



Universidade Estadual Paulista – UNESP

“JULIO DE MESQUITA FILHO”

Pós-Graduação em Engenharia Elétrica

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS
NA PREDIÇÃO DE DIAMETRO E RUGOSIDADE
DURANTE O PROCESSO DE FURAÇÃO**

JOÃO GABRIEL CONTRUCCI

Bauru – SP
Setembro 2012



Universidade Estadual Paulista – UNESP

“JULIO DE MESQUITA FILHO”

Pós-Graduação em Engenharia Elétrica

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DE DIAMETRO E RUGOSIDADE DURANTE O PROCESSO DE FURAÇÃO

JOÃO GABRIEL CONTRUCCI

Orientador: Prof. Dr. Paulo Roberto de Aguiar

Dissertação apresentada à Faculdade de Engenharia da
UNESP *Campus* de Bauru, para obtenção do Título de
Mestre em Engenharia Elétrica.

Bauru – SP
Setembro 2012

Contrucci, João Gabriel.

Aplicação de Redes Neurais Artificiais na predição de diâmetros e rugosidade durante o processo de furação / João Gabriel Contrucci, 2012
180 f.

Orientador: Paulo Roberto de Aguiar


Dissertação (Mestrado)-Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2012


1. Redes Neurais Artificiais 2. Predição. 3. Furação. 4. Ligas Aeronáuticas. I. Universidade Estadual Paulista. Faculdade de Engenharia. II. Título.

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE JOÃO GABRIEL CONTRUCCI, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DO(A) FACULDADE DE ENGENHARIA DE BAURU.

Ao 01 dia do mês de junho do ano de 2012, às 14:30 horas, no(s) ANFITEATRO DO STI 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. AMAURI HASSUI do(a) Faculdade de Engenharia Mecânica / Universidade Estadual de Campinas - UNICAMP, 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 JOÃO GABRIEL CONTRUCCI, intitulada "APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DE DIÂMETRO E RUGOSIDADE DURANTE O PROCESSO DE FURAÇÃO". 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. AMAURI HASSUI


Prof. Dr. JOSE ALFREDO COVOLAN ULSON

DEDICATÓRIA

Aos meus pais Luiz Robson e Silvia,
Ao meu irmão José Guilherme e a minha
Esposa Michelle e filha Julia pelo amor e dedicação.

AGRADECIMENTOS

Primeiramente agradeço Deus, responsável por todas as conquistas e realizações na minha vida.

Agradeço a minha esposa, Michelle, pelo carinho, amor e compreensão nos momentos de ausência e pelo seu incansável incentivo que nunca me deixou pensar em desistir. Exalto minha gratidão aos meus pais, Luiz Robson e Silvia Nogueira pela educação recebida e amor incondicional ao longo desses anos que sempre me deram suporte para chegar até aqui.

Agradeço meu Orientador, Prof. Dr. Paulo Roberto de Aguiar que esteve presente durante toda minha pesquisa e me proporcionou uma longa caminhada de conhecimento e evolução, do qual tenho o prazer e orgulho de trabalhar. Agradeço a todos os meus amigos pelo apoio e ajuda das mais diversas formas. Em especial, ao amigo e engenheiro, Carlos Eduardo Dorigatti Cruz pela grande amizade, companheirismo de longa data e participação nesta pesquisa.

Agradeço a UNESP e a todos os seus docentes, discentes e funcionários que fizeram parte de minha formação desde a graduação. Tenho grande orgulho de aqui ter estudado e de carregar o nome desta Universidade em meu diploma. Agradeço ao Prof. Dr. Alfredo Ulson Covalan, que com seu imenso conhecimento pode me guiar durante esse trabalho garantindo que o mesmo pudesse se tornar mais completo e fundamentado. Agradeço ao Prof. Dr. Eduardo Carlos Bianchi, que sempre contribuiu para o aperfeiçoamento desse trabalho. Agradeço também ao Prof. Dr. Luiz Eduardo de Ângelo Sanchez que cedeu o laboratório L.U.A para realização dos ensaio.

Agradeço a empresa OSG e a seu engenheiro de aplicações Gustavo Santos pelo fornecimento das ferramentas de corte utilizadas neste trabalho e por todo auxílio durante o desenvolvimento e discussões dos métodos utilizados neste trabalho.

“Those who control the past, control the future”

George C. Orwell

LISTA DE FIGURAS

<i>Figura 1 - Estrutura do neurônio biológico (adaptado de www.rc.unesp.br/biosferas/mat0002.php).</i>	<i>24</i>
<i>Figura 2 - Estrutura do neurônio artificial (EYNG, 2008).</i>	<i>26</i>
<i>Figura 3 - Função de ativação tangente hiperbólica e derivada (CARRARA, 1997).</i>	<i>28</i>
<i>Figura 4 - Rede estática ou com alimentação direta – modificada de CARRARA, 1997.</i>	<i>29</i>
<i>Figura 5 - Rede com realimentação na saída – modificada de CARRARA, 1997.</i>	<i>30</i>
<i>Figura 6 - Rede com realimentação entre camadas, conexões laterais e recorrência – modificada de CARRARA, 1997.</i>	<i>30</i>
<i>Figura 7 - Rede com neurônios completamente conectados – modificada de CARRARA, 1997.</i>	<i>31</i>
<i>Figura 8 - Representação de uma rede neural de alimentação direta com duas camadas –modificada de CARRARA, 1997.</i>	<i>33</i>
<i>Figura 9 - Entradas e saídas da camada k de uma rede neural – modificada de CARRARA, 1997.</i>	<i>34</i>
<i>Figura 10 – Rede recorrente sem laço de auto-realimentação e sem neurônio oculto – modificada de HAYKIN, 2001.</i>	<i>37</i>
<i>Figura 11 – Rede recorrente com neurônio oculto – modificada de HAYKIN, 2001.</i>	<i>38</i>
<i>Figura 12 – Rede TDNN , DODONOV, 2008.</i>	<i>41</i>
<i>Figura 13 – Esquema de rede do tipo realimentada, CORREA, 2004.</i>	<i>43</i>
<i>Figura 14 – Variáveis que afetam a qualidade das furações (Cruz, 2010).</i>	<i>61</i>
<i>Figura 15 - Cinemática do processo de furação (Novaski, 1996).</i>	<i>62</i>
<i>Figura 16 – Aresta postiça de Corte (DINIZ, 1999).</i>	<i>63</i>
<i>Figura 17 – Influencia na forma do cavaco (Adaptado de STOETERAU, 2007).</i>	<i>65</i>
<i>Figura 18 – Tipos do cavaco (STOETERAU, 2007).</i>	<i>65</i>
<i>Figura 19 – Forma do cavaco segundo a classificação ISO 3685 -1977.</i>	<i>66</i>
<i>Figura 20 – Componentes da Forças de usinagem (PEREIRA, 2010).</i>	<i>67</i>
<i>Figura 21 – Principais Ângulos de uma Broca Helicoidal (BOEIRA et al., 2010).</i>	<i>73</i>
<i>Figura 22 – Formas de desgaste de uma broca helicoidal (CRUZ, 2010).</i>	<i>74</i>
<i>Figura 23 - Tipos de acabamento superficial (WHITEHOUSE, 1994).</i>	<i>75</i>

<i>Figura 24 - Rugosidade média Ra (WHITEHOUSE, 1994).</i>	76
<i>Figura 25 - Parâmetro Rz DIN (TAYLOR, 2000).</i>	78
<i>Figura 26 - Parâmetro R_t DIN (TAYLOR,2000).</i>	79
<i>Figura 27 – Vista Lateral do Corpo de Prova.</i>	82
<i>Figura 28 – Vista Superior do Corpo de Prova.</i>	82
<i>Figura 29 – Identificação das brocas helicoidais utilizadas nos ensaios.</i>	84
<i>Figura 30 – Medição das brocas helicoidais antes dos ensaios.</i>	85
<i>Figura 31 – Desenho esquemático da base utilizada nos ensaios.</i>	86
<i>Figura 32 – Base de Ensaio, Fresadora e Corpo de Prova.</i>	86
<i>Figura 33 – Fresadora e computador de aquisição utilizado nos ensaios.</i>	87
<i>Figura 34 – Desenho esquemático do banco de ensaios.</i>	89
<i>Figura 35 – Instalação do Dinamômetro.</i>	91
<i>Figura 36 – Posição dos sensores de emissão acústica.</i>	92
<i>Figura 37 – Posição dos sensores de aceleração.</i>	94
<i>Figura 38 – Força em Z utilizadas para a determinação do ponto inicial das aquisições e do ponto de corte.</i>	96
<i>Figura 39 – Ilustrações dos sinais de Força envolvidos na aquisição.</i>	98
<i>Figura 40 – Ilustrações dos sinais de Aceleração, E.A, Potência do Motor Elétrico.</i>	98
<i>Figura 41 – Divisão dos sinais durante a usinagem dos diferentes materiais</i>	101
<i>Figura 42 – Esquema do funcionamento do aparelho de medição dos diâmetros.</i>	102
<i>Figura 43 – Processo de medição dos diâmetros de cada furo.</i>	103
<i>Figura 44 – Metodologia de medição da rugosidade.</i>	104
<i>Figura 45 – Diagrama das redes neurais utilizadas no trabalho.</i>	105
<i>Figura 46 – Arquitetura da rede neural para estimação dos diâmetros.</i>	107
<i>Figura 47 – Arquitetura da rede neural para estimação das rugosidades.</i>	109
<i>Figura 48 – Arquitetura da rede neural para predição de diâmetro.</i>	110
<i>Figura 49 – Arquitetura da rede neural para estimação dos diâmetros.</i>	112
<i>Figura 50 – Controle estatístico do processo de furação realizado no ensaio.</i>	116
<i>Figura 51 – Valores de rugosidade interpolados para a liga de Titânio.</i>	117
<i>Figura 52 – Valores de rugosidade interpolados para a liga de Alumínio.</i>	118
<i>Figura 53 – Medição dos diâmetros de Titânio.</i>	119
<i>Figura 54 – Medição dos diâmetros de Alumínio.</i>	120
<i>Figura 55 – Média e desvio padrão dos sinais de força em Z.</i>	121

<i>Figura 56 – Média e desvio padrão dos sinais de Força X e Força Y.</i>	<i>122</i>
<i>Figura 57 – Média e desvio padrão dos sinais de Potência.</i>	<i>123</i>
<i>Figura 58 – Média e desvio padrão dos sinais de aceleração.....</i>	<i>124</i>
<i>Figura 59 – Média e desvio padrão dos sinais de emissão acústica.....</i>	<i>125</i>
<i>Figura 60 – Média e desvio padrão dos diâmetros medidos.</i>	<i>127</i>
<i>Figura 61 – Média e desvio padrão das Rugosidades medidas.....</i>	<i>129</i>
<i>Figura 62 – Resultado da Rede Neural para estimação do diâmetro médio do furo em Titânio a partir de todos os sinais adquiridos.....</i>	<i>130</i>
<i>Figura 63 – Erros de estimação para os diâmetros estimados pela rede feedforward em Titânio.....</i>	<i>131</i>
<i>Figura 64 – Resultado da Neural para estimação do diâmetro médios do furo em alumínio a partir de todos os sinais adquiridos.</i>	<i>132</i>
<i>Figura 65 – Erros de estimação para os diâmetros estimados pela rede feedforward em Alumínio.....</i>	<i>132</i>
<i>Figura 66 – Rede para estimação da Rugosidade em Alumínio a partir de todos os sinais adquiridos.</i>	<i>134</i>
<i>Figura 67 – Erros de estimação para as rugosidades estimadas pela rede feedforward em Alumínio.....</i>	<i>135</i>
<i>Figura 68 – Rede para estimação da Rugosidade em Titânio a partir de todos os sinais adquiridos.</i>	<i>135</i>
<i>Figura 69 – Erros de estimação para as rugosidades estimadas pela rede “feedforward” em Titânio.</i>	<i>136</i>
<i>Figura 70 – Rede para predição do diâmetro em Titânio a partir de todos os sinais adquiridos.</i>	<i>137</i>
<i>Figura 71 – Erros de predição para os diâmetros estimados pela rede “feedforward” em Titânio.</i>	<i>138</i>
<i>Figura 72 – Rede para predição do diâmetro em alumínio com todos os sinais adquiridos.</i>	<i>139</i>
<i>Figura 73 – Erros de predição para os diâmetros estimados pela rede “feedforward” em Alumínio e preditos pela rede TDNN.....</i>	<i>139</i>
<i>Figura 74 – Resultado da predição da Rugosidade Ra dos furos em Alumínio com todos os sinais.....</i>	<i>140</i>
<i>Figura 75 – Erros de predição para as rugosidades estimadas pela rede “feedforward” em Alumínio e preditas pela rede TDNN.....</i>	<i>141</i>
<i>Figura 76 – Rede Neural para predição da Rugosidade em Titânio com todos os sinais.</i>	<i>142</i>
<i>Figura 77 – Erros de predição para as rugosidades em Titânio com todos os sinais.</i>	<i>142</i>
<i>Figura 78 – Diâmetro médio em Titânio a partir dos sinais de força em Z e potência.....</i>	<i>146</i>

<i>Figura 79 – Erros de predição para os diâmetros preditos em Titânio com os sinais de Potência e Força em Z.</i>	<i>147</i>
<i>Figura 80 – Diâmetro médio dos furos em Alumínio a partir dos sinais de força no eixo Z e potência.</i>	<i>148</i>
<i>Figura 81 – Erros de predição em relação aos dados estimados coma utilização dos sinais de força no eixo z e Potência.</i>	<i>149</i>
<i>Figura 82 –Rugosidade em Titânio com os sinais de potencia e força no eixo Z.</i>	<i>150</i>
<i>Figura 83 – Erros de predição para as rugosidades estimadas pela rede “feedforward” em Titânio</i>	<i>150</i>
<i>Figura 84 –Rugosidade em Alumínio a partir dos sinais de força no eixo Z e potência.....</i>	<i>152</i>
<i>Figura 85 – Erros de predição para as rugosidades estimadas pela rede “feedforward” em Titânio e preditas pela rede TDNN.....</i>	<i>152</i>

LISTA DE TABELAS

<i>Tabela 1 – Velocidade de corte ideal (Adaptado de Rodrigues, 2005).</i>	<i>69</i>
<i>Tabela 2 – Valores de Ra para processos de fabricação (Adaptado da norma DIN 4766 por CAVALCANTE, 2010).</i>	<i>76</i>
<i>Tabela 3 – Constituição das Ligas Utilizadas (Fonte: www.matweb.com).</i>	<i>83</i>
<i>Tabela 4 – Valores de ganhos utilizados no módulo do sensor de força.</i>	<i>91</i>
<i>Tabela 5 – Valores de ajustes no módulo de emissão acústica.</i>	<i>93</i>
<i>Tabela 6 – Valores de ajustes no módulo de emissão acústica.</i>	<i>94</i>
<i>Tabela 7 – Parâmetros de Usinagem.....</i>	<i>95</i>
<i>Tabela 8 – Parâmetros da rede de estimação de diâmetros – Todos os sinais.</i>	<i>108</i>
<i>Tabela 9 – Parâmetros da rede de estimação da rugosidade - Todos os sinais.</i>	<i>109</i>
<i>Tabela 10 – Parâmetros finais da rede de predição para os diâmetros médios - Com todos os sinais adquiridos na rede de estimação.....</i>	<i>111</i>
<i>Tabela 11 – Parâmetros da rede de predição para as rugosidades - Com todos os sinais adquiridos na rede de estimação.....</i>	<i>112</i>
<i>Tabela 12 – Parâmetros da rede de estimação para o diâmetro – Com os sinais de potência e força Z.....</i>	<i>113</i>
<i>Tabela 13 – Parâmetros da rede de estimação para as rugosidades – Com os sinais de potência e força Z.....</i>	<i>114</i>
<i>Tabela 14 – Parâmetros da rede de predição para o diâmetro - Com os sinais de potência e força Z na rede de estimação.</i>	<i>114</i>
<i>Tabela 15 – Parâmetros da rede de predição para rugosidade - Com os sinais de potência e força Z na rede de estimação.</i>	<i>115</i>
<i>Tabela 16 – Análise geral dos Diâmetros Medidos.</i>	<i>126</i>
<i>Tabela 17 – Análise geral das Rugosidades Medidas.....</i>	<i>128</i>
<i>Tabela 18 – Resumo geral dos erros com as redes neurais de estimação....</i>	<i>143</i>
<i>Tabela 19 – Resumo geral dos erros com as redes neurais de predição.</i>	<i>144</i>
<i>Tabela 20 – Resumo geral dos erros encontrados pelas redes neurais de estimação.....</i>	<i>153</i>
<i>Tabela 21 – Resumo geral dos erros encontrados pelas redes neurais de predição.....</i>	<i>154</i>

LISTA DE SIMBOLOS

6 σ	Seis Sigmas
2CR	Dois Capacitores e um Resistor
μ	micron
CEP	Controle Estatístico do Processo
Cut-off	Ponto de Corte
CN	Comando Numérico
CNC	Comando Numérico Computadorizado
DIN	Deutsches Institut fur Normung
ISO	“International Organization for Standardization” (Organização Internacional de Padronização)
R _z	Medida de rugosidade que considera os cinco maiores picos e maiores vales de um perfil
R _t	Altura máxima de rugosidade
Ra	Rugosidade média aritmética
R _v	Profundidade máxima do vale do perfil
RNAs	Redes Neurais Artificiais
Rpm	Rotações por minuto
RHSC	Contagem dos pontos altos de rugosidade
NAS	National Aircraft Standards
MLP	<i>Multi-Layer Perceptron</i>

RESUMO

O mercado, de maneira geral, vem exigindo níveis de qualidade cada vez maiores e redução de custos operacionais. Dentro desse contexto, as indústrias buscam processos mais automatizados e robustos, visando padronização nas operações e redução dos desperdícios. O controle eficaz do processo de fabricação é chave para atender às crescentes exigências do mercado. A utilização de redes neurais artificiais para o controle de processos complexos, com inúmeras variáveis, é um método que vem ganhando destaque acadêmico ao longo dos anos. O processo de furação para instalação de prendedores em estruturas aeronáuticas é um processo especial, no qual são exigidos controles rigorosos de qualidade devido aos requisitos de projeto, sendo, em muitos casos, mais importante a qualidade da furação, do que a vida útil da ferramenta. Este trabalho tem por objetivo apresentar um método para predição de diâmetros médios e rugosidades de furos realizados durante o processo de furação de ligas aeronáuticas por meio de brocas helicoidais. Com a utilização de um sistema multi sensores acoplados a uma fresadora extraíram-se sinais, potência do motor elétrico, emissão acústica, vibração e forças de usinagem que alimentaram uma primeira rede neural artificial *feedforward* que teve a função de estimar a rugosidade e o diâmetro médio do furo. Uma vez de posse do valor estimado, ele servia de entrada em uma segunda rede neural “*time delay*” - TDNN que atuou na predição da rugosidade e diâmetro médio do próximo furo a ser realizado, mesmo antes de esse ser realizado mecanicamente. Posteriormente, buscou-se o mesmo procedimento previamente descrito, porém utilizando apenas os sinais de potência e força no eixo Z como entrada da rede neural de estimação. Todos os valores preditos apresentaram erros pequenos quando comparados aos valores reais e estimados, mostrando que o método foi capaz de prever os valores de rugosidade e diâmetro dentro dos limites estipulados.

Palavras-chave: monitoramento do processo de furação, redes neurais artificiais, diâmetro de furo usinado, rugosidade, predição.

ABSTRACT

The market, in general, is demanding high levels of quality and reduction of the operational costs. The majority of companies has been searching for processes even more automatic and robust, aiming to standardize operations and reduce wastage. The effective control of the manufacturing process is the key for the growing market demands. The use of artificial neural networks for the control of complex processes, with many variables, has been drawing attention over the last years. The drilling process for fasteners installation in aircraft structures is a special process which requires a rigorous quality control due to the design requirements and, in many cases; the most important characteristic is the quality of hole. This work aims to present a method for prediction of diameter and surface roughness of holes performed in aeronautic alloys with carbide drill bit. Using a multi sensory system connected to a milling machine, signals were extracted (electric power, acoustic emission, vibration, cutting forces) and fed up into artificial neural network “feedforward” that had the function of estimating the surface roughness and the final diameters of the holes. The estimated values were used as inputs to a time delay neural network (TDNN) that acted in the prediction of the surface roughness and the final diameter of the next hole carried through, even before this hole was performed. Also, only the electrical motor power and force in Z axis were used as inputs to the first artificial neural network. All predicted values showed small errors when compared to the actual and the estimated values, the method was able to predict the values of roughness and diameter within the stipulated limits.

Keywords: drilling process monitoring, artificial neural network, hole diameter, surface roughness, prediction.

SUMÁRIO

DEDICATÓRIA.....	5
AGRADECIMENTOS	6
LISTA DE FIGURAS	7
LISTA DE TABELAS	11
LISTA DE TABELAS	11
LISTA DE SIMBOLOS.....	12
RESUMO.....	13
ABSTRACT	14
3) JUSTIFICATIVA PARA REALIZAÇÃO DO TRABALHO	22
4) REVISÃO BIBLIOGRÁFICA.....	23
4.1) <i>Redes Neurais Artificiais</i>	23
4.1.1) <i>Aspectos Biológicos de um Neurônio Humano</i>	24
4.1.2) <i>Modelo de um Neurônio Artificial</i>	25
4.1.3) <i>Conexão entre os Neurônios</i>	29
4.1.4) <i>Redes Neurais feedforward</i>	33
4.1.5) <i>Redes neurais recorrentes</i>	37
4.1.6) <i>Redes neurais com processamento temporal</i>	38
4.1.6.1) <i>Rede Neural “Time Delay Neural Network” - TDNN</i>	39
4.1.7) <i>Treinamento de Redes Neurais</i>	42
4.1.7.1) <i>Treinamento de redes feedforward</i>	44
4.1.7.2) <i>Treinamento de redes com algoritmos de retro-propagação</i>	48
4.1.7.3) <i>Treinamento com o Algoritmo dos Mínimos Quadrados</i>	52
4.1.7.4) <i>Matriz de Derivadas Parciais</i>	55
4.2) <i>Redes neurais aplicadas em processo de usinagem</i>	58

4.3) Processo de Usinagem - Furação.....	60
4.3.1 Cavacos	64
4.3.2 Forças na furação	67
4.3.3) Usinagem do Alumínio.....	68
4.3.4) Usinagem do Titânio	70
4.3.5) Brocas Metal Duro	71
4.3.6) Brocas Helicoidais.....	72
4.3.7) Rugosidade.....	75
4.3.7.1) Parâmetros de superfície geométrica	76
4.4) Sensores.....	79
5) MATERIAL E MÉTODOS.....	81
5.1) Preparação dos corpos de prova	81
5.2) Ferramentas de Corte	84
5.3) Confecção do banco de ensaios.....	85
5.4) Preparação da fresadora para os ensaios	87
5.5) Instalação dos sensores	88
5.5.1) Sensor de potência elétrica.....	89
5.5.2) Sensor de força.....	90
5.5.3) Sensor de emissão acústica	92
5.5.4) Acelerômetro – Sensor de Vibração	93
5.5.5) Ligação dos sensores a placa de aquisição.....	94
5.6) Parâmetros de corte utilizados no ensaio	95
5.7) Tratamento e análise dos sinais coletados	96
5.8) Medição dos diâmetros dos furos.	101
5.9) Medição da Rugosidade	103
5.10) Construção das redes neurais	105

5.10.1) Redes Neurais na Estimação do Diâmetro	107
5.10.2) Redes Neurais na Estimação da Rugosidade.....	108
5.10.3) Redes Neurais na Predição do Diâmetro Médio	110
5.10.4) Redes Neurais na Predição da Rugosidade.	111
5.11) Melhor configuração das redes com a utilização dos Sinais de Potência do Motor Elétrico e Força de corte no eixo Z.	113
6) RESULTADOS E DISCUSSÃO	115
6.1) Comportamento dos Diâmetros de Rugosidades durante os ensaios de Furação.....	115
6.2) Comportamento dos sinais coletados durante a Furação.....	120
6.3) Comportamento dos Diâmetros	125
6.4) Comportamento dos Rugosidades.....	127
6.5) Redes neurais com todos os sinais aquisitados	129
6.5.1) Redes neurais utilizadas para Estimação dos Diâmetros	130
6.5.2) Redes neurais utilizadas para Estimação da Rugosidade	133
6.5.3) Redes neurais utilizadas para Predição dos Diâmetros.....	137
6.5.4) Redes neurais utilizadas para Predição da Rugosidade.....	140
6.6) Visão geral dos Erros encontrados para as redes de estimação e predição com a utilização de todos os sinais	143
6.7) Redes Neurais com Sinais de Força no eixo Z e Potência	145
6.7.1) Redes utilizadas para Estimação/Predição dos Diâmetros.....	145
6.7.2) Redes utilizadas para Predição da Rugosidade	149
6.8) Erros para as redes de estimação e predição com a utilização dos sinais de Potência e a Força no eixo Z	153
7) CONCLUSÃO	156
8) SUGESTÕES PARA TRABALHOS FUTUROS	157
REFERÊNCIAS BIBLIOGRÁFICAS	159

ANEXO1.....	171
ANEXO2.....	174
ANEXO3.....	176
ANEXO4.....	178
ANEXO5.....	179
ANEXO6.....	180

1) Introdução

Em qualquer processo industrial, as condições de operação estão sujeitas às variações ao longo do tempo. Controlar um processo significa atuar sobre ele, ou sobre as condições na qual o processo está inserido, de modo a atingir um objetivo, como por exemplo, manter um processo sempre próximo a um determinado estado estacionário, mesmo que efeitos externos tentem desviá-lo dessa condição. Esse estado estacionário deve melhor atender aos requisitos de qualidade, engenharia e segurança do processo. É imprescindível saber o que se deseja controlar em um processo para que os melhores métodos possam ser selecionados.

A furação de precisão, em um único passe e sem a utilização de lubrificação, abordada neste trabalho, é um processo de fabricação onde são exigidas apertadas tolerâncias dimensionais, acima de ISO IT11 – IT14, e um bom acabamento superficial, em torno de 1,6 Ra. Tal processo é largamente utilizado em montagens estruturais dentro das industriais aeronáuticas para a instalação de pinos interferentes, pois se busca o aumento de produtividade sem a contaminação do selante necessário para vedação entre as chapas. Furos com diâmetros de 1/8", 5/32" e 3/16" costumam trabalhar com classe de interferência na ordem de $\pm 25 \mu\text{m}$ para ligas de Alumínio e $\pm 24 \mu\text{m}$ para ligas de Titânio (NAS618).

Furos de precisão podem ser obtidos com a utilização de vários passes de furação, com brocas de diâmetros escalonados e, no final do processo, com outra ferramenta de corte chamada alargador, que dá o acabamento, trazendo o furo para o diâmetro e rugosidade final. Este processo normalmente é lento e oneroso, devido à grande quantidade de brocas e alargadores de diferentes diâmetros necessários para a realização de um único furo de precisão (AMORIM, 2003).

Com uma maior participação das máquinas automáticas aos processos produtivos, especialmente aos de usinagem, associados ao desenvolvimento de ferramentas de corte com materiais e geometrias de melhor desempenho, maior rigidez estrutural das máquinas ferramentas, trazem ganhos significativos

para a redução dos custos operacionais e ciclos produtivos (Stoeterau, 2004). Essa mesma evolução foi capaz de criar um processo que consegue alcançar os requisitos dimensionais apertados, como os estudados neste trabalho, com um único passe de furação.

A modelagem matemática do processo estudado requer um grande conhecimento do fenômeno, principalmente quando a dinâmica for não-linear. Dependendo do grau de precisão que se deseja obter, a modelagem pode se tornar mais complexa, e seu estudo mais demorado. Existe, portanto, um compromisso entre a sofisticação e a qualidade de ambos. Outro aspecto que frequentemente dificulta a modelagem de sistemas dinâmicos é a grande quantidade de parâmetros (não necessariamente variáveis de estado) que se alteram em função da posição e do tempo (CARRARA, 1997).

Redes neurais artificiais (RNAs) mostram um expressivo sucesso na identificação e controle de sistemas dinâmicos (químicos, mecânicos, eletrônicos e térmicos), quando o equacionamento matemático do fenômeno químico-físico estudado é de grande complexidade e com inúmeras variáveis que podem influenciar a dinâmica da reação. A utilização de redes neurais artificiais consegue estabelecer a correspondência entre as variáveis do sistema e resposta desejada (CHEN *et al.*, 1990; CHEN e BILLINGS, 1989). As RNAs, já foram utilizadas em sistemas de direção automática em veículos automotores, em análise de aplicações financeiras e bolsas de valores, síntese de vozes, reconhecimento visual e reconstrução de padrões, previsão de variação cambial, controle de processos em manufatura, sistemas visuais de inspeção de qualidade, controle de manipuladores robóticos, entre outros (DEMUTH e BEALE, 1992). Valores preditos por sistemas de redes neurais têm boa correlação com os valores obtidos em laboratório, o que as credencia aplicações em ambientes industriais (AGUIAR *et al.*, 2008).

Este trabalho propõe um método de prever, um passo à frente, o diâmetro médio e rugosidade de furos, realizados em um único passe por meio de sinais provenientes do processo de usinagem e integrados a redes neurais artificiais, com satisfatória precisão para os padrões aeronáuticos.

2) Objetivo

O objetivo deste trabalho foi realizar a predição da rugosidade Ra e do diâmetro médio de furos realizados por meio de brocas helicoidais, utilizando os sinais provenientes da potência do motor elétrico, da emissão acústica, da força de avanço e vibração durante um processo de furação de ligas aeronáuticas.

