

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Determinação da qualidade de furos e do comprimento da junta através de dados coletados de máquinas automatizadas de furação

Frederico Leoni Franco Kawano

Dissertação de Mestrado do Programa de Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria (MECAI)

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Frederico Leoni Franco Kawano

Determinação da qualidade de furos e do comprimento da
junta através de dados coletados de máquinas
automatizadas de furação

Dissertação apresentada ao Instituto de Ciências
Matemáticas e de Computação – ICMC-USP,
como parte dos requisitos para obtenção do título
de Mestre – Mestrado Profissional em Matemática,
Estatística e Computação Aplicadas à Indústria.
VERSÃO REVISADA

Área de Concentração: Matemática, Estatística e
Computação

Orientador: Prof. Dr. Cláudio Fabiano Motta Toledo

USP – São Carlos
Maio de 2021

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

L585d Leoni Franco Kawano, Frederico
 Determinação da qualidade de furos e do
 comprimento da junta através de dados coletados de
 máquinas automatizadas de furação. / Frederico Leoni
 Franco Kawano; orientador Claudio Fabiano Motta
 Toledo. -- São Carlos, 2021.
 109 p.

 Dissertação (Mestrado - Programa de Pós-Graduação
 em Mestrado Profissional em Matemática, Estatística
 e Computação Aplicadas à Indústria) -- Instituto de
 Ciências Matemáticas e de Computação, Universidade
 de São Paulo, 2021.

 1. Furação. 2. Comitê. 3. Redes Neurais. 4.
 Classificação. I. Motta Toledo, Claudio Fabiano,
 orient. II. Título.

Frederico Leoni Franco Kawano

Determination of the quality of the holes and the length of
the drilled stack analyzing the data collected from the drilling
Machines

Dissertation submitted to the Instituto de Ciências Matemáticas e de Computação – ICMC-USP – in accordance with the requirements of the Professional Master's Program in Mathematics Statistics and Computing Applied to Industry, for the degree of Master in Science. *FINAL VERSION*

Concentration Area: Mathematics, Statistics and Computing

Advisor: Prof. Dr. Cláudio Fabiano Motta Toledo

USP – São Carlos
May 2021

À minha amada esposa Priscilla e amado filho Gustavo.

Aos meus pais Fumio e Lilia (in memoriam)

Ao meu orientador Cláudio

Aos amigos da EMBRAER

AGRADECIMENTOS

Os agradecimentos principais são direcionados aos meus amados Priscilla e Gustavo, que com muita paciência e amor me incentivaram a terminar esta jornada.

Também aos incentivos sempre presentes dos meus pais Fumio e Lilia (*in memoriam*) para que iniciasse e depois terminasse essa empreitada. Fico feliz de também estar realizando um sonho de vocês.

Ao meu orientar Cláudio que com extrema paciência me ajudou demais em todos estes anos.

Aos amigos da EMBRAER, principalmente meu supervisor Orlando que me acompanha, orienta e incentiva a tantos anos e aos grandes amigos Bizeli, Rafael, Marcel, Mariana, Valmir, Rodrigo, Caio e Marcos que sempre me ajudaram muito durante este intenso período.

Finalmente à Universidade de São Paulo, na qual me formei engenheiro em 2001 e agora completo mais esta etapa de meu desenvolvimento.

“A menos que modifiquemos a nossa maneira de pensar, não seremos capazes de resolver os problemas causados pela forma como nos acostumamos a ver o mundo.”
(Albert Einstein)

RESUMO

KAWANO, F. L. F. **Determinação da qualidade de furos e do comprimento da junta através de dados coletados de máquinas automatizadas de furação.** 2021. 109 p. Dissertação (Mestrado – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2021.

Este trabalho tem como objetivo desenvolver um método capaz e eficiente de se determinar a qualidade final dos furos e o comprimento da junta furada através da utilização de um comitê de redes neurais e algoritmos, pela análise de dados obtidos pelo monitoramento do consumo de corrente elétrica por máquinas automatizadas de furação. O método desenvolvido neste trabalho deve trazer mais eficiência no processo de furação automatizada, evitando-se etapas de medição e inspeções físicas que implicam em aumento de ciclo do processo como um todo. Além disso, o método deve evitar a propagação de erros e trazer base de informação para a análise de causa raiz em caso de discrepâncias encontradas.

Palavras-chave: Furação, Comitê, Redes Neurais, Classificação.

ABSTRACT

KAWANO, F. L. F. **Determination of the quality of the holes and the length of the drilled stack analyzing the data collected from the drilling Machines.** 2021. 109 p. Dissertação (Mestrado – Mestrado Profissional em Matemática, Estatística e Computação Aplicadas à Indústria) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2021.

This master thesis has as objective develop an efficient and capable method to determine the quality of holes and the length of the drilled stack, trough the use of neural networks committee and algorithms throught analyze data obtained from monitoring the consumed electrical current by automated drilling machines. The developed method shall include more efficiency on automated drilling process, avoiding physical measurements and ,inspections that increase the cycle time of entire process. Although it shall prevent errors propagation and provide appropriate data for root cause analysis of eventual discrepancies.

Keywords: Drilling, Committee, Neural Networks, Classification.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de Robô de Furação	23
Figura 2 – Exemplo Cabeçote de Furação com <i>probe</i> de Medição	24
Figura 3 – Máquina de Furação Automatizada.	36
Figura 4 – Equipamento para Medição Manual.	36
Figura 5 – Comparativo entre Instrumentos de Medição Citados.	37
Figura 6 – Comprimento do Prendedor - Requisitos de Fabricação	41
Figura 7 – Importância da escolha do comprimento do Prendedor	42
Figura 8 – Medição Manual da Espessura da Junta Furada	43
Figura 9 – Requisitos dos Furos	43
Figura 10 – Medição Física de Furos	44
Figura 11 – Gráfico Esquemático da variação da Corrente Elétrica em Função do Tempo	45
Figura 12 – Gráfico Avanço do Cabeçote de Furação em Função do Tempo	46
Figura 13 – Gráfico Avanço do Cabeçote de Furação em Função do Tempo	47
Figura 14 – Gráfico Esquemático da Variação da Corrente Elétrica em Função do Tempo e Eixo "x"	50
Figura 15 – Gráfico Avanço do Cabeçote de Furação em Função do Tempo	51
Figura 16 – Importantes fatores a serem considerados no calculo do Patamar Crista	58
Figura 17 – Ilustração do Cálculo do Fim da Crista	59
Figura 18 – Avaliação de Sinais (Furos)	66
Figura 19 – Esquema de Funcionamento do Comitê de Redes MLP	68
Figura 20 – Padrão de Sinal de Corrente Elétrica para uma Furo com peck drill	70
Figura 21 – Corpo de Prova Construído para Simular Condições Afetadas e Não Afetadas por Fatores Externos	71
Figura 22 – Padrão de Corrente para furos <i>Aceitáveis</i> e <i>Não Aceitáveis</i>	73
Figura 23 – Padrão de Ondas para Furos <i>Aceitáveis</i>	75
Figura 24 – Padrão de Ondas para Furos <i>Não Aceitáveis</i>	77
Figura 25 – Representação Esquemática de Redes Neurais MLP	77
Figura 26 – Modelagem Preliminar do Problema	78
Figura 27 – Modelagem Final do Problema	78
Figura 28 – Sinal da Corrente x Tempo do furo #7	84
Figura 29 – Sinal da Corrente x Tempo do furo 14	86
Figura 30 – Sinal da Corrente x Tempo do furo 19	86
Figura 31 – Gráfico do Erro médio em Função da Quantidade de Neurônios	89

Figura 32 – Tabela de Confusão da Rede MLP com Simples Camada de 79 Neurônios	91
Figura 33 – Sinal de Corrente do Furo 7 - Destaque à Onda Não Normal	93
Figura 34 – Sinal de Corrente do Furo 35 - Destaque às Ondas Não Normais	94
Figura 35 – Sinal de Corrente do Furo 23 - Destaque às Ondas Não Normais	94

LISTA DE TABELAS

Tabela 1 – Resumos dos Resultados Obtidos pelo Método de Medição do Comprimento dos 60 Furos Realizados no Produto Real	83
Tabela 2 – Arquiteturas das Redes MLP com Simples Camada que apresentaram os Melhores Resultados Estatísticos de Erro	88
Tabela 3 – Arquiteturas das Redes MLP com Dupla Camada que apresentaram os Melhores Resultados Estatísticos de Erro	88
Tabela 4 – Arquiteturas das Redes MLP com os Melhores Resultados Estatísticos de Erro	90
Tabela 5 – Resultados Individuas das Redes MLP - Furos Contendo Ondas Não Normais	92
Tabela 6 – Resultados Individuas das Redes MLP - Posição das Ondas Não Normais . .	92
Tabela 7 – Resultados das Redes MLP e Comitê - Furos Contendo Ondas Não Normais	95
Tabela 8 – Resultados das Redes MLP e Comitê - Posição das Ondas Não Normais . .	95
Tabela 9 – Resultados das Redes MLP e Comitê - Onda do Furo 7	96
Tabela 10 – Resultados das Redes MLP e Comitê - Onda do Furo 35	96
Tabela 11 – Resultados das Redes MLP e Comitê - Ondas do Furo 35 - Continuação . .	97
Tabela 12 – Resultado Final do Modelo de Avaliação da Qualidade dos 60 Furos Executados no Produto Real	98

SUMÁRIO

1	INTRODUÇÃO	21
1.1	Contextualização	22
1.2	Objetivos	24
1.3	Estrutura da Dissertação	25
2	REVISÃO BIBLIOGRÁFICA	27
3	PROBLEMA ABORDADO	35
3.1	Visão Geral do Problema	35
3.2	Melhoria Contínua em Produção Aeronáutica	38
3.3	Requisitos Estruturais Aeronáuticos	39
3.3.1	<i>Procedimento para a Escolha do Comprimento do Prendedor</i>	40
3.3.2	<i>Requisitos Relacionados ao Diâmetro da Furação</i>	43
3.4	Comportamento da Corrente Elétrica Durante o Processo Automatizado de Furação	44
4	METODOLOGIA PARA MEDIÇÃO DO COMPRIMENTO DA JUNTA	49
4.1	Conceito da Medição do Comprimento da Junta Furada	49
4.2	Algoritmos Baseados no Comportamento da Corrente Elétrica	50
4.3	Descrição do Algoritmo	53
4.3.1	<i>Fase 1 - Pré-Processamento</i>	53
4.3.2	<i>Fase 2 - Aproximação da Ferramenta</i>	54
4.3.3	<i>Fase 3 - Patamar de Preparação</i>	55
4.3.4	<i>Fase 4 - Peck Drill</i>	55
4.3.4.1	<i>Certificar que a rotação da ferramenta está estabilizada quando o peck drill se inicia</i>	55
4.3.4.2	<i>Definição do início da Onda</i>	56
4.3.4.3	<i>Definição do Final da Crista da Onda</i>	56
4.3.4.4	<i>Verificação de Folgas Entre as Peças da Junta</i>	58
4.3.4.5	<i>Verificação de Corrente Excessiva com Peck Drill em Recuo</i>	58
4.3.4.6	<i>Verificação do Fim do Peck Drill com o Fim do Furo</i>	60
4.3.5	<i>Fase 5 - Afastamento da Ferramenta e Procedimentos Finais</i>	60

5	METODOLOGIA PARA AVALIAÇÃO A QUALIDADE DO FURO EXECUTADO	63
5.1	Comitê de Redes Neurais <i>Multi-Layer Perceptron</i>	63
5.1.1	<i>Conceitos de Machine Learning</i>	64
5.1.2	<i>Redes Neurais e Comitê de Redes Neurais</i>	65
5.2	Criação do Corpo de Prova Padrão	69
5.3	Criação da Base de Dados de Treinamento	74
5.4	Arquitetura das Redes Neurais MLP	76
5.5	Modelo para Solucionar o Problema	78
6	RESULTADOS	81
6.1	Resultados Obtidos com a Metodologia de Medição da Espessura da Junta	81
6.2	Resultados Obtidos com a Metodologia de Avaliação da Qualidade do Furo	87
6.2.1	<i>Determinação da Quantidade de Camadas Escondidas e Neurônios das Redes MLP</i>	87
6.3	Resultados Obtidos com as Redes MLP Definidas no Produto Final	90
7	CONCLUSÕES	101
	REFERÊNCIAS	107

INTRODUÇÃO

A presente dissertação propõe soluções baseadas na análise de dados provenientes do sistema de controle de máquinas automatizadas de furação. As soluções propostas são obtidas através de métodos computacionais capazes de extrair informações relevantes sem a necessidade de investimentos em hardwares ou outros ativos. Logo, os métodos focam em soluções capazes de determinar tanto a qualidade dos furos executados por estas máquinas quanto o seu comprimento, o qual impacta na determinação dos prendedores a serem instalados em tais furos.

A utilização de máquinas automatizadas de furação se iniciou na montagem de estruturas aeronáuticas com o intuito de prover aumento de eficiência operacional e repetibilidade ao processo e, por consequência, reduzindo o custo de produção destas estruturas. O sistema de controle destas máquinas gera um volume de dados que fornece importantes informações sobre o comportamento da máquina e sobre condições do furo realizado. Um importante dado a ser explorado neste trabalho é o consumo da corrente elétrica pelos acionadores de rotação e avanço da ferramenta de furação. Esse consumo se altera sempre que algum fator externo influencia a furação, visto que a máquina tem como prioridade manter a rotação e avanço da ferramenta de corte constantes.

Assim, a presente dissertação apresenta métodos que visam analisar o comportamento da corrente elétrica consumida pelos acionadores da ferramenta de corte, gerando como saída um índice capaz de classificar cada furo realizado quanto a sua qualidade e o valor do comprimento da junta que fora furada, permitindo assim, decidir a respeito do comprimento apropriado do prendedor a ser instalado.

As soluções descritas neste trabalho proporcionam ganho de tempo e eficiência na produção de estruturas aeronáuticas. Os processos de determinação da qualidade dos furos e do comprimento apropriado dos prendedores instalados são usualmente realizados através de medições mecânicas diretas, efetuadas manualmente que, pela natureza de sua execução, são mais lentas e causam paradas no processo produtivo para que possam ser realizadas. Logo, as

soluções propostas estão alinhadas com o conceito de manufatura enxuta (*lean manufacturing*) que destaca a necessidade de se eliminar os desperdícios na linha de produção. No contexto aqui abordado, tais desperdícios podem ser traduzidos como sendo as atividades mecânicas desnecessárias e as interrupções na linha de produção, muitas vezes executadas por uma ausência de um sistema inteligente capaz de avaliar com melhor acurácia o comprimento da junta e a qualidade dos furos. O presente trabalho propõe eliminar tal desperdício, através de métodos computacionais provenientes dos conceitos de análise de dados que se inserem atualmente na chamada indústria 4.0 ou quarta revolução industrial.

1.1 Contextualização

Nos dias atuais a transformação digital associada ao emprego de soluções automatizadas se tornaram uma realidade, caracterizando-se como um processo de transformação tecnológica que afeta toda a sociedade, incluindo os setores industriais. Com foco neste setor, pode-se dizer que, segundo (AZEVEDO, 2017), a partir de meados do século XX iniciou-se a "Terceira Revolução Industrial", com o início do emprego de sistemas eletrônicos e da tecnologia da informação, proporcionando a automação de vários tipos de processos industriais, realidade que se estende até os dias de hoje.

Nesse contexto, pode-se afirmar que, atualmente, a utilização de soluções automatizadas na indústria se mostra muito eficaz, provendo garantia da qualidade, produtividade e retorno financeiro. Esta realidade se provou viável, primeiramente, nas produções de alta cadência como a automobilística. Características como padronização das atividades produtivas, utilização de juntas soldadas e a já citada alta cadência de produção formam o conjunto dos principais contribuintes para uma razoável viabilidade destas soluções. A utilização destas soluções começou a se propagar em larga escala, abrangendo inclusive a indústria aeronáutica. Pode-se citar inicialmente que a impossibilidade de se utilizar juntas soldadas em aeronaves, levou à existência de juntas fixadas por prendedores, as quais contêm uma enorme quantidade de furos de precisão, tornando-se um importante nicho a ser explorado por soluções de furação automatizada, como a mostrada na figura 1.

