro máximo. Para a escolha da configuração a ser utilizada, foi analisada a rede que figurou entre as cinco melhores – com o menor erro médio – tanto para o diâmetro mínimo, como para o diâmetro máximo.

Após a classificação, um novo algoritmo foi desenvolvido, com a finalidade de verificar a influência da média de cada um dos sinais coletados no desempenho da rede. Também foi considerada a influência da combinação de dois sinais. Tal procedimento foi adotado visando obter uma estratégia de monitoramento do processo na qual o menor número de sensores seja utilizado, reduzindo os custos

de implantação e a interferência no processo de fabricação. O algoritmo é representado através de fluxograma na Figura 26.




Figura 25 - Fluxograma representativo do algoritmo para o teste de arquitetura e parâmetros da rede MLP, proposto por CRUZ (2010).




Figura 26 - Fluxograma representativo do algoritmo desenvolvido para teste dos sinais.

5.2.2 SISTEMA ANFIS

A definição da configuração do sistema ANFIS consiste na determinação de um sistema de inferência *fuzzy* (FIS), com suas componentes, conforme apresentado em 4.3.2, e posterior adaptação das funções de pertinência, regras e pesos.

Os testes realizados incluem a avaliação da influência dos centros de agrupamento na definição das regras do FIS realizado por tentativa e erro, e a influência dos sinais de entrada combinados.

Assim como foi implementada a rede MLP, o sistema ANFIS disponível no *toolbox Fuzzy* do MATLAB® foi utilizado. Como o sistema possui suporte para gerar apenas uma saída, foram desenvolvidos quatro sistemas ANFIS sendo dois para

cada liga do corpo-de-prova. Os resultados foram analisados através do erro quadrático médio gerado na saída do ANFIS. Outra limitação inerente ao MATLAB® é que o número máximo de quatro entradas simultâneas pode ser utilizado.

Um algoritmo foi desenvolvido para analisar a influência do número de épocas de treinamento (Figura 27). Para o teste de influência das entradas foi utilizado o algoritmo do MATLAB® com um método de combinação das entradas, conhecido como método sequencial, método semelhante ao desenvolvido para o treinamento da rede MLP (Figura 26). Para este teste foram consideradas somente os sinais de emissão acústica, potência, força em Z e aceleração.




Figura 27 - Fluxograma representativo do algoritmo utilizado para verificar a influência do número de épocas de treinamento.

5.2.3 REDE RBF

Os testes realizados na rede RBF consistiram na análise da influência dos sinais aplicados e do parâmetro espalhamento (*spread*), que significa o suporte, raio ou desvio-padrão de uma função gaussiana.

Devido ao reduzido esforço computacional envolvido, justificado pela verificação de apenas um parâmetro, o algoritmo de teste da RBF contemplou os testes dos sinais simultaneamente com o teste do *spread*. Dessa forma, para cada sinal ou combinação de sinais o *spread* foi variado de 10 a 1000 com passos de 10.

Assim como nos testes de sinais realizados nas redes MLP e ANFIS, a combinação sequencial ocorreu em conjuntos de dois sinais combinados ou um sinal isolado. O algoritmo é representado através do fluxograma da Figura 28.




Figura 28 - Fluxograma representativo do algoritmo desenvolvido para teste de influência dos sinais e do suporte das gaussianas.

6 RESULTADOS E DISCUSSÕES

Este capítulo apresenta as arquiteturas e parâmetros selecionados após análise dos resultados da execução dos algoritmos descritos no capítulo 5. Os resultados obtidos nos testes foram analisados através dos erros gerados na simulação dos sistemas de inteligência artificial após o treinamento.

6.1 DESEMPENHO DA REDE MLP COM TODOS OS SINAIS NA ENTRADA

Após a execução da rotina para avaliar a influência dos parâmetros foram analisadas as configurações da rede para cada liga do corpo-de-prova em consideração ao desempenho na estimativa dos diâmetros mínimo e máximo. Na análise do menor erro foi verificado que uma configuração figurou entre as cinco melhores para os dois diâmetros e materiais, conforme tabelas 6 e 7. O algoritmo de Levenberg-Marquardt foi utilizado para treinamento.

Tabela 6 - Cinco melhores resultados obtidos para a estimativa do diâmetro na liga Ti6Al4V, pela rede MLP.

MELHORES RESULTADOS PARA O DIÂMETRO MÍNIMO					
NÚMERO DE NEURÔNIOS			MOMENTO	TAXA APRENDIZADO	ERRO MÉDIO D_{MIN} [mm]
CAMADA 1	CAMADA 2	CAMADA 3			
10	10	10	0,7	0,3	0,0069
20	5	5	0,3	0,3	0,0070
20	10	5	0,7	0,05	0,0070
5	5	5	0,3	0,9	0,0071
10	5	20	0,5	0,9	0,0071
MELHORES RESULTADOS PARA O DIÂMETRO MÁXIMO					
NÚMERO DE NEURÔNIOS			MOMENTO	TAXA APRENDIZADO	ERRO MÉDIO D_{MAX} [mm]
CAMADA 1	CAMADA 2	CAMADA 3			
5	40	20	0,6	0,05	0,0069
5	5	5	0,3	0,9	0,0069
20	15	40	0,6	0,05	0,0069
10	10	10	0,8	0,3	0,0069
10	10	10	0,7	0,3	0,0070

Tabela 7 - Cinco melhores resultados obtidos para a estimação do diâmetro na liga 2024-T3.

MELHORES RESULTADOS PARA O DIÂMETRO MÍNIMO					
NÚMERO DE NEURÔNIOS			MOMENTO	TAXA DE APRENDIZADO	ERRO MÉDIO D_{MIN} [mm]
CAMADA 1	CAMADA 2	CAMADA 3			
5	20	40	0,5	0,50	0,0076
20	10	5	0,8	0,30	0,0076
15	10	20	0,3	0,15	0,0077
40	20	10	0,4	0,15	0,0078
10	10	15	0,9	0,30	0,0078
MELHORES RESULTADOS PARA O DIÂMETRO MÁXIMO					
NÚMERO DE NEURÔNIOS			MOMENTO	TAXA DE APRENDIZADO	ERRO MÉDIO D_{MAX} [mm]
CAMADA 1	CAMADA 2	CAMADA 3			
20	10	5	0,8	0,30	0,0084
20	5	10	0,3	0,30	0,0086
40	5	5	0,9	0,05	0,0087
10	20	20	0,3	0,50	0,0087
10	10	15	0,9	0,30	0,0087

Os resultados das tabelas 6 e 7 acima foram utilizados para treinar uma rede MLP para cada liga e os resultados obtidos foram analisados em relação a três critérios:

- ✓ **Erro médio:** Cálculo da média dos erros médios absolutos e relativos obtidos na estimativa de cada par de diâmetros.
- ✓ **Controle de Qualidade:** Análise de falsos positivos ou falsos negativos, levando às aceitações ou rejeições indevidas dos resultados da furação.
- ✓ **Tolerâncias:** Classificação dos erros de acordo com os desvios dimensionais permitidos, segundo a norma NBR 6158:1995 (ver tabela 2), necessários para um processo de furação de precisão (até $\pm 48\mu\text{m}$), segundo a precisão do instrumento de medição utilizado ($\pm 5\mu\text{m}$) e segundo a tolerância geralmente utilizada na indústria ($\pm 12\mu\text{m}$).

A Figura 29 exibe a configuração da rede MLP com três camadas escondidas e tendo os seis sinais disponíveis como entrada, além dos parâmetros de corte e do diâmetro da broca, com o conjunto de parâmetros vencedores destacados nas tabelas 6 e 7.




Figura 29 - Representação da arquitetura da rede MLP utilizada para as duas ligas dos corpos-de-prova, utilizando os seis sinais disponíveis.

6.1.1 REDE MLP PARA A LIGA Ti6Al4V

Cada arquitetura da Figura 29 foi avaliada contra os três critérios estabelecidos acima. A figura 30 apresenta a resposta da rede para a liga de titânio a cada amostra, para o diâmetro máximo e mínimo, possibilitando visualizar o desempenho para as duas saídas e, o comportamento do erro a cada estimativa.

Os resultados (tabela 8) indicam um erro médio ligeiramente superior nas estimativas, cuja justificativa está na divisão dos dados distinta da que foi realizada no algoritmo para a análise dos parâmetros e arquitetura da rede. O erro médio na estimativa do diâmetro máximo foi de 0,0079mm e no diâmetro mínimo o valor encontrado foi 0,0081mm. O erro relativo percentual foi baixo, correspondendo a apenas 0,2% em média para ambos os diâmetros.

Tabela 8 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de titânio.

D_{MIN}		D_{MAX}	
Erro relativo	0,2%	Erro relativo	0,2%
Erro médio [mm]	0,0081	Erro médio [mm]	0,0079




Figura 30 - Resultados da estimativa da rede MLP para a liga Ti6Al4V.

A análise pelo critério de controle de qualidade indicou a capacidade da rede MLP em realizar a análise dimensional adequadamente baseada nos diâmetros medidos, indicando a aceitação ou rejeição de um furo usinado (tabela 9). Os resultados indicam que a rede estimou de forma incorreta apenas 7,1% dos furos, com falso negativo em média 5,8% e 1,3% para falso positivo, em média.

Tabela 9 - Comportamento da rede MLP na avaliação de controle de qualidade para a liga de titânio.

D_{MIN}		D_{MAX}	
Falso positivo	1,1%	Falso positivo	1,5%
Falso negativo	6,0%	Falso negativo	5,6%
Resultados falsos	7,1%	Resultados falsos	7,1%

O terceiro critério, que relaciona os dados obtidos na estimativa dos diâmetros às classes de tolerâncias exibe os erros organizados em quatro classes:

1. $\text{Erro} < 5\mu\text{m}$ → Corresponde aos erros menores que a precisão do relógio comparador utilizado nas medições e, portanto, indetectáveis.
2. $5\mu\text{m} < \text{Erro} \leq 12\mu\text{m}$ → Contém os erros detectáveis pelo relógio comparador, mas dentro da tolerância h7, de maior utilização industrial.
3. $12\mu\text{m} < \text{Erro} \leq 48\mu\text{m}$ → Erros que extrapolaram o limite h7, mas ainda são considerados dentro da classe da mecânica precisa.

4. Erro > 48µm → Nesta faixa os erros dimensionais estão na classe da mecânica grosseira, com resultados inadequados para o processo de furação no qual se baseou este trabalho.

Os resultados para o terceiro critério foram avaliados para as estimativas corretas, segundo o critério número dois, ou seja, desprezando-se os resultados que apresentaram falsos positivos ou negativos. Tal procedimento foi adotado visando avaliar somente o desempenho satisfatório da rede em termos do desvio dimensional válido, podendo se tratar de um furo conforme ou não-conforme.

O resultado, exibido na Figura 31, indica que 49% dos erros cometidos pela rede MLP na estimativa do diâmetro mínimo são indetectáveis sendo que, para o diâmetro máximo o percentual obtido foi de 56%. O desempenho deste sistema de inteligência artificial se mostrou eficaz na indicação satisfatória dos resultados dimensionais, o que pode ser observado na ausência de erros superiores a 48µm no diâmetro mínimo e na presença de apenas 0,4% de erro acima do limite da mecânica grosseira, o que corresponde ao resultado de apenas uma medição para um conjunto de 249 medições do diâmetro do furo. Cabe ressaltar que apesar desse único caso de saída do limite de precisão, a rede foi capaz de detectar adequadamente a não-conformidade detectada na medição com o relógio comparador.