Para tal objetivo, foi necessário que os sinais coletados fossem enviados primeiramente a uma rede neural artificial do tipo *Perceptron* multicamadas (MLP), que teve a função de estimar os valores de diâmetros médios e rugosidades Ra, para que uma segunda rede neural do tipo *Time Delay Neural Network* (TDNN), rede neural de atrasos temporais, pudesse prever o valor de rugosidade Ra e diâmetro médio um passo a frente, mesmo antes de esse ser realizado.

3) Justificativa para Realização do Trabalho

As indústrias de maneira geral buscam, dentro de suas atividades, processos cada vez mais estáveis e controláveis. Os mecanismos de monitoramento que geram informações avançadas de um possível desvio no processo de fabricação são de grande utilidade para que os altos níveis de qualidade sejam mantidos e os custos de não conformidades possam ser reduzidos.

Uma vez que a tendência de desvio no processo de fabricação é percebida, inúmeros meios podem ser acionados para evitar a não conformidade. Nesse contexto e para este trabalho, pode ser entendido como não conformidade uma variação dimensional tanto do diâmetro médio, como da rugosidade Ra desses furos fora dos limites de controle especificados em projeto.

Um processo de fabricação no qual as medições não interrompam o processo produtivo, tomando tempo de ciclo e conseguindo gerar informações um passo à frente com precisão podem, com certeza, evitar desvios de qualidade e reduzir custos de fabricação.

O método de predição proposto neste trabalho aplica-se a qualquer indústria que utilize o processo de furação em máquina CNC, e tem especial importância para as indústrias de fabricação de estruturas aeronáuticas, que utilizam do processo de furação de precisão em larga escala. Nessas empresas, a falta de um sistema de controle confiável onera significativamente os custos de produção e não garante a qualidade plena de seus componentes.

Este trabalho também buscou contribuir para o desenvolvimento de métodos inteligentes aplicados ao controle e monitoramento do processo de usinagem na manufatura.

4) Revisão Bibliográfica

Nesta revisão bibliográfica serão abordados os principais tópicos que dão subsídio à discussão acadêmica do trabalho, assim como irão fundamentar a metodologia aplicada durante os ensaios, discussões apresentadas e à conclusão final deste trabalho.

Também será abordada a importância deste trabalho para fins industriais e os benefícios da utilização de redes neurais artificiais na predição de características de processo.

4.1) Redes Neurais Artificiais

No mundo real, fora de ambientes controlados, existem fenômenos com inúmeras variáveis e que tornam os equacionamentos matemáticos extremamente complexos e de difícil correlação. Sendo assim, as redes neurais artificiais podem simplificar a real natureza dos fenômenos e trazer uma correlação entre os parâmetros de entrada e variáveis de saída.

As redes neurais artificiais têm como base os estudos sobre a estrutura do cérebro humano para tentar entender sua forma inteligente de processar informações. Mesmo desconhecendo a maneira pela qual o cérebro humano manipula informações com inúmeros parâmetros de entrada, a modelagem do conhecimento contido em um problema específico pode ser representada através das interconexões entre as células nervosas.

As pesquisas em redes neurais artificiais tentam, em sua abrangência, entender o funcionamento da inteligência que reside nos neurônios humanos e mapeá-la para uma estrutura artificial, por exemplo, uma combinação de hardware e software, assim transformando as redes neurais artificiais em redes neurais biológicas (TAFNER, 1999).

4.1.1) Aspectos Biológicos de um Neurônio Humano

A Rede Neural Humana é baseada em inúmeros conjuntos de neurônios, onde todas as funções biológicas e motoras do organismo estão relacionadas ao funcionamento dessas pequenas células. (CARVALHO, 2004).

Estruturalmente, a rede neural artificial, também conhecida por modelo conexionista de computação, se assemelha à rede neural biológica pela composição de seus neurônios e pela conexão entre eles (WASSERMAN, 1989).




Figura 1 - Estrutura do neurônio biológico (adaptado de www.rc.unesp.br/biosferas/mat0002.php).

Os principais elementos que compõem essa célula humana são o corpo celular, os dendritos e os axônios.

O corpo celular é também chamado de *soma*, e é formado por um conjunto de estruturas celulares, como núcleo, citoplasma e suas organelas. Sua principal função é dar suporte metabólico para manter a célula viva, além de ser responsável por coletar e combinar informações vindas de outros neurônios (CARVALHO, 2004).

Os dendritos são prolongamentos na forma de ramificações que normalmente formam uma árvore dendrital que pode ter um volume maior que o corpo celular. Possuem poucos milímetros de comprimento e têm como função fazer a comunicação entre os neurônios através das conexões sinápticas, possuindo, para isso, a região receptora e outra efetora.

Os axônios são também chamados de fibras nervosas e são extensões tubulares, longas e únicas encontradas no corpo celular. São responsáveis por transmitir impulsos elétricos para outras células (CARVALHO, 2004).

O neurônio pode ser considerado um dispositivo computacional à base de carbonos que possui muitas entradas e uma única saída. Os estímulos de entrada são recebidos através de ligações, denominadas de sinapses, entre os dendritos e os axônios de outras células. As informações fluem, em forma de impulsos elétricos do axônio para o dendrito. No próximo neurônio, essa informação é então processada e, através de funções ativadoras ou inibidoras, é produzida a resposta. A transferência de um impulso elétrico se dá pela sinapse e é feita por mediadores químicos que processam em sentido único, do axônio para o dendrito (TAFNER, 1998). A substância responsável pela emissão do impulso elétrico é chamada de neurotransmissor. Sua intensidade varia de acordo com sua concentração, dimensão geométrica da sinapse e distância do axônio ao neurônio (CARVALHO, 2004).

4.1.2) Modelo de um Neurônio Artificial

Semelhante ao sistema nervoso que é composto por bilhões de células, a rede neural artificial também é formada por inúmeras unidades de processamento, ou neurônios artificiais, que podem ser entendidos como pequenos módulos que simulam o funcionamento de um neurônio biológico.

Estes módulos são ligados por conexões sinápticas, que estão associadas a determinados pesos. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma rede neural artificial vem das interações entre as unidades de processamento da rede (TAFNER, 1998).

Na formulação computacional de uma rede neural, admite-se que a informação flui através dos neurônios sequencialmente e instantaneamente, isto é, as saídas dos diversos neurônios estão sincronizadas entre si, e não há atraso temporal significativo entre os sinais. Essa idealização, na verdade, não ocorre em um neurônio natural, pois além de não haver sincronismo nas conexões entre eles, existe um atraso entre a excitação e a resposta. Na

tentativa de aproximar o funcionamento do neurônio artificial de seu equivalente biológico, é introduzida uma dinâmica linear na operação efetuada pelo neurônio (HOPFIELD, 1982; HUNT *et al.*, 1992). Essa dinâmica produz um atraso na resposta e, portanto, faz com que o neurônio atue como um elemento armazenador de informação. A Figura 2 ilustra de maneira esquemática o funcionamento de um neurônio artificial.




Figura 2 - Estrutura do neurônio artificial (EYNG, 2008).

Na implementação computacional, esse atraso é responsável pelo sincronismo nas saídas dos neurônios em redes com grande número de conexões. Embora, na proposição de Hopfield, a cada intervalo de tempo apenas um neurônio qualquer da rede (escolhido aleatoriamente) tem sua saída avaliada, o que a torna completamente assíncrona. A dinâmica linear, nem sempre presente na modelagem do neurônio, aplica uma integral de convolução no valor de entrada, na forma (CARRARA, 1997):

$$z(t) = \int_{-\infty}^t h(t-t') \bar{x}(t') dt' \quad (4.1)$$

na qual $\bar{x}$ constitui o somatório das entradas ponderadas no neurônio, dado por:

$$\bar{x}(t) = \sum_{i=1}^n w_i x_i(t) \quad (4.2)$$

sendo que x_i , $i = 1, \dots, n$, constituem as entradas do neurônio combinadas linearmente no somatório através dos pesos $w_1, w_2, \dots, w_n$.

Se a transformação $h(t)$ representar uma função exponencial, a convolução resulta em:

$$\alpha_0 \dot{z}(t) + \alpha_1 z(t) = \bar{x}(t) \quad (4.3)$$

válida para sistemas contínuos, com α_0 e α_1 constantes. No caso discreto, a integral resulta:

$$\alpha_0 z(t+1) = \bar{x}(t) - \alpha_1 z(t) \quad (4.4)$$

na qual o atraso introduzido pela dinâmica linear fica evidente.

Ao resultado da dinâmica linear, acrescido de um limiar de ativação ou patamar b , é aplicada uma função de ativação, $f()$, geralmente uma função não linear limitada. A saída do neurônio é dada então por:

$$y(t) = f(z(t) + b) \quad (4.5)$$

O desempenho característico de uma rede neural artificial é, em grande parte, influenciado pelo tipo de função de ativação escolhida. Em problemas de classificação, reconhecimento de padrões e memorização, quando as respostas geralmente assumem poucos valores (sim ou não, 0 ou 1, etc.) empregam-se funções de ativação descontínuas do tipo degrau, linear truncada ou a função sinal (HUNT *et al.*, 1992; DEMUTH e BEALE, 1992).

Segundo Carrara, 1997, sistemas contínuos não-lineares utilizam funções contínuas e não-lineares nas camadas intermediárias da rede e

agrupam-nas linearmente na saída. Entre essas funções, destacam-se a função sigmóide:

$$f(x) = \frac{1}{1 + e^{-\alpha x}} \quad (4.6)$$

e suas variações como a função tangente hiperbólica, que é mostrada na Figura 3 (juntamente com sua derivada):




Figura 3 - Função de ativação tangente hiperbólica e derivada (CARRARA, 1997).

$$f(x) = \frac{1 - e^{\alpha x}}{1 + e^{\alpha x}} \quad (4.7)$$

O parâmetro α , positivo, estabelece o grau de transição entre os limites inferior e superior da função sigmóide. Para valores grandes de α a tangente hiperbólica se aproxima da função sinal. Também bastante utilizada como função de ativação é a gaussiana dada por:

$$f(x) = e^{-x^2 / \sigma^2} \quad (4.8)$$

A função de ativação irá definir as formas de treinamento possíveis para a rede. Certos procedimentos de determinação dos pesos requerem, por exemplo, que essa função seja limitada e diferenciável em todos seus pontos.

4.1.3) Conexão entre os Neurônios

Dependendo de como são realizadas as conexões entre os neurônios, tanto o seu comportamento, como sua forma de treinamento é afetada. Uma possibilidade frequentemente empregada é a disposição dos neurônios em camadas, com as saídas de uma determinada camada conectadas nas entradas de todos os neurônios da próxima camada e, assim por diante. Outro aspecto de grande importância no comportamento das redes neurais é a maneira como os dados são tratados dentro de sua estrutura (CARRARA, 1997).

Com o intuito de facilitar o entendimento das redes neurais a seguir, as ilustrações são compostas de somente duas camadas com dois neurônios em cada. Redes Neurais mais complexas podem conter inúmeras camadas escondidas com inúmeros neurônios.

A Figura 4 representa uma rede estática ou de alimentação direta (*feedforward*). A arquitetura dessa rede foi utilizada para estimar o valor do diâmetro e da rugosidade na primeira etapa do trabalho na qual os sinais coletados dos sensores instalados na fresadora alimentavam a rede.




Figura 4 - Rede estática ou com alimentação direta – modificada de CARRARA, 1997.

Na Figura 5, as saídas da rede são realimentadas nas entradas, constituindo uma configuração bastante utilizada na identificação de sistemas, denominado de modelo em paralelo (NARENDRA e PARTHASARATHY, 1990).




Figura 5 - Rede com realimentação na saída – modificada de CARRARA, 1997.

Na Figura 6 há uma realimentação entre camadas, isto é, as saídas de uma determinada camada são realimentadas na camada anterior. Além disso, ocorrem também conexões laterais (a saída de um neurônio de uma determinada camada alimenta os neurônios da mesma camada) e recorrência (auto-realimentação dos neurônios) nesse tipo de rede (JIN *et al.*, 1994).




Figura 6 - Rede com realimentação entre camadas, conexões laterais e recorrência – modificada de CARRARA, 1997.

Na rede com conexão completa, mostrada na Figura 7, a saída de cada neurônio alimenta todos os outros, inclusive a si próprio. Como as entradas da rede também excitam os outros neurônios, a noção de camadas perde o sentido. Ainda assim, pode-se dizer que nesta configuração a rede apresenta uma camada de saída, cujos neurônios são conectados diretamente aos sinais de saída, e uma camada interna não conectada a estes sinais. A saída dos neurônios internos é, algumas vezes, denominada de hiperestado da rede (ZBICOWSKI e GAWGHROP, 1992).




Figura 7 - Rede com neurônios completamente conectados – modificada de CARRARA, 1997.

A saída de uma rede neural estática pode ser colocada em termos de suas entradas como na relação 4.9, que não reflete necessariamente um comportamento dinâmico.

$$y = f(x) \quad (4.9)$$

Devido a esse comportamento, redes estáticas têm uso limitado na identificação de sistemas dinâmicos, podendo ocasionar instabilidade e um aprendizado deficiente. Entretanto, o uso de redes estáticas para controlar sistemas é um processo viável, caso seja possível atribuir uma forma não dinâmica ao controlador, como por exemplo, para prover um ganho não-linear num sistema de realimentação de erro (ZBICOWSKI e GAWGHROP, 1992).

Numa rede realimentada, a sincronia ou o atraso na realimentação exerce papel fundamental. Note-se na Figura 7, por exemplo, que a rede fornece a saída no instante $t + \delta t$, e essa informação é realimentada no instante t .

Para tornar esse atraso evidente, adota-se um neurônio dinâmico, ou, no caso em que o neurônio não possua um comportamento dinâmico, pode-se introduzir na malha de realimentação um elemento de atraso: um integrador ou um armazenador. Assim, a rede discretizada fornece na saída uma relação na forma:

$$y(t+1) = f[y(t), x(t)] \quad (4.10)$$

Este processo, infelizmente, é impraticável nas redes contendo conexões laterais e de recorrência, conforme mostram a Figura 6 e Figura 7. Torna-se necessário, então, admitir que cada neurônio tem uma dinâmica própria, capaz de prover por si só o atraso necessário (CARRARA, 1997).

A saída de cada neurônio, no instante $k+1$, fica determinada pelo estado em que os demais neurônios a ele conectados possuem no instante k . O estado assumido pela camada k da rede da Figura 7, por exemplo, no instante $t+1$ pode possuir a forma:

$$x^k(t+1) = f^k[W^{k-1,k}x^{k-1}(t) + W^{k,k}x^k(t) + W^{k+1,k}x^{k+1}(t)] \quad (4.11)$$

em que W_{ij} é a matriz de peso que relaciona a saída dos neurônios da camada i à entrada dos neurônios da camada j , e f^k é a função de ativação da camada k .

O primeiro termo do argumento da função de ativação traduz a alimentação direta (*feedforward*); o segundo compreende as conexões laterais (*crosstalk*) e recorrência (*recurrency*), e o terceiro termo é a realimentação (*feedback*) da camada posterior. É claro que a expressão 4.11 deve ser modificada, convenientemente, quando se tratar da primeira e última camada, visto que nesses casos não deve haver, respectivamente, alimentação direta e realimentação (CARRARA, 1997).

Embora o treinamento possa ser dificultado face às interconexões existentes, o poder de representação de sistemas dinâmicos dessas redes é aumentado pelo mesmo motivo. Essa formulação, embora simplificada, é análoga à relação 4.4, com a constante α_1 nula (JIN, *et al.*, 1994).

A estabilidade das redes neurais realimentadas é um problema bastante abordado na literatura. Embora ainda careçam de prova abrangente, alguns resultados parciais garantem a estabilidade da rede neural sob certas hipóteses simplificadas (HUNT *et al.*, 1992, ETXEBARRIA, 1994). Uma das possibilidades para a prova de estabilidade consiste em se admitir que o

sistema dinâmico possa ser representado por uma equação diferencial linear invariante no tempo (CARRARA, 1997).

4.1.4) Redes Neurais *feedforward*

Na sua forma típica, esta rede apresenta várias camadas de neurônios artificiais, em que cada camada é composta por vários neurônios não dinâmicos, conforme esquematizado na Figura 8.




Figura 8 - Representação de uma rede neural de alimentação direta com duas camadas – modificada de CARRARA, 1997.

As diferentes camadas da rede ponderam suas respectivas entradas com pesos e aplica a função ativação no somatório das entradas ponderadas, para cada uma de suas saídas. Cada camada de uma rede é formada por vários neurônios, e a forma usual de representação de uma camada é dada na Figura 9. A camada k representada na figura 9 possui n_{k-1} argumentos na entrada e n_k parâmetros de saída. O expoente dos vetores e matrizes se referem ao número da camada em questão (CARRAR, 1997).




Figura 9 - Entradas e saídas da camada k de uma rede neural – modificada de CARRARA, 1997.

A saída x_i^k apresentada pelo neurônio i da camada k é então dada pela relação:

$$x^k = f^k \left(\sum_{j=1}^{n_{k-1}} w_{ij}^k x_j^{k-1} + b_i^k \right) \quad (4.12)$$

O processo de determinação do patamar fica automaticamente transferido para a estimação de mais um conjunto de pesos associados à entrada unitária. É claro que nem sempre esse artifício pode ser empregado, particularmente em redes cujas funções de ativação incluem o patamar de forma não-linear. Nesses casos, uma formulação convencional pode ser realizada (CARRARA, 1997).

O processo de cálculo efetuado pela rede neural pode ser colocado numa forma algébrica utilizando vetores e matrizes, confirmando assim a característica de paralelismo apresentada pelas redes. Nesta notação, sendo W^k a matriz de pesos da camada k , o vetor de saída desta camada fica:

$$x^k = f^k(W^k x^{k-1}) \quad (4.13)$$

na qual o vetor x^k e a matriz de pesos W^k são compostos por:

$$x^k = \begin{bmatrix} f^k(\bar{x}_1^k) \\ \vdots \\ f^k(\bar{x}_{n_i}^k) \\ 1 \end{bmatrix} \quad (4.14)$$

$$W^k = \begin{bmatrix} w_{11}^k & \cdots & w_{1n_{i-1}}^k & b_1^k \\ w_{21}^k & \cdots & w_{2n_{i-1}}^k & b_2^k \\ \vdots & \cdots & \vdots & \vdots \\ w_{n_i 1}^k & \cdots & w_{n_i n_{i-1}}^k & b_{n_i}^k \end{bmatrix} \quad (4.15)$$

e, portanto, com a introdução do patamar dentro da matriz de pesos, as dimensões de x^k e W^k estendem-se para n^k+1 e n^k e $n^{k-1}+1$, respectivamente.

Segundo Carrara, 1997, diversas camadas podem ser agrupadas para formar uma rede neural estática. Geralmente, as funções de ativação são comuns para as camadas intermediárias, mas diferem da última. Redes estáticas com duas camadas (uma camada oculta e outra de saída) aplicam, primeiro, uma função de ativação não-linear (sigmóide ou tangente hiperbólica) nos parâmetros de entrada, para, em seguida combiná-los linearmente na saída. Se n^k for o número de neurônios da camada k de uma rede composta por l camadas, então, o vetor de saídas da rede, x^l , é função do vetor de entrada x^0 na forma:

$$x^l = f^l(W^l f^{l-1}(W^{l-1} \dots f^1(W^1 x^0) \dots)) \quad (4.16)$$

O número de camadas influi na qualidade dos resultados da rede, e pode ser mostrado que uma rede com um número maior de camadas geralmente apresenta resultados melhores, quando comparados com uma rede com menores camadas e mesma quantidade de neurônios (NGUYEN e WIDROW, 1990; CHEN e BILLINGS, 1992). No entanto, a capacidade de generalização da rede, isto é, o grau de aproximação nos pontos na qual a rede não foi treinada, é mais pronunciado nas redes com poucas ou apenas uma camada oculta (BAFFES *et al.*, 1991).

Por outro lado, redes com mais camadas conseguem uma maior precisão nos pontos na qual ela foi treinada. De qualquer forma, pode ser mostrado que uma rede com duas camadas, sendo a segunda uma combinação linear das saídas não-lineares da primeira camada, pode representar com um dado grau de aproximação qualquer função não-linear contínua e limitada. Sistemas dinâmicos estáveis, representados por equações diferenciais ou a diferenças em termos das variáveis de estado e de ação, possuem característica de continuidade e confinamento e podem, por isso, serem aproximadas por redes neurais (CHEN e BILLINGS, 1992).

Portanto, quando a dinâmica do sistema a ser modelado não for complexa, uma rede estática de duas camadas com função de transferência do tipo sigmóide na primeira camada e linear na camada de saída irá produzir resultados satisfatórios na maior parte das aplicações. O número de neurônios nas camadas intermediárias (ou ocultas) é importante do ponto de vista da aproximação dos resultados. Poucos neurônios levam à instabilidade ou má aproximação. Muitos neurônios, por sua vez, além de sobrecarregar o tempo de aprendizado, podem acarretar grandes oscilações da saída nos pontos em que a rede não foi treinada (BILLINGS *et al.*, 1992). Na verdade, utilizam-se redes com mais de duas camadas somente em sistemas muito complexos, principalmente para reduzir o número de neurônios total da rede e aumentar o desempenho computacional (CARRARA, 1997).

O treinamento de redes estáticas consiste em métodos de obtenção de seus parâmetros. Esses parâmetros são formados nos pesos associados às conexões ligando os diversos neurônios e seus respectivos patamares (bias). Os algoritmos de treinamento normalmente partem da minimização do erro apresentado na saída da rede como forma de obtenção dos pesos e variam, também, conforme, a forma de implementação: podem ser estimadores por lote, estimação estocástica (NETO, 1994) ou por recursão, sendo que esses últimos são utilizados mais frequentemente, devido principalmente à facilidade de uso do algoritmo recursivo de retro-propagação do erro.

Cabe ainda salientar que, uma vez concluído o treinamento de uma rede estática, a diferença entre o sistema real e o resultado da rede é função exclusiva do número de neurônios empregado, do número de camadas e da forma de treinamento (CARRARA, 1997).

4.1.5) Redes neurais recorrentes

Uma rede neural recorrente se distingue de uma rede neural alimentada adiante por ter pelo menos um laço de realimentação. Uma rede recorrente pode ser formada, por exemplo, de uma única camada de neurônios com cada neurônio alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios, como ilustrado na Figura 10. Na estrutura representada nessa figura, não há laços de auto-realimentação na rede; auto-realimentação se refere a uma situação na qual a saída de um neurônio é realimentada para a sua própria entrada. A rede recorrente, ilustrada na Figura 10, também não tem neurônios ocultos (HAYKIN, 2001).




Figura 10 – Rede recorrente sem laço de auto-realimentação e sem neurônio oculto – modificada de HAYKIN, 2001.

Na Figura 11, ilustra-se outra classe de redes recorrentes com neurônios ocultos. As conexões de realimentação mostradas na Figura 11 se originam dos neurônios ocultos e vêm como dos neurônios de saída.

A presença de laços de realimentação quer seja na estrutura recorrente da Figura 10 ou na Figura 11 tem um impacto profundo na capacidade de

aprendizagem da rede e no seu desempenho. Além disso, os laços de realimentação envolvem o uso de ramos particulares compostos de elementos de atraso unitários (representados por z^{-1}) o que resulta em um comportamento dinâmico não linear, admitindo-se que a rede neural contenha unidades não lineares (HAYKIN, 2001).




Figura 11 – Rede recorrente com neurônio oculto – modificada de HAYKIN, 2001.

4.1.6) Redes neurais com processamento temporal

O tempo constitui um ingrediente importantíssimo no processo de aprendizagem de uma rede neural artificial, podendo esse ser contínuo ou discreto. Independente de sua forma, o tempo é uma entidade ordenada de grande importância para muitas tarefas de reconhecimento de padrões, tais como, reconhecimento de voz, detecção de movimentos, visão, processamento de sinais, controle motor, entre outros. É com a incorporação do tempo na operação de uma rede neural que ela é capacitada a trabalhar com problemas de reconhecimento de padrões dinâmicos. Para que uma rede neural seja considerada dinâmica, ela precisa possuir memória (BRAGA *et al.*, 2000).

Alguns algoritmos de treinamento de redes neurais não são capazes de utilizar mapeamentos dinâmicos, como por exemplo, o algoritmo de *backpropagation*, que aprende apenas mapeamentos estáticos. Um artifício utilizado para processamento temporal é a utilização de janelas de tempo, em que a entrada da rede é formada por trechos das sequências temporais dos dados como se fossem padrões estáticos (FERREIRA, 2004).

Existem duas maneiras básicas de incluir memória a uma rede neural: Introduzir atraso no tempo ou utilizar redes recorrentes.

Redes recorrentes são aquelas em que a saída de algum neurônio na *i*-ésima camada da rede é utilizada como entrada de nodos em camadas de índice menor ou igual a *i* (FERREIRA, 2004).

Há dois tipos de redes recorrentes: aquelas em que o padrão de entrada é fixo e a saída caminha, dinamicamente, para um estado estável, e aquelas em que tanto a entrada quanto a saída variam com o tempo; essas últimas são mais gerais e são utilizadas com mais frequência (FERREIRA, 2004),

4.1.6.1) Rede Neural “*Time Delay Neural Network*” - TDNN

Buscando o melhor entendimento entre as diferentes técnicas de predição, avaliou-se uma pesquisa, a qual foi analisada métodos para detectar padrões de acessos de forma automática, que avaliam e comparam três métodos de detecção do padrão de acesso – um baseado em abordagem estocástica de Cadeias de Markov; um baseado em predição linear, e um método que utiliza redes neurais TDNN (SAKR *et al.*, 1996). Nessa pesquisa foram comparadas as eficiências dos mecanismos para a predição de acessos em curto prazo (*one-step-ahead prediction*). Os autores da pesquisa afirmam que, enquanto todas as técnicas apresentam uma eficiência compatível para padrões de acesso simples, com o aumento do grau de complexidade de acessos os modelos simples passam a se tornar ineficientes, e o modelo baseado em redes neurais TDNN oferece a melhor eficiência.

Redes neurais do tipo TDNN são caracterizadas pela utilização de uma topologia especial, voltada ao reconhecimento de sub-padrões independentes dentro de um padrão de entrada contínuo (WAIBEL *et al.*, 1989).

A técnica TDNN (WAIBEL *et al.*, 1989) é uma técnica que introduz atraso no tempo. As redes TDNN são alimentadas adiante, com múltiplas camadas, cujos nodos das camadas escondidas e da camada de saída são duplicados ao longo do tempo. A topologia de uma rede TDNN está embutida em uma rede PMC (*Perceptron* multicamadas), em que cada conexão é representada por um filtro de impulso de resposta com duração finita, conhecida como FIR (*Finite Duration Impulse Response*). Esse tipo de rede, conhecida como FIR MLP é treinada através da criação de uma rede estática equivalente. Essa rede é obtida desdobrando a FIR MLP no tempo. Após isso pode ser utilizado o algoritmo *backpropagation* padrão (BRAGA *et al.*, 2000). Utilizou-se a técnica de janelas de tempo como uma técnica TDNN, pois esta introduz atraso de tempo através da formatação dos dados de entrada (FERREIRA, 2004).

Pode-se, ainda, considerar uma rede neural TDNN, que em essência, é uma arquitetura *feedforward*, na qual sua resposta no tempo t é baseada nas entradas no tempo $(t-1)$, $(t-2)$, . . . , $(t-n)$. Assim, é considerado no treinamento da rede um histórico da sequência temporal dos dados.

Originalmente, as redes TDNN foram propostas para reconhecimento de som. Para esse trabalho algumas considerações foram feitas, tais como:

- 1) A rede é composta por múltiplas camadas e conexões, e é focada em aprendizado não-linear;
- 2) A rede deve ser capaz de representar relacionamentos entre eventos em tempo;
- 3) O número de pesos na rede deve ser suficientemente pequeno comparando com a quantidade de dados treinados. Dessa forma, a rede é forçada a codificar os dados observados, extraíndo regularidades e comportamentos repetitivos.

Em redes neurais convencionais, um neurônio é responsável por calcular uma soma ponderada de todas as suas entradas e, após isso, propagá-la por meio de uma função não-linear (geralmente função de corte ou sigmóide) para as próximas unidades. Na rede TDNN, as entradas são modificadas para introduzir n atrasos à entrada de dados. Dessa maneira, uma camada de entrada composta por y elementos gera $z = y(n + 1)$ entradas para a rede. Dessa forma, a rede necessita de z pesos para y entradas. Enquanto em redes neurais convencionais cada neurônio geralmente conecta-se

somente uma vez com outro da camada sucessora, no modelo TDNN são realizadas diversas conexões com pesos independentes. Antes do cálculo do peso de cada conexão, os dados sofrem um atraso que os elimina do cálculo da soma de pesos. Uma vez que cada conexão é associada a um comum atraso correspondente, as conexões atuam como o mecanismo de memória de curto prazo, possibilitando relatar e comparar o vetor de entrada atual aos dados observados anteriormente. As saídas de cada camada são computadas e utilizadas como valores de entrada para as camadas sucessoras, até chegar à camada de saída. Os valores de saída são comparados aos valores esperados, calculando o erro, que é propagado pela rede, atualizando os pesos e, conseqüentemente, decrementando o erro global. O procedimento é repetido até a rede convergir para a saída desejada. Dessa maneira, uma predição eficiente somente é possível após o treinamento repetitivo da rede (DODONOV, 2008).

Entre as extensões ao modelo TDNN pode-se citar a rede ATDNN (*Adaptive Time-Delay Neural Network*), que possibilita adaptar os atrasos da rede dinamicamente (DAY e DAVENPORT, 2003). A Figura 12 mostra como a rede neural temporal utiliza uma janela inicial para começar o processo de predição.




Figura 12 – Rede TDNN , DODONOV, 2008.