Cabeçotes controlados eletronicamente têm a capacidade de garantir com eficácia os parâmetros de corte como avanço e rotação. Esses parâmetros são extremamente críticos para se garantir a qualidade da furação, principalmente quando se pretende realizar esta atividade em velocidade de execução otimizada. A capacidade destes equipamentos de manterem controladas as velocidades de rotação e avanço da ferramenta de corte é permitida pela atuação de sua unidade de controle. Ao perceber qualquer tendência de alteração destes parâmetros devido a alteração nas condições de contorno da furação, a unidade de controle faz sua correção por meio da alteração da corrente elétrica que alimenta os acionadores dos citados movimentos da ferramenta de corte. Assim, é importante esclarecer que, ao se executar um furo em condições

Figura 1 – Exemplo de Robô de Furação

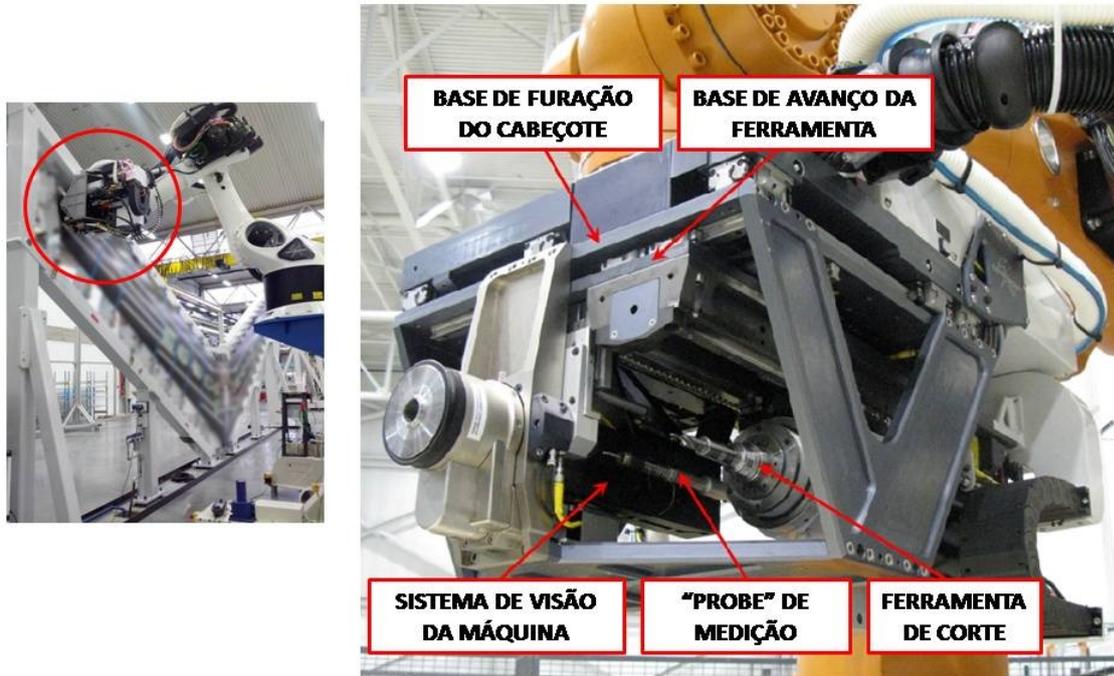


Fonte: Elaborada pelo autor.

normais e controladas, os acionados de rotação e avanço da ferramenta de corte devem apresentar um consumo de corrente elétrica com pouca variação em função do tempo. Por outro lado, um outro furo realizado em condições mais adversas, como por exemplo, com falta de lubrificação ou com as peças da junta mal fixadas, deverá apresentar um consumo de corrente elétrica mais ruidoso, indicando maior intervenção do controlador com o objetivo de se manter as velocidades constantes mesmo sob condições de contorno instáveis. A variação do consumo de corrente elétrica dos acionadores, como o citado anteriormente neste trabalho, também deve aumentar e diminuir abruptamente com a variação do esforço de corte no início e fim de cada furo.

Com a consolidação destas soluções de furação, a próxima oportunidade a ser explorada foi a construção de cabeçotes capazes de, além de furar com rapidez e qualidade, também inspecionar e medir os furos executados contra os requisitos de qualidade atuais, inserindo os prendedores nos mesmos de uma forma otimizada em termos de tempo. Entretanto, mesmo os métodos automatizados de inspeção dos furos consomem tempo de produção para serem executados, pois não deixam de ser métodos diretos e mecânicos de medição que concorrem com a ferramenta de corte no cabeçote de furação. Além disso, essas *probes* muitas vezes são oferecidas como opcionais nos cabeçotes de furação, requerendo assim, investimento para sua aquisição. Tratam-se de itens com alto custo, os quais exigem um alto nível de manutenção preventiva para seu correto funcionamento. A figura 2 mostra um cabeçote de furação automatizado que possui uma *probe* de medição posicionada ao lado da ferramenta de corte. Após a execução de furos, para que o mesmo seja medido, é necessário que a *probe* seja posicionada no interior do furo para que os dados relacionados ao diâmetro do mesmo sejam adquiridos. Logo, temos uma interrupção no processo de furação que poderia ser contínuo, caso a solução de análise dos dados de furação em tempo real, proposta neste trabalho, esteja implementada.

Outro cenário a ser explorado é o de definição de prendedores a serem instalados nos furos realizados por estas máquinas automatizadas. Há juntas estruturais que, devido ao acúmulo das tolerâncias provenientes das etapas anteriores de montagem de conjuntos e de

Figura 2 – Exemplo Cabeçote de Furação com *probe* de Medição

Fonte: Elaborada pelo autor.

fabricação de peças, têm a sua espessura incerta, ou seja, impossível de se determinar apenas pelo conhecimento teórico do produto. Isso exige que a mesma seja medida a cada montagem, para que o comprimento correto do prendedor a ser instalado possa ser determinado. Assim, esta medição do comprimento da junta furada se caracteriza como sendo uma atividade relevante, em termos de tempo de execução, porém necessária, para que a qualidade da junta estrutural seja garantida. No processo atual, sem a implantação das soluções propostas por este trabalho, após o término da furação automatizada, esta etapa de medição manual do comprimento da junta ocorre, em cada um dos furos realizados, consumindo um relevante tempo do ciclo produtivo.

1.2 Objetivos

Uma vez apresentado o cenário de furação automatizada em estruturas aeronáuticas considerado, pode-se detalhar os seguintes objetivos deste trabalho:

- Reduzir o tempo de medição manual ou automática do diâmetro de furos realizados por sistemas automatizados de furação, pela utilização de um método de análise, baseado em um comitê de redes neurais, capaz de classificar os furos realizados quanto a sua qualidade

a partir dos dados de consumo da corrente elétrica dos acionadores da ferramenta de corte, reduzindo-se a necessidade de amostragem de medições mecânicas. A leitura e análise dos dados pelo comitê serão realizadas em tempo real com a execução da furação, de forma a não consumir tempo do ciclo produtivo.

- Reduzir o tempo de medição manual da espessura da junta na posição de cada um dos furos realizados manualmente, substituindo-a por um método de análise dos dados de consumo da corrente elétrica dos acionadores da ferramenta de corte, através da proposição de um algoritmo. A leitura e análise dos dados pelo algoritmo serão realizadas em tempo real com a execução da furação pelo sistema automatizado de furação.

1.3 Estrutura da Dissertação

A presente dissertação traz a descrição do desenvolvimento das soluções propostas em 6 tópicos. O tópico 2 traz uma discussão conceitual, com base na literatura, das soluções propostas para o cumprimento dos dois objetivos citados, assim como uma revisão dos artigos científicos que direcionaram o desenvolvimento e detalhamento das mesmas soluções já citadas.

Já o capítulo 3 detalha todos os requisitos existentes no processo de furação e fixação de juntas em estruturas aeronáuticas, justificando a necessidade de execução das atividades descritas neste capítulo, suportando assim a importância das soluções propostas. Neste capítulo também são abordados conceitos de melhoria contínua de suportam a importância do trabalho e uma abordagem do comportamento da corrente durante a furação, que serve de informação base para os métodos a serem discutidos nos capítulos posteriores.

Com relação aos tópicos 4 e 5, pode-se descrever o primeiro como uma descrição detalhada da solução de algoritmo proposta para se determinar a espessura da junta na posição de cada um dos furos realizados pelo cabeçote de furação de um sistema de furação automatizado. Já o segundo, como uma descrição detalhada da solução proposta baseada em um comitê de redes neurais para se determinar a qualidade de cada um dos furos realizados.

O penúltimo capítulo 6 traz uma discussão detalhada dos resultados obtidos pelo algoritmo de cálculo da espessura e pelo comitê de redes neurais e o capítulo final 7 faz um fechamento de todo o trabalho, citando as dificuldades encontradas, um resumo dos resultados obtidos e os próximos passos que poderão ser dados em futuras pesquisas.

REVISÃO BIBLIOGRÁFICA

A utilização de sistemas ciberfísicos, visando alavancar produtividade e competitividade, é uma das principais características da chamada indústria 4.0 (LEE; BAGHERI; KAO, 2015). O uso de técnicas de aprendizado de máquinas ou inteligência artificial se torna uma das formas de aprimorar tanto o processo produtivo quanto a tomada de decisões na indústria, onde análise de dados passam a ser realizadas de forma inteligente e ágil a partir de informações gerados na planta industrial, levando ao conceito de Inteligência Artificial Industrial (IA-I) (ZHANG *et al.*, 2019). Assim, inteligência artificial, análise de grande volume de dados, integração de sistemas via internet das coisas e o uso de computação em nuvem são tecnologias emergentes que estão impactando nos processos de manufatura (PREUVENEERS; ILIE-ZUDOR, 2017).

Neste trabalho, estaremos fazendo uso de um comitê de redes neurais para aprimorar o cenário de furação automatizada em estruturas aeronáuticas. Os sistemas de furação automatizados fornecem agilidade e repetição dentro do ciclo de fabricação. No entanto, a indústria não considera o uso da automação apenas como um recurso para melhorar a eficiência da produção, mas também uma forma de fornecer dados que podem ser pós-processados e gerar informações relevantes para as decisões de gestão em tempo real (FRANK; DALENOGARE; AYALA, 2019). Pode-se considerar, como exemplo, (PREEZ; OOSTHUIZEN, 2019), onde é mostrada uma revisão da literatura de 2000 a 2017, revelando como métodos de *machine learning*, envolvendo redes neurais artificiais e algoritmos evolutivos, tem sido aplicados em processos de manufatura, com foco em usinagem, como fresamento, torneamento, furação, retífica, corte por jato d'água e laser entre outros. A aplicação destas metodologias trazem para estes processos e, conseqüentemente para a indústria, aumento de produtividade, com qualidade, redução de custos e desperdícios, levando a um conceito de manufatura sustentável que traz desenvolvimento a toda uma região e/ou nação. Na indústria aeronáutica, o processo de furação executado sobre os componentes deve atingir alta eficiência e qualidade para fornecer estruturas confiáveis ao final. Trata-se de um aspecto crítico e a automação no processo de furação tem sido empregada, onde sistemas inteligentes se tornam possíveis para evitar violações de parâmetros que geram

problemas (THOROGOOD *et al.*, 2013).

Os autores em (AAMIR *et al.*, 2020) trazem uma revisão conceitual detalhada sobre furação de precisão em estruturas aeronáuticas em alumínio. O trabalho mostra que parâmetros de corte como as velocidades de avanço e rotação da ferramenta afetam diretamente o controle do diâmetro, circularidade, rugosidade e acabamento superficial, além de outras características capazes de indicar a qualidade do furo executado. Outra análise relevante reside na variação da força de corte e torque sofrido pela sistema de furação nas diversas fases de execução de um furo. Por fim, os autores tratam de característica da formação de cavaco como um indicativo da qualidade do processo de furação.

Os aspectos avaliados em (AAMIR *et al.*, 2020) estão presentes nesta dissertação, onde discutiremos no capítulo 3 as bases conceituais que suportam o estudo aqui conduzido. Por exemplo, a necessidade do sistema de furação manter as velocidades de avanço e rotação da ferramenta constantes e controladas, o movimento de *peck drill* para se evitar a formação de cavacos exageradamente grandes, já que temos no nosso problema um processo de furação *one step drilling*, e a variação do esforço de corte que pode ser traduzido em variação da corrente elétrica nos acionados dos eixos de avanço e rotação da máquina.

O processo de furação em fibras de carbono reforçada, chamado *Carbon Fiber Reinforced Composites (CFRP) drilling process*, é abordado em (HINTZE *et al.*, 2018) no contexto da indústria aeronáutica. Os autores reportam que o processo de furação em CFRP sofre influência do ângulo de corte da fibra e varia durante a furação por conta da rotação da ferramenta. Por isso, é proposta uma nova configuração para execução do corte que permita o registro de todos os componentes da força de corte durante a furação. Estruturas primárias em carbono são cada vez mais comuns em aeronaves, de forma que o método proposto nesta dissertação também pode ser utilizado em máquinas de furação de peças em fibra de carbono.

Os autores em (MEI; ZHU; KE, 2018) também reportam uma análise para a realização do processo de furação na indústria aeronáutica, mas considerando o erro no posicionamento das peças no momento da realização dos furos. O objetivo é avaliar uma estratégia para reduzir o efeito desta variação de posicionamento na furação. Um sistema de visão industrial é aplicado além de estratégias baseadas na análise matemática a partir do posicionamento. Variações dimensionais em estruturas aeronáuticas, não podem ser evitadas e tão pouco negligenciadas, principalmente quando se trata de estruturas com dimensões maiores, como segmentos de fuselagem e asas, ao se pensar em um sistema de furação automatizado. Mesmo quando se parte de uma referência conhecida, uma estrutura se distancia da posição prevista no projeto teórico 3D (CAD) ao longo que, a medição ou as atividades de furação, se afastam do ponto onde a referência primária foi determinada. Desta forma, se o sistema automatizado seguir apenas as informações do modelo 3D para se localizar no espaço, provavelmente irá executar um furo em uma posição incorreta, ao se considerar as referências locais da peça. Assim, o foco em (MEI; ZHU; KE, 2018) é propor métodos que possibilitem a máquina partir da referência comum

(conhecida pelo projeto teórico) mas, ao se aproximar da posição de trabalho, fazer uso dos métodos propostos para realizar um ajuste fino de posicionamento, de acordo com referências locais do próprio produto, referências estas que podem ser percebidas por sistemas de visão e reconhecimento de imagens.

Os autores em (ZHANG *et al.*, 2020) abordam o controle inteligente do processo de furação mas em uma plataforma montada em veículo. O sistema de controle deve lidar com fatores externos como mudanças repentinas e interferências durante o processo de furação automática. O trabalho analisa a adaptabilidade do controle Proporcional–Integral–Derivativo (PID) tradicional, PID difuso e o chamado *Feedback linearization sliding mode variable structure control algorithm*. Os resultados obtidos indicam que os três métodos solucionam o problema e conseguem lidar com as mudanças externas.

O artigo em (ZHANG *et al.*, 2019) se relaciona com esta dissertação uma vez que explora a análise de sinais para geração de informação e tomada de decisão. A análise dos sinais também explica o funcionamento do controlador de um sistema de furação automatizado do veículo, que apesar das diferenças na escala e na energia utilizada para seu acionamento, se assemelha conceitualmente do sistema de controle do sistema de furação automatizado usado como base de testes nesta dissertação. Logo, esta dissertação e o trabalho de (ZHANG *et al.*, 2019) monitoram os dados de um equipamento que, apesar das influências externas, altera a potência de alimentação dos acionadores de avanço para manter este movimento sob controle.

Para o desenvolvimento desta dissertação, a utilização de Redes Neurais Artificiais (RNAs) foi validada a partir de dados do mundo real, fornecidos pelo cenário da linha de produção na indústria aeronáutica. Os autores em (CAGGIANO *et al.*, 2018) e em (PATRA *et al.*, 2017) apresentam uma abordagem que utiliza de redes neurais na predição da vida útil de ferramentas de corte. O trabalho em (MANOHAR *et al.*, 2018) propõe a utilização de redes neurais para se prever calços que serão necessários a partir de um volume de dados otimizados, referentes a medição da superfície onde estes calços deverão ser instalados.