Figura 31 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de titânio, com todos os sinais na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e às classes de tolerância da norma ABNT NBR 6158:1995.

6.1.2 REDE MLP PARA A LIGA 2024-T3

Os resultados (tabela 10) indicam um erro médio ligeiramente superior nas estimativas, cuja justificativa está na divisão dos dados distinta da que foi realizada no algoritmo para a análise dos parâmetros e arquitetura da rede. O erro médio na estimativa do diâmetro máximo foi de 0,0082mm e no diâmetro mínimo o valor encontrado foi 0,0093mm. O erro relativo percentual foi baixo, correspondendo a apenas 0,2% em média para ambos os diâmetros, como na rede para a liga de titânio.

Tabela 10 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de titânio.

D_{MIN}		D_{MAX}	
Erro relativo	0,2%	Erro relativo	0,2%
Erro médio [mm]	0,0082	Erro médio [mm]	0,0093

Os erros médios apontados na Tabela 10 foram calculados a partir das estimativas ponto a ponto desta configuração da MLP, cujo perfil pode ser visualizado na Figura 32. Pode-se observar que a linha mais escura, que indica as estimativas da MLP, acompanhou a linha mais clara, que mostra o resultado das medições feitas com o auxílio do relógio comparador no trabalho de Cruz (2010). A diferença entre os pontos das duas linhas revela o erro em determinada estimativa que está exibido nos dois gráficos de barra.




Figura 32 - Resultados da estimativa da rede MLP para a liga Ti6Al4V.

A análise pelo critério de controle de qualidade indicou a capacidade da rede MLP em realizar a análise dimensional adequadamente baseada nos diâmetros medidos, indicando a aceitação ou rejeição de um furo usinado (tabela 11). Os resultados indicam que a rede estimou, em média, de forma incorreta 12,9% dos furos, com falso positivo 9,0% e 3,9% para falso negativo.

Tabela 11 - Comportamento da rede MLP na avaliação de controle de qualidade para a liga de alumínio.

D_{MIN}		D_{MAX}	
Falso positivo	7,5%	Falso positivo	10,5%
Falso negativo	3,7%	Falso negativo	4,1%
Resultados falsos	11,2%	Resultados falsos	14,6%

O resultado, exibido na Figura 33, indica que 46% dos erros cometidos pela rede MLP na estimativa do diâmetro mínimo são indetectáveis sendo que, para o diâmetro máximo o percentual obtido foi de 39%. O desempenho deste sistema de inteligência artificial se mostrou excelente na indicação satisfatório dos resultados dimensionais, o que pode ser observado na ausência de erros superiores a 48µm no diâmetro mínimo e na presença de apenas 0,4% de erro acima do limite da mecânica grosseira, o que, novamente, corresponde ao resultado de apenas uma medição para um conjunto de 238 medições do diâmetro do furo. Assim como na rede para a liga de titânio, a rede MLP para a liga de alumínio apresentou uma única medição com desvio superior a 48µm.




Figura 33 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de alumínio, com todos os sinais na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e às classes de tolerância da norma ABNT NBR 6158:1995.

6.2 DESEMPENHO DAS REDES MLP CONSIDERANDO A INFLUÊNCIA DOS SINAIS DE ENTRADA

As configurações “vencedoras” de cada material (ver tabelas 6 e 7) foram submetidas a um teste de influência dos sinais e combinações de sinais, conforme relatado em 5.2.1.

O resultado para a liga Ti6Al4V indicou que o uso dos sinais de emissão acústica e de aceleração como entradas da rede MLP atingiu o menor erro médio na estimativa dos diâmetros. Contudo, estes sinais levaram a um desempenho inferior quando aplicados isoladamente. Considerado isoladamente como entrada da rede, o sinal com informações sobre a força no eixo Z levou ao menor erro médio. Os resultados do teste são exibidos na Figura 34.




Figura 34 - Resultado do teste de influência dos sinais isolados e combinados em pares para a liga Ti6Al4V.

Na rede MLP utilizada na estimação dos diâmetros na liga 2024-T3, o uso dos sinais de potência elétrica e da força no eixo Z resultaram no menor erro dentre o conjunto de entradas com dois sinais combinados. Repetindo o resultado da rede para a liga de titânio, a força no eixo Z resultou no menor erro, em comparação com os outros sinais aplicados isoladamente como entrada. Estes resultados podem ser conferidos na Figura 35.




Figura 35 - Resultado do teste de influência dos sinais isolados e combinados em pares para a liga 2024-T3.

Os resultados de ambos os testes realizados para a influência dos sinais nos dois materiais mostram que dois sinais se destacam na função de caracterizar o processo de furação quando aplicados em conjunto com outro sinal: a força no eixo Z e a emissão acústica. Entretanto, na comparação dos sinais isolados apenas o sinal da força no eixo Z se destaca para as duas redes. Por esse motivo, os testes seguintes foram realizados para a melhor configuração para um sinal isolado e para as configurações com as melhores combinações de sinais.

6.2.1 REDES MLP COM O SINAL DA FORÇA Z APLICADO NA ENTRADA

Os testes realizados são os mesmos daqueles aplicados às redes MLP com todos os sinais na entrada, ou seja, seguindo os três critérios estabelecidos em 6.1. A Figura 36 contém a arquitetura definitiva para este caso.




Figura 36 - Redes MLP com apenas o sinal da força no eixo Z aplicada na entrada, para cada material.

6.2.1.1 RESULTADOS PARA A REDE MLP DA LIGA Ti6Al4V

Os resultados (tabela 12) indicam um erro médio menor que aquele conseguido na combinação de todos os seis sinais disponíveis. O erro médio na estimativa do diâmetro máximo foi de 0,0076mm e no diâmetro mínimo o valor encontrado foi 0,0078mm. O erro relativo percentual foi baixo, correspondendo a apenas 0,2% em média para ambos os diâmetros, como na rede para a liga de titânio.




Figura 37 - Resultados da estimativa da rede MLP para a liga Ti6Al4V, com a força Z na entrada.

Tabela 12 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de titânio, com a força Z na entrada.

D_{MIN}		D_{MAX}	
Erro relativo	0,2%	Erro relativo	0,2%
Erro médio [mm]	0,0076	Erro médio [mm]	0,0078

Os erros médios apontados na Tabela 12 foram calculados a partir das estimativas ponto a ponto desta configuração da MLP, cujo perfil pode ser visualizado na Figura 37. Pode-se observar que a linha mais escura, que indica as estimativas da MLP, acompanhou a linha mais clara com maior precisão.

A análise pelo critério de controle de qualidade apresentou os resultados apresentados na tabela 13. Os resultados indicam que a rede estimou, em média, de forma incorreta 4,1% dos furos, com falso positivo 0,7% e 3,4% para falso negativo. Os números apresentados se mostraram muito superiores aos obtidos na configuração com todos os sinais na entrada da rede.

Tabela 13 - Comportamento da rede MLP, com a força Z na entrada, na avaliação de controle de qualidade para a liga de titânio.

D_{MIN}		D_{MAX}	
Falso positivo	0,7%	Falso positivo	0,7%
Falso negativo	3,0%	Falso negativo	3,7%
Resultados falsos	3,7%	Resultados falsos	4,5%

O resultado, exibido na Figura 38, indica que 48% dos erros cometidos pela rede MLP na estimativa do diâmetro mínimo são indetectáveis sendo que, para o diâmetro máximo o percentual obtido foi de 54%. O desempenho deste sistema de inteligência artificial se mostrou excelente na indicação satisfatório dos resultados dimensionais, o que pode ser observado na ausência de erros superiores a 48µm tanto no diâmetro máximo como no diâmetro mínimo, acima do limite da mecânica grosseira, o que, novamente, corresponde ao resultado de apenas uma medição para um conjunto de 255 medições do diâmetro do furo.




Figura 38 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de alumínio, com a força em Z na entrada, segundo a precisão do instrumento de medição utilizado ($5\mu\text{m}$) e as classes de tolerância da norma ABNT NBR 6158:1995.

6.2.1.2 RESULTADOS PARA A REDE MLP DA LIGA 2024-T3

Os resultados (Tabela 14) indicam um erro médio menor que aquele conseguido na combinação de todos os seis sinais disponíveis. O erro médio na estimativa do diâmetro máximo foi de $0,0095\text{mm}$ e no diâmetro mínimo o valor encontrado foi $0,0085\text{mm}$ (ver Figura 39). O erro relativo percentual foi baixo, correspondendo a apenas $0,2\%$ em média para ambos os diâmetros, como na rede para a liga de titânio.




Figura 39 - Resultados da estimativa da rede MLP para a liga 2024-T3, com a força Z na entrada.

Tabela 14 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de alumínio, com a força Z na entrada.

D_{MIN}		D_{MAX}	
Erro relativo	0,2%	Erro relativo	0,2%
Erro médio [mm]	0,0085	Erro médio [mm]	0,0095

A análise pelo critério de controle de qualidade apresentou os resultados apresentados na Tabela 15. Os resultados indicam que a rede estimou, em média, de forma incorreta 24,9% dos furos, com falso positivo 6,4% e 18,5% para falso negativo.

Tabela 15 - Comportamento da rede MLP, com a força Z na entrada, na avaliação de controle de qualidade para a liga de alumínio.

D_{MIN}		D_{MAX}	
Falso positivo	3,4%	Falso positivo	9,4%
Falso negativo	21,0%	Falso negativo	16,1%
Resultados falsos	24,3%	Resultados falsos	25,5%

O resultado, exibido na Figura 40, indica que 43% dos erros cometidos pela rede MLP na estimativa do diâmetro mínimo são indetectáveis sendo que, para o diâmetro máximo o percentual obtido foi de 44%. O desempenho deste sistema de inteligência artificial se mostrou excelente na indicação satisfatório dos resultados dimensionais, o que pode ser observado na ausência de erros superiores a 48µm tanto no diâmetro máximo como no diâmetro mínimo, acima do limite da mecânica grosseira.




Figura 40 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de alumínio, com a força em Z na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e as classes de tolerância da norma ABNT NBR 6158:1995.

6.2.2 REDE MLP COM DOIS SINAIS APLICADOS NA ENTRADA

Os resultados dos testes com diferentes sinais aplicados na entrada das redes MLP mostram que o sinal de emissão acústica em conjunto com o sinal de aceleração apresentou o menor erro para estimativas na liga de titânio, enquanto que, os sinais de potência elétrica e da força no eixo Z levaram ao melhor desempenho para a liga de alumínio, conforme pode ser observado na Figura 34 e Figura 35. As arquiteturas utilizadas para uma análise mais detalhada são representadas na Figura 41.




Figura 41 - Arquiteturas utilizadas para testes das redes MLP com dois sinais aplicados na entrada.

6.2.2.1 RESULTADOS PARA A REDE MLP DA LIGA Ti6Al4V

Os resultados (Tabela 18) indicam um erro médio muito próximo daquele conseguido na combinação de todos os seis sinais disponíveis. O erro médio na estimativa do diâmetro máximo foi de 0,0085mm e no diâmetro mínimo o valor encontrado foi 0,0095mm. O erro relativo percentual foi baixo, correspondendo a apenas 0,2% em média para ambos os diâmetros, como na rede para a liga de titânio.




Figura 42 - Resultados da estimativa da rede MLP para a liga Ti6Al4V, com os sinais de emissão acústica e aceleração na entrada.

Tabela 16 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de titânio, com os sinais de emissão acústica e aceleração na entrada.