4.1.7) Treinamento de Redes Neurais

Na forma de treinamento que ocorrem as maiores diferenças nas várias implementações possíveis de redes neurais. O treinamento pode diferir de início, quer a rede seja estática ou dinâmica, entre outros fatores. O importante é buscar prover as características que melhor se adaptem ao problema em questão.

Embora seja possível, em determinadas situações, obter os pesos da rede diretamente a partir de um processo algébrico (SARTORI e ANTSAKLIS, 1992), os algoritmos iterativos são mais difundidos em virtude de diversos aspectos. Esses algoritmos, geralmente, bastante simples na sua formulação, utilizam critérios de busca por aproximações sucessivas, em que a função a ser minimizada depende da diferença entre o valor desejado na saída da rede e o valor realmente apresentado. Nas redes estáticas, algoritmos do tipo método do gradiente, com retro-propagação do erro, são bastante eficazes no treinamento. Este mesmo processo pode ser empregado nas redes dinâmicas, embora existam alternativas no caso de utilização de neurônios dinâmicos (HOPFIELD, 1982). Os algoritmos de treinamento são bastante variados em sua forma, mas, raramente, dispensam o uso do algoritmo de retro-propagação na avaliação do erro nas camadas intermediárias. Existem algumas ferramentas já implementadas em MATLAB que permitem a construção e o treinamento de redes em diversas configurações (DEMUTH e BEALE, 1992; NORGAARD, 1996).

Dependendo da maneira como as conexões entre os neurônios da rede são confeccionadas, a forma de treinamento é também afetada. Uma possibilidade de treinamento frequentemente empregada é à disposição dos neurônios em camadas, com as saídas de uma determinada camada conectadas nas entradas de todos os neurônios da camada seguinte, e assim por diante (CARRARA, 1997).

Redes realimentadas, como aquelas mostradas na Figura 13, podem ser treinadas para assumir dois tipos de comportamentos distintos: treinamento de ponto fixo e treinamento para trajetória.




Figura 13 – Esquema de rede do tipo realimentada, CORREA, 2004.

No primeiro caso, a saída apresentada pela rede deve ser igual à sua entrada, e o intuito é fazer com que a rede atinja o regime permanente num ponto de equilíbrio predefinido, com eventuais oscilações totalmente amortecidas. A rede é treinada com padrões não corrompidos por ruídos, que se tornam pontos de equilíbrio. A seguir, são apresentados para a rede alguns desses padrões contendo ruídos. A cada nova iteração, a saída da rede se aproxima do ponto de equilíbrio associado ao padrão apresentado e, como essa saída é realimentada na própria rede, ao fim de algumas iterações, obtém-se o resultado final. Esse tipo de treinamento é utilizado em problemas de reconhecimento de padrões (HOPFIELD, 1982; HUNT, 1992), embora, dado o seu caráter dinâmico, são também usualmente empregadas na identificação, isto é, na emulação de sistemas físicos.

Conforme citado anteriormente, uma rede estática embora não possua as características de comportamento dinâmico, a realimentação do estado do sistema, permite que ela adquira tal particularidade, mesmo na ausência da dinâmica linear embutida no modelo dos neurônios. Essa peculiaridade das redes estáticas, aliada à relativa facilidade de treinamento fornecida pelo algoritmo de retropropagação do erro, faz com que ela se torne uma poderosa ferramenta na identificação e controle de sistemas dinâmicos (CARRARA, 1997).

4.1.7.1) Treinamento de redes *feedforward*

O treinamento de uma rede neural consiste num procedimento numérico de estimação dos pesos, geralmente baseado na minimização de uma função que depende do erro apresentado na saída da rede. Diferentes processos de obtenção dos pesos, e diferentes funções de minimização levam a diferentes algoritmos de treinamento, com características particulares que se prestam melhor para resolver determinados problemas. Quase todos os algoritmos, entretanto, utilizam a retro-propagação do erro (RUMERLHART *et al.*, 1986) na estimativa dos pesos das camadas ocultas. Um dos algoritmos mais utilizados no treinamento de uma rede é o algoritmo do gradiente, que, por estar fortemente associado ao algoritmo de retro-propagação, é confundido com esse em alguns trabalhos.

O algoritmo de retro-propagação consiste, na verdade, de uma fórmula recorrente para obter a variação apresentada na saída de um dado neurônio, quando um dos pesos da rede é alterado. Esta derivada, como será visto, pode ser descrita em termos das derivadas dos neurônios da camada imediatamente anterior, o que caracteriza uma relação recorrente. Com isso a derivada é obtida para a saída apresentada na última camada, a seguir para a penúltima e assim por diante, de onde procede ao nome de retro-propagação. O algoritmo do gradiente utiliza essa forma de retro-propagação para propagar o erro na saída da rede até as camadas ocultas, para com isso efetuar um ajuste nas matrizes de pesos dessas camadas. Já o algoritmo de mínimos quadrados, também mostrado a seguir, utiliza a retro-propagação para obter a variação de cada sinal na saída com relação a todos os pesos que constituem a rede. Uma vez obtida essa variação, efetua-se um ajuste nos pesos de forma a minimizar o erro final da rede (CARRARA, 1997).

O algoritmo de retro-propagação é formado da derivada parcial do valor apresentado na saída de um determinado neurônio com relação a um determinado peso de uma camada anterior. Considere então a componente i do vetor x^k apresentado na saída da camada k . A derivada dessa componente com relação ao peso j associado a esse neurônio é obtida derivando-se a expressão 4.13, e resulta:

$$\frac{\partial x_i^k}{\partial w_{ij}^k} = f^{k'}(\bar{x}_i^k) x_j^{k-1} \quad (4.17)$$

na qual $f^{k'}(x)$ é a derivada da função de ativação da camada k com relação ao seu argumento. É claro que se fosse escolhido outro componente do vetor x^k (por exemplo, m), essa derivada seria nula, já que essa componente não depende do peso w_{ij} . A derivada pode ser posta em termos vetoriais, resultando:

$$\frac{\partial x^k}{\partial w_{ij}^k} = F^k \begin{bmatrix} 0 \\ \vdots \\ x_j^{k-1} \\ \vdots \\ 0 \end{bmatrix} \quad (4.18)$$

na qual todas as componentes da última parcela são nulas, exceto a i -ésima componente, e F^k é uma matriz diagonal contendo as derivadas da função de ativação:

$$F^k = \frac{df^k(\bar{x}^k)}{d\bar{x}^k} = \begin{bmatrix} f^{k'}(\bar{x}_1^k) & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & f^{k'}(\bar{x}_{n_k}^k) \end{bmatrix} \quad (4.19)$$

sendo a função de ativação conhecida e contínua, a derivada pode ser avaliada em todos os valores de x_k . Considere, agora, a variação da componente m com relação ao peso w_{ij} da camada anterior, $k-1$:

$$\frac{\partial x_m^k}{\partial w_{ij}^{k-1}} = f^{k'}(\bar{x}_m^k) \sum_{s=1}^{n_{k-1}} w_{ms}^{k-1} \frac{\partial x_s^{k-1}}{\partial w_{ij}^{k-1}} \quad (4.20)$$

Veja que a derivada de x_s da camada $k-1$ é análoga à derivada obtida na equação 4.17, desde que s seja igual a i ; para outros valores de s a derivada resulta nula e, portanto:

$$\frac{\partial x_m^k}{\partial w_{ij}^{k-1}} = f^{k'}(\bar{x}_m^k) w_{mi}^k f^{k-1'}(\bar{x}_i^{k-1}) x_j^{k-2} \quad (4.21)$$

ou, na forma vetorial:

$$\frac{\partial \mathbf{x}^k}{\partial \mathbf{w}_{ij}^{k-1}} = F^k W^k F^{k-1} \begin{bmatrix} 0 \\ \vdots \\ x_j^{k-2} \\ \vdots \\ 0 \end{bmatrix} \quad (4.22)$$

na qual, novamente, todas as componentes do vetor do segundo membro são nulas, exceto a i -ésima.

Essas expressões permitem estabelecer formas de recorrência, na qual a derivada com relação ao peso de uma dada camada é obtida a partir de valores calculados durante a avaliação da derivada das camadas superiores, caracterizando com isso a retro-propagação. A derivada do elemento m da camada i (suposta como a última camada da rede), com relação ao peso j associado ao neurônio i da camada k fica então:

$$\frac{\partial x_m^i}{\partial w_{ij}^k} = \delta_{m,i}^k x_j^{k-1} \quad (4.23)$$

onde os escalares $\delta_{m,i}^k$, são obtidos de forma recorrente:

$$\delta_{m,i}^k = f^{k'}(\bar{x}_i^k) \sum_{s=1}^{n_k+1} \delta_{m,s}^{k+1} w_{si}^k \quad (4.24)$$

com condição inicial dada por:

$$\delta_{m,i}^l = \begin{cases} f'^l(\bar{x}_i), & \text{se } \dots i = m \\ 0, & \text{se } \dots i \neq m \end{cases} \quad (4.25)$$

As relações 4.23, 4.24 e 4.25 podem ser traduzidas na forma de operações entre matrizes, onde a derivada do vetor de saídas da rede fica sendo dada por:

$$\frac{\partial x^l}{\partial w_{ij}^k} = \Delta^k \begin{bmatrix} 0 \\ \vdots \\ x_j^{k-1} \\ \vdots \\ 0 \end{bmatrix} \quad (4.26)$$

e a matriz de retro-propagação, Δ^k vale:

$$\Delta^k = F^l W^l F^{l-1} W^{l-1} \dots F^{k+1} W^{k+1} F^k \quad (4.27)$$

ou, na forma recorrente:

$$\Delta^k = \Delta^{k+1} W^{k+1} F^k \quad (4.28)$$

desde que se conheça, a princípio, o valor inicial da matriz I , que para a camada de saída, I , vale $I = F^l$. As componentes da matriz de retro-propagação são dadas pelos δm_i^k , fornecidos na equação 4.24. Nota-se que a matriz k possui dimensão de $n_l \cdot n_k$. Quando multiplicada pelo erro na saída, essa matriz constitui uma forma de retro-propagação do erro, o que permite o ajuste dos pesos nas camadas ocultas da rede. Vale ainda salientar que a dimensão da matriz de pesos da camada k é de $n_k \cdot n_{k-1} + 1$, já incluindo os pesos referentes ao patamar de ativação na última coluna. Nesse caso, a matriz de derivadas da função de ativação, F^k , deveria possuir dimensão $n_{k-1+1} \cdot n_{k-1+1}$, mas como o último elemento da diagonal é sempre nulo (por

representar a derivada de uma constante), pode-se reduzir a dimensão da matriz de pesos (e também da matriz F) durante as multiplicações (CARRARA, 1997).

4.1.7.2) Treinamento de redes com algoritmos de retro-propagação

O algoritmo de treinamento, conhecido como gradiente do erro (também conhecido como retro-propagação), é, sem dúvida, o mais difundido e utilizado entre todos os outros algoritmos (HUNT *et al.*, 1992). A sua principal vantagem reside no alto grau de paralelismo alcançado por esse método na atualização dos pesos da rede.

Sua origem remonta ao início da década de 60, quando Widrow e Hoff propuseram um circuito para uso em filtragem de sinal, o qual denominaram Adaline (NGUYEN e WIDRO, 1990).

A saída única desse circuito era obtida pela adição das entradas ponderadas por pesos e, a seguir, submetendo este resultado a uma função não-linear (originalmente uma função sinal, ou degrau). Os pesos eram ajustados através de um processo de minimização do erro apresentado na saída, o que levava a uma solução de mínimos quadrados. Dessa forma, uma rede Adaline pode ser visualizada como uma rede neural de uma única camada (CARRARA, 1997).

O aprendizado via algoritmo do gradiente foi adaptado da generalização do método de Widrow-Hoff para redes de multi-camadas e funções de ativação diferenciáveis e não-lineares. Da mesma forma que na rede Adaline, o algoritmo do gradiente usa um critério de minimização do erro da rede no ajuste dos pesos durante a fase de aprendizagem. Como resultado, o algoritmo de ajuste caminha na direção do gradiente da função a ser minimizada, provocando uma convergência segura (CARRARA, 1997).

Os pesos começam a ser ajustados a partir da última camada de neurônios e, com isso, fornecem informações suficientes para o ajuste do peso na camada anterior e assim sucessivamente, de onde decorre o nome alternativo de retro-propagação (RUMELHART, HILTON e WILLIAMS, 1986). A

função a ser minimizada, nesse caso, é o erro quadrático na saída da rede, ou seja:

$$J(t) = \frac{1}{2} \varepsilon(t)^T \varepsilon(t) \quad (4.29)$$

em que $\varepsilon(t)$ é o erro na saída da rede, no instante t , e vale:

$$\varepsilon(t) = y^d(t) - y(t) \quad (4.30)$$

em que $y^d(t)$ é o vetor de saídas desejadas para a rede. O gradiente dessa função com relação aos pesos da camada k de neurônios, já incluindo o patamar de ativação na última coluna, é definido pela matriz:

$$\nabla J^k = \begin{bmatrix} \frac{\partial J}{\partial w_{11}^k} & \cdots & \frac{\partial J}{\partial w_{l_{m_{k-1}+1}}^k} \\ \vdots & \ddots & \vdots \\ \frac{\partial J}{\partial w_{n_k 1}^k} & \cdots & \frac{\partial J}{\partial w_{n_k n_{k-1}+1}^k} \end{bmatrix} \quad (4.31)$$

O ajuste dos pesos se faz na direção do gradiente da função, conforme a equação:

$$W^k(t+1) = W^k(t) - \lambda \nabla J^k \quad (4.32)$$

e onde a matriz de pesos W^k é dada por:

$$W^k = \begin{bmatrix} w_{11}^k & \cdots & w_{l_{n_{k-1}+1}}^k \\ \vdots & \ddots & \vdots \\ w_{n_i 1}^k & \cdots & w_{n_k n_{k-1}+1}^k \end{bmatrix} \quad (4.33)$$

sendo que os patamares de ativação da camada k estão representados pelos pesos da última coluna, $w_{n_k, n_{k-1}+1}^k$, e λ é o parâmetro de convergência do aprendizado, compreendido normalmente entre 0 e 1.

Quanto maior o valor de λ mais rápido o aprendizado, porém não se consegue boa estabilidade dos coeficientes quando a rede adquire conhecimento do sistema. Por outro lado, valores pequenos de λ acarretam tempos de aprendizado extremamente longos e frequentemente podem fazer com que o processo de treinamento fique preso a um mínimo local.

A derivada da função com relação ao peso j associado ao neurônio i da camada k é obtida derivando-se a equação 4.29, e como o vetor de saída da rede, $y(t)$, é dado por:

$$y(t) = x^l(t) \quad (4.34)$$

obtem-se a relação:

$$\frac{\partial J}{\partial w_{ij}^k} = -\varepsilon^T \frac{\partial x^1}{\partial w_{ij}^k} \quad (4.35)$$

Aplicando, a seguir, a relação 4.26, chega-se a:

$$\frac{\partial J}{\partial w_{ij}^k} = -\varepsilon^T \Delta^k \begin{bmatrix} 0 \\ \vdots \\ x_j^{k-1} \\ \vdots \\ 0 \end{bmatrix} \quad (4.36)$$

que pode ser simplificado, resultando:

$$\frac{\partial J}{\partial w_{ij}^k} = -x_j^{k-1} \sum_{m=1}^{n_l} \varepsilon_m \delta_{m,i}^k \quad (4.37)$$

Note-se que esse resultado indica que a derivada da função depende exclusivamente da componente j do vetor de entrada da camada $k-1$ e da

coluna i da matriz δ^k . Isso sugere que o gradiente pode ser colocado em termos de operações entre matrizes, que resulta, após algumas manipulações:

$$\nabla J^k = -\Delta^{k^T} \varepsilon X^{k-1^T} \quad (4.38)$$

A formulação obtida aqui, para o algoritmo do gradiente, difere em certos aspectos daquela difundida correntemente na literatura. A principal diferença se deve à incorporação, na formulação tradicional, do vetor de erros ε na matriz de retro-propagação, e, desta forma, propaga-se um vetor de erros e não, como aqui, uma matriz de variações, da seguinte forma:

$$\delta^{k^T} = \delta^{k+1^T} W^{k+1} F^k \quad (4.39)$$

em que δ^k , o erro retro-propagado, é um vetor de n_k colunas, e com condição inicial δ^l dada por:

$$\delta^{l^T} = \varepsilon^T F^l \quad (4.40)$$

A derivada da função, neste caso, resulta em:

$$\frac{\partial J}{\partial w_{ij}^k} = -\delta_i^k x_j^{k-1} \quad (4.41)$$

na qual o escalar δ_i^k é a i -ésima componente do vetor δ^k . Por sua vez, o gradiente fica expresso pelo produto do vetor δ^k pelo vetor x^{k-1} , ou seja:

$$\nabla J^k = -\delta^k X^{k-1^T} \quad (4.42)$$

Embora o equacionamento anterior pareça, a princípio, mais trabalhoso pelo fato de ser necessário efetuar uma retro-propagação de uma matriz contra uma retro-propagação de um vetor, no entanto, ele irá facilitar a implantação do

algoritmo de treinamento por mínimos quadrados, como ficará claro mais adiante.

O algoritmo de retro-propagação resulta da otimização, e como todo processo desse tipo, ele pode levar o resultado para um mínimo local. Parâmetros de convergência elevados podem levar o processo de aprendizagem para uma situação instável, enquanto que valores pequenos resultam numa razão de convergência muito baixa. Para contornar esse problema e também para acelerar o processo de aprendizagem, foram desenvolvidos métodos de ajuste de λ , de forma a se ter valores grandes no início do aprendizado e reduzi-lo à medida que a rede caminha para a solução absoluta. Ainda assim, e dada a grande quantidade de variáveis envolvidas, o processo de aprendizado de uma rede multi-camadas, via retro-propagação é demasiadamente lento (CHEN e BILLINGS, 1992), exceto nos casos em que o treinamento é realizado num conjunto reduzido de valores.

4.1.7.3) Treinamento com o Algoritmo dos Mínimos Quadrados

Considere $y(t)$ o vetor (dimensão n_l) de saída da rede neural no instante t , função dos pesos dos neurônios $w(t)$ e do vetor de entrada $x(t)$, (dimensão n_i) no mesmo instante:

$$y(t) = f(x(t).w(t)) \quad (4.43)$$

Nesse caso, por simplicidade, optou-se por representar todos os pesos dos diversos neurônios que compõem a rede em um único vetor $w(t)$. Os algoritmos de estimação de parâmetros foram desenvolvidos para sistemas lineares e, como a função $f(t)$ é não-linear, efetua-se uma linearização da mesma em torno do instante $t-1$, no qual por hipótese são conhecidos os pesos. Desta forma, como o vetor de entradas $x(t)$ não varia durante o processo de atualização dos pesos e desprezando os termos de segunda ordem, tem-se:

$$y(t) = y(t-1) + \frac{\partial y}{\partial w} \Big|_{t-1} [w(t) - w(t-1)] \quad (4.44)$$

Essa expressão pode ser posta em termos do erro apresentado na saída da rede, bastando para isso substituir o valor de $y(t)$ obtido da equação 4.30. Reagrupando-se os termos, chega-se a:

$$z(t) = H(t)w(t) + \varepsilon(t) \quad (4.45)$$

onde a matriz de derivadas da saída da rede, $H(t)$, vale:

$$H(t) = \frac{\partial y}{\partial w} \Big|_{t-1} \quad (4.46)$$

e o vetor $z(t)$ é dado por:

$$z(t) = y^d(t) - y(t-1) + H(t)w(t-1) \quad (4.47)$$

A equação 4.45 se encontra na forma de um sistema linear, e, neste caso, pode-se aplicar um método de estimação de parâmetros com informação a priori de forma a se obter o vetor de pesos w . O algoritmo dos mínimos quadrados é obtido a partir da minimização de uma função representada por uma ponderação da informação a priori e do erro quadrático médio na saída, ou seja:

$$J(t) = \frac{1}{2} \left\{ \hat{w}^T(t-1) \bar{P}(t) \hat{w}(t-1) + \varepsilon^T(t) R^{-1}(t) \varepsilon(t) \right\} \quad (4.48)$$

onde $\hat{w}(t)$ é a estimativa do vetor de pesos, a matriz $\bar{P}(t)$ pode ser associada a propagação da matriz de covariâncias $P(t)$ do erro de estimação de $w(t)$, e $R(t)$ pode ser associada com uma matriz diagonal das variâncias dos erros tolerados nas respectivas componentes de $\varepsilon(t)$ ao se tentar anulá-las durante a

minimização da função objetivo (GELB, 1974). A estimativa do vetor de pesos no instante t , $\hat{w}(t)$, é obtida recursivamente através da relação.

$$\hat{w}(t) = (\underline{1} - K(t)H(t))\hat{w}(t-1) + K(t)z(t) \quad (4.49)$$

no qual $\underline{1}$ é a matriz identidade e $K(t)$ é o chamado ganho de Kalman, e vale:

$$K(t) = \bar{P}(t)H(t)^T [H(t)\bar{P}(t)H(t)^T + R(t)]^{-1} \quad (4.50)$$

Como não existe propagação de equações dinâmicas nesse processo, adota-se um fator de esquecimento, λ , de forma a garantir que a covariância não diminua em demasia, conforme o sistema adquira conhecimento do vetor de pesos $w(t)$:

$$\bar{P}(t) = \frac{P(t-1)}{\lambda}, 0 < \lambda \leq 1 \quad (4.51)$$

A atualização da matriz de covariância se faz na forma:

$$P(t) = [\underline{1} - K(t)H(t)]\bar{P}(t) \quad (4.52)$$

Reagrupando os termos da expressão 4.49, chega-se a:

$$\hat{w}(t) = \hat{w}(t-1) + K(t) \left[z(t) - H(t)\hat{w}(t-1) \right] \quad (4.53)$$

ou, mais resumidamente:

$$\Delta \hat{w}(t) = K(t)\varepsilon(t) \quad (4.54)$$

que traduz a implementação da forma recursiva para o treinamento da rede neural. Em algumas referências (CHEN e BILLINGS, 1992), as equações 4.51

e 4.52 são substituídas na relação 4.50 e, após alguma manipulação algébrica, chega-se ao seguinte resultado

$$K(t) = P(t)H(t)^T R(t)^{-1} \quad (4.55)$$

Embora mais simples que a expressão 4.50, esta última não se encontra numa forma recursiva, tornando-se com isso impraticável sua implementação na forma de algoritmo.

Resta ainda informar as condições iniciais para a formulação recursiva, isto é, os valores dos pesos $w(t)$ e da matriz de covariância $P(t)$ no instante inicial. Normalmente, adota-se para os pesos uma distribuição aleatória uniforme entre -1 e 1, e, para a matriz de covariância do erro de estimação o valor:

$$p(0) = \delta_0^2 \mathbf{1} \quad (4.56)$$

A variância quadrática média, $\delta_0^2 \mathbf{1}$, deve representar o desconhecimento acerca dos pesos no início do treinamento. É geralmente fixada entre 10 e 10000 (NORGAARD, 1996). Por sua vez, a matriz de covariância do erro $\varepsilon(t)$, $R(t)$, geralmente é admitida como uma matriz identidade.

4.1.7.4) Matriz de Derivadas Parciais

Foi visto que a identificação dos pesos da rede neural utilizando mínimos quadrados requer a avaliação da matriz de derivadas parciais do vetor de saída $y(t)$ com relação aos pesos da rede, conforme a equação 4.44. Esse problema é de fácil solução em redes de apenas uma camada, mas a complexidade e a quantidade de operações aumentam com o número de camadas. Nesse caso, são usualmente empregados algoritmos recursivos para obter a matriz de derivadas (CARRARA, 1997). Considere-se, então, uma rede neural composta por l camadas, contendo n^k neurônios na camada k . Seja também x^k o vetor apresentado na saída da camada k , dado por:

$$x^k = \begin{bmatrix} f^k(\bar{x}^k) \\ 1 \end{bmatrix} \quad (4.57)$$

em que $f^k(x)$ é a função de ativação dos neurônios da camada k .

$$\bar{x}^k = W^k x^{k-1} \quad (4.58)$$

em que os patamares de ativação da camada k estão representados pelos pesos da última coluna, w_i^{nk-1+1} .

Derivando-se a relação 4.34 e após substituir as equações 4.57 e 4.58 obtém-se uma relação de recorrência entre as entradas e saídas das diversas camadas de neurônios, e assim pode-se obter a derivada dos parâmetros de saída da rede:

$$H_i^k = \frac{\partial x^1}{\partial w_i^k} = F^l W^l \frac{\partial x^{l-1}}{\partial w_i^k} \quad (4.59)$$

em que F^k é a matriz de derivadas da função de ativação da camada k com relação ao argumento x^k , e é dada pela expressão 4.19. Efetuando novamente a derivada na camada $l-1$, e assim sucessivamente, a relação 4.60 resulta

$$H_i^k = F^l W^l F^{l-1} W^{l-1} \dots F^{k+1} W^{k+1} F^k \frac{\partial \bar{x}^k}{\partial w_i^k} \quad (4.60)$$

Esta expressão pode ser colocada em termos de relações recorrentes, de tal forma que as matrizes de derivadas parciais vão sendo obtidas a partir da última camada até atingir a primeira camada:

$$H_i^k = \Delta^k \frac{\partial \bar{x}^k}{\partial w_i^k} \quad (4.61)$$

onde as matrizes Δ^k são obtidas da fórmula recorrente apresentada na relação 4.28, com a condição inicial dada por $\Delta^l = F'$. A derivada do vetor de argumentos da função de ativação da camada k com relação aos pesos w_i resulta na matriz de n_k linhas

$$\frac{\partial x^{-k}}{\partial w_i^k} = \begin{bmatrix} 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ x_1^{k-1} & x_2^{k-1} & \cdots & x_{n_k-1}^{k-1} \\ 0 & 0 & \cdots & 0 \end{bmatrix} \quad (4.62)$$

com apenas a linha i preenchida e todas as outras linhas nulas, já que as derivadas dos pesos dos demais neurônios da camada k não dependem dos pesos w_i . Se a matriz Δ^k for colocada na forma de suas componentes vetoriais, ou seja:

$$\Delta^k = [\delta_1^k \quad \delta_2^k \quad \cdots \quad \delta_{n_k}^k] \quad (4.63)$$

onde cada componente possui n_l linhas, então a matriz H_i^k pode ser escrita como:

$$H_i^k = \delta_i^k x^{k-1T} \quad (4.64)$$

A matriz de derivadas parciais considerando todos os pesos da rede pode agora ser composta a partir das matrizes de derivadas dos neurônios, na forma:

$$H = \begin{bmatrix} H_1^1 & \cdots & H_{n_1}^1 & H_1^2 & \cdots & H_{n_2}^2 & H_1^3 & \cdots & \cdots & H_{n_1}^1 \end{bmatrix} \quad (4.65)$$

Esta matriz possui n_l linhas (correspondente ao número de variáveis na saída da rede neural) e cada coluna corresponde a um peso (ou limiar de ativação), que totalizam:

$$n_w = \sum_{m=1}^1 n_m (n_{m-1} + 1) \quad (4.66)$$

As matrizes de peso são atualizadas conforme a relação:

$$W^k(t+1) = W^k(t) + \Delta W^k(t) \quad (4.67)$$

cuja matriz de incremento dos pesos, $\Delta W^k(t)$, é composta pelos elementos do vetor $\Delta w(t)$, obtido da relação 4.54:

$$\Delta W^k(t) = \begin{bmatrix} \Delta \hat{w}_{p+1} & \Delta \hat{w}_{p+2} & \vdots & \Delta \hat{w}_{p+n_{k-1}+1} \\ \Delta \hat{w}_{p+n_{k+1}+2} & \Delta \hat{w}_{p+n_{k+1}+3} & \vdots & \Delta \hat{w}_{p+2(n_{k+1}+1)} \\ \dots & \dots & \ddots & \vdots \\ \Delta \hat{w}_{p+(n_k-1)(n_{k-1}+1)+1} & \Delta \hat{w}_{p+(n_k-1)(n_{k-1}+1)+2} & \dots & \Delta \hat{w}_{p+(n_k-1)(n_{k-1}+1)} \end{bmatrix} \quad (4.68)$$

onde o índice p depende da camada considerada

$$p = \sum_{m=1}^{k-1} n_m (n_{m-1} + 1) \quad (4.69)$$

Veja que o algoritmo do gradiente é bastante semelhante ao algoritmo de mínimos quadrados recursivos, e as expressões resultantes são muito parecidas. A principal diferença entre os algoritmos se refere à função que leva ao método de otimização. Nos mínimos quadrados recursivos, o erro em cada saída é considerado individualmente no processo de minimização, enquanto que no algoritmo do gradiente o erro quadrático de todas as saídas é minimizado nas iterações. Se, por um lado, o esforço computacional é significativamente maior nos mínimos quadrados, por outro o treinamento é conseguido mais rapidamente (CARRARA, 1997).

4.2) Redes neurais aplicadas em processo de usinagem

O uso de RNAs em aplicações de usinagem, de acordo com Sick (2002), pode ser categorizado em aplicações em linha (online) ou fora de linha (offline). Em aplicações em linha, sensores e atuadores são instalados nas máquinas

ferramentas e redes são treinadas em tempo real, usando os parâmetros do processo medidos e inseridas em algum esquema de controle da operação de usinagem. Já, nas aplicações fora de linha, dados experimentais ou dados históricos são usados para treinar a rede com o objetivo de construir modelos para uso em planejamento ou otimização de processos (PONTES, 2011).

O potencial das RNAs para uso em processos de usinagem foi percebido na década de 1990. A fim de prever a vida da ferramenta no torneamento de ferro fundido com ferramentas de corte de material cerâmico, utilizou-se dos resultados de experimentos envolvendo valores distintos de velocidade de corte e avanço para treinar uma MLP (ANTONY, 2005).