Os trabalhos em (RUIZ *et al.*, 2020) e (SACCO *et al.*, 2020) aplicam RNAs na classificação de imagens. Em (RUIZ *et al.*, 2020), o objetivo é classificar e identificar elementos em estruturas aeronáuticas que façam parte do processo de furação e fixação da mesma, como furos e prendedores já instalados. Assim, segrega-se demais elementos estranho à manufatura como gotas de óleo, outros resíduos e limalhas. Os autores em (SACCO *et al.*, 2020) desenvolvem uma método de análise de imagens provenientes da inspeção de estruturas de material composto, laminados automaticamente, que seja capaz de identificar e classificar os defeitos observados pelo sistema de ultrassom.

Como mencionado anteriormente, o trabalho em (CAGGIANO *et al.*, 2018) traz um desenvolvimento de redes neurais para a predição da vida útil de ferramentas de corte atuando em furação de juntas formadas por peças de material compostos a base de fibra de carbono. Neste trabalho, redes neurais foram utilizadas para analisar dados de velocidade de avanço e rotação da

ferramenta de corte, do esforço de corte e torque. Os dados foram obtidos através de sensores instalados na máquina de furação e foram relacionados com medições do desgaste da ferramenta, avaliado por uma máquina de medição óptica.

De forma semelhante ao estudo condizido nesta dissertação, os autores em (CAGGIANO *et al.*, 2018) buscam determinar a condição de desgaste da ferramenta a partir de dados que indicam seu modo de trabalho, ou seja, de como está sendo exposta ao desgaste. Apesar de não utilizar os mesmos parâmetros, nem o mesmo tipo de rede utilizada nesta dissertação, pode-se relacionar a natureza dos problemas abordados no citado artigo e neste trabalho, concluindo que a utilização de redes neurais artificiais para a determinação de características físicas, como a condição da furação quanto a sua qualidade ou da ferramenta de corte quanto ao seu desgaste, a partir do conhecimento dos valores de parâmetros de corte traz bons resultados. No caso deste artigo, foi reportada uma acurácia de 86% com o uso de RNA.

De forma semelhante, os autores em (PATRA *et al.*, 2017), trazem uma importante abordagem de utilização de redes neurais para a identificação da quantidade de micro-furos realizados com uma determinada ferramenta, podendo-se também determinar, deste modo, a vida útil ainda remanescente para a mesma. Os experimentos foram realizados medindo-se o desgaste das micro-ferramentas de corte e correlacioná-los com os esforços de corte gerados para o sistema de furação com diferentes parâmetros de corte (velocidades de rotação e avanço) após a realização de certas quantidades de micro-furos. As redes neurais foram treinadas através dos dados gerados pelos citados experimentos e apresentaram um erro de 3% a 6%, quando aplicadas a novos casos de predição da vida de ferramentas, usando-se como dados de entrada a leitura do esforço e parâmetros de corte reais. É importante se fazer, neste momento, uma correlação de (PATRA *et al.*, 2017) com este trabalho, onde o controle dos parâmetros de corte velocidades de avanço e de rotação da ferramenta também serão discutidos, porém, neste caso, como primordiais para a garantia da qualidade da furação. Entretanto, para este trabalho, a medida direta que faremos, e utilizaremos como dado de entrada para o comitê de redes neurais, é do consumo de corrente elétrica dos acionadores e não do esforço de corte como em (PATRA *et al.*, 2017), contudo, estas são grandezas correlacionadas para o cenário estudado nesta dissertação, como será mostrado no capítulo 3.

Já no citado (MANOHAR *et al.*, 2018), redes neurais artificiais foram empregadas para se prever o uso de calços em estruturas aeronáuticas. Isso permitiu se otimizar o processo produtivo que prevê a leitura das superfícies das peças, em cuja interface devem ser instalados calços, com auxílio de um instrumento de medição com *laser* ou outro recurso de reprodução de superfície. A medição e fabricação de calços é um importante fator de consumo de tempo da produção. De forma similar ao estudo em (MANOHAR *et al.*, 2018), a presente dissertação também lida com uma atividade que faz parte do caminho crítico de montagem de aeronaves. No nosso caso, tal atividade é a medição dos comprimentos dos prendedores.

O método descrito em (MANOHAR *et al.*, 2018) otimiza o processo atual, reduzindo

a quantidade de pontos medidos em uma determinada superfície na ordem de 97%, quando prevendo o calço a ser manufaturado e instalado na interface da superfície em questão. Para isso, tendo-se o conhecimento de informações referentes a medições de superfícies medidas e calços instalados em 54 aeronaves, desenvolveu-se um sistema de redes neurais e PCA (*Principal Components Analysis*) para determinar os pontos relevantes das medições e como estes estão relacionados com as dimensões dos calços. Este sistema foi treinado com informações referentes a superfícies medidas e calços instalados em 53 aeronaves e validado em uma última aeronave. Os resultados de acuracidade do método ficaram na ordem de 98%.

Ainda com relação à aplicações em manufatura aeronáutica, foi citado (RUIZ *et al.*, 2020), que propõe o uso de redes neurais convolucionais para a realização de classificação de imagens. As imagens são obtidas por meio de sistemas digitais de visão, identificando elementos do processo de fixação de juntas como furos e prendedores, ao longo de estruturas aeronáuticas. Como já mencionado neste trabalho, automatizar processos usando tecnologias digitais, como parte da transição para a Indústria 4.0, tem-se mostrado uma tendência atual.

Este tipo de reconhecimento de imagem pode ser empregado em verificação de instalação de prendedores, localização de máquinas automatizadas de furação, medição e reconhecimento de padrões de furação e distâncias chave em peças estruturais, entre outras aplicações. O trabalho em (RUIZ *et al.*, 2020) discorre sobre a eficiência que a técnica apresentada mostrou ao classificar, baseado em imagens, elementos do processo de fixação de juntas como furos com ou sem escareados, rebites com cabeça escareada e protuberante, a cabeça e a contra-cabeça de prendedores temporários, pinos e parafusos escareados e protuberantes com cabeça hexagonal ou não.

Outros elementos a serem classificados em (RUIZ *et al.*, 2020) são itens existentes na estrutura que não pertencem ao processo de fixação como resíduos da superfície das peças, limalhas ou cavacos, marcas de óleo ou até marcas realizadas de forma interacional com caneta não permanente. Estes itens foram chamados de itens *background*. O conjunto de dados de treinamento foi revisado e tratado de forma a conter imagens com nitidez correta que cubram diversos tons, simulem diversas condições de iluminação e possibilidades de brilho que possam estar presentes nas condições reais de classificação. Os resultados de acurácia foram de 98,3% quando se considera a capacidade do método de diferenciar elementos de fixação do *background*. Quando se pretende identificar exatamente qual o elemento, a acuracidade ficou entre 62,9% a 99,4% referente a rebites escareados e a furos, respectivamente.

Outra abordagem analisando imagens no processo de produção na indústria aeronáutica é reportada no já mencionado (SACCO *et al.*, 2020). Nele os autores empregam técnicas de classificação de imagens para melhorar os resultados de inspeções automatizadas por ultrassom, considerando peças laminadas também por processos de laminação automatizados (*Automated Fiber Placement*). Este trabalho também relata como redes neurais convolucionais foram utilizadas para se analisar imagens geradas por uma máquina automatizada de inspeção de peças de

material composto por ultrassom.

A proposta em (SACCO *et al.*, 2020) é classificar as regiões inspecionada em 5 diferentes tipos de imagens: área sem defeito, área com dobra de camada, folga entre camadas (*Gap*), sobreposição, existência de objeto estranho ao processo, área sem substrato de camada ou enrugamento. É importante mencionar que esses tipos de identificação são de grande importância na indústria aeronáutica atual, visto que peças com as características mencionadas são cada mais empregadas nas aeronaves. Por outro lado, inspeções por ultrassom requerem uma experiência muito grande dos inspetores para detecção dos defeitos, por isso a importância de método automatizado. Os autores reportam resultados promissores dada a complexidade do material a ser inspecionado. Uma iteração entre dados de inspeção com controle de parâmetros de funcionamento das máquinas de laminação é proposta como trabalho futuro.

Redes neurais também são utilizadas em aplicações reais em outras áreas do conhecimento. Por exemplo, RNA foi aplicada para resolver problemas de previsão no diagnóstico de câncer (DAOUD; MAYO, 2019), previsão de energia eólica (LIU *et al.*, 2019), saúde de manufatura (ANG; SUANDI, 2019); classificação de imagem (SUN *et al.*, 2020), diagnóstico de falhas (MALLA *et al.*, 2019; LEE; WU; PENG, 2019) e previsão de crises epiléticas intracranianas (RAGHU; SRIRAAM, 2017).

Os autores em (DAOUD; MAYO, 2019) revisam vários trabalhos de 2013-2018, onde RNAs são aplicados para filtrar expressões gênicas e prever o tipo de câncer. Os trabalhos revisados indicam as melhorias alcançadas pela RNA e discutem os aspectos relacionados ao projeto da RNA. O uso de preditores inteligentes para previsão de energia eólica é relatado em (LIU *et al.*, 2019), onde trabalhos são revisados aplicando técnicas como RNA, máquina de Boltzmann restrita, rede neural convolucional, entre outras técnicas. Os dados gerados durante o processo de manufatura são utilizados em (ANG; SUANDI, 2019) para prever condições de salubridade da produção.

Um algoritmo genético desenvolve o projeto de uma rede neural convolucional profunda em (SUN *et al.*, 2020). O método proposto foi capaz de definir redes neurais que superam vários outros métodos da literatura para classificação de imagens. O diagnóstico de falhas é abordado por (MALLA *et al.*, 2019) para sistemas de transmissão de potência, onde a RNA classifica o tipo de falhas a partir de características fornecidas pela transformada wavelet discreta. Tipos de operação de falha para unidades de tratamento de ar são abordadas por (LEE; WU; PENG, 2019), usando rede neural profunda com 200 neurônios dentro de cinco camadas ocultas.

A utilização de Redes Neurais *Multi-Layer Perceptron* (MLP) e outros métodos de classificação integrados por um comitê foi utilizada em (VOGADO *et al.*, 2017) para um sistema para diagnóstico de leucemia. Os autores em (CARVALHO; GUEDES; SALAME, 2020) utilizaram um comitê de redes neurais convolucionais na classificação de ervas daninhas em culturas agrícolas. Um comitês foi utilizado em (DANTAS *et al.*, 2018) para se estimar o volume individual de árvores de eucalipto.

No estudo reportado em (VOGADO *et al.*, 2017), o comitê é aplicado para compor os resultados de três métodos classificadores: uma MLP, uma classificação baseada em *Support Vector Machine* (SVM) e a outra em *Randon Forest*. O artigo propõe o diagnóstico de leucemia com base em imagens de amostra de sangue. A partir das imagens, a primeira abordagem é criar uma descrição desta imagem, gerando informações que possam ser relacionadas ao problema que se quer estudar. Este processo é feito por redes neurais convolucionais.

A próxima etapa do método consiste em se reduzir o tamanho da informação da imagem, utilizando PCA (*Principal Component Analysis*) para focar apenas nas informações relevantes para o problema em questão. Assim, passa-se um vetor com dimensões reduzidas para o comitê classificador, o qual é formado por três classificadores. O comitê avalia os três resultados de forma independente e utiliza o método de voto majoritário para obter um resultado final. Esta metodologia alcançou um resultado de 98,14% de acurácia na base de dados ALL-IDB1, superando resultados apresentados na literatura.

A utilização de classificadores com métodos diferentes não foi utilizada nesta dissertação, mas o estudo reportado em (VOGADO *et al.*, 2017) influenciou na decisão de se escolher redes MLP com arquiteturas diferentes, porém, certificando-se que as arquiteturas escolhidas apresentem erros médios obtidos nos testes compatíveis com os melhores resultados.

Já em (CARVALHO; GUEDES; SALAME, 2020), três comitês foram testados tratando as mesmas respostas das 5 redes neurais convolucionais treinadas para classificação de imagens, com o objetivo de se classificar imagens referentes a culturas como milho, trigo e beterraba de ervas daninhas. Um comitê utilizou voto majoritário e os outros dois a votação mediada por uma *Support Vector Machine* (SVM) e outra por uma *Rede Neural Artificial* (RNA). Os dados de treinamento foram compostos por imagens de culturas de interesse (classe positiva) e os exemplos remanescentes foram agrupados na classe relativa às ervas daninhas (classe negativa). A princípio, as quantidades de imagens referentes às duas classes encontraram-se desbalanceada para o treinamento, sendo que os exemplos disponíveis para a classe positiva estavam em menor quantidade. Assim, optou-se por adotar estratégias de *data augmentation*, baseadas principalmente em rotações e espelhamentos, e no estabelecimento de um limiar de 450 exemplos por espécie. Nota-se que este procedimento de *data augmentation* também foi utilizado de forma semelhante neste trabalho, na geração do conjunto de dados de *ondas não normais*, quando se espelhou ondas e até se gerou combinações entre vales e picos se fazem os algoritmos genéticos. Como resultado, este artigo mostrou que o a melhor rede neural convolucional obteve uma acurácia de 95,8% e o comitê mediado por SVM de 97,08%, o que mostra que o uso de comitês traz oportunidade de se aumentar a qualidade de respostas de redes neurais.

Em (DANTAS *et al.*, 2018) um comitê foi utilizado para se estimar o volume individual de árvores de eucalipto, a partir da média aritmética do resultado individual de 10 RNAs, quando estas arquiteturas foram empregadas em dados não utilizados em seu treinamento. Foram definidas 10 arquiteturas diferentes de redes neurais MLP, contendo diferentes quantidades de

neurônios na camada escondida. Cada uma destas arquiteturas sofreu 10 sessões de treinamento de onde a rede com melhor resultado foi escolhida para o teste final em uma amostra de 10 árvores que não compuseram o conjunto de dados de treinamento teste e validação. Os resultados as 10 redes MLP escolhidas apresentam uma variação, de forma que a resposta do comitê, que trabalha com a média aritmética do resultado individual de 10 RNAs, reduziu o erro geral das redes, porém, ficou equivalente ao resultado da melhor rede. Este fato leva a discussão da relevância do comitê para este caso visto que, uma das redes individualmente traz o mesmo resultado, ou seja com menor esforço computacional. Por outro lado este resultado também leva à reflexão da importância da utilização de comitês visto que não se pode escolher, ou não se sabe ao certo, qual rede individual terá o melhor resultado para todos os tipos de dados reais de termos que analisar no futuro, como o que será discutido no decorrer desta dissertação.

Assim, baseado nos trabalhos revisados, observamos dois relevantes aspectos que influenciaram a condução deste projeto. Primeiro, a forma como dados obtidos no processo produtivo podem ser utilizados no desenvolvimento de metodologias como reportado em (CAGGIANO *et al.*, 2018), (MANOHAR *et al.*, 2018), (RUIZ *et al.*, 2020) e (SACCO *et al.*, 2020). Segundo, a eficácia de redes MPL e comitê de redes neurais no suporte ao processo de tomada de decisão como descrito em (VOGADO *et al.*, 2017), (CARVALHO; GUEDES; SALAME, 2020) e (DANTAS *et al.*, 2018).

PROBLEMA ABORDADO

Como visto no capítulo 1, esta dissertação objetiva ganho de tempo e qualidade durante o processo de fixação de juntas aeronáuticas furadas por sistemas automatizados, através do emprego de métodos computacionais que realizariam, em tempo real, as atividades relacionadas à inspeção do diâmetro dos furos e à medição do comprimento da junta furada, a partir da análise dos dados adquiridos pelo próprio sistema de controle da furação. Tais dados estão relacionados ao consumo de corrente elétrica pelos acionadores de movimentação da ferramenta de corte.

Neste capítulo, o problema será estabelecido em linhas gerais para que seus aspectos principais sejam detalhados em seguida: melhoria do processo produtivo, requisitos do produto e comportamento da corrente elétrica durante o processo de furação. Assim, os conceitos de melhoria contínua em produções industriais, que justificam a existência deste estudo, serão tratados. O objetivo é justificar a necessidade da eliminação do tempo gasto em inspeções que levam ao desperdício e perda de eficácia da capacidade produtiva. Em seguida, os requisitos do produto no processo produtivo serão detalhados já que eles determinam a necessidade de execução das medições realizadas em tempo real. Por último, a principal fonte de dados que levará à proposta de uma solução eficiente será descrita: o comportamento da corrente elétrica durante o processo de furação automatizada. Os dados gerados durante o processo de furação, relacionados ao comportamento da corrente elétrica, servirão de base para a elaboração do algoritmo de cálculo do comprimento do prendedor ideal para cada furo realizado. Esses dados também servem de entrada para o comitê de redes neurais que classifica a qualidade de cada furo.