D_{MIN}		D_{MAX}	
Erro relativo	0,2%	Erro relativo	0,2%
Erro médio [mm]	0,0085	Erro médio [mm]	0,0095

Os erros médios apontados na Tabela 16 foram calculados a partir das estimativas ponto a ponto desta configuração da MLP, cujo perfil pode ser visualizado na Figura 42. Pode-se observar que a linha mais escura, que indica as estimativas da MLP, acompanhou a linha mais clara com certa precisão.

A análise pelo critério de controle de qualidade apresentou os resultados apresentados na Tabela 17. Os resultados indicam que a rede estimou, em média, de forma incorreta 7,9% dos furos, com falso positivo 5,1% e 2,8% para falso negativo. Os números apresentados se mostraram ligeiramente inferiores aos obtidos na configuração com todos os sinais na entrada da rede.

Tabela 17 - Comportamento da rede MLP na avaliação de controle de qualidade para a liga de titânio.

D_{MIN}		D_{MAX}	
Falso positivo	6,0%	Falso positivo	4,1%
Falso negativo	1,9%	Falso negativo	3,7%
Resultados falsos	7,9%	Resultados falsos	7,9%

O resultado, exibido na Figura 43, indica que 45% dos erros cometidos pela rede MLP na estimativa do diâmetro mínimo são indetectáveis sendo que, para o diâmetro máximo o percentual obtido foi de 44%. O desempenho deste sistema de inteligência artificial se mostrou excelente na indicação satisfatório dos resultados dimensionais, o que pode ser observado na ausência de erros superiores a 48µm tanto no diâmetro máximo e apenas uma medição no diâmetro mínimo acima do limite da mecânica grosseira em um conjunto de 246 medições do diâmetro do furo.




Figura 43 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de titânio, com a emissão acústica e a aceleração na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e as classes de tolerância da norma ABNT NBR 6158:1995.

6.2.2.2 RESULTADOS PARA A REDE MLP DA LIGA 2024-T3

Os resultados (Tabela 18) indicam um erro médio muito próximo daquele conseguido na combinação de todos os seis sinais disponíveis. O erro médio na estimativa do diâmetro máximo foi de 0,0089mm e no diâmetro mínimo o valor encontrado foi 0,0081mm. O erro relativo percentual foi baixo, correspondendo a apenas 0,17% em média para ambos os diâmetros, como na rede para a liga de titânio.

Os erros médios apontados na Tabela 18 foram calculados a partir das estimativas ponto a ponto desta configuração da MLP, cujo perfil pode ser visualizado na Figura 44. Pode-se observar que a linha mais escura, que indica as estimativas da MLP, acompanhou a linha mais clara, com boa precisão apesar das variações mais acentuadas nas características dos sinais presentes.




Figura 44 - Resultados da estimativa da rede MLP para a liga 2024-T3, com os sinais de potência elétrica e força no eixo Z na entrada.

Tabela 18 - Erro relativo percentual médio e erro absoluto médio na estimativa dos diâmetros na liga de alumínio, com os sinais de potência elétrica e força no eixo Z na entrada.

D_{MIN}		D_{MAX}	
Erro relativo	0,2%	Erro relativo	0,2%
Erro médio [mm]	0,0081	Erro médio [mm]	0,0089

A análise pelo critério de controle de qualidade apresentou os resultados da Tabela 19. Os resultados indicam que a rede estimou, em média, de forma incorreta 13,3% dos furos, com falso positivo 5,8% e 7,5% para falso negativo. Os números apresentados acompanham a tendência a uma classificação inferior para a liga e alumínio.

Tabela 19 - Comportamento da rede MLP na avaliação de controle de qualidade para a liga de alumínio.

D_{MIN}		D_{MAX}	
Falso positivo	4,1%	Falso positivo	7,5%
Falso negativo	7,5%	Falso negativo	7,5%
Resultados falsos	11,6%	Resultados falsos	13,3%

O resultado, exibido na Figura 45, indica que 47% dos erros cometidos pela rede MLP na estimativa do diâmetro mínimo são indetectáveis sendo que, para o diâmetro máximo o percentual obtido foi de 44%. O desempenho deste sistema de inteligência artificial se mostrou excelente na indicação satisfatório dos resultados dimensionais, o que pode ser observado na ausência de erros superiores a $48\mu\text{m}$ tanto no diâmetro máximo e apenas uma medição no diâmetro mínimo acima do limite da mecânica grosseira em um conjunto de 237 medições do diâmetro do furo.




Figura 45 - Classificação dos erros na estimativa dos diâmetros pela rede MLP para a liga de alumínio, com a potência elétrica e a força no eixo Z, segundo a precisão do instrumento de medição utilizado ($5\mu\text{m}$) e as classes de tolerância da norma ABNT NBR 6158:1995.

6.3 DESEMPENHO DO SISTEMA ANFIS

Os resultados do sistema ANFIS foram obtidos após a execução dos algoritmos descritos na seção 5.2.2. Antes do início dos testes, foram verificadas as influências dos sinais no desempenho do sistema. Tal avaliação foi realizada através de um comando disponível no MATLAB® que realiza o teste sequencial da mesma maneira em que foi programado nos algoritmos desenvolvidos para as redes MLP e RBF.

Os resultados obtidos para o teste do sistema ANFIS para a liga de titânio mostram que a força no eixo Z é o sinal que mais influencia positivamente, no sentido de menor erro, o desempenho. Na combinação de dois sinais na entrada, o melhor resultado ficou com a união dos dados das forças nos eixos X e Z. A classificação final pode ser visualizada na Figura 476.




Figura 46 - Resultado do teste de influência dos sinais isolados e combinados em pares para o sistema ANFIS desenvolvido para a liga Ti6Al4V.

Os resultados obtidos para o teste do sistema ANFIS para a liga de alumínio mostram que a força no eixo Z é o sinal que mais influencia positivamente, da mesma maneira que no resultado para o titânio. Na combinação de dois sinais na entrada, o melhor resultado ficou com a união dos dados de emissão acústica com os dados da força no eixo Z. A classificação final pode ser visualizada na Figura 47.




Figura 47 - Resultado do teste de influência dos sinais isolados e combinados em pares para o sistema ANFIS desenvolvido para a liga 2024-T3.

O teste para avaliação do número de épocas necessário para o treinamento foi avaliado, conforme algoritmo da Figura 27. O resultado indica um número de 105 épocas para treinamento do sistema dedicado à liga de titânio e 270 épocas necessárias ao treinamento do sistema da liga de alumínio.

O resultado do teste é exibido na Figura 48, onde se pode notar a diferença no comportamento do erro para os dois materiais do corpo-de-prova. Enquanto o erro diminuiu para a liga de alumínio, o mesmo ficou praticamente estável, independente do número de épocas utilizado no treinamento. Tal divergência, possivelmente, está associada às diferenças microestruturais da liga de titânio, que resultaram em pouca variação nos sinais coletados devido à baixa complexidade, tornando mais simples o mapeamento. Os valores obtidos no teste foram utilizados nos próximos testes.




Figura 48 - Resultado do teste de influência do número de épocas nos sistemas ANFIS para cada liga do corpo-de-prova.

Da mesma maneira como foram utilizados para analisar o desempenho da rede MLP, os três critérios definidos em 6.1 foram utilizados para organizar os resultados do sistema ANFIS.

Os raios de influência e a distância entre os centros dos agrupamentos foram obtidos por tentativa e erro para cada sistema ANFIS criado, conforme os tópicos seguintes.

6.3.1 SISTEMAS ANFIS COM O SINAL DA FORÇA Z APLICADO NA ENTRADA

6.3.1.1 RESULTADOS PARA O SISTEMA ANFIS DA LIGA Ti6Al4V

Os parâmetros referentes aos agrupamentos foram definidos por tentativa e erro até que se obtivesse o menor valor de erro possível e estão relacionados na tabela 20.

Tabela 20 - Parâmetros de influência dos centros de agrupamento definidos para o sistema ANFIS de estimativa para a liga de titânio.

Parâmetro	Valor
Raio de influência do centro do agrupamento	Agrupamento de entrada = 0,12 Agrupamento de saída = 0,12
Distância entre os centros dos agrupamentos	1,25

Com o sistema configurado o resultado das estimativas foram obtidos e estão representados na Figura 49.




Figura 49 - Resultados da estimativa do sistema ANFIS para a liga Ti6Al4V, com o sinal da força no eixo Z na entrada.

O erro médio absoluto na estimativa dos diâmetros foi de 0,0090mm, com erro médio percentual de 0,3%, conforme Tabela 21.

Tabela 21 - Erro relativo percentual médio e erro absoluto médio do sistema ANFIS na estimativa dos diâmetros na liga de titânio, com a força Z na entrada.

D_{MIN}		D_{MAX}	
Erro relativo	0,3%	Erro relativo	0,3%
Erro médio [mm]	0,0087	Erro médio [mm]	0,0093

No critério do controle de qualidade o sistema ANFIS mostrou boa eficácia ao apresentar apenas 4,9%, em média, de resultados falsos na avaliação dimensional dos furos. Dessa média, 1,3% correspondem a falsos positivos e 3,6% a falsos negativos. A Tabela 22 contém os resultados para o diâmetro mínimo e para o diâmetro máximo.

Tabela 22 - Comportamento da rede MLP na avaliação de controle de qualidade para a liga de titânio.

D_{MIN}		D_{MAX}	
Falso positivo	1,9%	Falso positivo	0,7%
Falso negativo	2,2%	Falso negativo	4,9%
Resultados falsos	4,1%	Resultados falsos	5,6%

Para o terceiro critério, a classificação dos erros aponta que 42% das estimativas, em média, ficaram com erro abaixo da precisão do instrumento de medição. No diâmetro mínimo nenhuma estimativa ficou acima do limite da mecânica precisa, enquanto que, para o diâmetro máximo apenas uma estimativa extrapolou este limite, conforme Figura 50.




Figura 50 - Classificação dos erros na estimativa dos diâmetros pelo sistema ANFIS para a liga de titânio, com a força em Z na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e as classes de tolerância da norma ABNT NBR 6158:1995.

6.3.1.2 RESULTADOS PARA O SISTEMA ANFIS DA LIGA 2024-T3

Os parâmetros referentes aos agrupamentos para o sistema ANFIS utilizado na estimativa dos diâmetros da liga de alumínio estão relacionados na Tabela 23.

Tabela 23 - Parâmetros de influência dos centros de agrupamento definidos para o sistema ANFIS de estimativa para a liga de alumínio.

Parâmetro	Valor
Raio de influência do centro do agrupamento	Agrupamento de entrada = 0,36 Agrupamento de saída = 0,21
Distância entre os centros dos agrupamentos	1,25

Com o sistema configurado o resultado das estimativas foram obtidos e estão representados na Figura 51.




Figura 51 - Resultados da estimativa do sistema ANFIS para a liga 2024-T3, com o sinal da força no eixo Z na entrada.

O erro médio absoluto na estimativa dos diâmetros foi de 0,0102mm, com erro médio percentual de 0,4%, conforme Tabela 24.

Tabela 24 - Erro relativo percentual médio e erro absoluto médio do sistema ANFIS na estimativa dos diâmetros na liga de alumínio, com a força Z na entrada.

D_{MIN}		D_{MAX}	
Erro relativo	0,4%	Erro relativo	0,4%
Erro médio [mm]	0,0103	Erro médio [mm]	0,0100

No critério do controle de qualidade o sistema ANFIS mostrou eficácia razoável ao apresentar apenas 18,7%, em média, de resultados falsos na avaliação dimensional dos furos. Dessa média, 5,8% correspondem a falsos positivos e 12,9% a falsos negativos. A Tabela 25 contém os resultados para o diâmetro mínimo e para o diâmetro máximo.