Os primeiros estudos sobre a modelagem da rugosidade da peça podem ser encontrados em Chien & Chou (2001), em que redes foram usadas para a predição da rugosidade da peça, força de corte e vida da ferramenta, em processo de torneamento de um aço inox 304.

A aplicação de RNAs em processos de usinagem tem sido o tema de um número considerável de publicações. Em muitas delas, pesquisadores têm chegado a conclusões favoráveis em relação a seu uso (PONTES, 2001).

Os modelos de redes neurais são capazes de predizer, para uma série de condições de corte, o desgaste da ferramenta e padrões de rugosidade da peça (ÖZEL *et al.*, 2007).

Um modelo de rede neural foi desenvolvido para a investigação e predição da relação entre os parâmetros de corte e rugosidade da peça durante o fresamento de acabamento em alta velocidade de uma liga de níquel Inconel 718. As redes apresentaram bom desempenho na predição (HOSSAIN *et al.*, 2008),

Deve-se ressaltar que não há consenso sobre a experiência com redes neurais para a modelagem da rugosidade da peça (PONTES, 2011).

A identificação de uma boa arquitetura de RNA requer várias tentativas de modelagem, consistindo em atividade longa e de resultado incerto (CERVELLERA *et al.*, 2007 e KARNIK *et al.*, 2008).

A necessidade de grande quantidade de dados para treinamento e validação pode ser um limitador para a aplicação prática de redes neurais para predição em processos de usinagem (AMBROGIO *et al.*, 2008).

A aplicação da técnica de redes neurais mostrou-se bastante poderosa e robusta para estimativa do desgaste de ferramentas de corte em processos de fresamento frontal, além de ser considerada rápida e simples (SANTOS, 2001).

Para a predição do diâmetro de furos usinados em ligas de alumínio e titânio, o modelo de rede neural artificial de múltiplas camadas (MLP) mostra-se o mais robusto em comparação com outros dois métodos de inteligência artificial, neuro-fuzzy (ANFIS) e função de base radial (RBF) (GERONIMO, 2012).

Inúmeros trabalhos podem ser citados com a utilização de redes neurais para determinação de uma característica do processo de usinagem por meio de parâmetros do processo associados a redes neurais artificiais, mostrando que o trabalho é atual e contextualizado com as novas linhas de pesquisas.

4.3) Processo de Usinagem - Furação

A furação é um processo de remoção de material largamente utilizado nas indústrias aeroespaciais, aeronáuticas e automotivas. Apesar da modernização dos métodos de remoção de material na indústria de fabricação, incluindo usinagem a laser, usinagem ultrassônica, usinagem eletrolítica e usinagem por jato abrasivo, a furação convencional permanece como um dos processos de usinagem mais utilizados (KURT *et al.*, 2008).

O processo de furação distingue-se em furação em cheio, com presença de pré-furo, com furo escalonado ou chanfro, furação de centro e trepanação (Ferraresi, 2003).

A qualidade de um furo é determinada por uma síntese dos erros ocasionados pela dinâmica do processo e pelo regime térmico na interface peça/broca. Os mecanismos que induzem esses erros incluem desvios e rotações anormais da broca durante a penetração; deflexões da ferramenta devido às forças desbalanceadas; erros devido ao corte nas bordas da broca; e erros gerados pela expansão térmica da broca e da peça. A rigidez da ferramenta de corte determina, em grande parte, os erros induzidos devido aos mecanismos dinâmicos, mas não é afetada pela presença ou ausência do revestimento da broca (KALIDAS, 2001).

O processo de usinagem não é linear e envolve fenômenos como a deformação plástica, fratura, impacto, pontos de contato intermitentes, contínuos e desgaste. Em temperaturas de trabalho elevadas, a ferramenta de corte pode perder sua forma rapidamente, resultando em acréscimo de força de corte, inexactidão dimensional do produto, redução de vida, problemas mecânicos e químicos à superfície acabada.

Inúmeros fatores são capazes de afetar os resultados finais do processo de furação. A Figura 14 mostra um diagrama que resume as variáveis mais relevantes de um processo convencional de furação.




Figura 14 – Variáveis que afetam a qualidade das furações (Cruz, 2010).

Industrialmente, a aresta de corte é utilizada até que as peças fiquem fora das especificações de tolerância e/ou acabamento de projetos, fazendo com que valores recomendados pela ISO 3685 assumam valores diferentes dependendo da condição. Entretanto, valores excessivos de desgaste causam aumento de força de usinagem e de geração de calor, elevando a chance de promover a falha catastrófica de ferramenta (MACHADO; SILVA, 2004).

Na furação com brocas helicoidais, os esforços atuantes estão ligados à geometria da broca e às condições de corte do processo tais como, avanço,

velocidade de corte e rigidez do conjunto peça e máquina-ferramenta (ARENAS, 2003).

A Figura 15 mostra a cinemática durante um processo de furação utilizando uma broca helicoidal. São destacados os movimentos de rotação e avanço da ferramenta de corte, além da profundidade de corte. Estas variáveis têm destacada importância nos resultados do processo de furação com ferramentas helicoidais.




Figura 15 - Cinemática do processo de furação (Novaski, 1996).

A velocidade de corte V_c é a velocidade instantânea do ponto de referência da aresta de corte da ferramenta, segundo a direção e sentido de corte. Para processo com movimento de rotação, a velocidade de corte é calculada pela Equação 4.74.

$$V_c = \frac{\phi \times f \times n}{1000} \quad (4.74)$$

Onde ϕ é o diâmetro (mm) da ferramenta de corte, no caso das ferramentas rotativas. A variável n corresponde ao número de rotações por minuto da ferramenta de corte. O avanço f é o percurso de avanço em cada volta (mm/volta) ou em cada curso da ferramenta. Como o diâmetro das peças

é dado em milímetros e a velocidade de corte é dada em metros por minuto, é necessário transformar a unidade de medida dada em metros para milímetros.

A profundidade de corte AP é profundidade ou largura de trabalho (NBR6162 / 1989).

A tolerância dimensional normal de peças furadas por meio de brocas helicoidais com diâmetro nominal entre 3 até 6 mm é da ordem IT 11 (0,075 mm), contra, por exemplo, tolerâncias entre IT 4 (0,004 mm) a IT 6 (0,008 mm) para a operação de retificação. O processo de furação enfrenta dificuldades em termos de precisão, devido à complexidade em sua obtenção. Portanto, quando são exigidos furos de precisão em um processo há a necessidade de operações de acabamento, tais como alargamento, brochamento, mandrilamento, torneamento interno, retificação interna, etc (DINIZ, 1999). A indústria aeronáutica vem constantemente investindo em equipamento e em novos processos de furação que permitam a obtenção de furos de precisão em um único passe de furação, em ligas de Titânio e Alumínio, por meio de brocas helicoidais de metal duro.

Na faixa de valores empregados comumente na indústria, a velocidade de corte apresenta influência discreta na força de usinagem. Em baixas velocidades de corte e na ausência de aresta postiça de corte, ocorre queda nos valores da força de corte (FERRARESI, 1977).

A aresta postiça de corte é constituída de partículas de material usinado que se acumulam na superfície de saída da ferramenta, sua forma característica é mostrada na Figura 16.




Figura 16 – Aresta postiça de Corte (DINIZ, 1999).

A aresta postiça aderente à aresta de corte se deforma e se encrua, aumentando sua resistência mecânica e atuando como uma nova aresta de corte com diferente geometria da original. A aresta postiça cresce gradualmente até romper-se bruscamente. Parte da aresta postiça que rompe é carregada com o cavaco e parte adere à peça, prejudicando, sensivelmente, seu acabamento superficial. Ao romper-se, a aresta postiça arranca partículas da superfície de folga da ferramenta, gerando um grande desgaste de flanco, mesmo em velocidades muito baixas. Já a superfície de saída da ferramenta é protegida, pois o cavaco atrita com a aresta postiça, fazendo com que o desgaste de cratera seja mínimo (DEMETTÉ, 2006).

O aumento do avanço, por sua vez, tende a aumentar a força de usinagem devido ao fato de se ter o aumento das áreas referentes aos planos de cisalhamento (MACHADO, 1999). Esse aumento também afeta as condições de integridade da ferramenta, as condições dimensionais do furo e o tempo de usinagem. Usualmente, valores maiores de avanço propiciam elevação nos valores de rugosidade, do diâmetro usinado e forças de corte (BEZERRA, 2001). Alterações no avanço refletem mais significativamente no tempo de usinagem que as alterações de rotação.

4.3.1 Cavacos

Cavacos podem ser considerados porções de material da peça retirada pela ferramenta de corte (STOETERAU, 2007).

A formação do cavaco é muito influenciada pelo movimento do mesmo sobre a superfície de saída da ferramenta. Dependendo das condições de corte, propriedades dos materiais da peça e da ferramenta, pode ocorrer aderência em parte do contato (DA SILVA, 1998).

Essa aderência tem uma importância fundamental em quase todos os fenômenos envolvidos durante o corte, e existem trabalhos importantes sobre esse tema (DA SILVA, 1998).

O desgaste da ferramenta de corte tem influência na formação do cavaco, já que além de alterar a geometria da ferramenta, altera as condições na região do contato cavaco-ferramenta (SOUSA *et al.*, 2011).

A Figura 17 mostra os principais fatores que influenciam a forma do cavaco produzido durante a usinagem.




Figura 17 – Influencia na forma do cavaco (Adaptado de STOETERAU, 2007).

Os cavacos podem apresentar basicamente a formação mostrada na Figura 18.




Figura 18 – Tipos do cavaco (STOETERAU, 2007).

Os cavacos contínuos são formados por lamelas justapostas numa disposição contínua e não há nitidez na distinção das lamelas. Geralmente, é obtido quando se usina materiais dúcteis, como aços de baixo teor de carbono, alumínio e cobre, com ferramentas com ângulos de saída elevados. Esse tipo de cavaco está associado a um baixo coeficiente de atrito entre o cavaco e ferramenta de corte e proporciona melhor acabamento, maior durabilidade da ferramenta e menor energia consumida (DINIZ *et al.*, 2006).

Os cavacos cisalhados também são formados por lamelas justapostas, mas, nesse caso, as lamelas são bem distintas. Esse tipo de cavaco ocorre quando há uma fissura do material no ponto mais solicitado ao longo do plano de cisalhamento, podendo haver uma ruptura parcial ou total do cavaco, porém, efeitos de pressão e temperatura soldam a lamela, e o cavaco torna-se inteiriço. Frequentemente, associam-se vibrações a esse tipo de cavaco, podendo comprometer o acabamento superficial da peça, a ferramenta e até a máquina-ferramenta (DINIZ *et al.*, 2006).

Os cavacos arrancados são formados por fragmentos independentes e distintos, principalmente através de tensões de compressão e tração no material da peça. Materiais como o ferro fundido e o latão, de estrutura frágil ou heterogenia, tendem a apresentar este tipo de cavaco. Recomenda-se o uso de ferramentas com ângulos de saída pequeno, nulo ou negativo (DINIZ *et al.*, 2006).

Os cavacos lamelares, geralmente, decorrem da usinagem de aços endurecidos ou Titânio com ferramentas com ângulo de saída negativo. As tensões aplicadas na peça fazem com que surjam trincas que funcionam como superfícies de escoamento para uma porção de material ser deformada plasticamente. As trincas não chegam a separar o cavaco completamente, atribuindo uma aparência serrilhada ao cavaco. A Figura 19 mostra a classificação dos cavacos quanto à forma.

1- Cavaco em fita	2- Cavaco tubular	3- Cavaco espiral	4- Cavaco hel, tipo arruela	5- Cavaco hel cônico	6- Cavaco em arco	7- Cavaco fragmentado	8- Cavaco tipo agulha
1-1- Longa	2-1- Longa	3-1- Plana	4-1- Longa	5-1- Longa	6-1- Conect		
1-2- Curta	2-2- Curta	3-2- Cônica	4-2- Curta	5-2- Curta	6-2- Solto		
1-3- Emaranhado	2-3- Emaranhado		4-3- Emaranhado	5-3- Emaranhado			

Figura 19 – Forma do cavaco segundo a classificação ISO 3685 -1977.

4.3.2 Forças na furação

Uma das formas mais importantes de avaliar o processo de usinagem durante a operação de corte é a determinação das componentes de força (SHAW, 2005).

Forças de usinagem podem ser medidas de duas formas: (i) a direta; e (ii) indiretamente (CHILDS *et al.*, 2000). As medições diretas são feitas utilizando dinamômetros que fornecem sinais elétricos proporcionais às forças aplicadas. Essas medições são utilizadas quando é necessário saber, com precisão, a magnitude e a direção das forças. As medições indiretas envolvem a dedução do comportamento da máquina ferramenta. Por exemplo, a potência usada pelo motor do eixo principal pode ser correlacionada com a força principal de corte ou com o torque. Particularmente, em máquinas com CNCs, métodos indiretos podem ser utilizados para determinar as forças ativas. Esses métodos são menos precisos que os diretos, mas podem ser suficientes para monitorar o comportamento da ferramenta de corte durante a ocorrência do processo de usinagem (PEREIRA, 2010)

As forças de usinagem que agem em uma broca helicoidal durante o processo de corte podem ser divididas em três componentes: Força de corte F_C , Força de avanço F_f e força passiva F_p (PEREIRA, 2010). A Figura 20 mostra essas forças.




Figura 20 – Componentes da Forças de usinagem (PEREIRA, 2010).

A força de corte F_c está relacionada diretamente à resistência do material ao corte, tendo grande influência sobre o momento torçor. A força de avanço F_f é decorrente da atuação da aresta transversal de corte e da resistência à penetração do material usinado. A Força passiva F_p atua em uma parcela da aresta principal. As forças passivas atuantes nas arestas tendem a se anular mutuamente. É desprezível quando comparada com as forças de corte e de avanço (PEREIRA, 2010).

O momento torçor para furação em cheio, vale:

$$M_t = F_c r \quad (4.75)$$

em que, F_c é a força de corte em [N] e r é o raio da broca em [m].

Os resultados das forças atuantes nas arestas principais da ferramenta são responsáveis pelo momento torçor, contribuindo entre 70 e 90% do valor do mesmo.

A potência de corte é o resultante do produto entre o momento torçor e a velocidade angular da ferramenta, e pode ser calculada pela seguinte relação (STEMMER, 2005):

$$P_c = \frac{M_t n}{9,549} [kW] \quad (4.76)$$

em que n é o número de rotações por minuto e o número de 9,549 serve para acertar as unidades das grandezas relacionadas na equação 4.76.

4.3.3) Usinagem do Alumínio

O alumínio e suas ligas se caracterizam por sua relação resistência-peso, sua resistência à corrosão em alguns ambientes comuns (incluindo a atmosfera ambiente), e sua elevada condutividade térmica e elétrica. A densidade do alumínio é 2.770 kg/m^3 (a do aço é 7.750 kg/m^3). A resistência à

tração do alumínio puro é baixa, cerca de 90 MPa, mas isso pode ser consideravelmente melhorado pelo trabalho a frio e pela adição de elementos de liga (BUDYNAS, 2008).


A usinagem de alumínio com ferramentas convencionais não é realizada sem dificuldades. Esse material tende a aderir na superfície da ferramenta e a formar rebarbas dentro dos furos. Uma das causas principais de danos à ferramenta durante a sua usinagem é a formação de camadas de aresta postiça, implicando redução da vida útil da ferramenta. Assim, fluídos de corte tem papel importante nesses tipos de processos, pois possibilitam a redução de adesão na superfície da ferramenta (NOUARI *et al.*, 2003).

Uma vez que o alumínio possui uma estrutura CFC (Cúbica de Face Centrada), a sua ductilidade é mantida até mesmo em temperaturas reduzidas. Porém a resistência mecânica pode ser aumentada pela deformação plástica ou mediante a formação de ligas, mas esses dois processos provocam uma diminuição na resistência à corrosão. A principal limitação do alumínio está na sua baixa temperatura de fusão, que restringe a temperatura máxima em que o alumínio pode ser utilizado (CALLISTER, 2006).

Devido à grande facilidade de deformação plástica, a usinagem do alumínio propicia furos maiores que o diâmetro da broca (STEMMER, 1995).

A Tabela 1 mostra faixas de velocidade de corte ideais para diferentes materiais.

Tabela 1 – Velocidade de corte ideal (Adaptado de Rodrigues, 2005).



4.3.4) Usinagem do Titânio

Constata-se que o titânio e suas ligas são, normalmente, utilizados na indústria aeronáutica e aeroespacial, em componentes como longarinas, fuselagem, reforçadores estruturais e prendedores. Trata-se de um excelente material na aplicação de componentes estruturais, devido sua alta resistência mecânica, baixa massa específica, boa resistência à corrosão e estabilidade metálica (CRUZ, 2010).

A combinação de alta resistência mecânica, baixa densidade, resistência à corrosão, biocompatibilidade, boa tolerância térmica e manutenção de suas características em altas temperaturas, configuram o titânio como um material excepcional para projetistas de diversas áreas. Infelizmente, essas boas qualidades refletem negativamente na sua usinabilidade. Uma vasta lista de problemas deve ser contornada durante a usinagem de ligas de titânio, dentre eles, altas temperaturas e pressões de corte, baixo módulo de elasticidade (que é um fator incentivador de vibrações), alta afinidade química com os materiais das ferramentas e problemas com integridade superficial das peças usinadas (PIRES e DINIZ, 2011).

Se comparado com o alumínio, o titânio é sessenta por cento (60%) mais pesado, porém duas vezes mais resistente. Tais características fazem com que o titânio seja muito resistente contra os tipos usuais de fadiga. Esse metal forma uma camada passiva de óxido quando exposto ao ar, mas quando está em um ambiente livre de oxigênio ele é dúctil. Ele queima, quando aquecido, e é capaz de queimar imerso em nitrogênio gasoso (CRUZ, 2010).

Na usinagem de ligas de titânio, a ferramenta de corte é submetida a severos choques mecânicos e térmicos, principalmente em uma pequena área próxima à aresta de corte, resultando em grande influência no desgaste e, consequentemente, na vida da ferramenta. Desgaste de flanco, desgaste de cratera, entalhamento, lascamento e quebra da aresta de corte são os modos de falha predominantes, sendo causados pela combinação de alta temperatura, alta solicitação mecânica, alta afinidade química do titânio com materiais de ferramentas e cisalhamento adiabático do cavaco (EZUGWU e WANG, 1997).

O titânio tem grande reatividade química e, portanto, tem a tendência de se precipitar sobre a ferramenta durante o processo de usinagem, prejudicando-o e causando a falha prematura da ferramenta de corte. São considerados materiais “difíceis de cortar” devido à sua alta temperatura de corte e/ou às altas tensões na aresta de corte. Esses fatores podem ser ocasionados devido ao pequeno comprimento de contato entre cavaco e ferramenta e ao cavaco pouco espesso, que geram uma pequena superfície de contato entre cavaco e a ferramenta (EZUGWU e WANG, 1997).

A usinagem é ainda dificultada pelo encruamento, que aumenta a resistência mecânica na superfície da peça e pela formação de aresta postiça de corte. Além destes fatores, a elevada tenacidade do material e a formação caótica de cavacos em forma de fita e espiral também têm contribuição negativa no processo. Na usinagem normal do aço, a aresta de corte da ferramenta recebe uma carga bem menor. Os cavacos são arrancados da peça com raio relativamente grande e a direção da força principal é feita em uma área de contato mais estável. Já o processo de deformação dos materiais resistentes a altas temperaturas ocorre diretamente na aresta de corte (WITTING, 2002).

Em relação ao material da ferramenta de corte, metal duro sem revestimento tem mostrado um melhor desempenho no torneamento e fresamento de ligas de titânio, mesmo quando comparado com ferramentas de diamante, cerâmica e CBN devido à alta afinidade química desses materiais com o titânio, resultando em rápido desgaste para altas velocidades de corte (JAWAID, SHARIF e KOKSAL, 2000).

4.3.5) Brocas Metal Duro

As brocas de metal duro são conhecidas como a mistura do pó de tungstênio com o cobalto (DINIZ, 1999). O pó de tungstênio e cobalto são misturados e comprimidos a pressões da ordem de 0,5 g/cm² em temperaturas entre 700 a 800°C. Após essa compressão, segue o processo de sinterização em que o material é levado à temperatura entre 1400 a 1600°C (MARCONDES, 1990).

Os metais duros podem ser revestidos com camadas de TiC, TiN, Al₂O₃, HfN, HfC, TiB₂ entre outros, variando o revestimento e o número de camadas de acordo com sua aplicação (MACHADO, 1999).

Problemas de adesão e fragilidade têm limitado o uso de brocas de metal duro; contudo, adições com alguns outros metais, nitretos e carbeto têm ajudado a superar esse problema (RENEVIER, 2004).

A utilização de metal duro vem ganhando cada vez mais espaço nas operações de usinagem, inclusive em furações como as estudadas nesse trabalho. O sucesso do metal duro está no fato deste possuir a combinação de resistência ao desgaste, resistência mecânica e tenacidade em níveis elevados. Com os novos centros de usinagem CNC é possível trabalhar com rotações que, antigamente, eram consideradas altas para furação, melhorando assim as características de usinagem (DINIZ, 2000).

Embora as brocas de metal duro apresentem custos de fabricação mais elevados quando comparados aos custos de fabricação de brocas de aço rápido, outro material existente para fabricação de brocas, a indústria aeronáutica, de maneira geral, vem optando por sua utilização, pois é possível alcançar melhores condições de usinagem, aumentando significativamente a qualidade das furações de precisão com um único passe.

4.3.6) Brocas Helicoidais

A broca helicoidal é normatizada de acordo com suas características construtivas e geométricas (DIN 1836, DIN 1962, ABNT PB-286, 1977). Levando em consideração as características construtivas e a aplicabilidade dentro da usinagem dos materiais, as brocas helicoidais possuem três tipos de hélices normatizadas:

- Tipo W: possui passo curto e é recomendada para materiais que formam cavacos longos, tais como liga de alumínio, magnésio.
- Topo N: possui passo normal e é recomendada para materiais mais comuns, como aços e ferros fundidos.

- Tipo H possui passo longo, recomendado para materiais que formam cavacos curtos, tais como liga de cobre, zinco, borracha dura e certos materiais plásticos.

Brocas helicoidais, geralmente, apresentam bons resultados de furação em ligas de alumínio, pois trabalham com ângulo de hélice de 40 a 48°, ângulo da ponta na faixa de 130 a 140° e isso gera um cavaco mais estreito que pode ser mais facilmente expelido através dos canais de escoamentos da broca. A saída dos cavacos e a adesão de cavaco nos canais são os dois principais problemas que tornam a lubrificação necessária e importante no processo de furação. As arestas principais e secundárias constituem as principais faces de corte de uma broca, sendo que a aresta principal penetra no interior da peça, enquanto que a outra face expulsa o material, produzindo a maior parte do torque de furação e da força de avanço. A contribuição da aresta principal de corte para força e torque é de respectivamente 40 a 80%, enquanto que a contribuição da aresta secundária é de 57 e 8%, respectivamente, para a força e torque (COTTERELL, 2002; DINIZ, 2000). A Figura 21 mostra os principais ângulos de uma broca helicoidal.




Figura 21 – Principais Ângulos de uma Broca Helicoidal (BOEIRA *et al.*, 2010).

Dentre as inúmeras geometrias, ângulos e gumes (arestas) presentes em uma broca destacam-se: aresta principal de corte, aresta secundária de corte, aresta transversal, ângulo de ponta (σ), ângulo de hélice (φ), ângulo de incidência normal (α_n), ângulo normal de cunha (β_n) e ângulo de saída (γ_n).

Em quase toda operação de usinagem, a ação do corte muda, gradativamente, a forma da aresta da ferramenta. Então, com o tempo, a ferramenta para de cortar de forma eficiente ou falha completamente (TRENT, 2000).

O desgaste na broca é caracterizado principalmente por: desgaste de flanco, desgaste das arestas principal e transversal, desgaste de cratera e lascamento (PANDA *et al.*, 2006). A Figura 22 mostra as principais formas de desgaste de uma broca helicoidal.




Figura 22 – Formas de desgaste de uma broca helicoidal (CRUZ, 2010).

Como o principal modo de falha das ferramentas de usinagem é o desgaste, pode-se afirmar que a taxa de falhas de uma ferramenta tem uma ocorrência crescente no tempo. A confiabilidade do processo de desgaste de uma ferramenta utilizada em operações de usinagem representa a probabilidade de que, em um tempo T , o valor do desgaste da ferramenta atinja um nível tal que comprometa as tolerâncias exigidas no projeto (CRUZ, 2010).

Uma das principais implicações do desgaste da ferramenta, é que ele leva a alterações geométricas que causam um desbalanceamento nas forças

de corte e, conseqüentemente, maior vibração e impacto com a parede do furo (ABU-MAHFOUZ, 2003; JANTUNEN, 2002).

A detecção do desgaste da ferramenta de corte é um dos primeiros passos à construção de um sistema de monitoramento de processo, já que afeta a capacidade de corte do sistema, influenciando em todos os seus resultados, a saber: diâmetro, circularidade dos furos, rugosidade, centralização e formação de rebarbas (ABU-MAHFOUZ, 2003).

4.3.7) Rugosidade

Rugosidade são imperfeições contidas em uma superfície, podendo ser mensurada com recursos e equipamentos apropriados. A importância do acabamento superficial aumenta, quando cresce a precisão de ajuste entre as peças. Uma menor tolerância de ajuste não é suficiente para garantir a funcionalidade do par acoplado (MARTINS, 2008).

Quando as superfícies são observadas com recursos apropriados, revelam irregularidades. As orientações das irregularidades dependem do tipo de processo que deu origem a superfície (OLIVEIRA, 2004). É importante lembrar que as superfícies reais de engenharia são compostas do perfil sem filtragem, ou seja, compostas de forma, ondulações e rugosidade.

A melhor maneira de analisar uma superfície está relacionada às orientações dos sulcos provenientes do processo de fabricação (WHITEHOUSE, 1994). Essas marcas oriundas dos processos de fabricação podem ser exemplificadas na Figura 23.

Paralelo		
Perpendicular		
Cruzado		
Multidirecional		
Particular		
Circular		
Radial		

Figura 23 - Tipos de acabamento superficial (WHITEHOUSE, 1994).

O comprimento, a forma e avanço do apalpador, as características do amplificador, a precisão do raio a ser medido e efeitos de filtragem mecânica são algumas das variáveis que podem afetar os resultados de uma medição de superfície (WHITEHOUSE, 1994).

Para a furação, a faixa de rugosidade média (R_a) pode ser compreendida entre 1,60 e 6,5 μ m, no entanto é difícil estipular um valor para os furos (BARBOSA, 2009).

A norma DIN 4766 abrange o valor de R_a na faixa compreendida entre 1,6 a 25 μ m para o processo de furação, conforme Tabela 2.

Tabela 2 – Valores de R_a para processos de fabricação (Adaptado da norma DIN 4766 por CAVALCANTE, 2010).

Método de Manufatura	Valores atingíveis médios de R_a em μ m											
	0,006	0,012	0,025	0,05	0,1	0,2	0,4	0,8	1,6	3,2	6,3	12,5
Furação												
Alargamento												
Mandrilamento												
Torneamento longitudinal												

Valores comuns Valores possíveis

4.3.7.1) Parâmetros de superfície geométrica

A rugosidade média (R_a) pode ser expressa como o desvio aritmético médio do perfil avaliado. A Figura 24 ilustra a obtenção da grandeza R_a .




Figura 24 - Rugosidade média R_a (WHITEHOUSE, 1994).

Devido à variação do parâmetro R_a , é possível indicar se o processo mudou em alguma variável (velocidade de corte, quantidade de fluidos, etc.); no entanto o R_a é um parâmetro de natureza média e, dependendo do tipo de processo, é ideal que ele seja associado com outros parâmetros de rugosidade (MARTINS, 2008).

Matematicamente, a expressão da rugosidade média correspondente à equação:

$$R_a = \frac{1}{l} \int_0^l |Z(x)| dx \quad (4.73)$$

O parâmetro R_a tem a desvantagem de não esclarecer ou caracterizar a variabilidade dos diferentes valores locais da rugosidade sobre o perfil analisado. Sua aplicação dentro da indústria é grande e é, normalmente, utilizado no acompanhamento de vários processos de fabricação. Devido à variação do parâmetro R_a é possível indicar se o processo mudou em alguma variável, como por exemplo, a velocidade de corte, quantidade de fluido, etc., (MARTINS, 2008).

Também conhecido como parâmetro R_{tm} , R_z (DIN) é a média de todos os valores de Z no comprimento de avaliação, em que Z é a altura máxima das rugosidades medidas no comprimento de amostragem. O parâmetro de rugosidade R_z fornece uma idéia mais clara para monitoração da variação do acabamento no processo de fabricação, visto que é a altura máxima do perfil analisado (MARTINS, 2008).

Fazendo uma comparação entre o parâmetro R_a e R_z , pode-se dizer que o parâmetro R_z é mais sensível às mudanças no acabamento superficial. A Figura 25 traz a análise da rugosidade de um perfil pelo parâmetro R_z .




Figura 25 - Parâmetro Rz DIN (TAYLOR, 2000).

Onde:

l_n = comprimento de avaliação

L = comprimento de amostragem (CUT-OFF)

A equação que define a rugosidade média R_z ou R_{tm} é dada pela relação 4.74:

$$(R_z(DIN) = R_{tm}) = \frac{Z_1 + Z_2 + Z_3 \dots Z_n}{n} \quad (4.74)$$

A aplicação do parâmetro R_z é semelhante à aplicação de outro parâmetro, como o R_t (definido em seguida), sendo que a diferença entre eles está na consequência de uma amplitude isolada entre picos e vales e na amplitude média entre todos os picos e vales (MARTINS, 2008).

A rugosidade R_t , mostrada na Figura 26, corresponde à distância entre o pico mais alto e vale mais profundo no comprimento de avaliação (l_n).