3.1 Visão Geral do Problema

O problema aqui abordado diz respeito à furos produzidos por sistema de furação automatizada, em estruturas aeronáuticas, com relação a sua qualidade e a determinação do comprimento dos prendedores que neles serão instalados. A figura 3 mostra uma máquina de

furação automatizada fazendo furos sobre junções de segmentos na fuselagem de uma aeronave.

Figura 3 – Máquina de Furação Automatizada.



O diâmetro dos furos deste tipo de estrutura tem tolerância controlada, variando em geral entre $50\mu\text{m}$ a $70\mu\text{m}$, o que torna a inspeção obrigatória. A inspeção feita manualmente, com este nível de precisão, é possível usando-se equipamentos como, por exemplo, o ilustrado na figura 4. Para algumas máquinas, uma sonda automatizada (*probe*) foi desenvolvida para medir os furos realizados, reduzindo o tempo gasto com inspeções manuais.

Figura 4 – Equipamento para Medição Manual.



No entanto, mesmo considerando-se medições automatizadas, a medição do diâmetro requer um tempo de produção relevante para ser executada. Assim, um método que permita uma verificação em tempo real da qualidade dos furos pode-se reduzir de forma expressiva o ciclo de montagem na linha de produção.

Como complemento dos parágrafos anteriores, pode-se citar como exemplos que instrumentos comuns utilizados na indústria aeronáutica o *intrames* e a *ogiva*. Estes dois tipo de instrumentos são baseados em princípios similares, onde a abertura de uma pinça ou a distância entre duas esferas respectivamente, determinam o diâmetro do furo inspecionado. No caso da *ogiva*, as esferas são instaladas em um corpo cilíndrico, o qual tem tensões similares com a do furo a ser inspecionado, servindo assim como um controlador do ângulo do instrumento durante a medição, recurso o qual o *intrames* não dispõe, ficando o controle do ângulo do instrumento por conta do inspetor. Já com relação às *probes* automatizadas, existem diferentes princípios de medição, como por *laser* e por ar comprimido como exemplo, que são possíveis de serem explorados, devido às características de controle de posição, velocidade de avanço e angularidade que o sistema automatizado proporciona. Entretanto, o princípio mecânico, semelhante ao das *ogivas* ainda é o mais utilizado atualmente. A figura 5 faz um resumo das diferenças entre os instrumentos citados.

Figura 5 – Comparativo entre Instrumentos de Medição Citados.



Logo, qualquer inspeção necessária para a garantia da qualidade do produto deve ser realizada de forma rápida e precisa, de forma a impactar o mínimo possível no andamento das atividades produtivas. Tanto as medições realizadas manualmente, por meio de instrumentos com escala milesimal, como o *intrames* ou as *ogivas*, como as realizadas automaticamente com o uso

de *probes* para medição de furos, atualmente existentes nos cabeçotes automatizados, impactam o andamento das atividades produtivas.

No caso das medições automatizadas, via *probes* por exemplo, elas apresentam alto custo e seu tempo de medição, apesar de rápido, não foge de interromper a sequência de furação, o que aumenta assim o ciclo total desta atividade. Quando se considera uma junta de cerca de 4.000 furos, por exemplo, o tempo gasto para a medição citada se torna muito representativo. Se considerarmos que uma máquina usa 6 segundos para realizar uma furação, se tivermos que inspecionar 10% dos furos teremos um custo em tempo de 40 minutos. Se considerarmos o mesmo cenário de medição, porém, realizado por medição manual, onde um inspetor leva em média 30 segundos, seriam dispendidas 3 horas e 20 minutos de medição. Outro fator importante a ser citado é a contaminação das *probes* com o selante da junta, cuja extrusão para o interior do corpo cilíndrico do furo é inevitável. Devido a isso, as *probes* necessitam de limpeza constante para se garantir a qualidade da medição.

Para lidar com todas as restrições envolvidas neste problema, o sistema de automação da furação se torna uma fonte capaz de fornecer informações relevantes sobre o processo de furação, onde se destacam os dados sobre o comportamento da corrente elétrica consumida pelos acionadores dos cortadores. A fim de manter estáveis as velocidades de avanço e rotação do cortador, o controlador da máquina causa variação contínua na corrente elétrica que é consumida pelos acionadores do cortador. Essa variação tem um padrão que muda, se houver algo diferente com o produto que está em processo de furação. Por exemplo, uma vibração excessiva causada por uma fixação incorreta das peças que compõem a junta.

3.2 Melhoria Contínua em Produção Aeronáutica

Todo o processo de furação e inserção de prendedores demanda o monitoramento do processo a fim de se garantir a qualidade dos produtos manufaturados, ou seja, sua aderência aos requisitos. Todavia, deve-se atingir tal objetivo de forma que o ciclo de produção seja minimamente afetado. Neste momento, um paralelo com os conceitos do *Lean Manufacturing*, inspirado no sistema de Toyota de produção, e o advento da *Indústria 4.0*, também conhecida como a quarta revolução industrial (AZEVEDO, 2017), pode ser estabelecido.

- *Lean Manufacturing*: Filosofia de gestão da produção desenvolvida pelo executivo da Toyota, Taiichi Ohno, durante o período de reconstrução do Japão, após a Segunda Guerra Mundial, que tem como principal objetivo de se aumentar a Qualidade e minimizar o Tempo de Custo da produção, através da eliminação de desperdícios. Voltando para o contexto deste trabalho podemos citar como desperdícios que devem ser eliminados:
 - Defeitos: Ir em busca do "zero defeito", e detecção e solução dos problemas em sua origem;

- Excesso de Processamento: Eliminar todas as etapas do processo que consomem Tempo de produção, porém, sem agregar valor ao produto final. Cliente não quer pagar por medição manual de comprimento de juntas para a procura de prendedores específicos;
- Tempo de Espera: Eliminar paradas desnecessárias da produção.
- *Industria 4.0*: Termo que se refere a utilização de algumas tecnologias como *Sistemas Cyber-Físicos, Internet das Coisas e Computação em Nuvem* para se criar "*Fabricas Inteligentes*" onde a partir de um sensoramento adequado dos processos físicos, os sistemas de informação possam tomar decisões e gerar informações que interferem na cadeia de produção como gerar, em tempo real, uma lista de pedidos de Prendedores com comprimento adequado para uma determina junta furada por um sistema automatizado, ou mesmo parar automaticamente um sistema automatizado, caso uma mudança em seu padrão de funcionamento, o qual possa ser indício de geração de não qualidades, seja detectado.

No problema aqui abordado, a espessura da junta a ser cravada deve ser determinada de forma rápida e eficaz, por meio de algoritmos desenvolvidos pelo estudo e observação do comportamento de dados relacionados ao sistema de controle automatizado de furação. Além disso, os mesmos dados devem ser utilizados para avaliar a qualidade da furação realizada pela máquina. Deste modo, a garantia da qualidade e a determinação do comprimento correto do prendedor a ser instalado em um determinado furo seriam realizadas de forma simultânea à operação das máquinas de furação. Essa solução para o problema permitiria selecionar e instalar em cada furo realizado o prendedor adequado de forma precisa e segura, sem que o ciclo padrão da atividade seja afetado.

Logo, a solução a ser proposta para o problema estudado neste trabalho deve exemplificar uma integração entre a filosofia do *Lean Manufacturing* e da *Industria 4.0* (AZEVEDO, 2017) ao buscar pela eficiência na eliminação de desperdícios e paradas no processo produtivos, por meio da análise de dados gerados pelos sistema automatizados de furação.

3.3 Requisitos Estruturais Aeronáuticos

De um modo geral, tomando-se como referência, aeronaves comerciais com capacidade maior que 19 passageiros, pode-se afirmar que, de acordo com (ANAC, 2014), estruturas aeronáuticas devem ser projetadas, dimensionadas, fabricadas e inspecionadas para suportar de forma estática os máximos esforços previstos em operação, multiplicados por um fator multiplicativo 1,5 (carga *ultimate*), e de forma dinâmica, ou seja à fadiga, um espectro de carregamento em função do tempo, que consiste nos esforços operacionais padrão de voo, limitados aos máximos previstos, por uma quantidade pré-definida de voos. Também deve ser

tolerante ao dano, ou seja, caso algum dano apareça ou já exista na estrutura, esta deve manter sua integridade de forma segura por um período equivalente a um intervalo entre inspeções.

Com isso, tais requisitos se desdobram por todos os níveis estruturais da aeronave até chegarmos aos furos e à instalação dos prendedores nas juntas da aeronave. Neste trabalho, o foco são as juntas com alta transferência de carga em cisalhamento, cujos furos e prendedores possuem os requisitos específicos que serão tratados neste capítulo. Assim, para este tipo de junta e para este nível de detalhamento (*furos e prendedores*) tem-se os seguintes requisitos como resultado do desdobramento:

- *O corpo roscado dos prendedores não deve apresentar contato com o corpo cilíndrico do furo (parede do furo).* Majoritariamente determinado pelo critério de fadiga, este requisito visa evitar que os "fios de rosca" ajam como um ponto de concentração de carga sobre a junta e possam assim gerar uma falha localizada que venha a se tornar uma trinca. Pode-se citar também como objetivo deste requisito manter o corpo liso do prendedor em contato com o corpo cilíndrico do furo, garantindo assim uma área de transferência de carga conhecida, o que facilita a execução das análises.
- *Limites de variação para o diâmetro da furação.* Geralmente o valor do diâmetro de um furo é definido pelo caso estático, porém a sua tolerância, ou seja, os limites de sua variação são definidos pela análise de fadiga com o intuito de se garantir a interferência controlada entre o prendedor e o furo. Isso proporciona uma melhor resposta em fadiga e assegura a distribuição de carga de acordo com o projetado. A necessidade de se garantir interferência entre o prendedor e seu respectivo furo corrobora com o requisito anterior;
- *O Acabamento superficial do corpo cilíndrico (Parede do furo) do furo precisa ser garantido a fim de se evitar que descontinuidades (trincas) sejam geradas durante o processo de furação;*

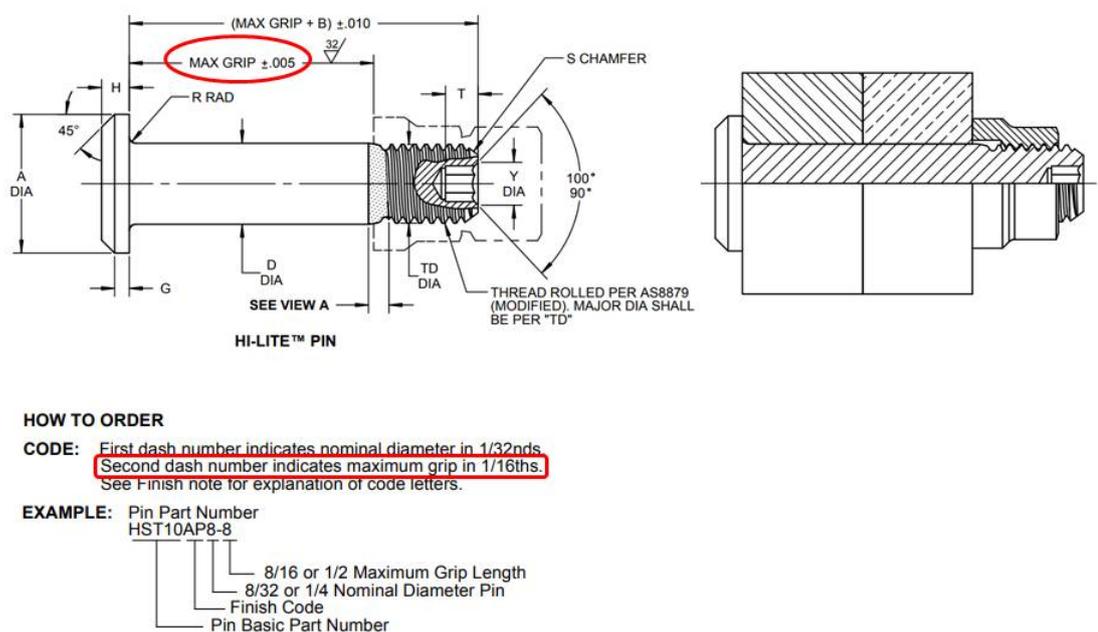
Desta forma, a partir dos requisitos indicados anteriormente, pode-se detalhar melhor as ações e procedimentos necessários para se garantir a atendimento dos mesmos. As próximas subseções detalham tais ações e procedimentos, evidenciando sua relação com os requisitos e as consequências para a eficiência produtiva, principalmente, em termos de tempo.

3.3.1 Procedimento para a Escolha do Comprimento do Prendedor

Como foi visto anteriormente, o corpo roscado dos prendedores não pode estar em contato com o corpo cilíndrico do furo (*Parede do furo*), principalmente para se evitar problemas na junta relacionados à fadiga e se garantir o correto caminho de carga do esforço no qual o avião foi solicitado. Para se cumprir este requisito, o comprimento do prendedor deve ser determinado de acordo com a espessura da junta onde será instalado. A figura 6, que foi obtida de uma especificação técnica pública, mostra o exemplo de um tipo de Pino denominado *HST10*

com sua porca padrão em corte e cotas que mostram o comprimento máximo de uma junta (*Max Grip*). A junta pode ser fixada por um prendedor desse tipo, sem que a mesma seja afetada por seu corpo roscado. A mesma figura também traz informações de como se deve escolher o comprimento do prendedor a ser instalado, pois como padrão, tem-se opções a cada 1/16" (um dezesseis avos de polegada) de comprimento útil, o que representa aproximadamente a cada 1,6mm.

Figura 6 – Comprimento do Prendedor - Requisitos de Fabricação

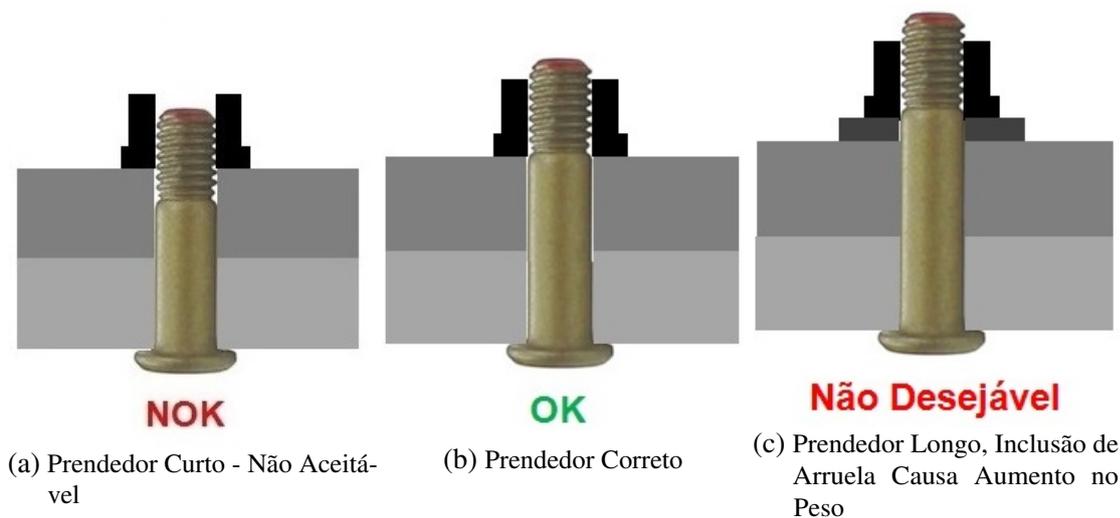


Fonte: Elaborada pelo autor.