Tabela 25 - Comportamento do sistema ANFIS na avaliação de controle de qualidade para a liga de alumínio.

D_{MIN}		D_{MAX}	
Falso positivo	3,0%	Falso positivo	8,6%
Falso negativo	12,4%	Falso negativo	13,5%
Resultados falsos	15,4%	Resultados falsos	22,1%

Para o terceiro critério, a classificação dos erros aponta que 44% das estimativas, em média, ficaram com erro abaixo da precisão do instrumento de medição. Nenhuma estimativa ficou acima do limite da mecânica precisa, conforme Figura 52.




Figura 52 - Classificação dos erros na estimativa dos diâmetros pelo sistema ANFIS para a liga de alumínio, com a força em Z na entrada, segundo a precisão do instrumento de medição utilizado ($5\mu\text{m}$) e as classes de tolerância da norma ABNT NBR 6158:1995.

6.3.2 SISTEMAS ANFIS COM DOIS SINAIS APLICADOS NA ENTRADA

Seguindo os resultados dos testes de influência realizados e cujos resultados foram exibidos no item 6.3, os sistemas foram configurados segundo a liga onde o furo foi executado.

6.3.2.1 RESULTADOS PARA O SISTEMA ANFIS DA LIGA TI6AL4V

Para a liga de titânio ficou evidenciado na Figura 46 que os sinais das forças nos eixos X e Z influenciaram de maneira positiva os resultados deste sistema, de modo que o menor erro foi obtido dentre todas as possibilidades de combinação entre os sinais disponíveis.

Os parâmetros relativos ao agrupamento dos sinais de entrada e saída foram obtidos por tentativa e erro e o conjunto que levou ao menor erro é apresentado na Tabela 26.

Tabela 26 - Parâmetros de influência dos centros de agrupamento definidos para o sistema ANFIS de estimativa para a liga de titânio, com duas entradas.

Parâmetro	Valor
Raio de influência do centro do agrupamento	Agrupamento da força X = 0,15 Agrupamento da força Z = 0,20 Agrupamento de saída = 0,1658
Distância entre os centros dos agrupamentos	1,25

Com o sistema configurado o resultado das estimativas foram obtidos e estão representados na Figura 53.




Figura 53 - Resultados da estimativa do sistema ANFIS para a liga Ti6Al4V, com os sinais das forças nos eixos X e Z combinados na entrada.

O erro médio absoluto na estimativa dos diâmetros foi de 0,0102mm, com erro médio percentual de 0,35%, conforme Tabela 27.

Tabela 27 - Erro relativo percentual médio e erro absoluto médio do sistema ANFIS na estimativa dos diâmetros na liga de titânio, com as forças X e Z na entrada.

D_{MIN}		D_{MAX}	
Erro relativo	0,3%	Erro relativo	0,4%
Erro médio [mm]	0,0099	Erro médio [mm]	0,0105

No critério do controle de qualidade o sistema ANFIS mostrou boa eficácia ao apresentar apenas 6,7%, em média, de resultados falsos na avaliação dimensional dos furos. Dessa média, 4,9% correspondem a falsos positivos e 1,9% a falsos negativos. A Tabela 28 contém os resultados para o diâmetro mínimo e para o diâmetro máximo.

Tabela 28 - Comportamento do sistema ANFIS na avaliação de controle de qualidade para a liga de titânio.

D_{MIN}		D_{MAX}	
Falso positivo	4,5%	Falso positivo	5,2%
Falso negativo	0,7%	Falso negativo	3,0%
Resultados falsos	5,2%	Resultados falsos	8,2%

Para o terceiro critério, a classificação dos erros aponta que 35% das estimativas, em média, ficaram com erro abaixo da precisão do instrumento de medição. Na estimativa do diâmetro mínimo apenas uma medição apresentou erro que ficou acima do limite da mecânica precisa, conforme Figura 54, entretanto, para o diâmetro máximo nenhum erro superou este limite.




Figura 54 - Classificação dos erros na estimativa dos diâmetros pelo sistema ANFIS para a liga de titânio, com as forças em X e Z na entrada, segundo a precisão do instrumento de medição utilizado ($5\mu\text{m}$) e as classes de tolerância da norma ABNT NBR 6158:1995.

6.3.2.2 RESULTADOS PARA O SISTEMA ANFIS DA LIGA 2024-T3

Para a liga de alumínio ficou evidenciado na Figura 47 que os sinais de emissão acústica e da força no eixo Z influenciaram de maneira positiva os resultados deste sistema, obtendo o menor erro para a liga de alumínio.

Os parâmetros relativos ao agrupamento dos sinais de entrada e saída foram obtidos por tentativa e erro e o conjunto que levou ao menor erro é apresentado na Tabela 29.

Tabela 29 - Parâmetros de influência dos centros de agrupamento definidos para o sistema ANFIS de estimativa para a liga de alumínio, com duas entradas.

Parâmetro	Valor
Raio de influência do centro do agrupamento	Agrupamento da EA = 0,36 Agrupamento da força Z = 0,20 Agrupamento de saída = 0,21
Distância entre os centros dos agrupamentos	1,25

Com o sistema configurado o resultado das estimativas foram obtidos e estão representados na Figura 55.




Figura 55 - Resultados da estimativa do sistema ANFIS para a liga 2024-T3, com os sinais da emissão acústica e da força no eixo Z combinados na entrada.

O erro médio absoluto na estimativa dos diâmetros foi de 0,0104mm, com erro médio percentual de 0,4%, conforme Tabela 30.

Tabela 30 - Erro relativo percentual médio e erro absoluto médio do sistema ANFIS na estimativa dos diâmetros na liga de alumínio, com a emissão acústica e a força Z na entrada.

D_{MIN}		D_{MAX}	
Erro relativo	0,4%	Erro relativo	0,4%
Erro médio [mm]	0,0099	Erro médio [mm]	0,0109

No critério do controle de qualidade o sistema ANFIS mostrou baixa eficácia ao apresentar apenas 22,1%, em média, de resultados falsos na avaliação dimensional dos furos. Dessa média, 4,5% correspondem a falsos positivos e 17,2% a falsos negativos. A Tabela 31 contém os resultados para o diâmetro mínimo e para o diâmetro máximo.

Tabela 31 - Comportamento do sistema ANFIS na avaliação de controle de qualidade para a liga de alumínio.

D_{MIN}		D_{MAX}	
Falso positivo	5,6%	Falso positivo	3,4%
Falso negativo	10,5%	Falso negativo	24,0%
Resultados falsos	16,1%	Resultados falsos	28,1%

Para o terceiro critério, apesar da baixa eficácia no controle de qualidade, a classificação dos erros aponta que 41% das estimativas, em média, ficaram com erro abaixo da precisão do instrumento de medição. Na estimativa do diâmetro mínimo apenas uma medição apresentou erro que ficou acima do limite da mecânica precisa, conforme Figura 56, e para o diâmetro máximo duas medições superaram este limite, representando 1% das estimativas.




Figura 56 - Classificação dos erros na estimativa dos diâmetros pelo sistema ANFIS para a liga de alumínio, com a emissão acústica e a força em Z na entrada, segundo a precisão do instrumento de medição utilizado ($5\mu\text{m}$) e as classes de tolerância da norma ABNT NBR 6158:1995.

6.4 DESEMPENHO DA REDE RBF

6.4.1 REDE RBF COM TODOS OS SINAIS NA ENTRADA

Conforme apresentado em 5.2.3 um algoritmo foi elaborado para testar simultaneamente os sinais e combinações em pares destes sinais em conjunto com o parâmetro suporte ou *spread*.

Porém, o teste do suporte também foi realizado para todas as entradas em conjunto, para cada material do corpo-de-prova. O intervalo de variação do parâmetro para a liga de titânio foi o mesmo utilizado no algoritmo, porém, para a liga de alumínio, este intervalo não apresentou bons resultados. Assim, o intervalo de variação utilizado para o segundo material foi de 10 até 10000. Os resultados são exibidos nas figuras Figura 57 e Figura 58.

O menor erro encontrado para a liga de titânio foi de 0,0085mm para um *spread* de 80 e, para a liga de alumínio de 0,0173mm para um *spread* de 10000. Foi

verificado que o valor do erro na liga de alumínio aumenta após este valor do spread.




Figura 57 - Avaliação do erro absoluto com a variação do spread na rede RBF para a liga de titânio.




Figura 58 - Avaliação do erro absoluto com a variação do spread na rede RBF para a liga de alumínio.

Com o resultado dos testes do spread foram configuradas duas redes RBF sendo uma para estimar os diâmetros na liga de titânio e outra para a liga de alumínio.

A configuração da rede RBF para a liga de titânio foi feita com o valor do spread de 80 e apresentou os resultados da Figura 59. O erro absoluto para os dois diâmetros foi de 0,0092mm em média e um erro percentual de 0,3%, conforme Tabela 32.




Figura 59 - Resultados da estimativa da rede RBF para a liga Ti6Al4V, com todos os sinais aplicados na entrada.

Tabela 32 - Erro relativo percentual médio e erro absoluto médio da rede RBF na estimativa dos diâmetros na liga de titânio, com todos os sinais na entrada.

D_{MIN}		D_{MAX}	
Erro relativo	0,3%	Erro relativo	0,3%
Erro médio [mm]	0,0091	Erro médio [mm]	0,0093

A análise pelo critério de controle de qualidade mostra que a rede RBF apresentou, em média, resultados falsos em 7,7% das estimativas, sendo 1,3% falsos positivos e, 6,4% falsos negativos (ver Tabela 33).

Tabela 33 - Comportamento da rede RBF na avaliação de controle de qualidade para a liga de titânio.

D_{MIN}		D_{MAX}	
Falso positivo	0,4%	Falso positivo	2,2%
Falso negativo	7,5%	Falso negativo	5,2%
Resultados falsos	7,9%	Resultados falsos	7,5%

Para o terceiro critério, a classificação dos erros aponta que 43,5% das estimativas, em média, ficaram com erro abaixo da precisão do instrumento de medição. Na estimativa do diâmetro mínimo nenhuma medição apresentou erro que ficou acima do limite da mecânica precisa, conforme Figura 60, e para o diâmetro máximo apenas uma medição superou este limite, representando 0,4% das estimativas.




Figura 60 - Classificação dos erros na estimativa dos diâmetros pela rede RBF para a liga de titânio, com todos os sinais na entrada, segundo a precisão do instrumento de medição utilizado ($5\mu\text{m}$) e as classes de tolerância da norma ABNT NBR 6158:1995.

Com um valor de spread de 10000, a rede RBF foi configurada para treinamento e submetida à simulação. De maneira adversa, esta configuração não conseguiu generalizar a partir dos dados de treinamento como pode ser visualizado na Figura 61. Após iniciar acompanhando as variações nos diâmetros medidos, a rede continua a realizar estimativas, porém, com uma variação ínfima, dando o aspecto de adotar um valor constante. Tal comportamento gerou um erro médio

relativamente baixo o que, em uma primeira análise pode levar a um pré-julgamento errôneo sobre o desempenho desta rede, o que pode ser resolvido pela análise da figura citada.




Figura 61 - Resultados da estimativa da rede RBF para a liga 2024-T3, com todos os sinais aplicados na entrada, não exibindo generalização.

O problema detectado invalida as análises posteriores, sendo importante destacar que 50,6% dos resultados de medição foram falsos.