Figura 26 - Parâmetro R_t DIN (TAYLOR,2000).

Onde:

l_n = comprimento de avaliação

l = comprimento de amostragem (CUT-OFF)

O emprego do parâmetro R_a foi adotado neste trabalho como o parâmetro de referência por ser o valor usualmente utilizado em ambiente industrial para fabricação de furos de precisão, especialmente os utilizados na indústria aeronáutica.

4.4) Sensores

A utilização de sensores associados a sistemas computacionais inteligentes obteve sucesso em alguns exemplos como em publicações de Guibert, Paris e Rech (2008), Ozel e Karpas (2005), e Aguiar *et al.* (2008), respectivamente para torneamento, fresamento e retificação.

Dentre os inúmeros sistemas sensoriais disponíveis, o sensor de efeito Hall, para medição da corrente elétrica do motor do cabeçote da máquina, é um dos mais efetivos sistemas de controle de processos de usinagem. A maior vantagem da utilização desse tipo de sensor é o fato dele ser instalado longe do ponto de corte, em um circuito elétrico independente, não tendo qualquer influência sobre o processo (LIN E TING, 1996). Soma-se a isso, o fato de ele ser um dos mais baratos sistemas sensoriais disponíveis (CRUZ, 2010).

Acelerômetros são de simples operação e também não têm influência sobre a rigidez ou sobre processo em si (ABU-MAHFOUZ, 2003). São de simples montagem e apresentam boa resistência à degradação pelo fluido de corte e cavacos, e sofrem baixas ou nenhuma influência de eletromagnetismo e variações térmicas. Para sua boa operação, precisam, contudo, ser montados próximo ao ponto de corte (GUIBERT; PARIS; RECH, 2008). Os procedimentos de monitoramento baseados em vibrações mecânicas fundamentam-se no fato de que os sistemas mecânicos, com partes móveis e com ciclo de movimento fechado e repetitivo, como ocorrem no processo de furação, são compostos de elementos flexíveis que oscilam em torno de suas posições de equilíbrio estático, devido às excitações dinâmicas oriundas das vibrações de esforços dinâmicos que atuam sobre o sistema como, por exemplo, massas desbalanceadas, força de inércia e outras (EL-WARDANY; ELBESTAWI, 1996).

Sensores de emissão acústica (EA) são mais caros que acelerômetros industriais, e sua aplicação exige uma alta taxa de aquisição, utilização de filtros, sistema de armazenamento de dados e alta memória computacional. Essas exigências estão associadas ao seu projeto feito para captar sinais de altas frequências resultantes da deformação dos materiais, fratura, e quebra de cavaco. A grande vantagem na aplicação de sensores emissão acústica é sua alta sensibilidade e exclusividade em ler alguns fenômenos do processo, sendo que, dentre eles, pode-se citar a capacidade do sensor em captar a energia dissipada durante a retração elástica dos materiais após a ruptura da porção cortada ou quebra do cavaco (ABU-MAHFOUZ, 2003).

Sensores de força apresentam, como principal vantagem, o fato de lerem diretamente umas das variáveis mais importantes e influentes no processo de furação. Medir o torque e a força de avanço durante o processo requer instrumentação cara, como o uso de dinamômetros e, na maioria dos casos necessita de um sistema de fixação especial, o que pode influenciar na dinâmica e rigidez características do sistema de furação (ABU-MAHFOUZ, 2003).

Um sistema de controle confiável permite operar próximo aos limites impostos pela segurança, pelo meio-ambiente e pelo processo (temperatura

máxima, pureza mínima), o que permite alterar as condições de operação normais para uma condição mais favorável (CRUZ, 2010).

5) Material e Métodos

Neste capítulo será descrita toda a metodologia aplicada na preparação do banco ensaio, corpos de prova, escolha dos materiais e também o processo de aquisição dos sinais e a construção das redes neurais.

5.1) Preparação dos corpos de prova

A liga de Alumínio 2024 T3, utilizada neste trabalho, é também empregada em uma série de indústrias em razão de sua resistência mecânica e baixa densidade. Sua maior usinabilidade também é um fator de seleção entre os outros materiais. A adição de silício ao alumínio decresce o seu ponto de fusão e melhora a resistência ao desgaste quando aplicada em componentes estruturais (COTTERELL, 2002).

A liga de Titânio Ti-6Al-4V, que também foi utilizada neste trabalho, na confecção do corpo de prova, tem sido usada desde 1960 em projetos aeronáuticos, devido a sua grande resistência mecânica associada a ao baixo peso molecular quando comparados aos aços (COTTERELL, 2002).

O corpo de prova adotado neste trabalho foi composto por uma chapa de 150 x 50 x 2 mm de Titânio (Ti6Al4V), seguida por uma chapa de 150 x 50 x 3 mm de Alumínio (2024T3).

As Figuras 27 e 28 mostram o corpo de prova utilizado com suas dimensões e posições de usinagem. A utilização dessas espessuras e materiais foram assim selecionada por representarem com fidelidade condições muito comuns em reforços estruturais de conjuntos aeronáuticos, nos quais são colocados para aumentar a resistência sem grandes aumentos de peso, pois associam leveza e resistência ao avião.



Figura 27 – Vista Lateral do Corpo de Prova.




Figura 28 – Vista Superior do Corpo de Prova.

O ensaio foi planejado em seis (6) corpos de prova, com vinte e sete (27) posições de furação cada um, totalizando cento e sessenta e dois (162) furos.

Para garantir a união entre as diferentes chapas durante o processo de furação, evitando que haja deflexão de apenas uma das chapas ou intrusão de cavaco entre elas, um dispositivo foi elaborado com uma tampa de contorno que se sobrepõe às extremidades dos corpos de prova, pressionando uma chapa contra a outra. Além deste dispositivo, uma fita adesiva foi colocada nas extremidades de cada corpo de prova para evitar que, depois de retirado do banco de ensaios, as chapas se separassem, gerando, assim, alguma confusão durante as medições de diâmetro e rugosidade.

As principais características físicas, mecânicas e térmicas, além dos constituintes de cada material utilizado nos ensaios, estão listadas na Tabela 3

Tabela 3 – Constituição das Ligas Utilizadas (Fonte: www.matweb.com).

	2024T3	Ti6Al4V
Constituição da Liga		
	Al : 90.7 - 94.7%	Al : 5.50 - 6.75 %
	Cr : <= 0.10 %	C : <= 0.0800 %
	Cu : 3.80 - 4.90 %	H : <= 0.0150 %
	Fe : <= 0.50 %	Fe : <= 0.400 %
	Mg : 1.20 - 1.80%	N : <= 0.0300 %
	Mn : 0.30 - 0.90 %	O : <= 0.200 %
Constituição da Liga	2024T3	Ti6Al4V
	Si : <= 0.50 %	V : 3.50 - 4.50 %
	Ti : <= 0.15 %	Ti : 87.725 - 91.0 %
	Zn : <= 0.25 %	-
	Outros, tota: <= 0.15 %	Outros, total: <= 0.30 %
Propriedades Físicas		
Densidade	2.78 g/cc	4.43 g/cc
Propriedades Mecânicas		
Dureza, Brinell	120	379
Dureza, Rockwell	75 Rockwell B	41 Rockwell C
Tensão de Ruptura	483 MPa	1170 MPa
Tensão de Escoamento	345 MPa	1100 MPa
Alongamento até a ruptura	18.00%	10.00%
Módulo de Elasticidade	73.1 GPa	114 GPa
Coeficiente de Poisson	0.33	0.33
Usinabilidade	70%	Não especificada
Propriedades Térmicas		
Calor Específico	0.875 J/g-Â°C	0.5263 J/g-Â°C
Condutividade Térmica	121 W/m-K	6.70 W/m-K
Ponto de Fusão	502 - 638 Â°C	1604 - 1660 Â°C

5.2) Ferramentas de Corte

Neste trabalho, optou-se pela utilização de metal duro para realização dos ensaios, pois houve a intenção de reproduzir, fielmente, as condições de usinagem aplicadas na indústria aeronáutica, especialmente as utilizadas em furações de precisão com máquina CNC.

As ferramentas utilizadas nos ensaios foram fabricadas pela empresa OSG Ferramentas, especialista na fabricação de ferramentas com geometria especial, sendo em sua atividade uma das mais conceituadas para o atendimento das necessidades das indústrias aeronáuticas do país.

A Figura 29 mostra a ferramenta de corte utilizada nos ensaios com suas principais dimensões.



Figura 29 – Identificação das brocas helicoidais utilizadas nos ensaios.

Antes dos ensaios de furação, o diâmetro externo das ferramentas de corte foi analisado em um projetor de perfis, para assegurar o real valor do diâmetro da ferramenta. Este valor é importante, pois o mesmo será utilizado na equação da velocidade de corte, e servirá como uma das entradas da rede neural de estimação. A Figura 30 ilustra o processo de medição utilizando este aparelho.



Figura 30 – Medição das brocas helicoidais antes dos ensaios.

Sabe-se, contudo, que o ajuste da posição durante a medição de máximo diâmetro não é preciso. Por isso, a ferramenta foi medida três (3) vezes, sendo aceito um valor médio das medidas encontradas.

O valor nominal da broca é 4,950 mm e o valor encontrado após as medições foi de 4,939 mm, mostrando um erro de 0,011 mm entre o diâmetro real e nominal da broca. Essa variação é aceitável para padrões industriais, mas buscaram-se valores mais precisos para realização deste trabalho.

Para o cálculo da velocidade de corte foi utilizado o valor de 4,939 mm como referência.

5.3) Confeção do banco de ensaios

O dispositivo de fixação projetado precisava garantir que as chapas que constituíam o corpo de prova ficassem unidas, uma contra a outra, de forma a impedir que, durante a furação, houvesse intrusão de limalha entre as chapas, prejudicando a qualidade dos sinais provenientes do sistema.

Havia, também, a necessidade de se projetar o dispositivo de fixação respeitando as dimensões do sensor de força, sobre o qual ele seria montado. Uma dimensão maior a do sensor poderia gerar um binário de forças que comprometeriam os valores lidos pelo dinamômetro.

O dispositivo foi confeccionado em aço com baixo percentual de carbono. Porcas borboletas foram colocadas no fechamento da tampa superior

para facilitar a troca de corpos de prova entre um ensaio e outro. A Figura 31 mostra o desenho esquemático da base utilizada nos ensaios.




Figura 31 – Desenho esquemático da base utilizada nos ensaios.

A Figura 32 mostra a instalação da base de ensaio na fresadora. A base foi confeccionada, especialmente, para garantir a fixação do mesmo na mesa da máquina e a correta fixação do corpo de prova.



(A)



(B)

Figura 32 – Base de Ensaio, Fresadora e Corpo de Prova.

5.4) Preparação da fresadora para os ensaios

A máquina ferramenta utilizada neste trabalho foi uma fresadora universal da marca Zocca, modelo U-30, localizada no Laboratório de Tecnologia da Usinagem (LATTUS), no campus da UNESP de Bauru.

Nesta fresadora, o controle da rotação do motor do cabeçote e da velocidade de corte é feito de forma mecânica, alterando as posições das alavancas e mudando as relações entre engrenagens.

Para facilitar o controle de posicionamento, a máquina foi equipada com réguas eletrônicas de precisão micrométrica para demarcação das posições dos eixos X, Y e Z ortogonais. Assim, antes do início dos ensaios, a máquina foi posicionada na demarcação de zero garantindo que os furos fossem realizados equidistantes entre si.

A Figura 33 mostra uma foto do banco de ensaios, sensores e do sistema de aquisição de dados.




Figura 33 – Fresadora e computador de aquisição utilizado nos ensaios.

O computador utilizado foi equipado com uma placa de aquisição de sinais da marca *National Instruments*, modelo PCI-6035E, de 16 bits de resolução, taxa de aquisição de 200.000 amostras por segundo. Para este trabalho, foi utilizada a taxa de aquisição de 2.000 amostras por segundo por canal. Nenhum sistema de lubrificação foi utilizado, pois se queria reproduzir as condições utilizadas na montagem de aeronaves em industriais aeroespaciais.

Dentro da indústria, utiliza-se de selantes de interface que são colocados em camadas, que variam de 0,1 a 0,4 mm na junção entre chapas. Os selantes de interface têm por objetivo evitar vazamentos de gases durante a pressurização para voo. Depois de aplicadas, estas substâncias permitem operações de furação e cravação (considerado tempo de manuseio) durante intervalos de tempo que vão de 20 a 80 horas, em média, dependendo do tipo de selante. Após essa janela de operação, a substância entra em processo de cura, não permitindo nenhuma furação nas superfícies seladas. É durante este período de manuseio que as montagens e processamentos, que afetam a região de interface, devem ser realizados para evitar o aparecimento de trincas no selante responsável pelas vedações.

Também durante o manuseio, os selantes são facilmente contaminados perdendo suas propriedades. Os fluidos de corte são contaminantes e, por isso, seu contato direto com o selante é evitado, justificando, assim, a condição de corte a seco.

5.5) Instalação dos sensores

A Figura 34 mostra o esquema do banco de ensaios com o posicionamento dos sensores.




Figura 34 – Desenho esquemático do banco de ensaios.

Sensores de emissão acústica, acelerômetro unidimensional, sensor de efeito Hall e dinamômetro tridimensional foram utilizados neste trabalho com a finalidade de monitorar, respectivamente, os sinais de emissão acústica, aceleração, potência do motor elétrico do cabeçote e força tri-axial ortogonal durante o processo de furação.

Estes sinais foram coletados por meio de sensores instalados na fresadora e ligados a um computador, passando por módulos de aquisição de sinais e por um conector de bornes do tipo BNC.

5.5.1) Sensor de potência elétrica

O sensor de efeito Hall, para medição da corrente elétrica do motor do cabeçote da máquina, é um dos mais efetivos sistemas de controle de processos de usinagem. A maior vantagem da utilização desse tipo de sensor é

o fato dele ser instalado longe do ponto de corte, em um circuito elétrico independente, não tendo qualquer influência sobre o processo (LIN e TING, 1996). O sensor de potência elétrica utilizado neste trabalho foi formado de um módulo desenvolvido pelo Grupo de Usinagem por Abrasão, da Faculdade de Engenharia de Bauru – UNESP, no qual se alojavam os sensores de corrente e tensão, bem como circuitos eletrônicos responsáveis pelo tratamento analógico desses sinais. A corrente elétrica foi medida por um sensor de efeito Hall, do fabricante Nana Eletronics Co. Ltda, e a tensão elétrica também por um sensor de efeito Hall, modelo LV25-P, do fabricante LEM. Para determinação da potência elétrica, os sinais eram multiplicados por um circuito integrado e, posteriormente, filtrados, resultando em um sinal elétrico equivalente à potência elétrica consumida pelo motor de indução trifásico, responsável pelo acionamento do eixo árvore da máquina.

A partir de curvas características do motor de indução, fornecidas pelo fabricante, pode-se determinar, com uma boa precisão, o valor da potência de corte. A equação de calibração para o módulo de potência está descrita pela relação 5.1.

$$Pot = 1341,1Pot_m - 7,5 \quad (5.1)$$

onde:

Pot: é a potência de corte média real;

Pot_m: é o nível de DC gerado na saída do módulo referente a potência elétrica consumida pelo motor de indução;

5.5.2) Sensor de força

O sensor de força tridimensional foi instalado sobre a bancada da máquina e sob o dispositivo projetado para fixação dos corpos de prova. Na montagem realizada, os eixos do sensor estão alinhados ao sistema de referência mostrados na Figura 34, sendo que o eixo Z é paralelo e de mesmo sentido ao movimento do avanço da ferramenta sobre a peça.

Parafusos foram utilizados para a fixação do sensor à bancada da máquina de forma a impedir qualquer deslocamento durante os ensaios.

A base do sensor de força (dinamômetro) foi presa na mesa da máquina por meio de parafusos de fixação, como a Figura 35 ilustra.




Figura 35 – Instalação do Dinamômetro.

O dinamômetro utilizado neste trabalho foi um sensor piezelétrico da marca Kistler, modelo 9257BA, e acompanhado por um módulo de leitura da mesma marca. Este módulo permite o ajuste individual de fundo de escala para o eixo Z, e em conjunto para os eixos X e Y. Assim, durante os ensaios preliminares, os sinais tiveram seus fundos de escala ajustados de forma a possibilitar a leitura de um sinal claro, sem haver saturação. A Tabela 4 mostra os valores empregados.

Tabela 4 – Valores de ganhos utilizados no módulo do sensor de força.

Eixo	Força Máxima [kN] Fundo de Escala	Taxa de Conversão [mV/N]
X	1,0	5,0
Y	1,0	5,0
Z	2,0	2,5

5.5.3) Sensor de emissão acústica

Ao modelar um sistema de monitoramento de um processo em ambiente industrial buscar-se-ia encontrar uma posição para instalação do sensor de emissão acústica (EA), de modo que ela não precisasse ser alterada ou removida durante um “set-up” de máquina ou troca de componente.

Pensando neste aspecto e na concepção das máquinas ferramentas existentes, verifica-se que a instalação ótima de um sensor de EA seria, para a grande maioria dos casos, em posição estática próxima ao cabeçote da máquina. Nesse local, o sensor não está distante dos pontos de corte, tampouco atrapalha a substituição da peça, ferramental ou ferramenta utilizada.

Pensando nos aspectos abordados, a posição inicial planejada para a instalação do sensor parafusado foi próximo ao mandril da máquina. Contudo, durante a realização dos ensaios preliminares, notou-se que, mesmo utilizando o maior ganho permissível deste sensor, o sinal lido era fraco e de baixa qualidade.

A Figura 36 mostra a região onde o sensor de emissão acústica foi instalado.




Figura 36 – Posição dos sensores de emissão acústica.

Um sensor de E.A., que têm fixação magnética, também foi testado em substituição ao modelo inicial, contudo, os resultados foram similares. Assim, a posição encontrada para a leitura de um sinal de qualidade foi fixado ao banco de ensaios, projetado para prender os corpos de prova.

A fixação foi feita utilizando grampos. Graxa foi colocada na interface do sensor com o banco de ensaios para reduzir os vazios e aumentar a qualidade da leitura dos sinais. O sensor e o módulo utilizados são da marca *Sensis*, modelo DM42. Os valores ajustados no módulo de emissão acústica são mostrados na Tabela 5.

Tabela 5 – Valores de ajustes no módulo de emissão acústica.

Módulo de Emissão Acústica	
Ganho de Entrada	15 db
Ganho de Sinal	50 db
Redução de Ruído	10 dB
Filtro Passa Alta	2 kHz
Constante de Tempo	1 ms

5.5.4) Acelerômetro – Sensor de Vibração

A mesma discussão realizada sobre a posição do sensor de emissão acústica também se aplica ao acelerômetro utilizado. Inicialmente, foi planejada a colocação deste sensor na parte superior da máquina; contudo, o sinal, também foi pobre para utilização nesta posição. A Figura 37 mostra o local final da instalação do sensor de vibração.




Figura 37 – Posição dos sensores de aceleração.

Os sensores de aceleração utilizados são da marca PCB, modelo 482811. Para a realização dos ensaios, o módulo do sensor de aceleração foi ajustado para fundo de escala de sinal de 100 vezes.

5.5.5) Ligação dos sensores a placa de aquisição

A ligação dos sensores a placa de aquisição se deu através de um conector de bornes da marca *National Instruments*, modelo BNC 2110. A **Erro! Fonte de referência não encontrada.** mostra os canais de leitura utilizados para cada um dos sinais.

Tabela 6 – Valores de ajustes no módulo de emissão acústica.

Sensor de Identificação	Grandeza Medida	Canal de Medição
Acelerômetro	Aceleração, Vibração	Canal 0
E. A	Emissão Acústica	Canal 1
Efeito Hall	Potencia do Motor Elétrico	Canal 2
Dinamômetro	Força eixo X	Canal 3
	Força eixo Y	Canal 4
	Força eixo Z	Canal 5

5.6) Parâmetros de corte utilizados no ensaio

Antecedendo a realização dos ensaios definitivos, foram realizados testes preliminares que tinham por objetivo principal o ajuste da posição de montagem dos sensores, o acerto dos valores de fundo de escala e a determinação das condições de corte.

Para coleta e armazenamento dos dados foi utilizado um programa construído em plataforma *LabVIEW*. O programa foi desenvolvido pelo aluno de Iniciação Científica, Hildo Guillard, e adaptado por Carlos Cruz para utilização neste trabalho.

Com os sensores posicionados e o programa em funcionamento, alguns furos foram realizados para verificar a leitura dos sensores. Como foi descrito anteriormente, as posições inicialmente pensadas para posicionamento dos sensores de aceleração e emissão acústica apresentaram sinais pobres e necessitaram alterações. Com os sensores em suas novas posições, iniciou-se um trabalho de ajuste dos módulos. Este ajuste visou possibilitar a leitura dos sinais na condição de usinagem mais branda, em que o corte era favorecido por um baixo avanço, e ao mesmo tempo, fazer a leitura na condição mais severa, sem que houvesse saturação dos sinais, fazendo com que dados importantes do processo não fossem perdidos ou saturados.

Depois de realizados os ajustes dos valores de ganho e redução de ruídos, deram-se a escolha das condições de usinagem para utilização nos ensaios definitivos. A tabela 7 mostra os parâmetros de corte utilizados durante os ensaios.

Tabela 7 – Parâmetros de Usinagem

Rotação [RPM]	Velocidade de Avanço [mm/min]	Velocidade de Corte [m/min]	Avanço [mm/rev]
1000	90,0	15,52	0,090

A escolha desses parâmetros visou à reprodução de algumas condições de usinagem usualmente utilizadas na indústria para processamento de ligas de titânio. Para a realização dos ensaios, o cabeçote da máquina era

posicionado a uma altura padrão; o programa de aquisição era iniciado e então a alavanca que controla o avanço era acionada. Quando o cabeçote atingia o fim do curso de avanço a alavanca da máquina era invertida para retrocesso da ferramenta. Ao atingir, novamente, a posição superior, o programa de aquisição era desligado, causando assim um tempo de inatividade dos sinais, anterior ao toque da broca no corpo de prova e posterior à sua saída.

5.7) Tratamento e análise dos sinais coletados

Os sinais coletados durante os ensaios foram analisados com o auxílio de rotinas desenvolvidas no MATLAB. Devido à sistemática utilizada durante os ensaios, os dados coletados pelos sensores apresentam dois períodos de inatividade. O período de inatividade está relacionado ao tempo transcorrido entre o acionamento do programa de aquisição de dados até o toque da ferramenta no corpo de prova e, posteriormente, corresponde ao tempo entre a saída da ferramenta da peça até o desligamento do sistema de aquisição. Estes períodos de inatividade podem ser visualizados na Figura 38.




Figura 38 – Força em Z utilizadas para a determinação do ponto inicial das aquisições e do ponto de corte

Dos sinais coletados, a força no eixo Z é a que mais facilmente permite determinar o exato momento de início e fim do corte, bem como o momento de transição da ferramenta entre os materiais. Baseado nesta característica, este sinal foi escolhido e utilizado dentro de um algoritmo, que detectava automaticamente, através da construção de médias móveis, o ponto inicial e final da usinagem.

Pela análise da Figura 38 é possível detectar seis pontos distintos e correlacioná-los com o processo, sendo:

- Ponto 1: Ponta da ferramenta de corte toca o corpo de prova de Titânio, iniciando o processo de usinagem. Há um rápido crescimento no valor da força lida.
- Ponto 2: Aresta principal de corte atinge a liga de Titânio dando início a geração do furo. Fato pode ser notado pela estabilização do sinal por um período de tempo até atingir o ponto três.
- Ponto 3: Ponta da broca toca a liga de Alumínio. Por se tratar de um material mais dúctil, inicia-se um decréscimo no valor da força no eixo Z.
- Ponto 4: Aresta principal de corte atinge a liga de Alumínio, fato demonstrado pelo início de uma nova região quase horizontal.
- Ponto 5: Ponta ferramenta começa a deixar o corpo de prova. Começa o retorno do sinal a seu patamar inicial.
- Ponto 6: Aresta principal de corte ultrapassa totalmente as chapas, fazendo com que o sinal retorne a um ponto de inatividade do processo.

A correlação entre os pontos nos diferentes sinais pode ser observada na Figura 39 e Figura 40.




Figura 39 – Ilustrações dos sinais de Força envolvidos na aquisição.




Figura 40 – Ilustrações dos sinais de Aceleração, E.A, Potência do Motor Elétrico.

Nestas figuras fica mais simples correlacionar os sinais com o avanço do processo no tempo, e nota-se que há uma maior dificuldade em detectar claramente o início e fim do processo senão pelo sinal da força no eixo Z.

A Figura 40 apresenta a leitura dos sinais para todas as outras grandezas medidas. É possível notar que, mesmo depois que o sinal de força em Z para de captar o processo de usinagem, o sinal de força em X e Y e o sensor de potencia motor elétrico ainda captam alguma leitura. Isso se deve ao fato de que mesmo depois da aresta principal da ferramenta ultrapassar totalmente as chapas do corpo de prova, ainda existe contato lateral da broca com a parede do furo.

Como foi descrito na revisão literária, o processo de usinagem envolvem deformações plásticas e deformações elásticas do material. A deformação plástica está relacionada ao processo de corte e à geração de tensões de cisalhamento que, ao atingirem determinado valor, provocam a ruptura do material, ocasionando a fragmentação do cavaco.

As deformações elásticas, por sua vez, se devem ao recalque do material usinado, provocado pela compressão exercida pela ferramenta na parede do furo. Quando esta compressão deixa de existir, ou seja, quando as arestas de corte ultrapassam totalmente a chapa, a região da porção final do material retorna da deformação plástica, ocasionando o contato da ferramenta com a parede do furo.

Este fenômeno é denominado de *spring back* e ocorre durante todo o avanço da ferramenta na porção exatamente acima das regiões das arestas principais de corte. Sua influência é, contudo, mais facilmente percebida, na porção final da geração do furo, uma vez que nesta região a guia ferramenta já deixou a peça e não existe mais o apoio das regiões frontais da broca que se contrapunham a força exercida pelo contato do material que retorna da deformação plástica.

Este contato fica ainda mais evidente durante o retorno do cabeçote da máquina, quando é possível escutar ruídos decorrentes da fricção da broca contra a parede do furo e mesmo detectar cavacos de tamanhos bem reduzidos gerados pelo corte da broca durante este retorno.

Como a máquina utilizada nos ensaios deste trabalho não é CNC, o tempo transcorrido entre o final do corte e o retorno do cabeçote variou de um

ensaio para outro, uma vez que dependia da percepção do operador do ensaio em notar que a ferramenta havia atingido o final de seu curso e reverter o movimento de avanço através de uma alavanca.

Por apresentar variações entre um ensaio e outro, os dados coletados depois do ponto seis (6) da Figura 38 foram descartados das análises, como será mostrado a seguir.

Pelo que foi apresentado, é possível afirmar que este contato da ferramenta com a parede do furo e o corte ocorrido durante o recuo da ferramenta afeta o diâmetro e a rugosidade dos furos produzidos, uma vez que há remoção de material e fricção da lateral da broca com a parede do furo. Contudo, não se pode dizer se esta influência é relevante ou não para os níveis de precisão do processo estudado e equipamentos utilizados neste trabalho. Assim, recomenda-se para o futuro que estas relações sejam mais detalhadamente estudadas, de preferência, utilizando máquina automática que permitam padronização na operação.

Excluídas as regiões tidas como inativas, construiu-se a base de dados para as discussões mostradas neste trabalho e a alimentação das redes neurais artificiais. A região remanescente do gráfico foi dividida em duas partes, sendo cada uma referente a um material. Os dois quintos (2/5) iniciais do gráfico são referentes à usinagem da liga de Titânio e os outros três quintos (3/5) ligados ao material 2024T3, conforme mostrado na Figura 41.

Esta divisão se deve à espessura desigual das chapas. Sabendo-se que a velocidade de avanço no ensaio é constante e que a chapa de alumínio é cinquenta por cento (50%) mais espessa que a chapa da liga de Titânio, resulta a divisão apresentada.

A importância de dividir os sinais em duas regiões é ter valores separados de cada material para alimentação da rede, pois conforme será descrito, cada liga terá seu valor de diâmetro e rugosidade associado para um mesmo furo.




Figura 41 – Divisão dos sinais durante a usinagem dos diferentes materiais

Feita a divisão, foi calculada a média aritmética dos valores absolutos de cada sinal. Estes resultados foram utilizados nas discussões acerca dos resultados da usinagem e serviram como entrada para as redes neurais artificiais.

5.8) Medição dos diâmetros dos furos.

Depois de realizados os ensaios, os corpos de prova foram limpos, utilizando ar comprimido e panos para eliminar os cavacos e sujeiras que pudessem existir.

Para realizar a medição do diâmetro dos furos foi utilizado um relógio comparador de precisão micrométrica da marca *Mahr*, modelo *Marcator 1087B*, equipado com uma haste com ogivas em sua ponta. Este equipamento permite a medição do diâmetro através da inserção da haste no interior do furo.

Quando a haste é introduzida, as esferas presentes em sua ponta se fecham, empurrando a agulha interna do aparelho para cima, o que resulta na medição por parte do relógio comparador, com uma precisão de $\pm 0,005$ mm conforme informação do fabricante. A Figura 42 apresenta o esquema do funcionamento do aparelho.

Como os materiais são diferentes, o diâmetro do furo produzido pelo processo de furação também é, geralmente, diferente. Isso pode ser explicado pelas diferenças de dureza e resistência a abrasão de cada material, pela formação de arestas postiças e pela deflexão da ferramenta, dentre outros.




Figura 42 – Esquema do funcionamento do aparelho de medição dos diâmetros.