A partir desta informação, o requisito estrutural realmente se traduziu em uma prática industrial, criando-se um processo de fabricação e classificação de prendedores de mesmo material e diâmetro, porém, com diversos comprimentos. Contudo, é importante destacar que o requisito se mostra presente na especificação, como a indicação do comprimento do corpo cilíndrico do prendedor, que se relaciona com a espessura máxima permitida para a junta a ser fixada pelo mesmo. Já a espessura mínima não se trata de um requisito fortemente estrutural e sim de cunho econômico e de peso, visto que a utilização de um prendedor maior que o necessário se caracteriza como um desperdício de material e acúmulo de peso na aeronave. Nesse caso, o problema é potencializado com a necessidade de inclusão de uma arruela à instalação do prendedor para se garantir que o torque aplicado sobre a porca esteja realmente surtindo efeito sobre a junta e não sobre o fim do corpo roscado do prendedor. A Figura 7 ilustra de forma

esquemática os três possíveis cenários relacionados ao comprimento de prendedores instalados, visando esclarecer os tipos de problemas que podem ser envolvidos ou não em cada um deles.

Figura 7 – Importância da escolha do comprimento do Prendedor

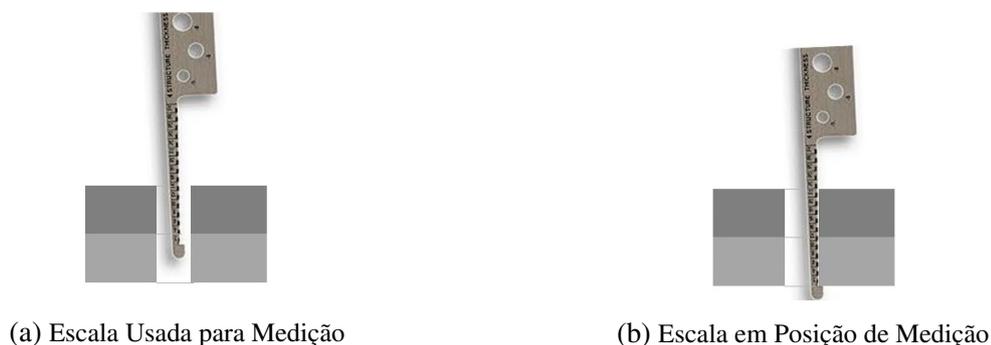


Fonte: Elaborada pelo autor.

Logo, há uma necessidade de se planejar a utilização, para um mesmo diâmetro, de uma grande quantidade de prendedores com diferentes comprimentos de seu corpo liso, ou corpo cilíndrico, para se adequar às diferentes espessuras das juntas a serem cravadas. Devido a condições de tolerância das peças e da montagem, observa-se que a espessura da junta nem sempre é a prevista em projeto em diversas montagem relevantes, podendo inclusive apresentar calços em sua composição. Tal situação implica na necessidade de se certificar fisicamente, furo a furo, qual o comprimento correto do prendedor a ser instalado com muito critério, visto que a troca de um prendedor instalado com comprimento incorreto não é trivial dada a interferência na instalação. A figura 8 mostra a escala utilizado para se medir a espessura da junta furada na determinação do comprimento correto do prendedor a ser instalado.

Essa atividade, quando feita manualmente, é representativa para o ciclo produtivo de montagem de segmentos estruturais aeronáuticos. Assim, a verificação do comprimento ideal do prendedor, a ser realizada em cada furo, pode tomar um tempo de 8 segundos em média, o que representa por exemplo, em uma junta com 4.000 furos, 8,9 horas de trabalho. Deste modo, assumindo-se uma dupla de operadores trabalhando nesta atividade de exemplo, tem-se 4,44 horas de ciclo de produção da aeronave.

Figura 8 – Medição Manual da Espessura da Junta Furada



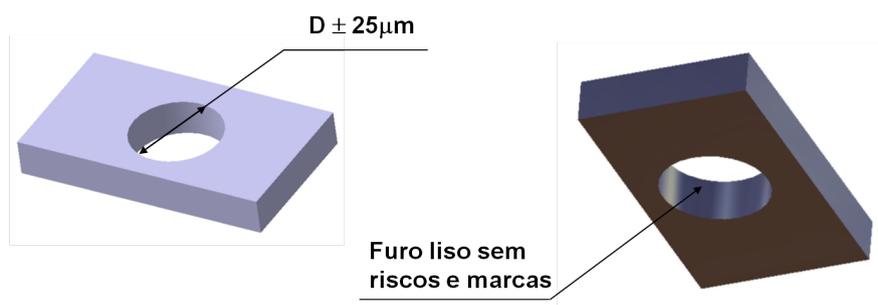
Fonte: Elaborada pelo autor.

3.3.2 Requisitos Relacionados ao Diâmetro da Furação

Como visto anteriormente, os requisitos relacionados ao controle da vida em fadiga limitam a tolerância do diâmetro dos furos, onde os prendedores serão instalados nas juntas estruturais com o intuito de assegurar uma interferência controlada entre junta e prendedor. Para as juntas estruturais estudadas neste trabalho, esta tolerância estava definida em torno de $60 \mu\text{m}$, a qual não pode ser garantida por instrumentos de medição convencionais como paquímetros, tão pouco por inspeção visual. A figura 9 mostra um esboço deste requisito estrutural desdobrado para tolerância de um furo executado em uma junta. Assim sendo, uma vez definida a necessidade de inspeção destes furos, esta deve ser realizada por meio de instrumentos específicos que proporcionam repetibilidade e acurácia em escala micrométrica, como o mostrado na figura 10.

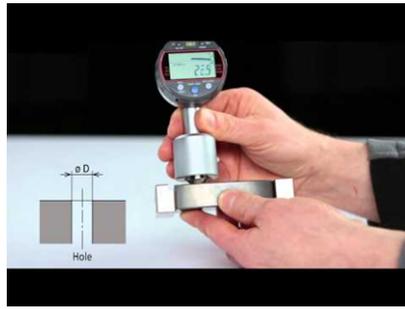
Com relação à inspeção destes furos em precisão, pode-se afirmar a necessidade de uma precisão de aproximadamente $50 \mu\text{m}$ exigida por este tipo de estrutura. Assumindo esta tolerância apertada, muitos processos de furação, ainda que automatizados, quando analisados estatisticamente, não apresentam um índice que exclui a necessidade de inspeção dos furos executados por amostragem. Inspeção a qual por ser realizada manualmente ou, quando disponível, por soluções automatizadas.

Figura 9 – Requisitos dos Furos



Fonte: Elaborada pelo autor.

Figura 10 – Medição Física de Furos



Fonte: Elaborada pelo autor.

3.4 Comportamento da Corrente Elétrica Durante o Processo Automatizado de Furação

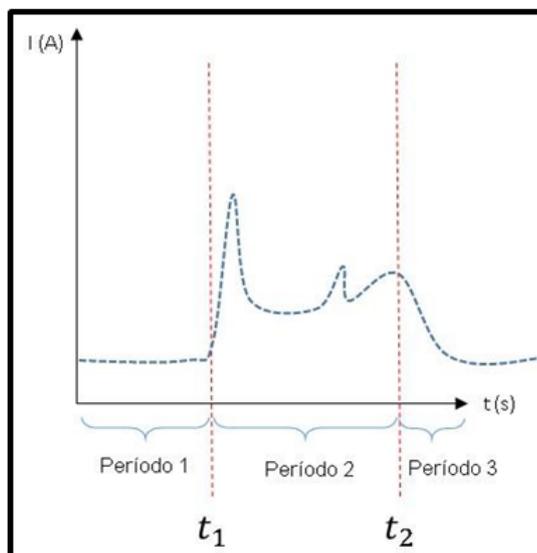
Um aspecto relevante no problema aqui tratado é o comportamento da corrente elétrica durante o processo de furação. A leitura e interpretação da corrente elétrica consumida pelos motores, que atuam na execução da furação, devem ser realizadas para determinar de forma indireta o comprimento do pacote furado, assim como a qualidade do furo executado. Assim, nesta seção, pretende-se detalhar como é o comportamento da corrente elétrica durante a execução de um furo automatizado.

Para se programar e controlar as velocidades de movimentação do cabeçote de furação e ferramenta de corte nos sentidos de avanço de furação e rotação de corte, respectivamente, o controlador na máquina ou robô determina a corrente a ser consumida pelos motores elétricos que os acionam. Observando a movimentação da ferramenta de corte, percebe-se que este se inicia antes do furo no produto e, também, se finaliza após o vencimento do pacote furado. Este fato nos dá uma ideia de como a corrente elétrica consumida pelos motores varia em função do tempo, ou melhor, em função da posição da ferramenta de corte em relação ao pacote a ser furado, cuja representação simplificada está na Figura 11.

De acordo com a figura 11, há três períodos distintos em relação ao comportamento da corrente elétrica. Os três períodos podem ser descritos como:

- "*Período 1*": Um período inicial, quando temos o início da movimentação, nos eixos "x" e "z", da ferramenta de corte, ainda sem tocar o produto. Neste momento, a corrente consumida é apenas para se estabilizar e manter os parâmetros de cortes com a ferramenta se movimentando "em vazio". Este período está representado na figura 11 com $t < t_1$;
- "*Período 2*": É o período de corte propriamente dito. Neste período, observamos o início do esforço de corte sobre a ferramenta, o qual imprime ao sistema uma tendência de se desacelerar o avanço e rotação. Para se evitar esta desaceleração, o controlador na máqui-

Figura 11 – Gráfico Esquemático da variação da Corrente Elétrica em Função do Tempo



Fonte: Elaborada pelo autor.

na/robô irá consumir mais corrente para que se possa manter constantes os parâmetros. Este período está representado na figura 11 com $t_1 < t < t_2$;

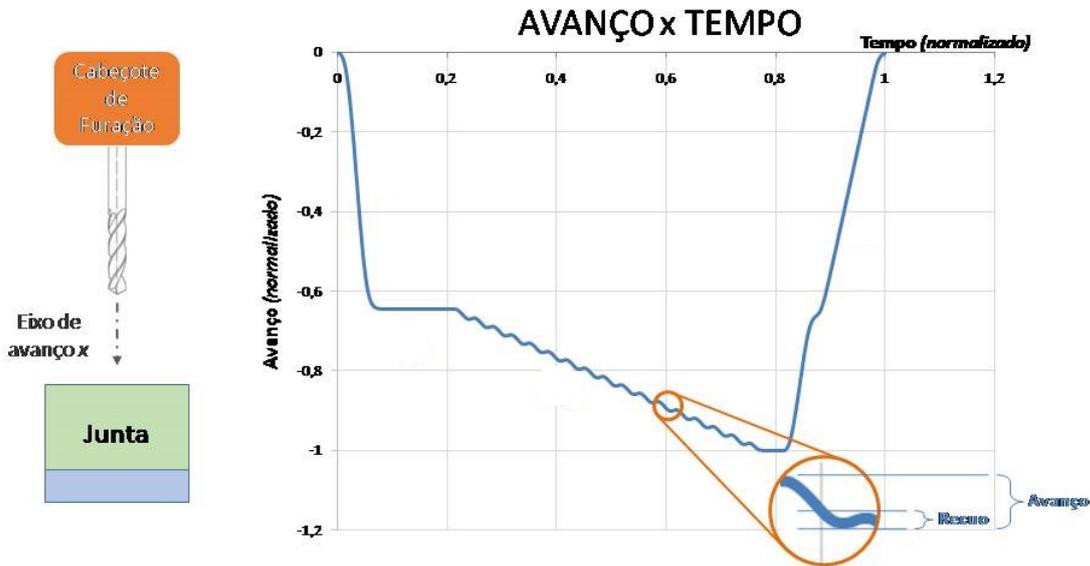
- "Período 3": Tendo-se vencido o pacote da junta furada pela ferramenta de corte, observa-se o fim da força de corte, implicando na necessidade do controlador diminuir a corrente elétrica. Este período está representado na figura 11 com $t_2 < t$.

Assim sendo, concluí-se que o "Período 2" corresponde ao corte propriamente dito, ou seja, quando a ferramenta está em contato com o produto, e consiste, para cada furo, na gama de dados importantes para o estudo proposto nesta dissertação.

O conceito apresentado na figura 11 se aplica ao sinal real da máquina estudada neste trabalho. Para isso, o primeiro passo consiste em se compreender o funcionamento da máquina quando esta realiza um determinado furo. A máquina, com o intuito de se preservar a rugosidade e acabamento superficial do corpo cilíndrico do furo, realiza um movimento chamado de "pica-pau" ou em inglês *peck drill*. Este movimento, se caracteriza por um avanço controlado, porém, não contínuo da ferramenta de corte na junta de modo que cada movimento de avanço é sucedido por um movimento de recuo da ferramenta, que por sua vez, tem menor amplitude que o primeiramente citado.

O recuo tem por objetivo garantir que os cavacos e limalhas, ou seja, os resíduos metálicos do processo de furação, sejam gerados com dimensões reduzidas o suficiente para não representar risco ao acabamento superficial da parede do furo, evitando gerar marcas e riscos durante a continuidade do processo de furação. A figura 12 contém um gráfico gerado a partir de dados reais da máquina de furação, onde temos a posição do eixo de avanço da ferramenta de corte em função do tempo, ilustrando como o *peck drill* ocorre na prática.

Figura 12 – Gráfico Avanço do Cabeçote de Furação em Função do Tempo

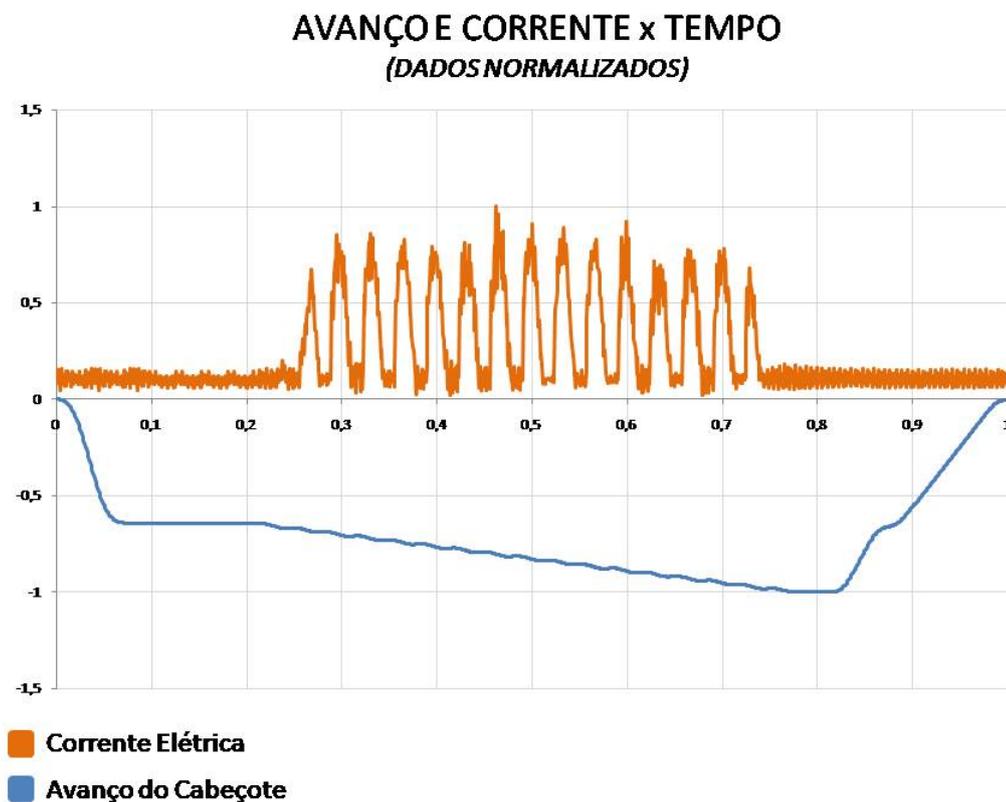


Fonte: Elaborada pelo autor.

Uma vez mostrado como o sistema de *peck drill* funciona, o próximo passo agora é apresentar o comportamento da corrente elétrica frente ao movimento realizado pelo cabeçote e consequentemente pela ferramenta de corte. Como o discutido na introdução deste trabalho, os sistemas automatizados de furação têm a capacidade de manter os parâmetros de corte, como a rotação e avanço da ferramenta de corte, constantes. Para que isto aconteça, estes sistemas usam a capacidade de variar a corrente elétrica, adaptando assim a potência dos atuadores dos movimentos de corte aos esforços provenientes das características e condições da junta, assim como do próprio movimento de *peck drill* do cabeçote. A figura 13 mostra um exemplo com dados normalizados. Esses dados se referem ao avanço do cabeçote de furação e ao valor da intensidade da corrente elétrica na alimentação no motor de rotação da ferramenta em função do tempo para um furo real.