6.4.2 AVALIAÇÃO DA INFLUÊNCIA DOS SINAIS E DO SPREAD

Os resultados dos testes de influência apresentados no fluxograma da Figura 28 exibem a influência positiva do sinal da força no eixo Z sobre o desempenho da rede RBF. Isoladamente aplicada na RBF da liga de titânio, a força Z resultou em um erro médio de 0,0100mm usando um spread de 30. O par de sinais com menor erro na estimativa foi a combinação da força no eixo Y com a aceleração, que resultou em um erro médio de 0,0097mm com spread de 40. A classificação completa pode ser visualizada na Figura 62.

Isoladamente aplicada na RBF da liga de alumínio, a força Z resultou em um erro médio de 0,0115mm usando um spread de 3020. O par de sinais com menor

erro na estimativa foi a combinação da força no eixo Y com a força no eixo Z, que resultou em um erro médio de 0,0101mm com spread de 2370. A classificação completa pode ser visualizada na Figura 63.




Figura 62 - Resultados do teste de influência dos sinais isolados e combinados em pares, mais o spread, no desempenho da rede RBF para a liga de titânio.




Figura 63 - Resultados do teste de influência dos sinais isolados e combinados em pares, mais o spread, no desempenho da rede RBF para a liga de alumínio.

A seguir as redes RBF foram testadas para os sinais que apresentaram o melhor desempenho, ou seja, a força Z e as combinações desta com a força Y, para a rede da liga de titânio e da força Y com a aceleração, para a rede da liga de alumínio.

6.4.3 REDE RBF COM O SINAL DA FORÇA Z NA ENTRADA

6.4.3.1 AVALIAÇÃO DA REDE PARA A LIGA DE TITÂNIO

Os resultados (Tabela 34) indicam um erro médio menor que aquele conseguido na combinação de todos os seis sinais disponíveis. O erro médio na estimativa do diâmetro máximo foi de 0,0105mm e no diâmetro mínimo o valor encontrado foi 0,0098mm. O erro relativo percentual foi baixo, correspondendo a apenas 0,2% em média para ambos os diâmetros, como na rede para a liga de titânio.

Tabela 34 - Erro relativo percentual médio e erro absoluto médio da rede RBF, com a força Z na entrada, na estimativa dos diâmetros na liga de titânio.

D_{MIN}		D_{MAX}	
Erro relativo	0,2%	Erro relativo	0,2%
Erro médio [mm]	0,0105	Erro médio [mm]	0,0098

A análise pelo critério de controle de qualidade apresentou os resultados apresentados na Tabela 35. Os resultados indicam que a rede estimou, em média, de forma incorreta 6,2% dos furos, com falso positivo 3% e 3,2% para falso negativo.

Tabela 35 - Comportamento da rede RBF, com a força Z na entrada, na avaliação de controle de qualidade para a liga de titânio.

D_{MIN}		D_{MAX}	
Falso positivo	1,9%	Falso positivo	4,1%
Falso negativo	4,5%	Falso negativo	1,9%
Resultados falsos	6,4%	Resultados falsos	6,0%

O resultado, exibido na Figura 64, indica que 35% dos erros cometidos pela rede RBF na estimativa do diâmetro mínimo são indetectáveis sendo que, para o

diâmetro máximo o percentual obtido foi de 41%. Apenas uma medição no diâmetro mínimo, ficou acima do limite da mecânica grosseira, e duas medições ultrapassaram este limite para o diâmetro máximo.




Figura 64 - Classificação dos erros na estimativa dos diâmetros pela rede RBF para a liga de titânio, com a força Z na entrada, segundo a precisão do instrumento de medição utilizado (5µm) e as classes de tolerância da norma ABNT NBR 6158:1995.

6.4.3.2 AVALIAÇÃO DA REDE PARA A LIGA DE ALUMÍNIO

Os resultados (Tabela 36) indicam um erro médio menor que aquele conseguido na combinação de todos os seis sinais disponíveis. O erro médio na estimativa do diâmetro máximo foi de 0,0101mm e no diâmetro mínimo o valor encontrado foi 0,0109mm. O erro relativo percentual foi baixo, correspondendo a apenas 0,2% em média para ambos os diâmetros, como na rede para a liga de titânio.

Tabela 36 - Erro relativo percentual médio e erro absoluto médio da rede RBF, com a força Z na entrada, na estimativa dos diâmetros na liga de alumínio.

D_{MIN}		D_{MAX}	
Erro relativo	0,2%	Erro relativo	0,2%
Erro médio [mm]	0,0101	Erro médio [mm]	0,0109

A análise pelo critério de controle de qualidade apresentou os resultados apresentados na Tabela 35. Os resultados indicam que a rede estimou, em média, de forma incorreta 18,9% dos furos, com falso positivo 7,7% e 11,2% para falso negativo.




Figura 65 - Resultados da estimativa da rede RBF para a liga 2024-T3, com todos os sinais aplicados na entrada, não exibindo generalização.

Os erros médios apontados na Tabela 36 foram calculados a partir das estimativas ponto a ponto desta configuração da RBF, cujo perfil pode ser visualizado na Figura 65. Pode-se observar que a linha mais escura, que indica as estimativas da RBF, acompanhou a linha mais clara, porém com uma precisão menor que a rede MLP.

Tabela 37 - Comportamento da rede RBF, com a força Z na entrada, na avaliação de controle de qualidade para a liga de alumínio.

D_{MIN}		D_{MAX}	
Falso positivo	7,9%	Falso positivo	7,5%
Falso negativo	8,2%	Falso negativo	14,2%
Resultados falsos	16,1%	Resultados falsos	21,7%

O resultado, exibido na Figura 64, indica que 51% dos erros cometidos pela rede RBF na estimativa do diâmetro mínimo são indetectáveis sendo que, para o diâmetro máximo o percentual obtido foi de 45%. Apenas uma medição no diâmetro máximo, ficou acima do limite da mecânica grosseira.




Figura 66 - Classificação dos erros na estimativa dos diâmetros pela rede RBF para a liga de alumínio, com a força Z na entrada, segundo a precisão do instrumento de medição utilizado ($5\mu\text{m}$) e as classes de tolerância da norma ABNT NBR 6158:1995.

6.4.4 REDE RBF COM SINAIS COMBINADOS NA ENTRADA

6.4.4.1 FORÇA Y E ACELERAÇÃO NA ENTRADA PARA LIGA DE TITÂNIO

O erro médio na estimativa do diâmetro mínimo foi de 0,0116mm e de 0,0119mm para o diâmetro máximo. Porém, da mesma maneira como ocorreu com a rede configurada com todos os sinais aplicados na entrada, a rede atual não foi capaz de generalizar a partir do treinamento recebido, com estimativas variando muito pouco (Figura 67). Portanto, outras análises foram inviabilizadas.




Figura 67 - Resultados da estimativa da rede RBF para a liga Ti6Al4V, com os sinais da força em Y e da aceleração aplicados na entrada, não exibindo generalização.

6.4.4.2 FORÇA Y E FORÇA Z NA ENTRADA PARA LIGA DE ALUMÍNIO

O erro médio na estimativa do diâmetro mínimo foi de 0,0172mm e de 0,0178mm para o diâmetro máximo. Porém, da mesma maneira como ocorreu com a rede configurada com todos os sinais aplicados na entrada e com a rede com as duas entradas para a liga de titânio, a rede atual não foi capaz de generalizar a partir do treinamento recebido, com estimativas variando muito pouco (Figura 68). Portanto, outras análises foram inviabilizadas.




Figura 68 - Resultados da estimativa da rede RBF para a liga 2024-T3, com os sinais da força em Y e da força em Z aplicados na entrada, não exibindo generalização.

6.5 COMPARAÇÃO DOS TRÊS SISTEMAS DE INTELIGÊNCIA ARTIFICIAL UTILIZADOS

Os resultados obtidos nos testes e simulações dos três sistemas de inteligência artificial utilizados neste trabalho estão organizados na Tabela 38. A separação entre os resultados das duas ligas foi realizada devido ao comportamento distinto dos sinais em cada material.

Tabela 38 - Comparativo final do desempenho dos três sistemas de inteligência artificial utilizados.

Ti6Al4V	MLP	ANFIS	RBF	2024-T3	MLP	ANFIS	RBF
	EA+POT+FX+FY+FZ+ACEL				EA+POT+FX+FY+FZ+ACEL		
Erro absoluto (mm)	0,0080	-	0,0092	Erro absoluto (mm)	0,0088	-	0,0176
Erro percentual (%)	0,2	-	0,3	Erro percentual (%)	0,2	-	-
Falsos positivos (%)	1,3	-	1,3	Falsos positivos (%)	9	-	-
Falsos negativos (%)	5,8	-	6,4	Falsos negativos (%)	3,9	-	-
Acertos ≤ 5µm (%)	52,5	-	43,5	Acertos ≤ 5µm (%)	42,5	-	-
Acertos IT7 (%)	35,5	-	40	Acertos IT7 (%)	34	-	-
Acertos IT10 (%)	12	-	16,5	Acertos IT10 (%)	23,5	-	-
	Força Z				Força Z		
Erro absoluto (mm)	0,0077	0,0090	0,0102	Erro absoluto (mm)	0,0090	0,0102	0,0105
Erro percentual (%)	0,2	0,3	0,2	Erro percentual (%)	0,2	0,4	0,2
Falsos positivos (%)	0,7	1,3	3	Falsos positivos (%)	6,4	5,8	7,7
Falsos negativos (%)	3,4	3,6	3,2	Falsos negativos (%)	18,5	12,9	11,2
Acertos ≤ 5µm (%)	51	42	38	Acertos ≤ 5µm (%)	43,5	44	48
Acertos IT7 (%)	34,5	39,5	39,5	Acertos IT7 (%)	37	34	33
Acertos IT10 (%)	14,5	18	21,5	Acertos IT10 (%)	19,5	21,5	19
	Sinais combinados				Sinais combinados		
	EA + ACEL	FX + FZ	FY + ACEL		POT + FZ	EA + FZ	FY + FZ
Erro absoluto (mm)	0,0090	0,0102	0,0118	Erro absoluto (mm)	0,0085	0,0104	0,0175
Erro percentual (%)	0,2	0,35	-	Erro percentual (%)	0,2	0,4	-
Falsos positivos (%)	5,1	4,9	-	Falsos positivos (%)	5,8	4,5	-
Falsos negativos (%)	2,8	1,9	-	Falsos negativos (%)	7,5	17,2	-
Acertos ≤ 5µm (%)	44,5	35	-	Acertos ≤ 5µm (%)	45,5	41	-
Acertos IT7 (%)	35	40	-	Acertos IT7 (%)	34	32	-
Acertos IT10 (%)	20,5	25	-	Acertos IT10 (%)	20,5	26,5	-

7 CONCLUSÕES

A RNA MLP apresentou-se como o sistema mais confiável, quando sujeito à variações no conjunto de treinamento apresentado.

No sistema ANFIS a limitação no número de entradas impossibilita o uso de mais de quatro entradas simultâneas.

A rede RBF mostrou grande instabilidade quando variações no conjunto de treinamento são introduzidas, o que ficou comprovado pela baixa capacidade de generalização. É importante ressaltar, que o bom desempenho da RBF está ligado à quantidade de dados de treinamento disponíveis que, devido à característica de seu algoritmo, requer uma grande quantidade de informações. Portanto, os resultados deste trabalho indicam que o número de pontos deve ser maior do que foi utilizado aqui, sendo um obstáculo intrínseco a determinação exata de um número ideal, para o caso em particular.