Nenhum furo é perfeitamente circular, apresentando sempre uma geometria oval. Desta forma, o diâmetro máximo e mínimo de cada furo, em cada material, também foi medido. Assim, cada furo teve seu diâmetro medido em duas regiões: Na entrada do furo, referente ao diâmetro da liga de Titânio e na saída do furo, referente à liga de Alumínio, conforme mostra a Figura 43.

A determinação desta diferença entre diâmetros de um mesmo furo foi possível através da utilização da função min/max do relógio comparador. Com a haste introduzida no furo, a função “máxima” do relógio comparador era acionada. Com o equipamento nesta posição era dado um giro de cento e oitenta graus (180°) na haste, no interior do furo, sendo que, ao fim do giro, o relógio mostrava em seu display o valor do máximo diâmetro. O processo era repetido para o menor valor.




Figura 43 – Processo de medição dos diâmetros de cada furo

Da forma descrita, ao final das medições, cada furo apresentava quatro medidas de diâmetro vinculadas, sendo: máximo diâmetro na liga Ti6Al4V, mínimo diâmetro na liga Ti6Al4V, máximo diâmetro na liga 2024T3 e mínimo diâmetro na liga 2024T3. Para cada material foi utilizado um valor de diâmetro médio, utilizando o valor médio e mínimo de cada furo para o treinamento das redes neurais.

5.9) Medição da Rugosidade

A medição da rugosidade da parede interna dos furos deste trabalho foi realizada no Laboratório de Metrologia da empresa Taylor Robson, localizada na sede nacional da empresa, na cidade de São Paulo.

Para a realização do trabalho foi utilizada uma máquina da Marca Taylor Robson, modelo Form Talysurf - Intra 50. A maior dificuldade encontrada em realizar esta medição está no pequeno diâmetro do furo, que impede a utilização de rugosímetros convencionais, uma vez que a haste com ponta de diamante destes equipamentos não é pequena o suficiente para percorrer o interior do furo. Assim, o equipamento utilizado foi equipado com uma haste

especial, denominada de *Small Bore*, própria para a medição de furos de pequeno calibre.

Como a medição da rugosidade dos furos é bastante trabalhosa e demorada, para cada corpo de prova de vinte e sete (27) furos, foram escolhidos apenas três (3) furos com o intuito de otimizar o processo de medição buscando não penalizar a qualidade dos dados. Os furos utilizados foram os primeiros, os últimos e os intermediários de cada corpo de prova.

A rugosidade média aritmética (R_a) foi utilizada para as comparações e análises deste trabalho. A Figura 44 mostra a máquina e a metodologia de medição e enfatiza os furos medidos de cada amostra.



Figura 44 – Metodologia de medição da rugosidade.

O valor de *cut-off* adotado para a medição da rugosidade foi de 0,8 mm, valor este sugerido pela norma ISO 4288-1996 para medição de superfícies com R_a entre 0,1 μm e 2 μm . Os comprimentos de amostragem adotados foram de 2,4 mm para a Liga de Alumínio, o que representa cinco vezes o *cut-off*, valor também sugerido pela mesma norma, e 1,5 mm para o Titânio, uma vez que a espessura da chapa (2,0 mm) não permitia adoção de comprimento de amostragem maior.

Da mesma forma que ocorre para o diâmetro do furo, a rugosidade também varia de um material para outro. Assim, para cada ponto escolhido de

análise, foi medida separadamente a rugosidade na parede interna do furo de ambas as ligas.

Os furos não medidos de cada corpo de prova tiveram sua rugosidade estimada através de uma regressão linear entre os valores de um furo e outro, fornecendo assim quantidade de dados suficiente para treinamento das redes.

5.10) Construção das redes neurais

O diagrama da Figura 45 mostra a inter-relação entre os dados aqisitados durante as furações e as redes neurais artificiais utilizadas para obtenção de informações um passo à frente.




Figura 45 – Diagrama das redes neurais utilizadas no trabalho.

Todas as redes construídas neste trabalho foram feitas com a utilização do software MATLAB e seu “*Toolbox*” específico para esta aplicação.

Para a predição dos diâmetros e rugosidades de cada furo realizado foi necessária a utilização de duas redes neurais artificiais conjugadas, uma para a estimação dos valores e outra para predição um passo a frente.

A rede neural do tipo *Perceptron* Multi-camadas *Feedforward* trabalhou para estimar os valores baseando-se nos sinais aqisitados durante cada ensaio de furação. Os resultados estimados desta rede serviram de entrada para uma segunda rede neural, do tipo TDNN, que possui características de predição.

Com o intuito de utilizar as redes neurais com a melhor configuração possível, minimizando os erros de estimação e predição, um esquema iterativo foi elaborado para que as redes fossem testadas, variando seus parâmetros internos após cada ciclo de treinamento.

Para a rede *feedforward*, variou-se o número de camadas escondidas, número de neurônio em cada camada, momento e taxa de aprendizagem da rede. Foram testadas redes com uma, duas e três camadas escondidas, e neurônios nestas camadas que variavam de 5 a 40 neurônios, num total de cento e cinquenta e cinco (155) combinações. Além dos neurônios e camadas, a taxa de aprendizagem foi testada com valores de 0,05, 0,20, 0,30, 0,50 e 0,90; e valores de momento que variavam de 0,1 a 0,9, com incrementos de 0,1.

Este processo resultou na construção de redes distintas aplicadas à estimação do diâmetro e da rugosidade. No total, estas combinações resultaram em mais de seis mil redes testadas para cada aplicação, sendo que, ao final do treinamento e validação de cada uma dessas arquiteturas de rede, os erros eram calculados.

O treinamento das redes de estimação seguiu a seguinte divisão: setenta por cento (70%) dos dados para treinamento, quinze por cento (15%) para validação e os outros quinze por cento (15%) para testar a eficácia do método proposto. Estas divisões eram realizadas automaticamente no momento do treinamento de cada rede.

Um procedimento semelhante para a rede temporal TDNN foi realizado, no qual se variou o tamanho das janelas iniciais, momento, taxa de aprendizado e o número de neurônio na camada escondida. Foram testadas redes com neurônios que variavam de 3 a 30 neurônios. A taxa de aprendizagem foi testada com valores de 0,05, 0,20, 0,30, 0,50 e 0,90; e o momento com valores que variavam de 0,1 a 0,9 com incrementos de 0,1. As janelas, por sua vez, variaram de 3 a 15.

Este processo resultou na construção de mais de cinco mil redes distintas, aplicadas à predição do diâmetro e da rugosidade, sendo que no final do processo de treinamento e validação, cada uma dessas arquiteturas teve seus erros comparados com os valores atuais para que se pudesse escolher a rede com menor erro.

5.10.1) Redes Neurais na Estimação do Diâmetro

A arquitetura proposta para a estimação do diâmetro utilizou como parâmetros de entrada para a rede a média simples dos sinais medidos durante os ensaios (aceleração, emissão acústica, potência, força em X, força em Y e força em Z). A configuração da rede é mostrada na Figura 46.




Figura 46 – Arquitetura da rede neural para estimação dos diâmetros.

Também foram utilizados como valor de entrada, para a rede neural de estimação, os parâmetros de usinagem, velocidade de corte e o avanço da ferramenta de corte. As saídas esperadas das redes era o diâmetro médio de cada furo medido.

Como se tivessem sido feitos em processos distintos, os sinais e medidas de diâmetro de cada material foram utilizados separadamente, gerando, assim, análises individuais do comportamento da rede neural para cada material.

De todas as combinações testadas de parâmetros internos à rede, realizados de forma automática, conforme descrito anteriormente, aquela que

apresentou menor erro na determinação dos diâmetros foi escolhida para realizar os demais testes do trabalho. Os melhores parâmetros encontrados após o processo iterativo estão mostrados na Tabela 8.

Tabela 8 – Parâmetros da rede de estimação de diâmetros – Todos os sinais.

Parâmetros da rede de estimação dos Diâmetros	
Número de Neurônios por camada	[5 2 5]
Função de Transferência entre neurônios da camada escondida	Tansig
Função de Transferência para camada de saída	Pureln
Momento	0,5
Taxa de Aprendizagem	0,1
Número máximo de épocas	100
Erro	1,00 E -04
Função de treinamento	Trainlm Lev-Maq

A rede neural que apresentou o melhor resultado, isto é, os menores erros quando comparados com os valores reais, tinha três (3) neurônios na camada escondida, com cinco, dois e cinco neurônios respectivamente em cada camada.

5.10.2) Redes Neurais na Estimação da Rugosidade

Da mesma forma que foi realizada para a estimação do diâmetro, a rede utilizada para estimação da rugosidade também utilizou os sinais dos sensores somados aos parâmetros de corte como padrões de entrada, porém, agora, como valor de saída foi utilizado a rugosidade média (R_a). A arquitetura discutida está apresentada na Figura 47.

Após uma longa rotina de treinamento, em que os parâmetros descritos na Tabela 6 foram variados, encontrou-se a arquitetura de rede com o menor erro quadrático médio em relação aos valores reais medidos. Lembrando que

alguns dos valores de rugosidade foram interpolados e utilizados como se fossem dados reais.




Figura 47 – Arquitetura da rede neural para estimativa das rugosidades.

A Tabela 9 mostra as características da rede neural artificial final utilizada para estimativa dos valores de rugosidade a partir dos dados parâmetros de entrada mostrados na Figura 57.

Tabela 9 – Parâmetros da rede de estimativa da rugosidade - Todos os sinais.

Parâmetros da rede de estimativa das rugosidades	
Número de Camadas	3
Número de Neurônios por Camada	[10 10 5]
Função de transferência entre neurônios da camada escondida	Tansig
Função de transferência para camada de saída	Pureln
Momento	0,8
Taxa de aprendizagem	0,15
Número máximo de épocas	200
Erro (objetivo)	1,00 E -07
Função de treinamento	Lev-Maq

A rede neural que apresentou o melhor resultado tinha três (3) neurônios na camada escondida, com dez, dez e cinco neurônios respectivamente em cada camada.

Nota-se que os valores de configuração da rede neural, para a determinação dos diâmetros, foram diferentes dos parâmetros para estimação da rugosidade, mostrando que os mesmos sinais precisam ser tratados de maneira diferente para determinar diferentes características do processo de furação.

5.10.3) Redes Neurais na Predição do Diâmetro Médio

A arquitetura proposta para a predição do diâmetro utilizou, como parâmetro de entrada, os resultados de saída da rede de estimação,. A arquitetura da rede proposta é mostrada na Figura 48.




Figura 48 – Arquitetura da rede neural para predição de diâmetro.

Esta arquitetura teve a função de prever o valor do diâmetro médio dos furos um passo a frente, utilizando com entrada o resultado estimado pela primeira rede neural. Nesta etapa da análise, não se trabalhou mais com os valores reais de diâmetro, mas somente os valores estimados pela rede anterior.

O treinamento da rede neural de predição um passo à frente se deu pelas inúmeras variações de parâmetros, em rotina no MATLAB, sendo os melhores valores encontrados estão mostrados na Tabela 10.

Tabela 10 – Parâmetros finais da rede de predição para os diâmetros médios -
Com todos os sinais aqisitados na rede de estimação.

Rede Neural de Predição com os menores erros médios	
Número de Camadas Escondidas	1
Número de Neurônios em cada Camada	8
Janela	8
Momento	0,3
Taxa de aprendizagem	0,2
Número máximo de épocas	200
Erro limite	1,00 E -07
Função de Treinamento	Lev-Maq

5.10.4) Redes Neurais na Predição da Rugosidade.

A arquitetura estudada para a predição da rugosidade utilizou como parâmetro de entrada os resultados de saída da rede de estimação, ou seja, os valores estimados de rugosidade. A arquitetura da rede proposta é mostrada na Figura 49; a qual se assemelha à da rede utilizada para predição dos diâmetros.




Figura 49 – Arquitetura da rede neural para estimação dos diâmetros.

O processo iterativo para encontrar a melhor rede de predição para a rugosidade um passo à frente resultou nos dados encontrados na Tabela 11.

Tabela 11 – Parâmetros da rede de predição para as rugosidades - Com todos os sinais aquisitados na rede de estimação.

Rede Neural de Predição com os menores erros médios	
Número de Camadas Escondidas	1
Número de Neurônios em cada Camada	8
Janela	8
Momento	0,3
Taxa de aprendizagem	0,2
Número máximo de épocas	200
Erro limite	1,00 E -07
Função de Treinamento	Lev-Maq

Nota-se que os valores de configuração da rede neural, para a determinação dos diâmetros, foram iguais aos parâmetros de estimação da rede de rugosidade. A rede neural TDNN para ambas as características, diâmetros e rugosidades, se assemelhou, não havendo uma distinção entre as grandezas e comportamentos das características preditas um passo a frente

5.11) Melhor configuração das redes com a utilização dos Sinais de Potência do Motor Elétrico e Força de corte no eixo Z.

O mesmo procedimento, anteriormente descrito, foi realizado para as redes de estimação e predição, porém, usando como entradas para a rede de estimação os sinais de potência e força de corte no eixo Z.

O processo iterativo para encontrar a melhor rede de estimação para o diâmetro, utilizando apenas os dois sinais aquisitados, resultou nos dados encontrados na Tabela 12.

Tabela 12 – Parâmetros da rede de estimação para o diâmetro – Com os sinais de potência e força Z.

Melhor configuração de rede de estimação para os diâmetros	
Número de Camadas	3
Número de Neurônios por camada	[2 2 3]
Função de Transferência entre neurônios da camada escondida	tansig
Função de Transferência para camada de saída	pureln
Momento	0,8
Taxa de Aprendizagem	0,3
Número máximo de épocas	100
Função de Treinamento	Lev-Maq

Nota-se que os valores de melhor configuração da rede neural, somente com os sinais de potência e força Z, para a determinação dos diâmetros, foram diferentes dos parâmetros para estimação para as redes com todos os sinais considerados na entrada da rede, mostrando que a mudança influenciou no resultado do treinamento. Configuração de rede neural de estimação para rugosidade é mostrada na Tabela 13, em que se empregaram apenas os sinais de potência e força em Z como entradas dessa rede.

Tabela 13 – Parâmetros da rede de estimação para as rugosidades – Com os sinais de potência e força Z.

Melhor configuração de rede de estimação para a rugosidade	
Número de Camadas	3
Número de Neurônios por Camada	[2 3 3]
Função de transferência entre neurônios da camada escondida	tansig
Função de transferência para camada de saída	pureln
Momento	0,5
Taxa de aprendizagem	0,9
Número máximo de épocas	100
Função de Treinamento	Lev-Maq

O processo iterativo para encontrar a melhor rede neural de predição para o diâmetro e rugosidade, um passo a frente, resultou nos dados mostrados na Tabela 14 e Tabela 15, respectivamente.

Tabela 14 – Parâmetros da rede de predição para o diâmetro - Com os sinais de potência e força Z na rede de estimação.

Melhor configuração de rede de predição para os diâmetros	
Número de Camadas Escondidas	1
Número de Neurônios em cada Camada	9
Janela	5
Momento	0,5
Taxa de aprendizagem	0,7
Número máximo de épocas	180
Erro limite	1,00 E -04
Função de Treinamento	Lev-Maq

Tabela 15 – Parâmetros da rede de predição para rugosidade - Com os sinais de potência e força Z na rede de estimação.

Melhor configuração de rede de predição para rugosidade	
Número de Camadas Escondidas	1
Número de Neurônios em cada Camada	15
Janela	8
Momento	0,3
Taxa de aprendizagem	0,2
Número máximo de épocas	200
Erro limite	1,00 E -07
Função de Treinamento	Lev-Maq

Os sinais de E.A, Força X, Força Y, Aceleração, Avanço e velocidade de corte, influenciaram, portanto, o processo de treinamento das redes de predição, impedindo uma distinção entre as redes de rugosidade e diâmetros preditos quando se utilizou todos os sinais coletados.

6) Resultados e Discussão

Neste capítulo serão apresentadas as discussões sobre os resultados obtidos durante a utilização das redes neurais para estimação e predição do diâmetro e rugosidade. Também será abordado o comportamento dos sinais provenientes dos sensores e aspectos do processo de usinagem, que correlacionam os sinais encontrados, buscando fundamentar a utilização de redes neurais neste trabalho.

6.1) Comportamento dos Diâmetros de Rugosidades durante os ensaios de Furação

Para o processo de furação neste trabalho, tem-se que os diâmetros podem variar em 50 micra para os furos realizados em Alumínio e 41 micra

para os furos realizados em Titânio, segundo a NAS618, “National Aircraft Standards”. Estes valores de variação diametral são especificados, em projetos aeronáuticos, para assegurar a vida em fadiga das estruturas.

Com o diâmetro de broca selecionado tem-se:

Alumínio

- Diâmetro nominal do furo: 4,981 mm
- LES: 5,006 mm
- LEI: 4,956 mm

Titânio

- Diâmetro nominal do furo: 4,981 mm
- LES: 5,006 mm
- LEI: 4,965 mm

Nota-se que os limites superiores permanecem inalterados para ambos os materiais, porém o limite inferior para o Titânio é menor, causando menor interferência quando o pino é inserido. A Figura 50 mostra o controle estatístico feito nos diâmetros para ambas as ligas, a fim de verificar sua coerência com as normas de projeto de aeronaves.




Figura 50 – Controle estatístico do processo de furação realizado no ensaio.

Nota-se que, em alguns pontos, os furos excederam os limites de especificação e seriam considerados inapropriados para o uso em estruturas aeronáuticas. Todos os furos ficaram acima do diâmetro nominal da ferramenta

de corte, o que é característico do processo de furação por meio de brocas helicoidais. Dentro de um processo industrial, os furos que excederam o limite de controle seriam rejeitados, demandando retrabalhos.

Uma vez que nem todos os furos tiveram suas medições realizadas, alguns foram interpolados. A Figura 51 mostra os valores medidos e interpolados de rugosidade Ra para a liga de Titânio. Nota-se que, ao longo das furações, os valores de Ra vão aumentando, caracterizando uma perda na qualidade de furação. Uma possível causa para esse aumento pode ser relacionada a alguns fatores, como o desgaste da ferramenta de corte ao longo dos ciclos (vide Anexo 5). Porém, o trabalho não objetivou uma análise mais profunda desse comportamento.




Figura 51 – Valores de rugosidade interpolados para a liga de Titânio.

A Figura 52 mostra os valores de rugosidade interpolados para a liga de Alumínio, na qual também se nota uma tendência de aumento no valor de Ra. Essa tendência se mostrou bem menor que as apresentadas na Liga de Titânio, porém com uma dispersão muito maior nos últimos ciclos de furação. O desgaste da ferramenta de corte e a geração de arestas postiças de corte durante a usinagem do Alumínio podem ser responsáveis pelo aumento na rugosidade e principalmente a dispersão dos últimos furos realizados. A velocidade de corte está bem abaixo das ideais para o material, gerando assim

condições não favoráveis de usinagem aumentando a rugosidade progressivamente. Os desgastes das brocas podem ser observados no Anexo 5 e 6.




Figura 52 – Valores de rugosidade interpolados para a liga de Alumínio.

A Figura 53 mostra os diâmetros medidos em Titânio após os ensaios. Os valores indicam uma tendência de aumento no diâmetro médio e uma dispersão maior nos últimos furos da sequência. Esse aumento no diâmetro dos furos em Titânio pode ser explicado pelo desgaste da ferramenta de corte ao longo dos ciclos, fenômeno esse comum em qualquer processo de usinagem mecânica, e acentuado quando parâmetros de corte são escolhidos de maneira errônea para o material a ser usinado.

Os diâmetros medidos mostram uma correlação adequada ao fenômeno físico analisado, logo a utilização dos sinais, como entrada nas redes neurais, irá representar um modelo adequado de usinagem de precisão. A Figura 53 mostra o comportamento do diâmetro em Titânio.




Figura 53 – Medição dos diâmetros de Titânio.

A Figura 54 mostra os diâmetros medidos em Alumínio após os ensaios. Os valores, também, indicam uma tendência de aumento no diâmetro médio.

O aumento no diâmetro dos furos em Alumínio pode ser explicado pelo desgaste da ferramenta de corte ao longo dos ciclos, principalmente por causa da liga anterior de Titânio, quando comparado com próprio Alumínio, que gera desgastes menores na ferramenta de corte. Outro fator, como a falta de lubrificação, pode justificar esse aumento no desgaste da ferramenta em tão poucos ciclos.

Outra justificativa para o aumento da rugosidade e diâmetro está no desgaste da ferramenta de corte, que pode ser verificado no Anexo 5.




Figura 54 – Medição dos diâmetros de Alumínio.

Ao longo dos ciclos, a qualidade de uma furação é prejudicada por mecanismos de desgaste. Um ponto importante desta análise está no fato de que essa característica de desgaste gera dados não aleatórios no tempo, mas sim dados que caracterizam uma tendência ao longo das furações, fazendo com que as redes de predição tenham bons resultados.

O principal objetivo destes gráficos é a constatação de fenômenos não aleatórios, indicando que as redes neurais de predição podem ser aplicadas a este processo.

6.2) Comportamento dos sinais coletados durante a Furação

Os sinais adquiridos durante os ensaios, inicialmente foram seccionados através de rotinas computacionais, sendo que só foi utilizada no trabalho a região que se refere ao corte da ferramenta durante seu movimento de avanço contra o corpo de prova. Os sinais provenientes da máquina, enquanto rodava em vazio não foram analisados.

Esta região foi, então, separada em duas partes, sendo que a primeira refere-se aos dois quintos (2/5) iniciais do total de pontos, e é associada ao

corte da liga de titânio, e os três quintos (3/5) de pontos restantes se refere à liga de alumínio. Deste total de pontos de cada material, foi calculada a média e, posteriormente, estes valores foram utilizados para treinamento, validação e teste das redes neurais, sendo associados ao valor do diâmetro ou rugosidade medido naquele furo.

Anteriormente à discussão dos resultados obtidos pelas redes neurais, será apresentada uma breve discussão de alguns sinais aqusitados, mostrando que, qualitativamente, os sinais representam o processo de usinagem estudado. Esta etapa da análise tem uma grande importância no trabalho, pois fundamentam todas as discussões posteriores, mostrando que os sinais representam reais características do processo de usinagem por meio de brocas helicoidais. Estas figuras foram geradas através da determinação do valor médio dos sinais e do desvio padrão de cada intervalo aqusitado, relativa a cada um dos furos.

A Figura 55 mostra a força no eixo Z durante o ensaio, tendo para ambos os materiais o mesmo avanço. Foi possível perceber que a força no eixo Z é maior na liga de Titânio e menor na liga de Alumínio. Este fenômeno já era esperado, devido às propriedades mecânicas dos materiais serem bem diferentes, como dureza, tensão de ruptura, limite de escoamento entre outros.




Figura 55 – Média e desvio padrão dos sinais de força em Z.

A liga de Titânio apresenta dureza significativamente maior que a liga de Alumínio, logo, as forças necessárias para usinagem deste material, com uma mesma ferramenta de corte, serão maiores. A liga de Alumínio apresenta menor resistência à conformação, mostrando os menores valores de força no eixo Z durante sua usinagem.

A Figura 56 mostra as variações das forças nos eixos X e Y.




Figura 56 – Média e desvio padrão dos sinais de Força X e Força Y.

Ao contrario da força no eixo Z, que foi maior para a liga de Titânio, a força no eixo X e Y foi maior na Liga de Alumínio. Este comportamento se deve a maior ductilidade do alumínio que o leva formação de cavacos com grandes áreas de contatos com a ferramenta, ao contrário do Titânio, em que estas áreas de contatos são pequenas. Mesmo o Titânio sendo mais resistente que o Alumínio, a maior área de contato de cavaco predominou, resultando em forças de corte no eixo X e Y maiores para a liga de Alumínio (vide Anexo 4).

A Figura 57 mostra a potência do cabeçote da máquina ferramenta necessária para usinar ambos os materiais. Este motor foi responsável por girar a ferramenta de corte durante a usinagem, diferente do motor do eixo Z que foi responsável por avançar a ferramenta durante o processo usinagem.

É possível notar que, para a mesma velocidade de corte, a potência necessária para usinar a liga de Titânio é maior que a liga de Alumínio; fenômeno este de certa maneira também intuitivo visto as diferenças de propriedades mecânicas de cada liga, e condizente com o sinal anterior de força no eixo Z.




Figura 57 – Média e desvio padrão dos sinais de Potência.

A liga de Titânio tem seus limites de escoamento e ruptura de 1100 MPa e 1170 Mpa, respectivamente. A liga de Alumínio tem seus limites de escoamento e ruptura de 345 MPa e 483 Mpa, respectivamente, o que indica a necessidade de maior potência para a usinagem do Titânio, quando comparado com o Alumínio.

Também foi realizada a análise no sinal de aceleração (vibração) do sistema, na qual é percebido, pela Figura 58, um valor de aceleração menor para a liga de Titânio em comparação com o valor de aceleração na liga de Alumínio.




Figura 58 – Média e desvio padrão dos sinais de aceleração.

Essa diferença de aceleração pode ser explicada pelo tipo de cavaco produzido durante a usinagem de cada um dos materiais. O Anexo 4 apresenta amostras de cavacos coletados durante a usinagem de cada um dos materiais. A liga de alumínio apresentou cavacos menores e mais quebradiços, ocasionado pela fratura periódica do material em contato com a ponta da ferramenta, elevando assim a vibração. A geometria quebradiça desses cavacos também pode ser associada a velocidades de corte não ideal utilizada no ensaio (15,52 m/min) para o Alumínio, no qual são exigidas altas velocidades de corte.

A Figura 59 mostra o resultado dos sinais de emissão acústica durante a realização dos ensaios.




Figura 59 – Média e desvio padrão dos sinais de emissão acústica.

A liga Alumínio apresentou um aumento nos valores médios durante a usinagem. O sensor de emissão acústica tem a capacidade de captar a energia propagada durante o retorno da deformação elástica no momento em que ocorre a fratura frágil da porção de cavaco, sucintamente descrito na seção 4.4. Quanto mais quebradiço for o cavaco gerado durante o processo de usinagem, maior o sinal de emissão acústica. O Anexo 4 mostra que o Alumínio, teve comportamento mais frágil, cavacos mais quebradiços, do que o Titânio, o que justifica os maiores níveis de emissão acústica percebidos durante sua usinagem.

6.3) Comportamento dos Diâmetros

Ainda antes de entrar nas discussões e resultados provenientes das redes neurais, foi feita uma análise nos diâmetros medidos após o ensaio. Os furos apresentam uma geometria oval, possuindo valores máximos e mínimos. Os valores mostrados na Tabela 16 são resultados da análise da média de cada furo individual.

Essa análise é de grande importância, pois gera a base para que as redes neurais possam trabalhar com dados que, realmente, estão representando um processo real de usinagem nas diferentes ligas.

Tabela 16 – Análise geral dos Diâmetros Medidos.

Parâmetros de Corte	Liga Titânio			Liga Alumínio		
Rotação 1000 RPM Avanço 90 mm/min	Ø Max (mm)	Ø Min (mm)	Ø Méd (mm)	Ø Max (mm)	Ø Min (mm)	Ø Méd (mm)
	4,990	4,949	4,966	5,023	4,969	4,991

Da observação da Tabela 16, é possível perceber a variação diametral decorrente das diferentes ligas, bem como a variação de diâmetro máximo e mínimo dentro de uma mesma liga.

Para o Titânio, encontrou-se 4,990 mm para o diâmetro máximo e 4,949 mm para o diâmetro mínimo, diferença de 0,041 mm. Já, para o alumínio, encontrou-se 5,023 mm para o diâmetro máximo e 4,969 mm para o diâmetro mínimo, diferença de 0,054 mm. Ambos os resultados mostram variações diametrais altas para padrões de furação de precisão.

Especificamente para o alumínio, essa diferença diametral é maior e justificada pela utilização de parâmetros de corte distantes dos ideais para a de furação deste material, gerando maior vibração no processo. Devido à grande facilidade de deformação plástica do alumínio associada à vibração durante o processo, os furos tenderam a ficar maior que o diâmetro nominal da ferramenta de corte.

A Figura 60 reforça as diferenças de diâmetros entre os diferentes materiais, mostrando que os furos na liga de alumínio ficaram maiores que os furos na liga de titânio.




Figura 60 – Média e desvio padrão dos diâmetros medidos.

As variações encontradas devem-se, além dos parâmetros, ora inadequados para o processo, pela falta de rigidez (fixações inadequadas das peças e condições da máquina) e batimento proporcionado pelo sistema de fixação porca-pinça.

6.4) Comportamento dos Rugosidades

Nesta seção foi feita uma análise comparativa entre as rugosidades obtidas após as furações, bem como seus valores interpolados após o ensaio.

A Tabela 17 mostra os resultados obtidos.

Tabela 17 – Análise geral das Rugosidades Medidas.

Parâmetros de Corte	Liga Titânio			Liga Alumínio		
1000 RPM Avanço 90 mm/min	Ra Max (mm)	Ra Min (mm)	Ra Méd (mm)	Ra Max (mm)	Ra Min (mm)	Ra Méd (mm)
	2,31	0,76	1,42	1,93	0,83	1,36

Para o Titânio encontrou-se Ra de 2,31 μm para a rugosidade máxima e 0,76 μm para a rugosidade mínima, diferença de 1,55 μm . Já para o Alumínio encontrou-se um Ra de 1,93 μm para a rugosidade máxima e 0,83 μm para a rugosidade mínima, diferença de 1,1 μm . Ambos os resultados mostram variações na rugosidade, altas para padrões de furação de precisão.

Os Anexos 5 e 6 mostram o desgaste prematuro da ferramenta de corte causados pelos parâmetros de corte não adequados para os materiais selecionados, que justificam uma rugosidade alta.

A Figura 61 reforça as diferenças de diâmetros entre os diferentes materiais, mostrando que os furos na liga de Alumínio tiveram rugosidades menores que os furos na liga de Titânio.