No movimento do *peck drill*, a ferramenta de corte toca a peça e o esforço de corte passa a existir, criando uma resistência à rotação da ferramenta. Essa resistência tende a desacelerar a ferramenta, logo, a corrente elétrica aumenta a fim de gerar uma potência que entre em equilíbrio com este esforço, mantendo-se a rotação constante. A corrente tende a se manter constante, por um breve patamar, até que a velocidade de avanço começa a diminuir, reduzindo o esforço de corte e consequentemente a corrente necessária para manter a rotação constante. Este decaimento da corrente continua até que o avanço do cabeçote se transforme em recuo para se completar um ciclo do *peck drill*, momento no qual se cessa o esforço de corte e a corrente passa ao regime de rotação "em vazio". Por esta razão, é possível observar na figura 13, que o gráfico da corrente se apresenta em forma de ondas, cujos ciclos acompanham os referentes ao movimento de *peck drill*.

Figura 13 – Gráfico Avanço do Cabeçote de Furação em Função do Tempo



Fonte: Elaborada pelo autor.

Desta forma, nesta seção foram estabelecidos os conceitos teóricos que embasam a necessidade dos requisitos a serem atendidos durante o processo de automatização. Também foram apresentados os conceitos de produção industrial que motivam o ganho previsto ao se automatizar o processo. Por último, o comportamento da corrente elétrica foi detalhado já que se trata da base de informação para a aplicação de todos os métodos propostos nos próximos capítulos.

METODOLOGIA PARA MEDIÇÃO DO COMPRIMENTO DA JUNTA

O presente capítulo introduz o primeiro método proposto que está focado na medição da corrente elétrica consumida pelos motores. Conforme mencionado anteriormente, a medição da corrente elétrica que atua na execução da furação permite determinar de forma indireta o comprimento do pacote furado. Assim, serão descritos algoritmos que fazem uma interpretação dos dados observados com o intuito de identificar as fases da furação explicadas na seção 3.4.

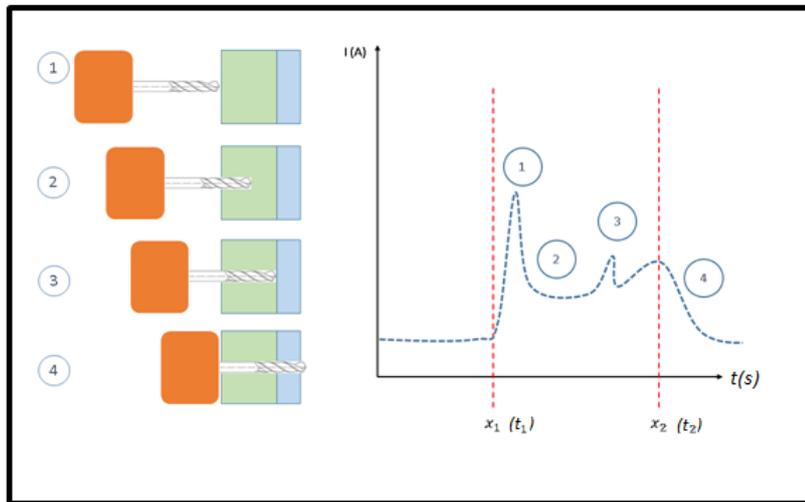
4.1 Conceito da Medição do Comprimento da Junta Furada

O monitoramento da corrente elétrica pode ser usado para se determinar a espessura de um pacote furado. Como descrito no capítulo 3, para se controlar e manter constantes as velocidades de movimentação nos dois eixos citados, o controlador na máquina e/ou robô varia a corrente a ser consumida pelos motores elétricos que os acionam. Isso ocorre de acordo com as variações dos esforços de corte que agem sobre a ferramenta de corte durante as diferentes etapas de furação. Assim sendo, concluí-se, observando-se a figura 14, que o período compreendido entre t_1 e t_2 corresponde ao corte propriamente dito, ou seja, quando a ferramenta está em contato com o produto. Além disso, a figura 14 mostra a interpretação deste mesmo período, porém, indicando que para cada instante t_1 e t_2 há, respectivamente, uma posição cabeçote x_1 e x_2 correspondente. Pode-se concluir que a espessura da junta furada é dada pela Equação 4.1:

$$espessura = x_2 - x_1 \quad (4.1)$$

A partir do valor da espessura, encontrado através da Equação 4.1, torna-se possível determinar o prendedor a ser instalado no furo executado pelo robô. Métodos de comparação e

Figura 14 – Gráfico Esquemático da Variação da Corrente Elétrica em Função do Tempo e Eixo "x"



Fonte: Elaborada pelo autor.

análise de sinais elétricos, como o citado no Capítulo 3 deste trabalho, deverão ser testados para se determinar com segurança e precisão os picos de corrente representados esquematicamente da Figura 14.

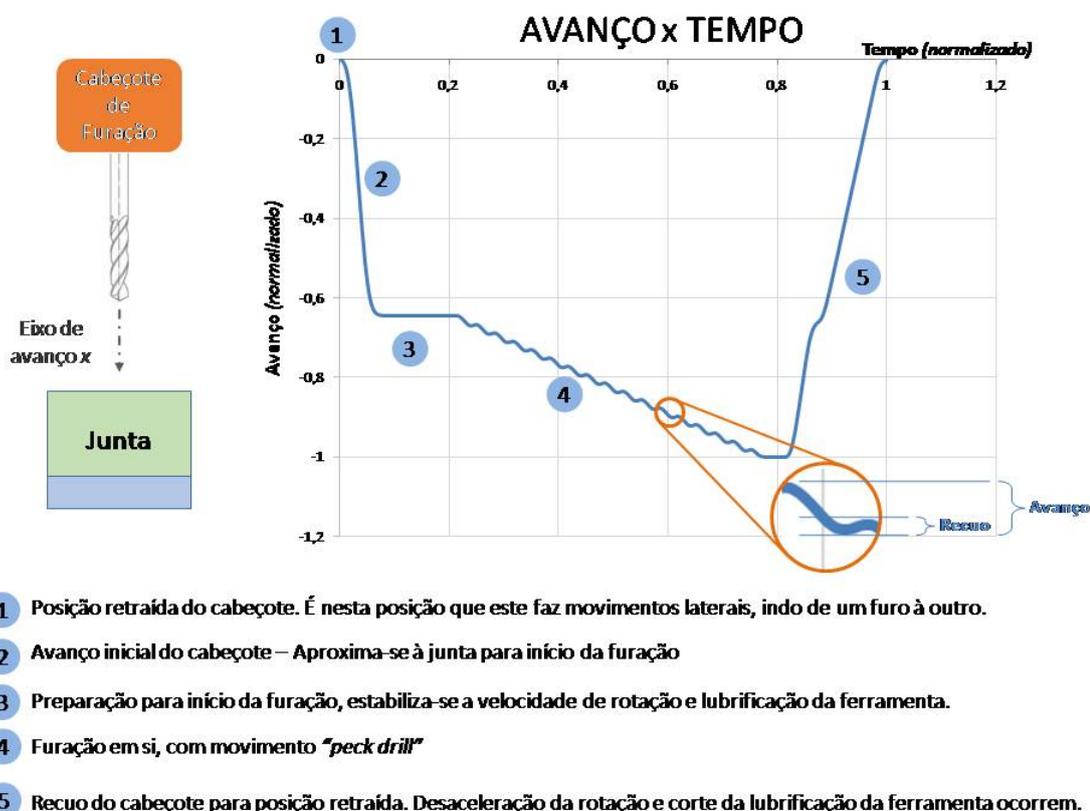
Vamos dividir o ciclo de furação com movimentação tipo *peck drill* em fases, para melhor explicar os blocos do algoritmo elaborado para se determinar o comprimento do furo executado. Também serão determinadas outras informações relacionadas ao correto cumprimento de todo o ciclo de furação pela máquina de furação automatizada. Como já descrito na seção 3.4, a máquina, com o intuito de se preservar a rugosidade e acabamento superficial do corpo cilíndrico do furo, realiza um movimento chamado de "pica-pau" ou em inglês *peck drill*. A figura 15 a seguir, contém um gráfico gerado, a partir de dados reais da máquina de furação, mostrando a posição do eixo de avanço da ferramenta de corte em função do tempo, durante um ciclo de furação (execução de um furo), contendo também uma legenda, mostrando as cinco fases que este ciclo foi dividido, as quais serão exploradas em detalhes na seção 4.3.

Uma vez organizado como o sistema de *peck drill* atua em fases, durante um ciclo de furação, o próximo passo é apresentar os algoritmos propostos para se calcular o comprimento da junta furada pelo sistema automatizado de furação.

4.2 Algoritmos Baseados no Comportamento da Corrente Elétrica

Um algoritmo é uma sequência finita de procedimentos precisos, não ambíguos, mecânicos, eficientes e corretos, que visam obter uma resposta para uma determinada pergunta. O conceito de um algoritmo foi formalizado em 1936 pela Máquina de Turing de Alan Turing. Os

Figura 15 – Gráfico Avanço do Cabeçote de Furação em Função do Tempo



Fonte: Elaborada pelo autor.

algoritmos podem ser classificados de acordo com sua forma de implementação:

- *Recursivo ou iterativo* - um algoritmo recursivo possui a característica de invocar a si mesmo repetidamente até que certa condição seja satisfeita e ele seja terminado, que é um método comum em programação funcional. Algoritmos iterativos usam estruturas de repetição tais como laços, ou ainda estruturas de dados adicionais tais como pilhas, para resolver problemas. Cada algoritmo recursivo possui um algoritmo iterativo equivalente e vice-versa, podendo apresentar maior ou menor complexidade em sua construção;
- *Lógico* - um algoritmo pode ser visto como uma dedução lógica controlada. O componente lógico expressa os axiomas usados na computação e o componente de controle determina a maneira como a dedução é aplicada aos axiomas. Tal conceito é base para a programação lógica;
- *Serial ou Paralelo* - algoritmos são geralmente assumidos por serem executados instrução a instrução individualmente, como uma lista de execução, o que constitui um algoritmo serial. Tal conceito é base para a programação imperativa. Por outro lado, existem algoritmos executados paralelamente que levam em conta as arquiteturas de computadores com mais

de um processador para executar mais de uma instrução ao mesmo tempo. Tais algoritmos dividem os problemas em subproblemas e o delegam a quantos processadores estiverem disponíveis, agrupando no final o resultado dos subproblemas em um resultado final ao algoritmo. Tal conceito é base para a programação paralela. De forma geral, algoritmos iterativos são paralelizáveis. Por outro lado, existem algoritmos que não são paralelizáveis, chamados então problemas inerentemente seriais.

- *Determinístico ou Não-Determinístico* - algoritmos determinísticos resolvem o problema com uma decisão exata a cada passo enquanto algoritmos não-determinísticos resolvem o problema ao deduzir os melhores passos através de estimativas sob forma de heurísticas;
- *Exato ou Aproximado* - enquanto alguns algoritmos encontram uma resposta exata, algoritmos de aproximação procuram uma resposta próxima a verdadeira solução, seja através de estratégia determinística ou aleatória. Possuem aplicações práticas sobretudo para problemas muito complexos, do qual uma resposta correta é inviável devido à sua complexidade computacional.

No caso deste trabalho, o algoritmo proposto para a determinação da espessura da junta furada pelo sistema automatizado de furação toma como base o comportamento da corrente elétrica do cabeçote da máquina. Assim, busca localizar padrões específicos que permitam:

- Identificar o início de cada onda;
- Identificar o patamar superior da crista de cada onda;
- Identificar o fim do patamar da crista de cada onda;
- Calcular o valor médio do patamar de corrente considerando-se as ondas já identificadas;
- Identificar o início do movimento de aproximação do cabeçote de furação da máquina;
- Identificar o fim do movimento de aproximação do cabeçote de furação da máquina;
- Identificar o início do movimento de *peck drill* do cabeçote de furação da máquina;
- Identificar o fim do movimento de *peck drill* do cabeçote de furação da máquina;
- Identificar o início do movimento de recuo do cabeçote de furação da máquina;
- Realizar operações matemáticas;
- Comparar os momentos identificados acima e através de lógicas pré-definidas avaliar possíveis problemas.

Com base nas funcionalidades do algoritmo descritas acima, o algoritmo proposto será *lógico, serial, exato e determinístico*. A seção 4.3, a seguir, contém toda a descrição do algoritmo desenvolvimento para o cumprimento das funcionalidades descritas acima.

4.3 Descrição do Algoritmo

Considerando-se então as informações já apresentadas, pode-se iniciar a explicação do algoritmo utilizado para o cálculo da espessura da junta furada. Este algoritmo tem as seguintes funções principais, considerando a forma com que a corrente elétrica se comporta devido ao *peck drill*:

- Identificar o início de cada onda;
- Registrar o início do furo como sendo o início da primeira onda identificada.
- Identificar o patamar superior da crista de cada onda e o seu valor médio.
- Identificar o fim do patamar da crista de cada onda.
- Registrar o fim do furo como sendo o fim do patamar da crista da última onda identificada.
- Calcular a espessura da junta furada através dados do início e fim do furo.

Com o início dos estudos, mais funcionalidades puderam ser observadas como oportunidades para o algoritmo, ou seja, há situações de erros que o algoritmo pode analisar através dos dados e comportamento da corrente e gerar um alerta. Estas são listadas a seguir:

- Certificar que a rotação da ferramenta está estabilizada no início do *peck drill*.
- Certificar que não há corrente excessiva em movimento de recuo do *peck drill*.
- Identificar possíveis vales de corrente em meio a regiões de crista.
- Certificar que o fim do furo não coincida com o fim de um avanço do *peck drill*.

A partir destas informações, a explicação do método proposto será apresentada para cada uma das 5 fases do ciclo de execução de um furo completo como ilustrado na figura 15.

4.3.1 Fase 1 - Pré-Processamento

A primeira fase do ciclo de furação, está descrita na figura 15 como sendo o período de tempo em que o cabeçote de furação fica estático em relação a movimentos no sentido do eixo de avanço na sua posição retraída. Nesta fase o braço/cabeçote da máquina se movimenta lateralmente para se posicionar entre a execução de um furo já realizado e o próximo. Esta posição retraída deve ser respeitada para se evitar colisões da ferramenta de corte com possíveis obstáculos que possam estar localizados sobre a junta, por exemplo, prendedores provisórios que mantêm a junta estável durante o próprio processo de furação a ser realizado pela máquina.

Até o momento dos estudos realizados neste trabalho, a máquina de furação automatizada, objeto principal do mesmo, não possuía um sistema dedicado de coleta de dados. Por isso, os dados são obtidos diretamente do controlador da máquina e, em sua forma bruta, não representam apenas o ciclo de furação padrão mostrado na figura 15. Eles podem conter dados de movimentação lateral do cabeçote e até tempo de latência e espera para alguma verificação na máquina ou no produto. Deste modo, como a fase 1 do ciclo de furação não contém dados relevantes para a espessura a ser calculada, nem para qualquer um dos itens a serem verificados, é importante entender o que ocorre com a máquina neste período. Assim, será possível identificar e remover dados não relevantes no tratamento da informação.

Um método de pré-processamento dos dados foi desenvolvido para se remover da base os dados gravados referentes a esta fase, limitando cada ciclo de furação ao período em que os eixos de movimentação lateral se mantêm estáticos e o eixo de avanço de corte inicia a movimentação da posição retraída.