Dentre os conjuntos de treinamento testados o uso de somente a força Z levou a bons resultados nos três sistemas, mostrando que um procedimento pouco intrusivo pode gerar bons resultados.

O potencial de gerar resultados corretos em controle de qualidade foi demonstrado pelo baixo percentual de resultados falsos para a liga de titânio. Porém, o mesmo não foi confirmado para a liga de alumínio.

Independente dos sinais apresentados na entrada os resultados analisados para as tolerâncias se mostraram muito confiáveis, visto que, dentre os resultados válidos um número muito pequeno de estimativas ficou acima da tolerância requerida pela mecânica precisa.

A RNA MLP mostrou-se o sistema de melhor desempenho entre os três analisados, exibindo grande versatilidade em relação às variações no conjunto de dados apresentados e mantendo erros baixos, mostrando confiabilidade na determinação de resultados válidos e com a maioria dos erros figurando abaixo da precisão do instrumento de medição. Foi verificada uma perda de desempenho com elevação do erro médio na liga de titânio e este fato está condizente com a característica da RNA MLP constituída inicialmente sobre a base de filtros. Assim, na presença de sinais ruidosos, a RNA tende a ignorar as variações induzidas no processo de furação, produzindo um resultado inferior ao encontrado na liga de alumínio.

Com relação aos sinais apresentados na entrada dos sistemas ficou evidente que a utilização apenas do sinal da força no eixo Z levou aos melhores resultados em todos os critérios analisados, com exceção no critério de controle de qualidade analisado para os sistemas configurados para a liga de alumínio, onde os resultados falsos apresentaram-se em maior número. Adicionalmente, a entrada com a força Z foi a única capaz de apresentar resultados válidos para todos os sistemas de inteligência artificial aqui analisados. Outro fato observado nos resultados foi o surgimento de sinais pouco representativos do processo de usinagem como as forças X e Y, o sinal de emissão acústica (EA) e o sinal de aceleração (ACEL), como a combinação EA + ACEL para a RNA MLP, ou ainda, FY + ACEL para a RBF (ambas as combinações para a liga de titânio). Isto corrobora com a grande aplicação destes sinais em monitoramento de processos, mas também levanta a necessidade de maiores pesquisas sobre a dinâmica do processo de furação, em particular, para uma maior compreensão de suas interações físicas.

Por fim, dadas as devidas restrições comentadas neste trabalho, sugere-se o desenvolvimento de posteriores trabalhos com os sistemas de inteligência artificial utilizados nos seguintes pontos:

- A análise da influência dos sinais levando em consideração outras estatísticas como o desvio-padrão, mediana e coeficientes com informações a respeito das frequências existentes em cada sinal, obtidos através de FFT ou wavelets.
- Um estudo sobre a melhor técnica de agrupamento dos dados para aplicação do sistema ANFIS, bem como a influência do tipo de função de pertinência nos resultados.
- A avaliação do potencial dos sistemas aqui empregados na perda de tolerância dimensional durante o processo de furação.
- A aplicação on-line destes sistemas seja no processo de furação, ou em outros processos de fabricação por usinagem.

REFERÊNCIAS

ABELLAN-NEBOT, J. V.; ROMERO SUBIRÓN, F. A review of machining monitoring systems based on artificial intelligence process models. **The International Journal of Advanced Manufacturing Technology**, v. 47, n. 1-4, p. 237-257, 2009.

ABLAMEYKO, S. **Neural networks for instrumentation, measurement and related industrial applications**. Amsterdam: IOS press, 2003.

ABU-MAHFOUZ, I. Drilling wear detection and classification using vibration signals and artificial neural network. **International Journal of Machine Tools and Manufacture**, v. 43, n. 7, p. 707-720, 2003.

AGUIAR, P. R. PAULA, W. C. F. BIANCHI, E. C. ULSON, J. A. C.; CRUZ, C.E.D. Analysis of forecasting capabilities of ground surfaces valuation using artificial neural networks. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, v. 32, n. 2, p. 146–153, 2010.

ALTROCK, C. VON. **Fuzzy Logic & Neuro-Fuzzy Applications Explained**. Upper Saddle River: Prentice Hall, 1995.

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

BALBINOT, A.; BRUSAMARELLO, V. J. **Instrumentação e fundamentos de medidas**. 2nd ed. Rio de Janeiro: LTC, 2010.

BATZER, S. HAAN, D. M. RAO, P. D. OLSON, W. W.; SUTHERLAND, J. W. Chip morphology and hole surface texture in the drilling of cast Aluminum alloys. **Journal of Materials Processing Technology**, v. 79, p. 72-78, 1998.

BUSTILLO, A.; CORREA, M. Using artificial intelligence to predict surface roughness in deep drilling of steel components. **Journal of Intelligent Manufacturing**, 2011.

CHANDRASEKARAN, M. MURALIDHAR, M. KRISHNA, C. M.; DIXIT, U. S. Application of soft computing techniques in machining performance prediction and optimization: a literature review. **The International Journal of Advanced Manufacturing Technology**, v. 46, n. 5-8, p. 445-464, 2009.

CHINNAM, R. B. DING, J.; MAY, G. S. Intelligent quality controllers for on-line parameter design. **IEEE Transactions on Semiconductor Manufacturing**, v. 13, n. 4, p. 481-491, 2000.

CHIU, S. L. Fuzzy model identification based on cluster estimation. **Journal of intelligent and Fuzzy systems**, v. 2, n. 3, p. 267–278, 1994.

CRUZ, CARLOS EDUARDO DORIGATTI. **Estimação do diâmetro e rugosidade em um processo de furação utilizando multi sensores e redes neurais artificiais**, 2010. UNESP - Univ Estadual Paulista.

DAVIM, J. P. **Machining: fundamentals and recent advances**. 2nd ed. London: Springer Verlag, 2008.

DOEBELIN, E. O. **Measurement Systems: Application and Design**. 5th ed. New York: McGraw-Hill, 2004.

DOTE, Y.; OVASKA, S. J. Industrial applications of soft computing: a review. **Proceedings of the IEEE**, v. 89, n. 9, p. 1243-1265, 2001.

EVSUKOFF, A. G.; ALMEIDA, P. E. M. DE. Sistemas Neuro Fuzzy. **Sistemas Inteligentes: Fundamentos e Aplicações**. p.525, 2003. Barueri: Manole.

FIGLIOLA, R. S.; BEASLEY, D. E. **Theory and design for mechanical measurements**. 2nd ed. New York: John Wiley & Sons, 1995.

HAGAN, M. T. DEMUCH, H. B.; BEALE, M. **Neural Network Design**. PWS Publishing Company, 1996.

HAGAN, M. T.; MENHAJ, M. B. Training Feedforward Networks with the Marquardt Algorithm. , v. 5, n. 6, p. 989-993, 1994.

HAMMOUDA, K.; KARRAY, F. A comparative study of data clustering techniques. **Tools of intelligent systems design. In Course Project, SYDE**, v. 625, p. 1-21, 2000. Citeseer.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2nd ed. Delhi: Pearson Prentice Hall, 1999.

HERMANN, G. Application of Neural Network Based Sensor Fusion in Drill Monitoring. 1st Slovakian-Hungarian Joint Symposium on Applied Machine Intelligence. **Anais...** , 2003.

HOPGOOD, A. A. **Intelligent Systems for Engineers and Scientists**. 2nd ed. Boca Raton: CRC Press, 2000.

HUANG, S. H.; ZHANG, H.-C. Artificial neural networks in manufacturing: concepts, applications, and perspectives. **IEEE Transactions on Components, Packaging, and Manufacturing Technology: Part A**, v. 17, n. 2, p. 212-228, 1994.

JANG, J. ANFIS: Adaptive-network-based fuzzy inference system. **Systems, Man and Cybernetics, IEEE Transactions**, v. 23, n. 3, 1993.

JANG, J. SUN, C. T.; MIZUTANI, E. **Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence**. Upper Saddle River: Prentice Hall, 1997.

KAMEN, E. W. **Industrial controls and manufacturing**. San Diego: Academic Press, 1999.

KANDILLI, I. SONMEZ, M. ERTUNC, H. M.; CAKIR, B. Online Monitoring Of Tool Wear In Drilling and Milling By Multi-Sensor Neural Network Fusion. **2007 International Conference on Mechatronics and Automation**, p. 1388-1394, 2007. Ieee.

KATZ, Z.; POUSTIE, A. On the Hole Quality and Drill Wandering Relationship. **International Journal of Advanced Manufacturing Technology**, v. 17, n. 4, p. 233-237, 2001.

KILLING, J. **Design and development of an intelligent neuro-fuzzy system for automated visual inspection**, 2007. Queen's University.

KLOCKE, F. **Manufacturing Process 1: Cutting**. London: Springer-Verlag, 2011.

LI, X.; TSO, S. K. Drill wear monitoring based on current signals. **Wear**, v. 231, n. 2, p. 172-178, 1999.

LIANG, S. Y. HECKER, R. L.; LANDERS, R. G. Machining Process Monitoring and Control: The State-of-the-Art. **Journal of Manufacturing Science and Engineering**, v. 126, n. 2, p. 297, 2004.

LIRA, I. **Evaluating the measurement uncertainty: Fundamentals and practical guidance**. London: CRC Press, 2002.

MATSUSHIMA, M. KAWAI, N. FUJIE, H.; YASUDA, K. Visual Inspection of Soldering Joints by Neural Network with Multi-angle View and Principal Component Analysis. In: K. Shirase; S. Aoyagi (Eds.); **Service Robotics and Mechatronics**. p.329-334, 2010. London: Springer-Verlag.

MONOSTORI, L. VÁNCZA, J.; KUMARA, S. R. T. Agent-Based Systems for Manufacturing. **CIRP Annals Manufacturing Technology**, v. 55, n. 2, p. 697-720, 2006.

NEGNEVITSKY, M. **Artificial Intelligence: A Guide to Intelligent Systems**. 2nd ed. Harlow: Addison-Wesley, 2005.

REZENDE, S. O. **Sistemas Inteligentes: Fundamentos e Aplicações**. Barueri: Ed. Manole, 2003.

SAMHOURI, M. S.; SURGENOR, B. W. Surface roughness in grinding: On-line prediction with adaptive neuro-fuzzy inference system. **Transactions of NAMRI/SME**, v. 33, p. 57-64, 2005.

SHAHIR, S. Adaptive fuzzy associative memory for online quality control. **Proceedings of the 35th Southeastern Symposium on System Theory, 2003.**, p. 357-361, 2003. Ieee.

STEPHENSON, D. A.; AGAPIOU, J. S. **Metal Cutting Theory and Practice**. 2nd ed. Boca Raton: CRC Press, 2006.

STRENKOWSKI, J. S. HSIEH, C. C.; SHIH, A. J. An analytical finite element technique for predicting thrust force and torque in drilling. **International Journal of Machine Tools and Manufacture**, v. 44, n. 12-13, p. 1413-1421, 2004.

SUGENO, M.; KANG, G. T. Structure identification of fuzzy model. **Fuzzy sets and systems**, v. 28, p. 15-33, 1988.

TAKAGI, T.; SUGENO, M. Fuzzy identification of system and its applications to modelling and control. **IEEE Transactions on Systems, Man., and Cybernetics**, v. SMC-15, n. 1, p. 116-132, 1985.

WALKER, J. M. Conventional fabrication process. In: R. Crowson (Ed.); **Parts Fabrication - Principles and Process**. p.63-172, 2006. Boca Raton: CRC Press.

WILAMOWSKI, B. M.; IRWIN, J. D. **Intelligent systems**. Boca Raton: CRC Press, 2010.