Uma maior rugosidade no Titânio pode ser justificada pelo retorno da ferramenta de corte após a usinagem de todo o corpo de prova. O diâmetro médio do Titânio foi menor que do Alumínio o que pode aumentar o contato entre a ferramenta e as paredes do furo.

Os cavacos de alumínio, mostrado no Anexo 4, são quebradiços, e podem, durante sua remoção, atritar com as paredes do Titânio, prejudicando a qualidade superficial.




Figura 61 – Média e desvio padrão das Rugosidades medidas.

6.5) Redes neurais com todos os sinais aqisitados

Os próximos gráficos mostram os resultados obtidos a partir da simulação em MATLAB das redes neurais artificiais previamente treinadas conforme descrito na sessão 5.10. Lembrando que todos os sinais aqisitados durante os ensaios foram utilizados como entrada em uma primeira rede neural, que estimou os valores de rugosidade e diâmetros médios. Após esse procedimento, e de posse dos valores de rugosidade e diâmetros estimados, utilizou-os em uma segunda rede neural que correlacionava estes dados em uma sequência temporal, predizendo o valor um passo à frente.

Outra análise também será apresentada, repetindo o procedimento de predição de rugosidade e diâmetro médio, porém utilizando apenas dois sinais como entrada para rede neural (Sinal de Força em Z e Potência), com o intuito de avaliar a influência dos sinais na resposta das redes.

6.5.1) Redes neurais utilizadas para Estimação dos Diâmetros

Neste item serão apresentados os resultados das redes neurais de estimação para os diâmetros em ambos os materiais, com a utilização de todos os sinais aqisitados.

Primeiramente, será apresentado o valor da estimação e o valor real medido do corpo de prova, seguidos de uma análise estatística dos erros apresentados. Esta análise levou em consideração o erro médio entre o valor estimado e real, destacando, também, o maior valor de erro encontrado, bem como o seu desvio padrão.

A Figura 62 mostra, em azul, o diâmetro médio dos furos medidos para o Titânio e, em vermelho, os valores estimados de diâmetro a partir da rede neural artificial *feedforward*. Esta rede foi a primeira utilizada neste trabalho.

Nota se que em alguns pontos, os valores estimados (vermelho) ficaram distantes dos valores reais (azul) de diâmetro.




Figura 62 – Resultado da Rede Neural para estimação do diâmetro médio do furo em Titânio a partir de todos os sinais aqisitados.

A Figura 63 mostra os erros de estimação para os diâmetros em Titânio. Pode-se notar que o desvio padrão é 0,008 mm com um erro máximo de 0,022 mm e um erro mínimo de – 0,021 mm.




Figura 63 – Erros de estimação para os diâmetros estimados pela rede *feedforward* em Titânio.

A análise estatística dos erros mostra que estão centrados próximo de zero (0) e dentro do controle de 6σ , demonstrando um bom resultado para os dados de estimação, visto que estão dentro do limite de controle proposto neste trabalho.

A Figura 64 mostra, em azul, a curva dos diâmetros médios dos furos medidos em Alumínio e, em vermelho, os valores estimados de diâmetro a partir da RNA “*feedforward*”.

Nota-se que os valores estimados oscilaram menos e, em alguns momentos não acompanhou a variação no valor do diâmetro. Embora os diâmetros medidos em Alumínio apresentassem certa tendência de aumento durante os ciclos, em relação ao do diâmetro da ferramenta de corte, a rede de estimação acompanhou esta tendência.




Figura 64 – Resultado da Neural para estimação do diâmetro médios do furo em alumínio a partir de todos os sinais aquisitados.

A Figura 65 mostra os erros de estimação para os diâmetros em Alumínio, em que o erro de estimação médio é de - 0,0006 mm com um erro máximo de 0,016 mm, erro mínimo de - 0,020 mm e o desvio padrão de 0,007 mm.




Figura 65 – Erros de estimação para os diâmetros estimados pela rede *feedforward* em Alumínio.

O valor de 0,0006 mm de erro médio é considerado um bom resultado, mostrando estar centrado próximo a zero (0) e com um desvio padrão de 0,007 mm. Quando analisado apenas o erro diametral médio de cada material e seu desvio padrão é possível afirmar que as redes de estimação para ambos os materiais, utilizando todos os sinais aquisitados, mostraram-se satisfatórias, visto que poderiam ser aplicados dentro de limites de controle estatísticos e representar o processo estudado.

Em outra análise, quando se leva em consideração os valores de erros máximos pode-se encontrar outro resultado. Simulando os valores de erro máximo encontrado para a rede neural aplicada ao Titânio, poderia acontecer um caso em que o valor real do diâmetro no Titânio fosse de 0,060 mm e com o erro mínimo de estimação de -0,021 a rede poderia acusar o valor de 0,039 mm mostrando, a princípio, um valor aceitável dentro da norma aeronáutica de 0,041 mm, mas na verdade o furo estaria fora de especificação. Para o Alumínio, ter-se-ia algo parecido quando se obtivesse, hipoteticamente, um valor de diâmetro de 0,070 mm, com um erro máximo de -0,021 mm a rede poderia estar estimando um valor de 0,049 mm, o que seria aceitável para a liga de Alumínio, porém, o valor real fora do especificado.

Para uma aplicação em furações de precisão Classe IV ($\pm 0,0205$ mm de variação no diâmetro de Titânio e $\pm 0,025$ mm para variação no diâmetro do Alumínio) os resultados poderiam encobrir diâmetros fora do aceitável.

A rede de estimação poderia, então, ser aplicada a outra tolerância de furação que fosse maior que os erros de estimação encontrados.

6.5.2) Redes neurais utilizadas para Estimação da Rugosidade

Conforme descrito anteriormente, para que se fosse possível realizar a predição dos valores um passo a frente, foi necessário primeiramente a utilização de uma rede neural auxiliar, que utilizava todos os sinais aquisitados para estimar o valor atual do furo sem que o mesmo fosse medido fisicamente.

A Figura 66 mostra a rugosidade (R_a) dos furos medidos em Alumínio e os valores estimados de R_a a partir da RNA *feedforward*. A linha em azul

mostra os dados de rugosidade interpolados e a linha, em vermelho, mostra dos dados estimados pela primeira rede.




Figura 66 – Rede para estimação da Rugosidade em Alumínio a partir de todos os sinais adquiridos.

A avaliação dos resultados obtidos com a rede de estimação mostra que, em alguns pontos, não houve acompanhamento da rugosidade estimada em relação a rugosidade medida, principalmente no início da sequência, ficando estática ao longo dos ciclos, entre os pontos 35 e 55. Esse parâmetro poderia ser melhorado alterando a taxa de aprendizagem da rede neural para que ela convergisse mais rapidamente. Com o aumento das medições de rugosidade, mais furos medidos, uma nova curva de rugosidade poderia ser confeccionada melhorando a linha de tendência do processo.

A Figura 67 mostra os erros de estimação para a rugosidade dos furos em Alumínio. Nesta figura, pode-se notar que o erro de estimação médio está centrado e próximo a zero (0), com um desvio padrão de 0,24 μm , valor de erro máximo de 0,57 μm e erro mínimo de 0,79 μm .

Estes valores mostram que, estatisticamente, os valores estão centrados próximos a zero (0), o que é muito bom para os erros de estimação, porém há um valor de erro que excede o limite de controle de $\pm 3\sigma$.




Figura 67 – Erros de estimação para as rugosidades estimadas pela rede *feedforward* em Alumínio.

A Figura 68 mostra, em azul, a rugosidade média aritmética (Ra) dos furos medidos em Titânio que foram interpolados e, em vermelho, os valores estimados de Ra a partir da RNA “feedforward”.




Figura 68 – Rede para estimação da Rugosidade em Titânio a partir de todos os sinais aqisitados.

Nota-se que para a liga de Titânio, a rede neural de estimação de rugosidade apresentou um comportamento de tendência, assim como os valores reais, porém com dificuldades para acompanhar os valores reais interpolados.

A Figura 69 mostra os erros de estimação para as rugosidades dos furos na Liga de Titânio. Pode-se notar que o erro médio também ficou centrado em zero (0), com um desvio padrão de $0,3 \mu\text{m}$, erro máximo de $0,76 \mu\text{m}$ e erro mínimo de $0,68 \mu\text{m}$.




Figura 69 – Erros de estimação para as rugosidades estimadas pela rede “feedforward” em Titânio.

Para a liga de Titânio o erro da rugosidade estimada se apresentou dentro dos limites de controle estatístico do processo.

Uma análise mais profunda demonstra que erros de estimação para a rugosidade em Titânio estão em uma região de conforto, pois tendo a rugosidade máxima permitida para esses furos de $1,6 \mu\text{m}$ e a variação máxima chegando $0,76 \mu\text{m}$, pode-se usar os dados de estimação como controle do processo.

6.5.3) Redes neurais utilizadas para Predição dos Diâmetros

Os diâmetros estimados para liga de Titânio e Alumínio, previamente discutidos, serviram de entrada para a rede TDNN (*Time Delay Neural Network*), de predição dos diâmetros médios.

A Figura 70 mostra, em azul, o diâmetro médio dos furos reais medidos em Titânio, em vermelho, os valores estimados de diâmetro a partir da RNA “feedforward”, e, em verde, os valores preditos pela rede neural TDNN um passo a frente.




Figura 70 – Rede para predição do diâmetro em Titânio a partir de todos os sinais aquisitados.

Nota-se que os valores preditos, em verde, ficaram entre os outros dois valores, estimado e real, mostrando uma boa correlação entre ambos. Na rede de estimação, percebe-se, que em alguns pontos, ela se distancia dos valores reais, enquanto que os valores preditos não apresentam tais picos.

A Figura 71 mostra os erros entre os valores preditos e os valores estimados para os diâmetros em Titânio, em que se encontra um desvio padrão de 0,004 mm, um erro entre 0,009 mm e -0,012 mm.




Figura 71 – Erros de predição para os diâmetros estimados pela rede “feedforward” em Titânio.

Há um ponto que excede ao limite inferior de controle, o que mostra que o método não está estável e a rede de predição necessita de ajustes. Embora estatisticamente os dados precisem ser melhorados, uma análise mais simplista mostra que entre os valores de erro 0,009 mm e -0,0012 mm, tem-se uma variação de 0,021 mm. Comparando esse valor de variação na assertividade da rede de predição com os valores de tolerância para o Titânio, de 0,041 mm ($\pm 0,0205$ mm), pode-se dizer que o método apresenta uma assertividade dentro da faixa de tolerância aceitável.

A Figura 72 mostra, em azul, a curva dos diâmetros médios dos furos reais em Alumínio e, em vermelho, os valores estimados de diâmetro a partir da RNA “feedforward”. A curva em verde mostra o valor do diâmetro médio predito a partir da rede TDNN. Nota-se que a rede de predição acompanhou a tendência dos valores de estimação.




Figura 72 – Rede para predição do diâmetro em alumínio com todos os sinais aquisitados.

A Figura 73 mostra os erros de predição para os diâmetros na liga de Alumínio. Nota-se que o erro médio ficou próximo a zero (0), assim como nos outros erros médios, e com desvio padrão de 0,003 mm, uma variação entre os erros máximos e mínimos de 0,01 mm e -0,008 mm.




Figura 73 – Erros de predição para os diâmetros estimados pela rede “feedforward” em Alumínio e preditos pela rede TDNN.

Um ponto fugiu do limite de controle, mostrando que, em termos estatísticos, a rede precisa ser aperfeiçoada.

Levando em consideração os erros máximos e mínimos da rede de predição do diâmetro em Titânio, encontra-se 0,018 mm de variação, o que pode ser considerado como um excelente resultado, visto que variação no diâmetro do furo aceitável para esse material é de 0,041 mm ($\pm 0,0205$ mm).

6.5.4) Redes neurais utilizadas para Predição da Rugosidade

A Figura 74 mostra, em azul, a rugosidade dos furos medidos em Alumínio, em vermelho, os valores estimados de Ra a partir da RNA “feedforward” e, em verde, os valores de rugosidade preditos pela rede TDNN a partir das rugosidades estimadas.




Figura 74 – Resultado da predição da Rugosidade Ra dos furos em Alumínio com todos os sinais.

A rede de estimação, em verde, acompanhou a tendência dos valores de estimação, porém apresentou um grande distanciamento desses valores.

A Figura 75 mostra os erros de predição para as rugosidades de diâmetros em Alumínio; pode-se notar um desvio padrão de 0,226 μm , e uma variação nos erros entre 0,428 μm e -0,678 μm .




Figura 75 – Erros de predição para as rugosidades estimadas pela rede “feedforward” em Alumínio e preditas pela rede TDNN.

Mais uma vez, encontrou-se o erro médio muito próximo a zero (0), porém os mesmos ficaram muito dispersos da linha média, tendo alguns pontos próximos ao limite do controle estatístico.

Para o caso das rugosidades, não há uma variação aceitável, mas sim um valor limite de 1,6 Ra, em que todos os furos acima dessa rugosidade são considerados fora das especificações para critérios de furos de precisão. Estes erros se somados aos erros da primeira rede de estimação, em relação aos valores reais podem gerar valores preditos muito distantes dos valores reais. Um exemplo disso seria quando a rede de estimação gerasse um erro de - 0,790 μm , em relação ao valor real de rugosidade, e a rede predição também cometesse um erro de -0,0678 μm , em relação ao valor estimado, gerando um valor de erro de - 1,468 μm .

A Figura 76 mostra, em azul, a rugosidade média aritmética (Ra) dos furos medidos e interpolados em Titânio, em vermelho, os valores estimados de Ra a partir da RNA “feedforward” e, em verde, os valores preditos de rugosidade pela rede TDNN em função dos valores estimados.




Figura 76 – Rede Neural para predição da Rugosidade em Titânio com todos os sinais.

Nota-se que a rede acompanhou a tendência de aumento na rugosidade, porém, apresentou uma dispersão muito alta.

A Figura 77 mostra os erros de predição para as rugosidades de diâmetros em Titânio, tendo como desvio padrão 0,257 μm , e como valores máximos e mínimos de erro 0,673 μm e -0,759 μm , respectivamente.




Figura 77 – Erros de predição para as rugosidades em Titânio com todos os sinais.

Os dados, de maneira estatística, estão dentro dos três (3) desvios padrão sugeridos como análise para os erros, porém, se apresentam com grandes oscilações ao redor da média. A mesma análise feita para a rugosidade em Alumínio pode ser feita para o Titânio, em que, dependendo dos erros associado ao valor real de rugosidade pode haver previsões fora do aceitável.

Na seção de 6.6 os resultados serão comentados de maneira mais global, buscando uma visão geral da associação das redes neurais de estimação e predição.

6.6) Visão geral dos Erros encontrados para as redes de estimação e predição com a utilização de todos os sinais

A Tabela 18 mostra um resumo geral dos erros encontrados com as redes de estimação para ambos os materiais, e para as características de diâmetro e rugosidade.

Tabela 18 – Resumo geral dos erros com as redes neurais de estimação.

Parâmetros Analisados	Com a utilização de todos os Sinais (EA, Força Z, Y, Z, Potencia do Motor elétrico e Vibração, Avanço, Rotação)		
	Rede Neural Artificial para estimação (feedforward)		
	Desvio Padrão	Maior Erro	Menor Erro
Ø Alumínio	0,007	0,016	-0,021
Ø Titânio	0,008	0,022	- 0,021
Ra Alumínio	0,24	0,57	-0,79
Ra Titânio	0,30	0,76	- 0,68

Os valores de diâmetros tiveram desvio padrão muito pequeno em relação à grandeza estudada de 4,9 mm; já os valores de rugosidade apresentaram desvios padrões maiores, mostrando a dispersão dos resultados.

A Tabela 19 mostra um resumo geral dos erros encontrados com as redes de predição para ambos os materiais, e para as características de diâmetro e rugosidade. A rede de predição em relação aos desvios padrão apresentou comportamento semelhante à da rede de estimação, cujos erros diametrais foram baixos em relação aos erros de rugosidade.

A rede neural de predição para os diâmetros mostrou erros menores em relação aos valores de entrada que a rede de estimação.

Tabela 19 – Resumo geral dos erros com as redes neurais de predição.

Parâmetros Analisados	Rede Neural Artificial para predição (TDNN)		
	Desvio Padrão	Maior Erro	Menor Erro
Ø Alumínio	0,004	0,009	-0,012
Ø Titânio	0,003	0,010	-0,008
Ra Alumínio	0,226	0,428	-0,678
Ra Titânio	0,257	0,673	-0,759

Em alguns momentos, tanto para a rugosidade quanto para o diâmetro, se houver uma sucessão de erros de estimação e predição distanciando o valor predito do valor real, pode-se realizar uma leitura errada do estado futuro do processo.

Ambas as redes apresentam erros dentro do tolerável quando analisadas individualmente, porém, quando se tenta encontrar uma correlação entre os valores preditos e reais, encontra-se um distanciamento muito grande.

Essa grande imprecisão entre os valores preditos e reais pode prejudicar a aplicação deste método em ambientes industriais, pois gera análises incorretas da realidade.

6.7) Redes Neurais com Sinais de Força no eixo Z e Potência

As próximas figuras mostram os resultados obtidos a partir da simulação das redes neurais artificiais com apenas os sinais de Força em Z e Potência do Motor elétrico.

Estes dois sinais foram escolhidos pela simplicidade da instalação dos sensores; se empregados em ambientes industriais, tendem a não interferir no processo de usinagem e, se apresentam como sinais importantes do processo de furação.

6.7.1) Redes utilizadas para Estimação/Predição dos Diâmetros

Os gráficos com os dados de estimação foram mesclados com os gráficos de predição para melhorar o entendimento global do processo de predição, e para que se possa realizar um comparativo entre o comportamento de ambas as redes.

A Figura 78 mostra, em azul, o diâmetro médio dos furos reais medidos em Titânio, os mesmos já apresentados nos gráficos com a utilização de todos os sinais na seção anterior; em vermelho, os valores estimados de diâmetros médios em Titânio com a RNA “feedforward”, porém, agora, apenas com a utilização dos sinais de Potência e Força em Z durante o processo de estimação e, em verde, são mostrados os valores preditos pela rede neural TDNN um passo à frente.




Figura 78 – Diâmetro médio em Titânio a partir dos sinais de força em Z e potência.

Nota-se que os valores preditos, em verde, ficaram entre os outros dois valores, estimado e real, mostrando uma boa correlação entre ambos. Na rede de estimação, percebe-se que, em alguns pontos, se distanciam dos valores reais, enquanto que os valores preditos não apresentam tais picos. O comportamento se assemelha às redes com todos os sinais.

A Figura 79 mostra os erros entre os valores preditos e os valores estimados para os diâmetros em Titânio, onde se encontra um desvio padrão de 0,003 mm, um erro entre 0,008 mm e -0,009 mm.

Embora o desvio padrão seja baixo, há três pontos que excedem o limite de controle, o que mostra certa fragilidade do método, e, portanto, a rede de predição necessita de ajustes. Embora estatisticamente os dados precisem ser melhorados, uma análise mais simplista mostra que entre os valores de erro 0,008 mm e -0,009 mm temos uma variação de 0,017 mm e, comparando esse valor de variação na predição com os valores de tolerância para os diâmetros de Titânio de 0,041 mm ($\pm 0,0205$ mm), segundo NAS618, pode-se dizer que o método apresenta uma assertividade dentro da faixa de tolerância aceitável.




Figura 79 – Erros de predição para os diâmetros preditos em Titânio com os sinais de Potência e Força em Z.

A Figura 78 mostra, em azul, a curva dos diâmetros médios dos furos reais em Alumínio e, em vermelho, os valores estimados de diâmetro a partir da RNA “feedforward”, usando-se apenas os sinais de força no eixo Z e potência do motor elétrico; a curva, em verde, mostra os valores dos diâmetros médios preditos por meio da rede TDNN. Nota-se que a rede de predição acompanhou a tendência dos valores de estimação, exceto por alguns pontos de pico em que não foi possível à predição com maior assertividade. A rede de estimação, em vermelho, se distanciou mais dos valores reais, mostrando que não conseguiu acompanhar o diâmetro real em alguns pontos de pico e vales.




Figura 80 – Diâmetro médio dos furos em Alumínio a partir dos sinais de força no eixo Z e potência.

A Figura 81 mostra os erros de predição para os diâmetros na liga de Alumínio. Nota-se que o erro médio ficou próximo a zero (0), indicando uma tendência favorável à predição. O desvio padrão encontrado foi de 0,003 mm, uma variação entre os erros máximos e mínimos de 0,013 mm e -0,016 mm. Quatro pontos fugiram do limite de controle, mostrando que, em termos estatísticos, a rede precisa ser aperfeiçoada.

Levando em consideração os erros máximos e mínimos da rede de predição, para o diâmetro em Alumínio, encontra-se 0,029 mm de variação. Este valor pode ser considerado como um resultado que precisa ser melhorado, visto que a variação aceitável para este material é de 0,050 mm ($\pm$ 0,025 mm) segundo a NAS618.




Figura 81 – Erros de predição em relação aos dados estimados coma utilização dos sinais de força no eixo z e Potência.

6.7.2) Redes utilizadas para Predição da Rugosidade

A Figura 82 mostra, em azul, a rugosidade real dos furos medidos em Titânio e, em vermelho, os valores estimados de Ra a partir da RNA “feedforward” com a utilização de apenas dois sinais aquisitados, o de Potência do motor elétrico e o de força no eixo Z; e, em verde, os valores de rugosidade preditos pela rede TDNN a partir das rugosidades estimadas.

A rede de predição, em verde, teve dificuldade de acompanhar os valores de estimação, em vermelho, e apresentou um grande distanciamento destes valores. Alguns pontos de vales e picos também podem ser notados na rede de predição.

A rede de estimação, em vermelho, manteve-se estável durante quase toda a estimação, não acompanhando os picos e vales dos valores reais.




Figura 82 –Rugosidade em Titânio com os sinais de potencia e força no eixo Z.

A Figura 83 mostra os erros de predição para as rugosidades de diâmetros em Titânio; pode-se notar um desvio padrão de 0,30 μm , uma variação nos erros entre 0,68 μm e -0,88 μm .




Figura 83 – Erros de predição para as rugosidades estimadas pela rede “feedforward” em Titânio

Mais uma vez encontrou-se o erro médio muito próximo a zero (0), porém, os mesmos ficaram muito dispersos da linha média, tendo alguns pontos próximos ao limite do controle estatístico.

Para o caso das rugosidades, não há uma variação aceitável, mas sim, um valor limite de $1,6\text{ }\mu\text{m}$, em que todos os furos acima dessa rugosidade são considerados fora das especificações para critérios de furos de precisão, segundo a NAS618. Os erros de predição, se somados aos erros da primeira rede de estimação, podem gerar valores preditos muito distantes dos valores reais. Um exemplo disso seria quando a rede de estimação gerasse um erro de $-0,90\text{ }\mu\text{m}$ em relação ao valor real de rugosidade, e a rede predição, também, cometesse um erro de $-0,88\text{ }\mu\text{m}$ em relação ao valor estimado, gerando um valor de erro de $-1,78\text{ }\mu\text{m}$.

A Figura 84 mostra, em azul, a rugosidade média aritmética (R_a) dos furos medidos e interpolados em Alumínio e, em vermelho, os valores estimados de R_a a partir da RNA *feedforward* com apenas os sinais de potência e força em Z, e, em verde, os valores preditos de rugosidade pela rede TDNN.

Nota-se que a rede acompanhou a tendência de aumento na rugosidade, porém apresentou uma dispersão muito alta. No início dos ciclos, a rede de estimação não acompanhou o valor real de rugosidade e se manteve com uma oscilação constante. A rede de predição se aproximou mais dos valores reais que a própria rede de estimação. A rede de estimação, em vermelho, apresentou uma oscilação muito grande entre os picos e valores dos valores reais.




Figura 84 –Rugosidade em Alumínio a partir dos sinais de força no eixo Z e potência.

A Figura 85 mostra os erros de predição para as rugosidades de diâmetros em alumínio, tendo como desvio padrão de $0,17 \mu\text{m}$ e como valores máximos e mínimos de erro $0,43 \mu\text{m}$ e $-0,58 \mu\text{m}$, respectivamente.




Figura 85 – Erros de predição para as rugosidades estimadas pela rede “feedforward” em Titânio e preditas pela rede TDNN.

Os dados estão dentro dos três (3) desvios padrão sugeridos como análise para os erros, porém se apresentam com grandes oscilações ao redor da média. Apenas um valor excedeu os limites de controle estatísticos.

6.8) Erros para as redes de estimação e predição com a utilização dos sinais de Potência e a Força no eixo Z

A Tabela 20 mostra um resumo geral dos erros encontrados com as redes de estimação para ambos os materiais e para as características de diâmetro e rugosidade, quando utilizados como entrada somente os sinais de potência e força em Z.

Tabela 20 – Resumo geral dos erros encontrados pelas redes neurais de estimação.

Parâmetros Analisados	Rede Neural Artificial para estimação (feedforward)		
	Desvio Padrão	Maior Erro	Menor Erro
Ø Alumínio	0,008	0,023	-0,016
Ø Titânio	0,006	0,014	- 0,022
Ra Alumínio	0,25	0,57	-0,70
Ra Titânio	0,33	0,62	- 0,90

A variação máxima para o diâmetro em Alumínio foi de 0,039 mm, a variação máxima para o diâmetro em Titânio foi de 0,036 mm, seguida de 1,27 µm para a rugosidade máxima do furo em alumínio, e 1,52 µm para a rugosidade máxima do furo em Titânio.

Os valores de diâmetros tiveram um valor de desvio padrão pequenos, quando comparados as variações máximas de 0,039 mm e 0,036 mm. Os valores de rugosidade apresentaram desvio padrão relativamente alto, quando comparados com as variações máximas de 1,52 µm e 1,27 µm.

A Tabela 21 mostra um resumo geral dos erros encontrados com as redes de predição para ambos os materiais, e para as características de diâmetro e rugosidade

A rede de predição, em relação aos desvios padrões, apresentou comportamento semelhante à rede de estimação, na qual os erros diametrais foram baixos em relação aos erros de rugosidade.

Tabela 21 – Resumo geral dos erros encontrados pelas redes neurais de predição.

Parâmetros Analisados	Rede Neural Artificial para predição (TDNN)		
	Desvio Padrão	Maior Erro	Menor Erro
Ø Alumínio	0,003	0,013	-0,016
Ø Titânio	0,003	0,008	- 0,009
Ra Alumínio	0,17	0,43	-0,58
Ra Titânio	0,30	0,68	-0,88

A variação máxima para o diâmetro em Alumínio foi de 0,029 mm, a variação máxima para o diâmetro em Titânio foi de 0,017 mm, seguida de 1,01 µm para a rugosidade máxima do furo em Alumínio, e 1,56 µm para a rugosidade máxima do furo em Titânio.

A rede neural de predição para os diâmetros apresentou erros menores em relação aos valores de entrada que a rede de estimação.

Os valores de diâmetros tiveram desvios padrão menores ainda que os estimados. Comparando variações máximas de 0,029 mm para os furos preditos em Alumínio, e de 0,036 mm para os furos preditos em Titânio, o desvio padrão pode ser considerado baixo.

Os valores de rugosidade apresentaram desvios padrão mais altos quando comparados com os diâmetros, visto que as variações máximas foram: 1,01 µm para os furos em Alumínio e 1,56 µm para os furos em Titânio.

Ambas as redes apresentam erros dentro do tolerável, quando analisadas individualmente, porém, quando se tenta encontrar uma correlação entre os valores preditos e reais, encontra-se um distanciamento muito grande. Essa grande imprecisão entre os valores preditos e reais pode prejudicar a aplicação deste método em ambientes industriais, pois gera análises incorretas da realidade.

7) Conclusão

Um comparativo entre os dois modelos de redes neurais, tanto de estimação como de predição, mostrou que os valores *estimados* se distanciaram mais dos valores de referência, quando comparados aos valores *preditos*, isto pode ser constatado pelo maior desvio padrão nos erros de valores estimados.

Os erros encontrados em ambas as redes neurais apresentaram dispersões que oscilaram em todo o campo de controle, limite superior e inferior, porém os valores de erros médios ficaram próximos a zero, indicando a centralidade do método

A aplicação deste processo para o controle de furação com um único passe (*one-step-drilling*) mostrou bons resultados, visto que os limites estabelecidos de controle foram excedidos em locais pontuais, tanto para as redes de estimação, como para as redes de predição, em ambas as ligas.

Analisando outras tolerâncias de furação, não mais a classe IV ($\pm 0,0205$ mm para Titânio e $\pm 0,025$ mm para Alumínio), em que fossem exigidas tolerâncias mais abertas, o método, aqui estudado mostra um potencial enorme de ganhos no processo industrial, visto que poderia ser incorporado com o intuito de não permitir a execução de furos fora dos especificados em normas de fabricação, como também poderiam indicar tendências durante o processo, sendo possível uma intervenção no processo mesmo sem que ele tenha gerado uma não conformidade.

Não houve expressiva variação entre os erros das redes com todos os sinais e as com somente os sinais de força Z e Potência, indicando que os demais sensores pouco influenciaram o resultado das redes. Mesmo com uma redução na assertividade do método com a utilização somente dos sinais de potência e força, essa alternativa mostra-se interessante para aplicações industriais, pois reduzem os custos de implementação do método, sem grande comprometimento da precisão dos resultados.