4.3.2 Fase 2 - Aproximação da Ferramenta

O pré-processador gera o conjunto de dados do furo já no início da fase 2 do ciclo de furação de um determinado furo. Com isso, o algoritmo segue analisando os dados de avanço do cabeçote até encontrar o patamar que caracteriza a fase 3. Nesta fase, como na anterior, nenhum dado importante é gerado de forma que apenas a posição do eixo de avanço do cabeçote é analisada. Todavia, o algoritmo segue a sequencia cronológica dos dados para saber o momento de se aplicar análises mais importantes. Algoritmo 1 utilizado para esta função é descrito a seguir:

Algoritmo 1 – Algoritmo de Definição da Fase 2

- 1: $t_2 \leftarrow t_1 + t$ ▷ "t" é a taxa de aquisição da máquina entre um dado e o próximo
 - 2: **procedimento** FASE2($Avanco(t_1), Avanco(t_2)$) ▷ Posição do cabeçote em t_1 e t_2
 - 3: **enquanto** $Avanco(t_2) - Avanco(t_1) \geq 0,01$ **faça** ▷ Procura-se pelo tempo até se encontrar o patamar, onde o cabeçote cessa o avanço)
 - 4: $t_1 \leftarrow t_2$
 - 5: $t_2 \leftarrow t_2 + t$
 - 6: **fim enquanto**
 - 7: **retorna** t_2 ▷ t_2 é o momento em que o patamar (fase 3) se inicia
 - 8: **fim procedimento**
-

Outro importante ponto na fase 2 é a correlação com o ID do furo. Cada furo da junta tem um ID para que possa ser identificado durante a programação da máquina de furação, ou em uma discussão técnica, ou caso algum problema ocorra. Por isso, como a fase 2 se inicie com as coordenadas laterais, as quais podem localizar no espaço qual furo está sendo executado, estas são utilizadas nesse momento para se definir qual o ID do furo que será realizado. Essa definição é feita pela aquisição das coordenadas laterais a partir dos dados de furação e uma busca em um dados de dados que contenha todos os IDs com as respectivas coordenadas teóricas.

Há uma diferença entre as coordenadas teóricas, pré-definidas pela máquina e as encontradas nos dados reais de furação. Estas diferenças são decorrentes de todo o processo de acúmulo de tolerâncias que acontece desde a fabricação das peças individuais, passa pelas primeiras montagens até culminar na junta em questão. Por isso, a busca é feita em todo o conjunto de dados, considerando erros cujos valores são limitados ao histórico da junta em questão e de modo a se evitar erro na determinação do ID. Caso a diferença real seja maior que o erro pré-determinado, nenhuma correlação com o conjunto de dados será encontrada e uma mensagem é exibida.

4.3.3 Fase 3 - Patamar de Preparação

O algoritmo segue analisando os dados de avanço do cabeçote até encontrar o fim do patamar que caracteriza a fase 3, ou seja, o início do *peck drill*. Nesta fase, como na anterior, nenhum dado importante é gerado, de forma que apenas a posição do eixo de avanço do cabeçote é analisada. Todavia, o algoritmo segue a sequencia cronológica dos dados para saber o momento de se aplicar análises mais importantes. Algoritmo 2 descreve os passos para tal função:

Algoritmo 2 – Algoritmo de Definição da Fase 3

- 1: $t_2 \leftarrow t_1 + t$ ▷ " t " é a taxa de aquisição da máquina entre um dado e o próximo
 - 2: **procedimento** FASE2($Avanco(t_1), Avanco(t_2)$) ▷ Posição do cabeçote em t_1 e t_2
 - 3: **enquanto** $Avanco(t_2) - Avanco(t_1) \leq 0,06$ **faça** ▷ Procura-se pelo tempo até se encontrar o fim patamar, onde o cabeçote inicia novamente o avanço)
 - 4: $t_1 \leftarrow t_2$
 - 5: $t_2 \leftarrow t_2 + t$
 - 6: **fim enquanto**
 - 7: **retorna** t_2 ▷ t_2 é o momento em que o *peck drill* (fase 4) se inicia
 - 8: **fim procedimento**
-

4.3.4 Fase 4 - Peck Drill

Esta é a fase mais complexa, pois tudo a ser calculado e verificado por este método acontece nesta fase. As subseções a seguir irão descrever os pontos chaves a serem analisados:

4.3.4.1 Certificar que a rotação da ferramenta está estabilizada quando o *peck drill* se inicia

Uma vez iniciado o *peck drill*, a primeira ação é verificar se a rotação da ferramenta já se encontra estabilizada. Este fato se caracteriza por uma corrente elétrica com pouca variação e baixo valor absoluto, ambos menores que 1. Caso valores maiores que 1 sejam encontrados, um aviso é inserido no relatório do furo junto com uma sugestão de inspeção do mesmo.

4.3.4.2 Definição do início da Onda

Uma vez iniciado o *peck drill* e checado o regime de rotação da ferramenta, a próxima ação é seguir a linha do tempo procurando pelo início da primeira onda de corrente. O método utilizado para se identificar este início é encontrar três leituras de corrente elétrica maiores que 1, 1,2 e 1,3 respectivamente. Estes valores foram determinados analisando-se as ondas de furos realizados em dados armazenados de furações de produtos anteriores, e evitam a falsa indicação de início de onda e do furo em si e picos isolado em meio ao ruído do sinal com a ferramenta de corte rotacionando "em vazio". Conforme esta descrição o desenvolvimento da função segue o Algoritmo 3:

Algoritmo 3 – Algoritmo de Definição da Fase 3

```

1:  $t_2 \leftarrow t_1 + t$            ▷ " $t$ " é a taxa de aquisição da máquina entre um dado e o próximo
2:  $t_3 \leftarrow t_2 + t$ 
3: procedimento FASE2( $Corrente(t_1), Corrente(t_2), Corrente(t_3), Avanco(t_1), Avanco(t_2), Avanco(t_3)$ )
   ▷ Posição do cabeçote e corrente elétrica em  $t_1, t_2$  e  $t_3$ 
4:   enquanto  $Corrente(t_1) \geq 1$  e  $Corrente(t_2) \geq 1,2$  e  $Corrente(t_3) \geq 1,3$  faça   ▷
   Procura-se por valores consecutivos de corrente maiores que um "threshold"
5:      $t_1 \leftarrow t_2$ 
6:      $t_2 \leftarrow t_3$ 
7:      $t_3 \leftarrow t_3 + t$ 
8:   fim enquanto
9:   retorna  $t_2$            ▷  $t_2$  é o momento em que a onda se inicia
10: fim procedimento

```

É importante pontuar que o início da primeira onda também caracteriza o início do furo, assim, este valor deve ser armazenado pelo algoritmo em uma variável global, para o cálculo final da espessura da junta.

4.3.4.3 Definição do Final da Crista da Onda

O próximo ponto define o fim da Crista da Onda. O principal conceito a ser empregado nesta etapa consiste na definição do *Patamar da Crista*, que pode ser definido como um nível de tensão médio, que represente a fase de regime da corrente enquanto o avanço da ferramenta de corte ocorre de forma constante em contato com o produto sendo furado. O valor numérico do *Patamar da Crista* é uma referência de limite (*threshold*), que servirá de auxílio na identificação do final da crista, como será visto a seguir. Seu cálculo está baseado no momento de início da onda, definido através do método mostrado na seção 4.3.4.2. Usa-se o valor da corrente elétrica no instante imediatamente posterior ao de início da onda, como o valor de referência t_3 para o cálculo do patamar e também os valores referentes aos três instantes que o antecedem e o sucedem, totalizando sete instantes a serem observados, ou seja, $t_0, t_1, t_2, t_3, t_4, t_5, t_6$. O Procedimento consiste em se observar o valor da corrente elétrica média nos sete instantes citados e agrupa-las em 7 grupos, formados pelas combinações possíveis de 3 corrente em instantes

consecutivos que contenham o instante de referência t_3 e as combinações possíveis de 4 corrente em instantes consecutivos que contenham o mesmo instante de referência. Estas combinações, para melhor entendimento são:

Combinação₁ : ($Corrente_1, Corrente_2, Corrente_3$)

Combinação₂ : ($Corrente_2, Corrente_3, Corrente_4$)

Combinação₃ : ($Corrente_3, Corrente_4, Corrente_5$)

Combinação₄ : ($Corrente_0, Corrente_1, Corrente_2, Corrente_3$)

Combinação₅ : ($Corrente_1, Corrente_2, Corrente_3, Corrente_4$)

Combinação₆ : ($Corrente_2, Corrente_3, Corrente_4, Corrente_5$)

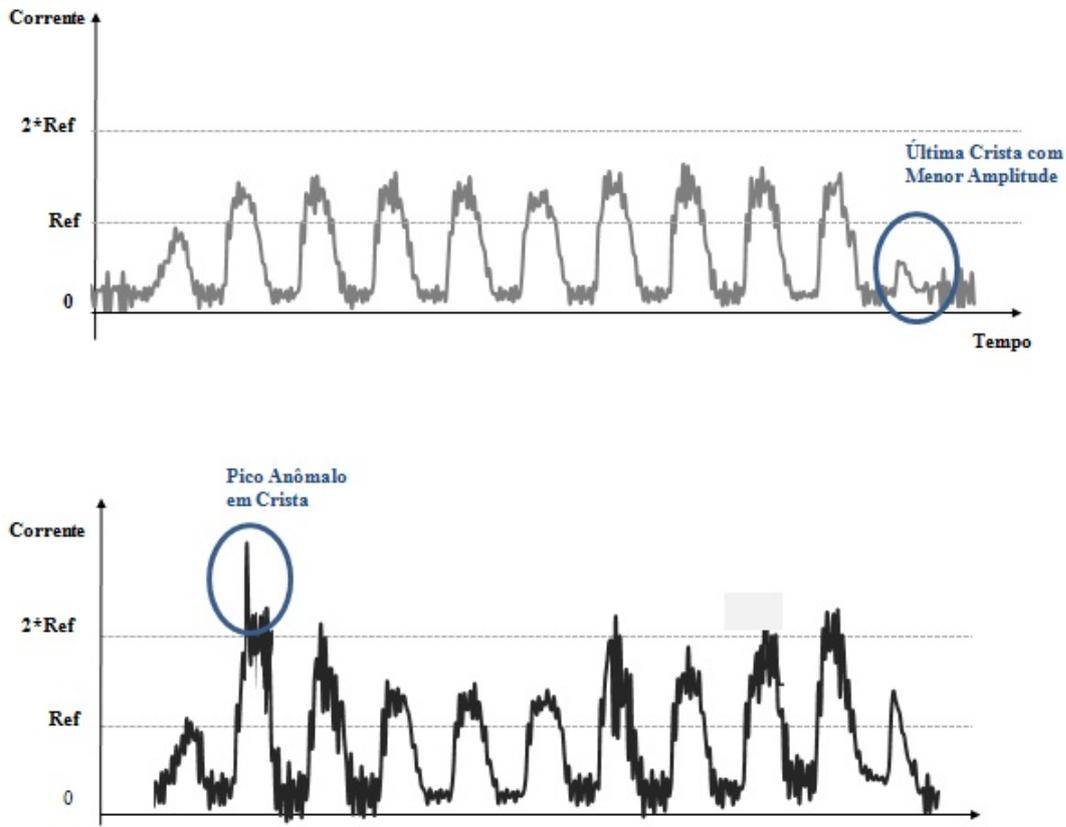
Combinação₇ : ($Corrente_3, Corrente_4, Corrente_5, Corrente_6$)

Como o mencionado na seção 4.3.4.2, este método foi igualmente desenvolvido analisando-se as ondas de furos realizados em dados armazenados de furações de produtos anteriores. O conceito do mesmo se baseia no fato dos ruídos não permitirem uma análise contínua, impossibilitando a determinação do início do patamar com precisão com apenas três pontos ou derivadas discretas. Assim, definiu-se um padrão de quatro pontos consecutivos escolhidos "ao redor" do ponto de referência. O fato de picos de corrente serem observados nestas regiões de patamar (ver figura 16), levaram à utilização de da média dos pontos relacionadas e não o valor máximo dos mesmos. Há casos também, de ondas muito pequenas, como o observado em últimas cristas de diversos furos (ver figura 16), onde a definição do fim da crista é crucial para a precisão do cálculo da espessura do pacote furado. Nestes casos, a utilização de quatro pontos pode trazer como consequências médias muito pequenas, por isso propõe-se considerar também três pontos consecutivos escolhidos "ou redor" do ponto de referência. Deste modo, definidos os conjuntos de valores de corrente, calcula-se então a média em cada um deles e definiu-se como o *Patamar da Crista* o maior valor encontrado.

Após a determinação deste valor, o algoritmo segue analisando a onda até que encontre o próximo vale, pela detecção de 3 valores consecutivos de corrente elétrica menores que 1, 1,5 e 1,5 consecutivamente, ou seja, a primeira região onde tem-se certeza de que o esforço de corte se cessou. Deste modo, assim que encontrado instante em que a onda esta no vale (t_{vale} ou t_1 no algoritmo 4), o seu fim de crista, ou seja, o momento em que a corrente começa a cair, o qual deve coincidir com a redução do esforço de corte, é encontrado, voltando-se na linha cronológica a partir de t_{vale} (t_1 no algoritmo 4) até se encontrar um valor maior que o *Patamar da Crista*. Algoritmo 4 mostra o conceito aplicado para se determinar o fim da crista:

O final da crista da última onda também caracteriza o final do furo e este valor deve ser armazenado pelo algoritmo, em uma variável global se for o caso, para o cálculo da espessura junta. A figura 17 ilustra a definição do *Patamar da Crista*:

Figura 16 – Importantes fatores a serem considerados no calculo do Patamar Crista



Fonte: Elaborada pelo autor.

4.3.4.4 Verificação de Folgas Entre as Peças da Junta

Um problema que deve ser verificado durante a leitura do sinal pelo algoritmo é a existência de folgas entre as peças da junta. Este fenômeno se caracterizará em uma queda no valor da corrente elétrica em pleno patamar da crista, ocasionado pela existência da folga descrita neste tópico. Isso resultará em um alívio no esforço de corte e conseqüentemente em uma necessidade de redução da corrente em pleno movimento de avanço do *peck drill*. A função para se detectar este fenômeno consiste em se verificar a existência de três pontos consecutivos abaixo do *Patamar da Crista*, não coincidentes com o final da crista. Caso um caso destes pontos seja encontrado, um aviso deve ser inserido no relatório de furação vinculado aos furos realizados por ID.

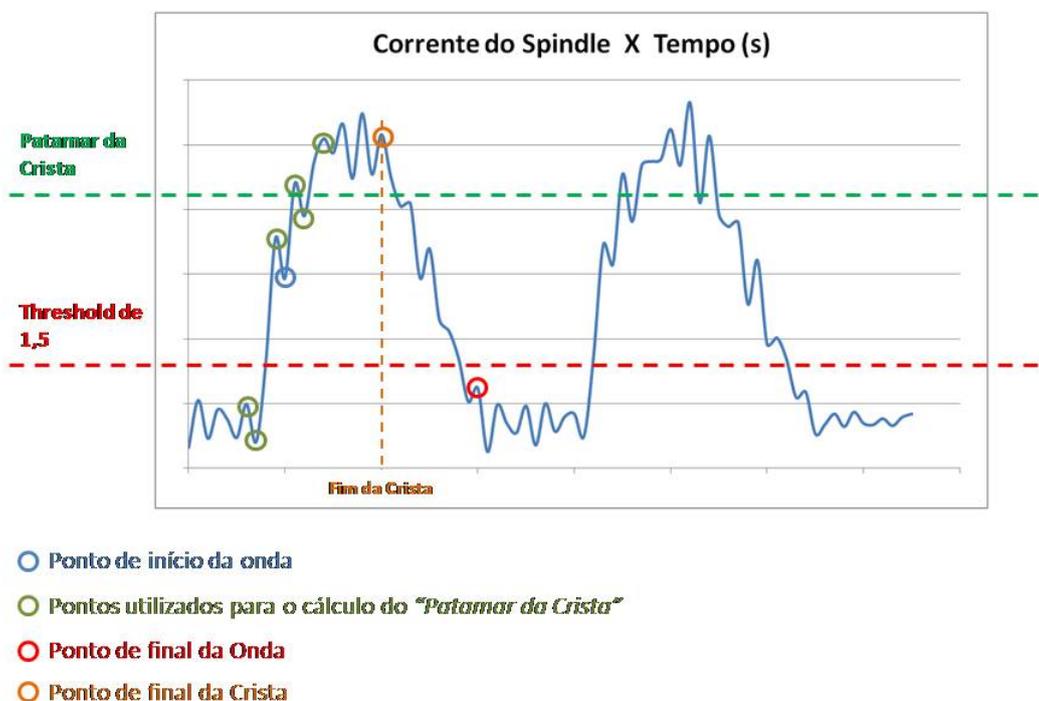
4.3.4.5 Verificação de Corrente Excessiva com Peck Drill em Recuo