YANG, X. KUMEHARA, H.; ZHANG, W. Back Propagation Wavelet Neural Network Based Prediction of Drill Wear from Thrust Force and Cutting Torque Signals. **Computer and Information Science**, v. 2, n. 3, p. 75-86, 2009.

YOUSSEF, H. A.; EL-HOFY, H. **Machining Technology**. Boca Raton: CRC Press, 2008.

ZADEH, L. A. Fuzzy sets. **Information and Control**, v. 8, p. 338-353, 1965.

ZADEH, L. A. Fuzzy logic, neural networks, and soft computing. **Communications of the ACM**, v. 37, n. 3, p. 77-84, 1994.

ZHAO, H. **Predictive models for forces, power and hole oversize in drilling operations**, 1994. University of Melbourne.

ZOCCA. Parâmetros principais da fresadora universal U-30. Disponível em: <<http://www.zocca.com.br/fresauni.htm>>. Acesso em: 21/9/2011.

APÊNDICE

ALGORITMOS UTILIZADOS PARA AVALIAÇÃO DOS SISTEMAS DE INTELIGÊNCIA ARTIFICIAL

A.1 AVALIAÇÃO DOS PARÂMETROS E ARQUITETURA DA RNA MLP

```
% Avaliação da variação dos parâmetros taxa de aprendizagem e momento,
% bem como da arquitetura da RNA MLP (n° de neurônios por camada).
% *****

clear all
close all
clc

%Carregando os dados de treinamento
load InputTi.txt; %ou InputAl.txt
load TabelaNeuronios.txt

p1=InputTi(:,1);%Aceleração
p2=InputTi(:,2);%Emissão Acústica
p3=InputTi(:,3);%Potência
p4=InputTi(:,4);%Força em X
p5=InputTi(:,5);%Força em Y
p6=InputTi(:,6);%Força em Z
p7=InputTi(:,7);%Diâmetro da Broca
p8=InputTi(:,8);%Rotação do Spindle
p9=InputTi(:,9);%Avanço
t1=InputTi(:,10);%Diâmetro Mínimo
t2=InputTi(:,11);%Diâmetro Máximo

p=[p1,p2,p3,p4,p5,p6,p7,p8,p9];
p=p';
t=[t1,t2];
t=t';
Indice=0;

for j=1:9

    for k=1:5

        for neuronios=1:155

            % [trainP,valP,testP,trainInd,valInd,testInd] = dividerand(p,0.6,0.2,0.2);
            % [trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);

            if TabelaNeuronios(neuronios,2)==0 & (TabelaNeuronios(neuronios,3)==0)
                NumNeuronios = TabelaNeuronios(neuronios,1);
                net = newff(trainP,trainT,[NumNeuronios]);
            end

            if (TabelaNeuronios(neuronios,3)==0)& (TabelaNeuronios(neuronios,2)~=0)
                NumNeuronios = TabelaNeuronios(neuronios,1:2);
                net = newff(trainP,trainT,[NumNeuronios]);
            end

            if TabelaNeuronios(neuronios,3)>0
                NumNeuronios = TabelaNeuronios(neuronios,1:3);
                net = newff(trainP,trainT,[NumNeuronios]);
            end

            %Variação do momento
            %*****
            Momento=0;
            if j==1
                Momento=0.1;
            end

            if j==2
                Momento=0.2;
            end

            end
        end
    end
end
```

```

if j==3
    Momento=0.3;
end

if j==4
    Momento=0.4;
end

if j==5
    Momento=0.5;
end
if j==6
    Momento=0.6;
end
if j==7
    Momento=0.7;
end
if j==8
    Momento=0.8;
end
if j==9
    Momento=0.9;
end
%*****
%Variação da taxa de aprendizagem
learn_rate=0;
if k==1
    learn_rate=0.05;
end

if k==2
    learn_rate=0.15;
end

if k==3
    learn_rate=0.30;
end

if k==4
    learn_rate=0.50;
end

if k==5
    learn_rate=0.90;
end
%*****
net.trainParam.mc = Momento;
net.trainParam.lr = learn_rate;
net.trainParam.show=5;
net.trainParam.goal = 1e-7;
net.trainParam.epochs = 2000;
net = train(net,valP,valT);
Y = sim(net,testP);

Indice= Indice+1
ErroDia(Indice,1)=TabelaNeuronios(neuronios,1); %N de Neurônios - Primeira Camada
ErroDia(Indice,2)=TabelaNeuronios(neuronios,2); %N de Neurônios - Segunda Camada
ErroDia(Indice,3)=TabelaNeuronios(neuronios,3); %N de Neurônios - Terceira Camada
ErroDia(Indice,4)= Momento; %Momento
ErroDia(Indice,5)= learn_rate; %Taxa de Aprendizagem
ErroDia(Indice,6)= mean(abs(testT(1,:)-Y(1,:))); %Erro Diâmetro Mínimo
ErroDia(Indice,7)= mean(abs(testT(2,:)-Y(2,:))); %Erro Diâmetro Máximo
end
end
end

```

A.2 AVALIAÇÃO DA INFLUÊNCIA DOS SINAIS NA ENTRADA DA RNA MLP

```
% Avaliação da combinação de diferentes sensores no desempenho
% da RNA MLP
% *****

clear all
close all
clc

%Carregando os dados de treinamento
load todascond_al.txt; % ou todascond_ti.txt
t1=todascond_al(:,1);%Diâmetro Mínimo
t2=todascond_al(:,2);%Diâmetro Máximo
p1=todascond_al(:,3);%Emissão Acústica
p2=todascond_al(:,4);%Potência
p3=todascond_al(:,5);%Força em X
p4=todascond_al(:,6);%Força em Y
p5=todascond_al(:,7);%Força em Z
p6=todascond_al(:,8);%Aceleração

p=todascond_al';
t=[t1,t2];
t=t';
Index=0; Ind=0; Ind2 = 0; Ind3 = 0; Ind4=0; Ind5=0;

for sinal=3:8
    if sinal > 3 % loop de combinação com EA + demais
        pcomb = [p1'; p(sinal,:)];
        [trainP,valP,testP,trainInd,valInd,testInd] = dividerand(pcomb,0.6,0.2,0.2);
        [trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);
        net = newff(trainP,trainT,[20 10 5]);
        net.trainParam.mc = 0.8;
        net.trainParam.lr = 0.3;
        net.trainParam.show=5;
        net.trainParam.goal = 1e-7;
        net.trainParam.epochs = 2000;
        net.trainParam.showwindow = 0;
        net = train(net,valP,valT);
        Y = sim(net,testP);

        Ind= Ind+1
        ErroEA(Ind,1)= mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
        ErroEA(Ind,2)= mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
        ErrominEA(Ind,:)= abs(testT(1,:)-Y(1,:)); % Erro a cada ponto, Diâmetro Mínimo
        ErromaxEA(Ind,:)= abs(testT(2,:)-Y(2,:)); % Erro a cada ponto, Diâmetro Máximo
    end;

    if sinal > 4 % loop de combinação com POT + demais
        pcomb = [p2'; p(sinal,:)];
        [trainP,valP,testP,trainInd,valInd,testInd] = dividerand(pcomb,0.6,0.2,0.2);
        [trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);
        net = newff(trainP,trainT,[20 10 5]);
        net.trainParam.mc = 0.8;
        net.trainParam.lr = 0.3;
        net.trainParam.show=5;
        net.trainParam.goal = 1e-7;
        net.trainParam.epochs = 2000;
        net.trainParam.showwindow = 0;
        net = train(net,valP,valT);
        Y = sim(net,testP);

        Ind2= Ind2+1
        ErroPOT(Ind2,1)= mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
        ErroPOT(Ind2,2)= mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
        ErrominPOT(Ind2,:)= abs(testT(1,:)-Y(1,:)); % Erro a cada ponto, Diâmetro Mínimo
        ErromaxPOT(Ind2,:)= abs(testT(2,:)-Y(2,:)); % Erro a cada ponto, Diâmetro Máximo
    end;
end;
```

```

end;

if sinal > 5 % loop de combinação com FX + demais
    pcomb = [p3'; p(sinal,:)];
    [trainP,valP,testP,trainInd,valInd,testInd] = dividerand(pcomb,0.6,0.2,0.2);
    [trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);
    net = newff(trainP,trainT,[20 10 5]);
    net.trainParam.mc = 0.8;
    net.trainParam.lr = 0.3;
    net.trainParam.show=5;
    net.trainParam.goal = 1e-7;
    net.trainParam.epochs = 2000;
    net.trainParam.showwindow = 0;
    net = train(net,valP,valT);
    Y = sim(net,testP);

    Ind3= Ind3+1
    ErroFX(Ind3,1)= mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
    ErroFX(Ind3,2)= mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
    ErrominFX(Ind3,:)= abs(testT(1,:)-Y(1,:)); % Erro a cada ponto, Diâmetro Mínimo
    ErromaxFX(Ind3,:)= abs(testT(2,:)-Y(2,:)); % Erro a cada ponto, Diâmetro Máximo
end;

if sinal > 6 % loop de combinação com FY + demais
    pcomb = [p4'; p(sinal,:)];
    [trainP,valP,testP,trainInd,valInd,testInd] = dividerand(pcomb,0.6,0.2,0.2);
    [trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);
    net = newff(trainP,trainT,[20 10 5]);
    net.trainParam.mc = 0.8;
    net.trainParam.lr = 0.3;
    net.trainParam.show=5;
    net.trainParam.goal = 1e-7;
    net.trainParam.epochs = 2000;
    net.trainParam.showwindow = 0;
    net = train(net,valP,valT);
    Y = sim(net,testP);

    Ind4= Ind4+1
    ErroFY(Ind4,1)= mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
    ErroFY(Ind4,2)= mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
    ErrominFY(Ind4,:)= abs(testT(1,:)-Y(1,:)); % Erro a cada ponto, Diâmetro Mínimo
    ErromaxFY(Ind4,:)= abs(testT(2,:)-Y(2,:)); % Erro a cada ponto, Diâmetro Máximo
end;

if sinal > 7 % loop de combinação com FZ + ACEL
    pcomb = [p5'; p(sinal,:)];
    [trainP,valP,testP,trainInd,valInd,testInd] = dividerand(pcomb,0.6,0.2,0.2);
    [trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);
    net = newff(trainP,trainT,[20 10 5]);
    net.trainParam.mc = 0.8;
    net.trainParam.lr = 0.3;
    net.trainParam.show=5;
    net.trainParam.goal = 1e-7;
    net.trainParam.epochs = 2000;
    net.trainParam.showwindow = 0;
    net = train(net,valP,valT);
    Y = sim(net,testP);

    Ind5= Ind5+1
    ErroFZ(Ind5,1)= mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
    ErroFZ(Ind5,2)= mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
    ErrominFZ(Ind5,:)= abs(testT(1,:)-Y(1,:)); % Erro a cada ponto, Diâmetro Mínimo
    ErromaxFZ(Ind5,:)= abs(testT(2,:)-Y(2,:)); % Erro a cada ponto, Diâmetro Máximo
end;

% Avaliação dos sinais aplicados isoladamente como entrada da MLP
[trainP,valP,testP,trainInd,valInd,testInd] = dividerand(p(sinal,:),0.6,0.2,0.2);
[trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);