8) Sugestões para trabalhos futuros

Com o objetivo de melhorar as técnicas empregadas, aumentando a precisão dos valores estimados e preditos neste trabalho, bem como expandir o trabalho para outros processos industriais, sugerem-se novas pesquisas que:

1) Aplique a técnica estudada nesse trabalho em outros materiais, não apenas em alumínio e titânio, pois pelas características de usinabilidade dos aços acredita-se que a estimação do diâmetro nestes materiais possa ser feita ainda com mais precisão utilizando o mesmo método proposto, e, assim, melhorando a correlação entre os dados preditos e reais;

2) Também se sugere que novas ferramentas estatísticas sejam empregadas, não apenas a média simples, para tratar os sinais que alimentaram as redes neurais, pois os sinais em cada material poderiam representar a dinâmica do processo de usinagem de uma maneira mais qualitativa que a média;

3) Estudos mais detalhados e aplicação de diferentes arquiteturas de redes neurais na estimação dos valores possivelmente possam trazer melhores resultados

4) Diversificação das técnicas de predição, como a utilização de outras redes temporais, e não apenas as redes neurais TDNNs;

5) Empregar a mesma técnica em outros processos de usinagem, como por exemplo, a retificação, em que vários parâmetros de interesse poderiam ser preditos um passo à frente;

6) Treinar as redes neurais que estimaram os valores de diâmetro e rugosidade, com diferentes níveis de lubrificação, incluindo o parâmetro de batimento das brocas, que nesse trabalho não foi levado em consideração, mas podem influenciar os resultados finais de diâmetros e rugosidades;

7) Investigar dentre os sinais analisados aquele que apresenta maior sensibilidade com o fenômeno analisado, e propor a utilização de apenas um sinal como entrada na rede neural, visando uma simplicidade maior na aplicação industrial;

8) Utilizar os dados preditos de rugosidade e diâmetros para criar uma curva de tendência do processo, e buscar uma predição não apenas de um passo a frente, mas sim, em um futuro mais distante, possibilitando a intervenção no processo de furação de maneira mais suave, evitando a realização de furos fora de especificação;

9) Utilizar as informações provenientes das redes neurais e elaborar um método de controle automático que atue no sistema, interrompendo a realização de furos fora de especificação.

REFERÊNCIAS BIBLIOGRÁFICAS

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. *et al.*. **Predicting surface roughness in grinding using neural networks: robotics, automation and control**. 1 ed. Vienna: I-Tech Education and Publishing KG, 2008, v. 1. p. 33-44.

AMORIM, H. **Processo de fabricação por Usinagem, Alargamento**. Universidade Federal do Rio Grande do Sul, UFRGS, Poto Alegre, 2003.

AMBROGIO, G.; FILICE, L.; SHIVPURI, R.; UMBRELLO, D. Application of NN technique for predicting the in-depth residual stresses during hard machining of AISI 52100 steel. **International Journal of Material Forming**, v.1, p.39–45, 2008.

ANTONY, J. **Multiple response optimization using Taguchi methodology and neurofuzzy based model**, Journal of Manufacturing Technology Management, v.17, n.7, p.908-925, 2005.

ARENCIBIA, R. V. **Primeiro seminário de Metrologia**, São Paulo, 2009.

BARBOSA, A. P. **Furação de ferro fundido austemperado e nodular perlítico**, Dissertação de mestrado em Engenharia Mecânica, UFU, Uberlândia, MG, 2009.

BAFFES, P. T.; SHELTON, R. O.; PHILLIPS, T. A. **A neural network development tool**, Huston, Lyndon B, Johnson Space Center, 1991.

BEZERRA, A. A.; MACHADO, A., R.; SOUZA, A, M.; EZUGWU, E.O., **Effects of machining parameters when reaming aluminium-silicon (SAE 322) Alloy**, Journal of Materials Processing Technology, V112, pp185-198, 2001.

BOEIRA, A. M. G. SCHROETER R. B., WEGENER K.; **Modelagem e simulação das forças na furação com brocas helicoidais a partir de dados obtidos no torneamento de segmentos cilíndricos** – Tese de Doutorado, 2010 – Universidade Federal de Santa Catarina.

BUDYNAS, RICHARD G. (Richard Gordon). **Shigley's mechanical engineering design**. 8th ed. New York: Mcgraw-Hill, 2008.

BRAGA, A. P.; LUDERMIR, T. B.; Carvalho, A. C. P. L. F. **Redes Neurais Artificiais Teoria e Aplicações**, LTC, 2000.

CALLISTER, W. D. **Fundamentos da ciência e engenharia de materiais: uma abordagem integrada**. Rio de Janeiro: LTC, 2006.

CARVALHO, D. S.; ABRÃO, A. M.; RUBIO, J. C. C. **Monitoramento da temperatura de usinagem**, In: CONGRESSO NACIONAL DE ESTUDANTES DE ENGENHARIA MECÂNICA, XI, 2004, Nova Friburgo, Anais, Nova Friburgo, 2004.

CARRARA, V. **Redes Neurais Aplicadas ao Controle de Atitude de Satélites com Geometria Variável**, Tese de Doutorado em Mecânica Espacial e Controle, INPE, São José dos Campos, Junho de 1997.

CAVALCANTE, F. J. N. **Análise de utilização de brocas escalonadas de canal reto no processo de furação em uma liga de alumínio utilizada na indústria automotiva**. Tese de mestrado. Universidade Tecnológica Federal do Paraná. Campus de Curitiba. 2010.

CERVELLERA, C.; WEN, A.; CHEN, V. C. P. Neural network and regression spline value function approximations for stochastic dynamic programming. **Computers & Operations Research**, v.34, p.70–90, 2007.

CORREA, L. G; **Memórias Associativas em Redes Neurais Realimentadas**. Dissertação de Mestrado, Instituto de Ciências Matemáticas e de Computação, USP, 2004.

COTTERELL, M. G.; KELLY, J. F. Minimal lubrication machining of aluminium alloys, *Journal of Materials Processing Technology*, nº 120, pp 327-334, 2002,

CHEN, S.; BILLINGS, S. A.; Grant, P. M. **Non-linear system identification using neural networks**, *International Journal of Control*, v, 51, n, 6, p. 1191-1214, June 1990.

CHEN, S.; BILLINGS, S. A.; GRANT, P. M. **Recursive hybrid algorithm for non-linear system identification using radial basis function networks**, *International Journal of Control*, v. 55, n. 5, p. 1051-1070, May 1992.

CHEN, S.; BILLINGS, S. **Recursive prediction error parameter estimator for non-linear models**, *International Journal of Control*, v, 49, n, 2, p, 569-594, Feb, 1989.

CHIEN, W. T.; CHOU, C. Y. The predictive model for machinability of 304 stainless steel, **Journal of Materials Processing Technology**, v.118, p.442-447, 2001.

CHEN, S.; COWAN, C. F. N.; BILLINGS, S. A.; Grant, P. M. **Parallel recursive prediction error algorithm for training layered neural networks**, *International Journal of Control*, v, 51, n, 6, p, 1215-1228, June 1990a.

CHEN, S.; BILLINGS, S. A.; COWAN, C. F. N.; GRANT, P. M. **Practical identification of NARMAX models using radial basis functions**, *International Journal of Control*, v, 52, n, 6 1327-1350, Dec, 1990b.

CHILDS, Thomas; MAEKAWA, Ktsuhiro; OBIKAWA, Toshiyuki; YAMANE, Yasuo. **Metal machining theory and applications**. 1th ed. New York: John Wiley & Sons Inc, 2000.

CRUZ, C. E. D. **Estimação do diâmetro e rugosidade em um processo de furação utilizando multi sensores e redes neurais artificiais**. Tese (Mestrado em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Universidade Estadual Paulista, Bauru, 2010.

DAVIS, M. M.; AQUILANO, N. J.; CHASE, R. B. **Fundamentos da administração da produção**, 3, ed, Porto Alegre: Bookman, 2001,

DAY, S. P.; Davenport, M. R. **Continuous-time temporal back-propagation with adap-table time delays**, *IEEE Transactions on Neural Networks*, 4(2):348–354, March 1993.

DEMENTEE, E. **Desenvolvimento e avaliações das propriedades de insertos sinterizados de aço rápido AISI M2 para usinagem**. Dissertação de mestrado, UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT, 2006.

DEMUTH, H.; BEALE, M. **Neural network toolbox user's guide**, Natick, MA: Math Works, 1992.

DINIZ, A. E.; MARCONDES, F. C.; CUPPINI, N. L. **Tecnologia da Usinagem dos Materiais**: MM Editora, São Paulo, 1999.

DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. **Tecnologia da Usinagem dos Materiais**, ArtLiber, 2ª Ed, 2000.

DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. **Tecnologia da Usinagem dos Materiais**, 4ª, Ed, São Paulo: Artliber, 2001.

DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. **Tecnologia da Usinagem dos Materiais**, ArtLiber, 5ª Ed, 2006.

DODONOV, E.; MELLO, R. F.; **Predição por meio de atrasos no tempo: TDNN for Estudo sobre abordagens de extração, classificação e predição de comportamento de processos**, ICMC/USP, 2008.

EYNG, E. **Controle Feedforward FeedBack aplicado as colunas de absorção o processo de etanol por fermentação**, Campinas, SP, 2008, Tese (Doutorado em Engenharia Química) – Departamento de Engenharia Química, Universidade Estadual de Campinas, Campinas, 2008.

ETXEBARRIA, V. **Adaptive control of discrete systems using neural networks**, IEE Proceedings - Control Theory and Applications, v. 141, n. 4, p,209-215, July 1994.

EZUGWU, E. O.; Wang, Z. M. **Titanium alloys and their machinability – a review**. Journal of Materials Processing Technology, v. 68, n. 3, p. 262-274, 1997.

FERRARESI, D. **Fundamentos da Usinagem dos metais**, São Paulo: Edgard Blucher PP 751, 1977.

FERRARESI, D. **Fundamentos da usinagem dos metais**. São Paulo: Blucher, 2003.

FERREIRA. A. A. **Comparação de arquiteturas de redes neurais para sistemas de reconhecimento de padrões em narizes artificiais**. Dissertação de Mestrado, Programa de Pós-graduação em Ciência da Computação – Universidade Federal de Pernambuco, UFPE, 2004.

FILHO, R. C. B. **Controle estatístico de qualidade**, Rio de Janeiro: Livros Técnicos e Científicos, 1976.

GELB, A. **Applied optimal estimation**, Cambridge, MA: The M,I,T, Press, 1974.

GERONIMO, T. M. **Estimação do diametro de furos em processo de furação: uma anlise comprativa entre diferentes técnicas de inteligência artificial**. Seminário da Pós-graduação em Engenharia Elétrica, FEB, UNESP, BAURU, 2012.

GUIBERT, N.; PARIS, H.; RECH, J. **A numerical simulator to predict the dynamical behavior of the self-vibratory drilling head**. *International Journal of Machine Tools and Manufacture*, v. 48, p. 644-655, 2008.

HAYKIN, S. S. **REDES NEURAIS, PRINCIPIOS E PRATICA**, 2ª edição, editora Bookman, 2001.

HUNT, K. J.; SBARBARO, D.; ZBIKIWSKI, R.; GAWTHROP, P. J. **Neural networks for control systems - a survey**, *Automatic*, v, 28, n, 6, p, 1083-1112, 1992.

HOPFIELD, J. J. **Neural networks and physical systems with convergent collective computational abilities**, *Proceedings of the National Academy of Sciences*, v, 79, p, 2554-2558, 1982.

HOSSAIN, M. I.; AMIN, A. K. M. N.; PATWARI, A. U. Development of an Artificial Neural Network Algorithm for Predicting the Surface Roughness in End Milling of Inconel 718 Alloy, In: IEEE ICCCE 2008. May 13-15, 2008, Kuala Lumpur, Malaysia. **Proceedings of the International Conference on Computer and Communication Engineering**, Kuala Lumpur: IEEE, 2008, p.1321-1324.

JAWAID, A.; Sharif, S.; Koksai, S. **Evaluation of wear mechanism of coated carbide tools when face milling titanium alloy**. *Journal of Materials Processing Technology*, v. 99, n. 1, p. 266-274, 2000.

JIN, L.; NIKIFORUK, P. N.; Gupta, M. M. **Adaptive control of discrete-time nonlinear systems using recurrent neural networks**, IEE Proceedings Control Theory Applications, v, 141, n, 3, p,169-176, May 1994.

JORDAN, M, I, **Attractor dynamics and parallelism in a connectionist sequential machine**, *Proceedings of Eighth Annual Conference of the Cognitive Science Society*, (pp, 531-546), Amherst, Hillsdale: Erlbaum, 1986.

KALIDAS, S.; DE VOR, R. E.; KAPOOR, S. G. **Experimental investigation of the effect od drill coatings on hole quality under dry wet drilling conditions** Surface and Coating Technology, nº, 148, pp 117-128, 2001.

KARNIK, S. R.; GAITONDE, V. N.; DAVIM, J. P. A comparative study of the ANN and RSM modeling approaches for predicting burr size in drilling. **International Journal of Advanced Manufacturing Technology**, v.38, n.9–10, p.868–883, 2008.

KURT, M., Kaynak, Y. and Bagei, E., **Evaluation of drilled hole quality in Al 2024 alloy**, **International Journal of Advanced Manufacturing Technology**, Vol. 37, pp. 1051–1060, 2008.

LIN, S. C.; TING, C. J. **Drill wear monitoring using neural network**. **International Journal of Machine Tools Manufacture**, v.36, p. 465-475, 1996.

LOPES, M. L. M. **“Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica”**, Tese de Doutorado, Programa de Pós-graduação em Engenharia Elétrica - Faculdade de Engenharia de Ilha Solteira - UNESP, 2005.

MACHADO, R. A.; Silva, M. B. **Usinagem dos metais**, 4ª versão, Uberlândia, Laboratório de Ensaio e Pesquisa em Usinagem UFU, PP 180-190, 1999.

MACHADO, A. R.; SILVA, M. B. **Usinagem dos Metais**. Apostila didática, 7ª versão. UFU, Uberlândia, 2004.

MARANHÃO, M. **ISO série 9000: manual de implementação – versão 2000**. 6. ed. Rio de Janeiro: Qualitymark, 2001.

MARCONDEZ, F. C. **A história do metal duro**, Editado pela Sandivik Coromant 1990.

MARTINS, P. S. **Avaliação dos sistemas de fixação hidráulica e térmica de brocas de metal duro em furação do cabeçote do motor Fire**, Pontifícia Universidade Católica de Minas Gerais, Tese de Mestrado, 2008.

MIRANDA, G. W. **Uma contribuição ao processo de furação sem fluido de corte com broca de metal duro revestida com TiAlN** Tese de Doutorado, Departamento de Engenharia Mecânica, Unicamp, Campinas, Brasil, 2003.

MOTORCU, A. R.; GULLU, A. Statistical process control in machining, a case study for machine tool capability and process capability. **Materials and Design**. v. 27, p. 364–372, 2006.

NARENDRA, K. S.; PARTHASARATHY, K. **Identification and control for dynamic systems using neural networks**. IEEE Transactions on Neural Networks, v. 1, n.1, p. 4-27, Mar. 1990.

NETO, R. A. **Stochastic parameter estimation neural nets supervised learning approach**, In: Brazilian Congress in Neural Nets, 1., Itajubá, 1994, Proceedings, Itajubá: EFEI, 1994, p. 62-65.

NOVASKI, O. **Contribuição ao Processo de Furação com Brocas Helicoidais**, Faculdade de Engenharia Mecânica, Universidade Estadual de campinas, PP 31, Tese de Livre Docência 1996.

NOUARI, M.; LIST, G.; GIROT, F.; COUPARD, D. **Experimental analysis and optimisation of tool wear in dry machining of aluminium alloys**. Wear. v.255, p. 1359–1368, 2003.

NORGAARD, M. **Neural network based system identification toolbox** [online], Institute of Automation, Denmark, Technical University of Denmark, 1995, [cited 1996], Technical Report 95-E-773, Available in Post Script from World Wide Web: <http://www.iau.dtu.dk/Projects/proj/nnsysid.html>.

NORGAARD, M. **Neural network based control system design toolbox** [online], Institute of Automation, Denmark, Technical University of Denmark, 1996, [cited 1996], Technical Report 96-E-830, Available in Post Script from World Wide Web: <http://www.iau.dtu.dk/Projects/proj/nnctrl.html>.

NGUYEN, D. H.; WIDROW, B. **Neural networks for self-learning control systems**, IEEE Control Systems Magazine, v. 10, n. 3, p.18-23, Apr, 1990.

OGATA, K.; **Engenharia de controle moderno**, 3,ed, Rio de Janeiro: Prentice Hall do Brasil,1998, 813p.

PONTES, F. J. **Projeto de otimização de redes neurais artificiais para predição da rugosidade em processo de usinagem com a utilização de da metodologia de projetos de experimentos**. Tese de doutorado. UNESP. Guaratinguetá, 2011.

SALES, W. F.; SANTOS, S. C. **Fundamentos da Usinagem dos Materiais**, Belo Horizonte, Minas Gerais, Brasil, 2003.

STOETERAU, R. L. **Introdução ao Projeto de Máquinas-Ferramenta Modernas**. Universidade Federal de Santa Catarina, UFSC, Centro Tecnológico, 2004.

STOETERAU, R. L. **Aula sobre Fundamentos de Usinagem – Cavacos**. Univesrsidade Federal de Santa Catarina, UFSC. 2007.

TAFNER, M. A. **Estagiamento automático do sono utilizando um canal de EEG e uma rede neural artificial com alta representação cortical**, 1999,

Tese (Doutorado em Engenharia de Produção) – Departamento de Engenharia de Produção e Sistemas, Universidade Federal de Santa Catarina, Florianópolis, 1999.

TRENT, E. M.; WRIGHT, P. K., **Metal Cutting**, Butterworths-Heinemann, 4ª, Ed, Ltd, London, 2000.

TOOL and MANUFACTURING ENGINEERS HANDBOOK, Machining, 4, ed,, v,1, Society of Manufacturing Engineers, Dearbon, Michigan, 1983, p.10,1-0,76.

OLIVEIRA, C. J. **Avaliação da Influencia de Sistemas de Filtragem Aplicados a Topografia de Superfície em Usinagem**, Dissertação de Mestrado PUC Minas, 2004.

ÖZEL, T.; KARPAT, Y. **Predictive modeling of surface roughness and tool wear in hard turning using regression and neural networks**. International Journal of Machine Tools and Manufacture, v. 45, p. 467–479, 2005.

ÖZEL, T.; KARPAT, Y.; FIGUEIRA, L.; DAVIM, J. P. Modelling of surface finish and tool flank wear in turning of AISI D2 steel with ceramic wiper inserts, **Journal of Materials Processing Technology**, v.189, p.192–198, 2007.

PANDA, S. S. *et al.*. Drill wear monitoring using back propagation neural network. **Journal of Materials Processing Technology**, v. 172, p. 283-290, 2006.

PEREIRA, A. C. **Análise de Capabilidade para Avaliar a Influencia da Geometria de Brocas helicoidais em Furação Profunda de uma liga de alumínio – UM ESTUDO DE CASO**. Tese de mestrado. Universidade Tecnológica Federal do Paraná. Campus de Curitiba. 2010.

PIRES, B. J.; DINIZ, A. E. **Avaliação da influencia de porta-ferramentas com haste de metal duro para fresamento frontal da liga de titânio TI-6AL-4V**.

6º Congresso Brasileiro de Engenharia de Fabricação, Caxias do Sul, Rio Grande do Sul, 2011.

REVEVIER, N. M.; TEER, D.G.; ASPINWALL, D. K.; DEWES, R. C.; COLDWELL, H. L. **The use of soft lubricating coating when dry drilling BS L168 aliminium alloy**, Surface and Coating Technology, nº 148, pp 716-726, 2004.

RODRIGUES, A. R. **Estudo da geometria de aresta de corte aplicadas em usinagem com altas velocidades de corte**. Tese de doutorado apresentada a Escola de Engenharia de São Carlos, da Universidade de São Paulo em 2005.

RUTHES, S.; CERETTA, P. S.; SOUZA, I. B. **Seis Sigm: Melhoria da qualidade atrvés da redução da variabilidade**. Revista Gestão Industrial, Universidade Tecnológica Federal do Paraná – UTFPR, ISSN 1808-0448 / v.02, n.02: p. 181-199, 2006.

RUMELHART, D. E.; HILTON, G. E.; WILLIAMS, R, J, **Learning internal representations by error propagation**, In: Rumelhart, D, E,; McClelland, J, L, (ed), Parallel data processing, Cambridge, MA: M,I,T, Press, 1986, v. 1, cap, 8.

SANTOS, A. L. B.; **Metodologia via Redes Neurais para estimativa da rugosidade e do desgaste de ferramentas de corte no processo de fresamento frontal**, Tese de doutorado apresentada a Universidade federal Uberlândia em março de 2001.

SARTORI, M. A.; ANTSAKLIS, P. J. **Implementations of learning control systems using neural networks**, IEEE Control Systems Magazine, v.12, n. 2, p. 49-57, Apr, 1992.

SICK, B. **On-line and indirect tool wear monitoring in turning with artificial neural networks: a review of more than a decade of research**. Mechanical Systems and Signal Processing, v.16, n.4, p.487–546, 2002.

SHAW, M. C. **Metal Cutting Principles**. Oxford: Oxford Science Publications, Claredon Press, 2005.

SOUSA, M. N.; SILVA, M.A.; SILVA, M. B. **Investigação experimental da formação do cavaco na usinagem do aço ABNT 1045 e do ferro fundido modular**. 6º CONGRESSO BRASILEIRO DE ENGENHARIA DE FABRICAÇÃO. Caxias do Sul – RS – Brasil, 2011.

STEMMER, Caspar Rich. **Ferramentas de corte II**. 2 ed. Florianópolis: Ed. da UFSC, 1995.

WAIBEL, A.; HANAZAWA, T.; HILTON, G.; SHIKANO, K.; LANG, K, **Phonemic Recognition using Time Delay Neural Networks**, *IEEE Trans, Acoust., Speech, Signal Processing*, vol. 37, n. 3, (pp, 328-339, 1989).

WHITEHOUSE, D. J, **Handbook of Surface Metrology**, Leicester, England, 1994.

WITTING, H. “**Torneamento de superligas**”, Máquinas e metais, n. 440, pp. 156–165, 2002.

WASSSERMAN, P. D. **Neural Computing: Theory and Practice**, Van Nostrand Reinhold, New York, 1989.

ZBIKOWSKI, R.; GAWTHROP, P. J. **A survey of neural networks for control**. In: **Neural networks for control and systems**. London: Peter Peregrinus, 1992. p. 31-50.

Anexo1

Rede neural para determinação da melhor configuração de rede para estimação de valores

```
% DEPARTAMENTO DE ENGENHARIA ELÉTRICA - FEB - UNESP
% Pos-graduação em Engenharia Elétrica
% JOAO GABRIEL CONTRUCCI
% REDE NEURAL DEFINIÇÃO DOS MELHORES PARAMETROS DE REDE AL DIAMTERO,
clear all
close all
clc
%Carregando os dados de treinamento
load InputAl_1A.txt;
p1=InputAl_1A(:,1);%Aceleração
p2=InputAl_1A(:,2);%Emissão Acústica
p3=InputAl_1A(:,3);%Potência
p4=InputAl_1A(:,4);%Força em X
p5=InputAl_1A(:,5);%Força em Y
p6=InputAl_1A(:,6);%Força em Z
p7=InputAl_1A(:,7);%Velocidade de Corte
p8=InputAl_1A(:,8);%Avanço
t1=InputAl_1A(:,9);%Diâmetro Médio
p=[p1,p2,p3,p4,p5,p6,p7,p8];
p=p';
t=[t1];
t=t';
Indice=0;
neuronio1 = 0;
neuronio2 = 0;
neuronio3 = 0;
for j=1:5
    for k=1:5
        for neuronio1=1:5
            for neuronio2=1:5
                for neuronio3=1:5
                    net = newff(p,t,[neuronio1 neuronio2 neuronio3]);
%Definição dos parâmetros
```

```

    Momento=0;
    if j==1
        Momento=0,1;
    end
    if j==2
        Momento=0,3;
    end
    if j==3
        Momento=0,5;
    end
    if j==4
        Momento=0,7;
    end
    if j==5
        Momento=0,9;
    end
    %Variação da taxa de aprendizagem (Learning Rate)
    learn_rate=0;
    if k==1
        learn_rate=0,1;
    end
    if k==2
        learn_rate=0,3;
    end
    if k==3
        learn_rate=0,5;
    end
    if k==4
        learn_rate=0,7;
    end
    if k==5
        learn_rate=0,9;
    end
    net,trainParam,mc = Momento;
    net,trainParam,lr = learn_rate;
    net,trainParam,show=5;
    net,trainParam,goal = 1e-7;
    net,trainParam,showWindow = 0;
    net,trainParam,epochs = 100;
    net = train(net,p,t);

```

```

Y = sim(net,p);
W = sim(net,p);
Indice = Indice+1;
ErroDia(Indice,1)= neuronio1;      %N de Neurônios - Primeira Camada
ErroDia(Indice,2)= neuronio2;      %N de Neurônios - Segunda Camada
ErroDia(Indice,3)= neuronio3;      %N de Neurônios - Terceira Camada
ErroDia(Indice,4)= Momento;        %Momento
ErroDia(Indice,5)= learn_rate;     %Taxa de Aprendizagem
ErroDia(Indice,6)= mean(abs(t(1,:)-Y(1,:))); %Erro Diâmetro Médio
end
end
end
end
end

```

Anexo2

Rede neural com a melhor configuração de rede para estimação de valores

```
% REDE NEURAL DEFINIÇÃO DOS MELHORES PARAMETROS DE REDE AL DIAMTERO,
clear all
close all
clc
%Carregando os dados de treinamento
load InputAl_1A.txt;
p1=InputAl_1A(:,1);%Aceleração
p2=InputAl_1A(:,2);%Emissão Acústica
p3=InputAl_1A(:,3);%Potência
p4=InputAl_1A(:,4);%Força em X
p5=InputAl_1A(:,5);%Força em Y
p6=InputAl_1A(:,6);%Força em Z
p7=InputAl_1A(:,7);%Velocidade de Corte
p8=InputAl_1A(:,8);%Avanço
t1=InputAl_1A(:,9);%Diâmetro Médio
p=[p1,p2,p3,p4,p5,p6,p7,p8];
p=p';
t=[t1];
t=t';
net = newff(p,t,[5 2 5]);
trainRatioRatio = 0,70;
valRatioRatio = 0,15;
testRatioRatio = 0,15;
net,trainParam,max_fail = 10;
net,trainParam,mc = 0,5;
net,trainParam,lr = 0,1;
net,trainParam,show=5;
net,trainParam,goal = 0,0001;
net,trainParam,showWindow = 1;
net,trainParam,epochs = 100;
net = train(net,p,t);
Y = sim(net,p);
W = sim(net,p);
```

```
for i=1:length(Y)
    vetplot(i)=i;
end
%subplot(2,1,1,'replace')
plot(vetplot,Y,'r',vetplot,t,'b');
grid
```

Anexo3

Rede neural com a melhor configuração de rede para predição de valores

```
% DEPARTAMENTO DE ENGENHARIA ELÉTRICA - FEB - UNESP
% Pos-graduação em Engenharia Elétrica
% JOAO GABRIEL CONTRUCCI
% REDE NEURAL RedeNeuralAI_diametro_Pot,
clear all
close all
clc
% Carregando os dados de treinamento
load InputAI_1A_full.txt;
load InputAI_Ra_full.txt
p1= InputAI_1A_full(:,1); % Aceleração
p2= InputAI_1A_full(:,2); % EA
p3= InputAI_1A_full(:,3); % Potencia
p4= InputAI_1A_full(:,4); % Força Fx
p5= InputAI_1A_full(:,5); % força FY
p6= InputAI_1A_full(:,6); % força FY
p7= InputAI_1A_full(:,7); % velocidade de corte
p8= InputAI_1A_full(:,8); % avanço
t1= InputAI_1A_full(:,9); % Diâmetro Médio
t2= InputAI_Ra_full(:,1); % Rugosidade
p_estima = [p1,p2,p2,p3,p4,p5,p6,p7,p8];
p_estima = p_estima';
t_diametro = t1';
t_rugosidade = t2';
net = newff(p_estima,t_diametro,[5 2 5]);
net,trainParam,min_grad = 1e-10;
net,trainParam,max_fail = 400;
net,trainParam,mc = 0,9;
net,trainParam,lr = 0,3;
net,trainParam,show=5;
net,trainParam,goal = 0,00001;
net,trainParam,showWindow = 1;
net,trainParam,epochs = 400;
```

```

net = train(net,p_estima,t_diametro);
Y = sim(net,p_estima);
for i=1:length(Y)
    vetplot(i)=i;
end
plot(vetplot,Y,'r',vetplot,t_diametro,'b');
title('Diâmetro Médio Estimado Alumínio (Vermelho - Diâmetro Médio Estimado / Azul - Diâmetro Médio Real)') xlabel('nº de furos ')
ylabel('Diâmetro em mm')
grid
p_predicao = con2seq(Y);
t_predicao = con2seq(t_diametro);
ftdnn_net = timedelaynet([1:4],6);
ftdnn_net,trainParam,goal = 0,00001;
ftdnn_net,trainParam,show = 30;
ftdnn_net,trainParam,max_fail = 400;
ftdnn_net,trainParam,min_grad = 1e-10;
ftdnn_net,trainParam,epochs = 400;
ftdnn_net,trainParam,mc = 0,5;
ftdnn_net,trainParam,lr = 0,2;
e = p_predicao(5:end);
s = t_predicao(5:end);
Pi= p_predicao(1:4);
ftdnn_net = train(ftdnn_net,e,s,Pi);
yp = ftdnn_net(p_predicao,Pi);
e = gsubtract(yp,t_diametro);
rmse = sqrt(mse(e));

```







Anexo4

Cavacos gerados no processo de usinagem





Anexo5

Desgaste da aresta de Corte

Broca Inicial	FIM do CDP 1	FIM do CDP 3
		
FIM do CDP 4	FIM do CDP 5	Fim das Furações
		

Anexo6

Desgaste de Flanco

Broca Inicial	FIM do CDP 1	FIM do CDP 3
		
FIM do CDP 4	FIM do CDP 5	Fim das Furações