```

```

net = newff(trainP,trainT,[20 10 5]);
net.trainParam.mc = 0.8;
net.trainParam.lr = 0.3;
net.trainParam.show=5;
net.trainParam.goal = 1e-7;
net.trainParam.epochs = 2000;
net.trainParam.showwindow = 0;
net = train(net,valP,valT);
Y = sim(net,testP);

Index= Index+1
ErroSinal(Index,1)= mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
ErroSinal(Index,2)= mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
ErrominSinal(Index,:)= abs(testT(1,:)-Y(1,:)); % Erro a cada ponto, Diâmetro Mínimo
ErromaxSinal(Index,:)= abs(testT(2,:)-Y(2,:)); % Erro a cada ponto, Diâmetro Máximo
end

resposta = input('Deseja gravar os dados em .xls? (1 - Sim / 2 - Não)');

if resposta == 1
    gravasinal;
else
    close;
end;

```

A.3 AVALIAÇÃO DO NÚMERO DE ÉPOCAS NO TREINAMENTO E INFLUÊNCIA DAS ENTRADAS DO ANFIS

```

%% Preparação do workspace
clear all
close all
clc
%% Preparação dos dados de entrada e saídas desejadas
load todascond_ti.txt
p1=todascond_ti(:,3); %Aceleração
p2=todascond_ti(:,4); %Emissão Acústica
p3=todascond_ti(:,5); %Potência
p4=todascond_ti(:,6); %Força em X
p5=todascond_ti(:,7); %Força em Y
p6=todascond_ti(:,8); %Força em Z
TiTgt1=todascond_ti(:,1); %Diâmetro Mínimo
TiTgt2=todascond_ti(:,2); %Diâmetro Máximo

% Tiln=[p1,p2,p3,p4,p5,p6];
% Tiln=Tiln';

erroEpocas = zeros(100,1);
m = 0;

%% Combinar entradas
MelhEntr1 = todascond_ti(:,6)';
MelhEntr2 = todascond_ti(:,7)';
MelhEntrTI = [MelhEntr1;MelhEntr2]; % Para usar com mais de uma entrada.

%% Divisão dos dados de treinamento, validação e teste
[trainP,valP,testP,trainInd,validInd,testInd] = dividerand(MelhEntrTI,0.6,0.2,0.2);
[trainT,valT,testT] = divideind(TiTgt2,trainInd,validInd,testInd);
trainP = trainP'; valP = valP'; testP = testP';
trainT = trainT'; valT = valT'; testT = testT';

%% Teste das entradas para o menor erro
numEpochs = 20; numMFs = 2;
NomesEntr = ['EA--';'POT--';'FX--';'FY--';'FZ--';'ACEL']; % Define o nome das entradas para exibição no gráfico final.

% teste exaustivo para a melhor combinação de entradas.
[bestdmin,tempo] = exhsrch(2,[trainP(:,1:6) trainT(:,1)],[valP(:,1:6)
valT(:,1)],NomesEntr(1:6,:),numMFs,numEpochs);

% teste sequencial para a melhor combinação de entradas.
[bestdmin,tempo] = seqsrch(2,[trainP(:,1:6) trainT(:,1)],[valP(:,1:6)
valT(:,1)],NomesEntr(1:6,:),numMFs,numEpochs);

%% Definição do FIS (Fuzzy Inference System = Sistema de Inferência Fuzzy)

raio_infl = [0.10 0.22 0.1658];
subcluster_op = [1.25; 0.6; 0.3; 1];
fisdmin = genfis2(trainP,trainT,raio_infl,[],subcluster_op); % fistmg é a matriz que define o FIS p/ o Ømin.

%% Treinamento do ANFIS (Sistema de Inferência Adaptável Neuro-Fuzzy , SIANF)
for i = 10:10:1000 % Teste do número de épocas
    fprintf('\n\n=====Interação => %d\n=====\\n',m);
    numEpochs = i;

    trnData = [trainP trainT];
    chkData = [valP valT];
    [trnOpt] = [numEpochs; 1e-7; 0.04; 1.2; 1.8];
    [dispOpt] = [1; 0; 0; 1];
    [fisdmin1,trnErr,ss,fisdmin2,chkErr] = anfis(trnData,fisdmin,trnOpt,dispOpt,chkData,1);
    tempoanfisfim = toc(tempoanfisini);

```

```
fprintf('Tempo p/ treinar o ANFIS = %d',tempoanfifim);

%% Verifica os resultados
dmin = evalfis(testP(:,1:2),fisdmin1);
erromediomin = mean(abs(chkData(:,3)-dmin));
erdmin = abs(dmin-chkData(:,3));
erpercmin = erdmin./chkData(:,3);
fprintf('Erro médio dmin calculado = %1.4f\n',erromediomin);
m = m + 1;
erroEpocas(m,1) = erromedio;
end
```

A.4 AVALIAÇÃO DO SPREAD E DA INFLUÊNCIA DOS SINAIS NA REDE RBF

```
% Avaliação da combinação de diferentes sensores no desempenho
% da rede RBF
% *****

clear all
close all
clc

%Carregando os dados de treinamento
load todascond_ti.txt;

t1=todascond_ti(:,1);%Diâmetro Mínimo
t2=todascond_ti(:,2);%Diâmetro Máximo
p1=todascond_ti(:,3);%Emissão Acústica
p2=todascond_ti(:,4);%Potência
p3=todascond_ti(:,5);%Força em X
p4=todascond_ti(:,6);%Força em Y
p5=todascond_ti(:,7);%Força em Z
p6=todascond_ti(:,8);%Aceleração

%% ALOCA AS MATRIZES P/ ARMAZENAR OS RESULTADOS
ErroEArbf = zeros(10000,1); ErroPOTrbf=zeros(10000,1); ErroFXrbf=zeros(10000,1);
ErroFYrbf=zeros(10000,1); ErroFZrbf=zeros(10000,1); ErroACELrbf=zeros(10000,1);
ErroSinalrbf=zeros(10000,1);

p=todascond_ti';
t=[t1,t2];
t=t';
Indice=0; Ind=0; Ind2 = 0; Ind3 = 0; Ind4=0; Ind5=0; linha=0;

for sinal=3:8
    if sinal > 3 % loop de combinação com EA + demais
        pcomb = [p1'; p(sinal,:)];
        [trainP,valP,testP,trainInd,valInd,testInd] = dividerand(pcomb,0.6,0.2,0.2);
        [trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);

        linha=0;
        for a = 10:10:1000
            spread3 = a;
            thiagogrnn = newgrnn(trainP,trainT,spread3);
            linha = linha +1;
            fprintf('\n\n=====\\nIteração =>
%d\\n=====\\n',linha);
            Y = sim(thiagogrnn,testP);

            Ind = Ind+1;
            ErroEArbf(Ind,1) = mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
            ErroEArbf(Ind,2) = mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
        end;
        save RBFresult ErroEArbf ErroPOTrbf ErroFXrbf ErroFYrbf ErroFZrbf ErroACELrbf ErroSinalrbf a b c d e f
    end;

    if sinal > 4 % loop de combinação com POT + demais
        pcomb = [p2'; p(sinal,:)];
        [trainP,valP,testP,trainInd,valInd,testInd] = dividerand(pcomb,0.6,0.2,0.2);
        [trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);

        linha=0;
        for b = 10:10:1000
            spread4 = b;
            thiagogrnn = newgrnn(trainP,trainT,spread4);
            linha = linha +1;
```

```

        fprintf('\n\n===== \nIteração =>
%d\n===== \n',linha);
        Y = sim(thiagogrnn,testP);

        Ind2= Ind2+1;
        ErroPOTrbf(Ind2,1)= mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
        ErroPOTrbf(Ind2,2)= mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
    end;
    save RBFresult ErroEArbf ErroPOTrbf ErroFXrbf ErroFYrbf ErroFZrbf ErroACELrbf ErroSinalrbf a b c d e f
    sinal;

end;

if sinal > 5 % loop de combinação com FX + demais
    pcomb = [p3'; p(sinal,:)];
    [trainP,valP,testP,trainInd,valInd,testInd] = dividerand(pcomb,0.6,0.2,0.2);
    [trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);

    linha=0;
    for c = 10:10:1000
        spread5 = c;
        thiagogrnn = newgrnn(trainP,trainT,spread5);
        linha = linha +1;
        fprintf('\n\n===== \nIteração =>
%d\n===== \n',linha);
        Y = sim(thiagogrnn,testP);

        Ind3= Ind3+1;
        ErroFXrbf(Ind3,1)= mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
        ErroFXrbf(Ind3,2)= mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
    end;
    save RBFresultTI ErroEArbf ErroPOTrbf ErroFXrbf ErroFYrbf ErroFZrbf ErroACELrbf ErroSinalrbf a b c d e f
    sinal;

end;

if sinal > 6 % loop de combinação com FY + demais
    pcomb = [p4'; p(sinal,:)];
    [trainP,valP,testP,trainInd,valInd,testInd] = dividerand(pcomb,0.6,0.2,0.2);
    [trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);

    linha=0;
    for d = 10:10:1000
        spread6 = d;
        thiagogrnn = newgrnn(trainP,trainT,spread6);
        linha = linha +1;
        fprintf('\n\n===== \nIteração =>
%d\n===== \n',linha);
        Y = sim(thiagogrnn,testP);

        Ind4= Ind4+1;
        ErroFYrbf(Ind4,1)= mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
        ErroFYrbf(Ind4,2)= mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
    end;
    save RBFresultTI ErroEArbf ErroPOTrbf ErroFXrbf ErroFYrbf ErroFZrbf ErroACELrbf ErroSinalrbf a b c d e f
    sinal;

end;

if sinal > 7 % loop de combinação com FZ + ACEL
    pcomb = [p5'; p(sinal,:)];
    [trainP,valP,testP,trainInd,valInd,testInd] = dividerand(pcomb,0.6,0.2,0.2);
    [trainT,valT,testT] = divideind(t,trainInd,valInd,testInd);

    linha=0;
    for e = 10:10:1000
        spread7 = e;

```

```

thiagogrnn = newgrnn(trainP,trainT,spread7);
linha = linha +1;
fprintf("\n\n===== \nIteração =>
%d\n===== \n',linha);
Y = sim(thiagogrnn,testP);

Ind5= Ind5+1;
ErroFZrbf(Ind5,1)= mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
ErroFZrbf(Ind5,2)= mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
end;
save RBFresultTI ErroEARbf ErroPOTrbf ErroFXrbf ErroFYrbf ErroFZrbf ErroACELrbf ErroSinalrbf a b c d e f
sinal;

end;
% Avaliação dos sinais aplicados isoladamente
[trainP,valP,testP,trainInd,vaInd,testInd] = dividerand(p(sinal,:),0.6,0.2,0.2);
[trainT,valT,testT] = divideind(t,trainInd,vaInd,testInd);

linha=0;
for f = 10:10:1000
    spread = f;
    thiagogrnn = newgrnn(trainP,trainT,spread);
    linha = linha +1;
    fprintf("\n\n===== \nIteração =>
%d\n===== \n',linha);
    Y = sim(thiagogrnn,testP);

    Indice= Indice+1;
    ErroSinalrbf(Indice,1)= mean(abs(testT(1,:)-Y(1,:))); %Erro Médio, Diâmetro Mínimo
    ErroSinalrbf(Indice,2)= mean(abs(testT(2,:)-Y(2,:))); %Erro Médio, Diâmetro Máximo
end;
save RBFresultTI ErroEARbf ErroPOTrbf ErroFXrbf ErroFYrbf ErroFZrbf ErroACELrbf ErroSinalrbf a b c d e f
sinal;

end

save RBFresultTI ErroEARbf ErroPOTrbf ErroFXrbf ErroFYrbf ErroFZrbf ErroACELrbf ErroSinalrbf a b c d e f
sinal;

```