Um problema que deve ser verificado durante a leitura do sinal pelo algoritmo é a existência de excesso de limalhas e rebarbas presas à ferramenta de corte. Este fenômeno se caracterizará com um aumento de corrente em pleno movimento de recuo do *peck drill*. Como foi explicado na seção 3.4, o valor da corrente deve baixar a valores próximos a zero quando o cabeçote de furação inicia um movimento de recuo no ciclo do *peck drill*, pois praticamente não

Algoritmo 4 – Algoritmo de Definição da Fase 4 (Fim da Crista)

- 1: $t_2 \leftarrow t_1 + t$ ▷ "t" é a taxa de aquisição da máquina entre um dado e o próximo
- 2: $t_3 \leftarrow t_2 + t$
- 3: **procedimento** FIM DA ONDA($Corrente(t_1), Corrente(t_2), Corrente(t_3)$) ▷ Corrente do cabeçote em t_1, t_2 e t_3
- 4: **enquanto** $Corrente(t_1) < 1$ e $Corrente(t_2) < 1,5$ e $Corrente(t_3) < 1,5$ **faça** ▷ Procura-se pelo tempo até se encontrar o vale da onda)
- 5: $t_1 \leftarrow t_2$
- 6: $t_2 \leftarrow t_3$
- 7: $t_3 \leftarrow t_3 + t$
- 8: **fim enquanto**
- 9: **retorna** t_1 ▷ t_1 é o momento em que o Vale da Onda em análise começa
- 10: **fim procedimento**
- 11: **procedimento** FIM DA CRISTA(t_1) ▷ Momento em que o Vale da Onda em análise começa,
- 12: **enquanto** $Corrente(t_1) < PatamarCrista$ **faça** ▷ Procura-se regressivamente pelo tempo até se encontrar um valor de corrente superior ao *Patamar da Crista*
- 13: $t_1 \leftarrow t_1 - t$
- 14: **fim enquanto**
- 15: **retorna** $Avanco(t_1)$ ▷ $Avanco(t_1)$ é o avanço em que a crista da onda em questão termina
- 16: **fim procedimento**

Figura 17 – Ilustração do Cálculo do Fim da Crista



Fonte: Elaborada pelo autor.

há esforço de corte nesta condição. Porém, caso haja excesso de limalhas presas à ferramenta de corte, o atrito entre esta e a parede do furo irá aumentar, juntamente com o valor da corrente nos acionadores. Assim, esta função tem por objetivo se detectar este fenômeno e consiste em se procurar um pico de corrente consistente, que caracteriza um início de uma onda ou furo, como a função descrita na seção 4.3.2, fazendo-se sempre uma verificação cruzada com o movimento do cabeçote, certificando-se que o pico de onda, caso encontrado, esteja em um movimento de retração do cabeçote, caracterizando a situação descrita acima. Caso esta condição seja confirmada, um aviso deve ser inserido no relatório de furação vinculado aos que estava sendo realizado por ID.

4.3.4.6 Verificação do Fim do Peck Drill com o Fim do Furo

Um problema que deve ser verificado durante a leitura do sinal pelo algoritmo é a possibilidade do cabeçote terminar o movimento do *peck drill* sem que o pacote da junta tenha sido efetivamente vencido pela ferramenta de corte. Este fenômeno se caracterizará com o final da crista coincidindo com o final do último ciclo do *peck drill*. A função para se detectar este fenômeno consiste em, juntamente com a função descrita na seção 4.3.4.3, fazer uma verificação cruzada com o movimento do cabeçote, certificando que o fim da crista definido não esteja coincidindo com o patamar inferior que caracteriza do fim do *peck drill* mostrado na figura 15. Caso seja confirmado que o final da última crista coincida com o cabeçote, iniciando o último patamar que encerra o *peck drill* para início da *fase 5*, um aviso deve ser inserido no relatório de furação vinculado aos furos realizados por ID.

4.3.5 Fase 5 - Afastamento da Ferramenta e Procedimentos Finais

Nesta fase, não é mais necessário nem ao menos o acompanhamento da posição do cabeçote já que se trata da última fase do ciclo de furação. Após terminado o ciclo de furação, tem-se duas variáveis globais, $furo_{inicio}$ e $furo_{fim}$, que foram calculadas através dos algoritmos conforme descrito nas seções 4.3.4.2 e 4.3.4.3, respectivamente. A partir destas duas variáveis, a espessura da junta furada pode ser determinado pela equação 4.2:

$$espessura_{real} = furo_{fim} - furo_{inicio} \quad (4.2)$$

Contudo, o algoritmo deve fornecer uma informação mais precisa, substituindo de forma direta a informação da nomenclatura do comprimento do prendedor a ser utilizado e não a espessura da junta em milímetros. Assim, tomando como exemplo o prendedor mostrado na figura 6, a nomenclatura do comprimento do prendedor representa a espessura máxima da junta na qual o mesmo pode ser instalado em 1/16 partes de polegada. Por exemplo, um prendedor classificado como comprimento "8" pode ser instalado em uma junta com espessura máxima de 8/16" (oito dezesseis avos de polegada) que se multiplicarmos pela constante aproximada

25,4 podemos transformar em 12,7mm. Assim, temos o Algoritmo ?? para se calcular qual o comprimento do prendedor do exemplo da figura 6 a ser instalado na junta, a partir da $espessura_{real}$:

Algoritmo 5 – Algoritmo de Definição do Comprimento do Prendedor

- 1: **procedimento** COMPRIMENTOPRENDEDOR($espessura_{real}$) ▷ Espessura real em milímetros
 - 2: $comprimentopadiao \leftarrow (1/16) * 25,4$ ▷ Calcula o valor da unidade de comprimento padrão da nomenclatura do prendedor em milímetros
 - 3: $Comprimento_{prendedor} \leftarrow quociente(espessura_{real}/comprimentopadiao)$ ▷ Calcula a divisão inteira da espessura medida e o comprimento padrão em milímetros
 - 4: $Comprimento_{prendedor} \leftarrow prendedor + 1$
 - 5: **retorna** $Comprimento_{prendedor}$ ▷ $prendedor$ é a nomenclatura do comprimento do prendedor que deve ser instalado na junta analisada
 - 6: **fim procedimento**
-

Após o calculo, o valor do comprimento do prendedor $Comprimento_{prendedor}$ é inserido no relatório de furação vinculado aos furos realizados por ID.

METODOLOGIA PARA AVALIAÇÃO A QUALIDADE DO FURO EXECUTADO

A medição do diâmetro de furos de precisão em estruturas aeronáuticas, requer um tempo de produção relevante para ser executada, mesmo considerando-se um método mecânico automatizado com *probes* de medição. Por isso, um método que permita a verificação em tempo real da qualidade dos furos, economizará uma quantidade expressiva de tempo. Portanto, é relevante desenvolver um método em tempo real que tenha a capacidade de avaliar a qualidade dos furos e, por consequência, minimizar a medição manual feita atualmente.

Seguindo essa motivação, é possível extrair do sistema de furação automatizado dados relevantes sobre todos os seus controladores, através da corrente elétrica consumida pelos acionadores do cabeçote de furação. Conforme descrito anteriormente, a fim de manter estáveis as velocidades de avanço e rotação do cortador, o controlador da máquina causa variação contínua na corrente elétrica que é consumida pelos acionadores do cortador. Essa variação tem um padrão que só deve apresentar mudanças, se houver algo diferente com o produto que está sob o processo de furação. Por exemplo, uma vibração excessiva causada pela fixação incorreta das peças que compõem a junta a ser furada.

Assim, a metodologia para se resolver este problema será descrita neste capítulo e está baseada na implantação de um comitê de redes neurais. A ideia é usar tal comitê para classificar o sinal da corrente elétrica gravada, a partir da execução de um determinado furo, frente a sinais conhecidos, gravados e armazenados que permitirão classificar tal furo como bom ou ruim.

5.1 Comitê de Redes Neurais *Multi-Layer Perceptron*

Para que se entenda toda a metodologia aplicada na solução do problema de classificação dos furos, é necessário descrever os vários aspectos teóricos envolvendo os comitês de redes neurais, deste os conceitos preliminares de aprendizado de máquina, até os comitês compostos

por redes neurais *Multi-Layer Perceptron* (MARSLAND, 2015).

5.1.1 Conceitos de Machine Learning

O aprendizado pode ser entendido como a capacidade que seres humanos têm de se ajustar e se adaptar à novas circunstâncias frente à experiências já vividas, e também de generalizar estas citadas experiências à situações semelhantes onde estas foram vivenciadas anteriormente. Tendo-se em mente este conceito, segundo (MARSLAND, 2015), o aprendizado de máquina está relacionado a capacidade de sistemas computacionais se adaptarem ou modificarem para que suas ações e decisões proporcionem resultados mais acretivos e/ou precisos.

A criação de um conjunto de dados de treinamento pode alavancar tal aprendizado uma vez que, analogamente ao aprendizado biológico, armazena a experiência da máquina em relação a um determinado problema ou cenário. A partir dessa experiência, é possível não só treinar como permitir que o sistema se adapte e generalize seu comportamento para eventos semelhantes. Assim, há três classes de algoritmos de aprendizado de máquina:

- Algoritmos de Aprendizado Supervisionado: conjunto de dados de treinamento são elaborados com exemplos do problema contendo a solução correta, ou seja, o algoritmo aprende a solução correta para uma determinada amostragem de situações e a partir deste cenário tem a função de generalizar para outras possíveis situações similares do mesmo problema. É um aprendizado por exemplos. Este tipo de algoritmo será o empregado nesta dissertação, onde os dados de treinamento serão criados simulando as diversas situações a serem exploradas. As corretas classificações serão informadas para o treinamento das redes neurais utilizadas.
- Algoritmos de Aprendizado Não Supervisionado: Para este tipo de algoritmo, as respostas corretas não são fornecidas e, devido a isso, o funcionamento do método se baseia em identificar similaridades e/ou categorizar os dados de entrada;
- Algoritmos de Aprendizado de Reforço: O objetivo desse tipo de aprendizado é encontrar um modelo de ação adequado que maximize a recompensa acumulada total do agente. Diferentemente dos aprendizados anteriores, este tipo de aprendizado é usado nos casos em que seu problema não está relacionado a conjunto de dados, mas você tem um ambiente para lidar. Logo, há uma indicação de ação incorreta, ou insatisfatória por parte do ambiente externo, mas não se diz como corrigir.

Para que se possa treinar e verificar qual foi o aproveitamento e eficácia deste treinamento no aprendizado de maquina, três conjuntos de dados podem ser estabelecidos:

- Conjunto de Treinamento para realmente treinar o algoritmo;

- Conjunto de Validação para acompanhar o quão bem o algoritmo se comporta à medida que aprende;
- Conjunto de Teste para produzir um grupo de resultados, e se checar a acuracidade do método, após terminado o período de aprendizado.

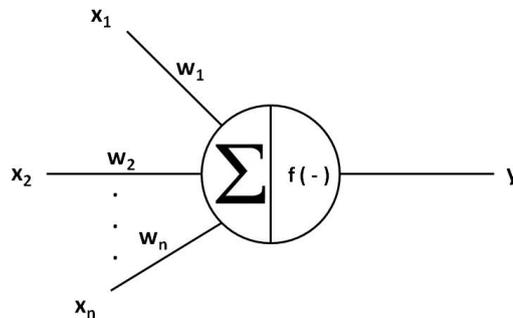
De forma geral, quanto mais dados o algoritmo processa no treinamento e mais abrangentes são os mesmos, mais provável é que o método tenha visto exemplos de cada tipo possível de entrada. Nesse caso, aumenta-se a chance de sucesso no processo de generalização da solução para problemas similares, porém há o custo do aumento no tempo de aprendizado. Argumento semelhante pode ser usado para justificar que os conjuntos de validação e teste sejam razoavelmente grandes. Geralmente, o usual é dividir o conjunto de dados de testes em partes randômicas na proporção para o conjunto de treinamento, validação e teste de 50:25:25 se há muitos dados, e 60:20:20 caso contrário.

Independentemente da quantidade de dados que usamos para testar o algoritmo treinado, ainda precisamos trabalhar se o resultado é bom ou não para o problema de classificação tratado. Nesse caso, usamos a "matriz de confusão" que consiste em uma matriz quadrada contendo todas as possíveis classes nas direções horizontal e vertical. As colunas representam as classes indicadas pelo método, enquanto as linhas indicam as classes *target* do conjuntos de dados. Assim, entende-se que cada entrada $A_{i,j}$ da matriz representa a quantidade de conjuntos de entradas cuja classificação de treino *target* era "*i*" e que o método a classificou como "*j*". Assim, conclui-se que as classificações corretas efetuadas serão contabilizadas na diagonal principal da "matriz de confusão", onde $i = j$ e as incorretas estarão identificadas nas demais posições da "matriz de confusão".

5.1.2 Redes Neurais e Comitê de Redes Neurais

De acordo com (BRAGA; CARVALHO; LUDERMIR, 2007) no final da década de 80, surge o conceito de *Redes Neurais Artificiais* (RNAs). Essa forma de computação não-algorítmica é caracterizada por sistemas que, em algum nível, relembram a estrutura do cérebro humano. Por não ser baseada em regras, a computação neural se constitui em uma alternativa à computação algorítmica convencional. Trata-se de sistemas paralelos distribuídos, compostos por unidade de processamento simples (*neurônios artificiais* que calculam determinadas funções matemáticas lineares ou não-lineares). Tais unidades são dispostas em um ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos, essas conexões estão associadas a pesos, os quais armazenam o conhecimento adquirido pelo modelo e servem para ponderar a entrada recebida por cada neurônio da rede. A figura 18 mostra um conceito esquemático do neurônio artificial:

Figura 18 – Avaliação de Sinais (Furos)



Fonte: Elaborada pelo autor.

O modelo de *neurônio artificial* apresenta n terminais (dentrítos) que recebem as entradas x_1, x_2, \dots, x_n , representando as ativações dos neurônios anteriores, e apenas um terminal de saída y , que representa o *axônio*. Para representar o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados w_1, w_2, \dots, w_n , cujos valores podem ser positivos ou negativos, dependendo das sinapses correspondentes serem inibitórias ou excitatórias. A soma ponderada das entradas dos neurônios (soma dos valores $x_i * w_i$) alimenta a *Função de Ativação*, que decide se o neurônio dispara ou não, ou seja, ativa ou não a saída do mesmo. Independentemente da *Função de Ativação* escolhida, neurônios artificiais possuem capacidade computacional limitada, porém, um conjunto de neurônios artificiais conectados na forma de rede é capaz de resolver problemas de complexidade elevada.

O procedimento usual na solução de problemas usando RNAs passa inicialmente por uma fase de *aprendizagem*, onde o conjunto de exemplos é apresentado para a rede visando extrair as características necessárias para representar a informação fornecida. Essas características são utilizadas posteriormente para gerar respostas para o problema. A capacidade de *aprender* por meio de exemplos e de generalizar a informação aprendida é, sem dúvida, o atrativo principal da solução de problemas por meio de RNAs.

A generalização, que está associada à capacidade da RNA aprender por meio de um conjunto reduzido de exemplos e posteriormente dar respostas coerentes para dados não conhecidos, é uma demonstração de que a capacidade das RNAs vai além de simplesmente mapear relações de entrada e saída. As RNAs são capazes de extrair informações não apresentadas de forma explícita através dos exemplos.

Não obstante, as RNAs são capazes sim de atuar no mapeamento de relações em funções multivariáveis. Nesse caso, o custo computacional cresce apenas linearmente com o número de variáveis. Outra característica importante é a capacidade de auto-organização e de processamento

temporal que, aliada às aquelas citadas anteriormente, torna as RNAs ferramentas computacionais atrativas para a solução de problemas complexos.

As chamadas redes perceptron são um conjunto de neurônios, formando uma camada (*layer*), onde cada um recebe um valor inicial que consiste em cada dado ou parâmetro de entrada do problema multiplicado por um peso específico acoplado. Cada um destes neurônios tem uma função de ativação própria que dispara um valor de saída específico, caso a combinação das entradas com esta função assim o determine. Não há número definido de neurônios para este tipo de rede.

As Redes Neurais *Multi-Layer Perceptron* (MLP), as quais são indicadas para problemas de classificação (MARSLAND, 2015; RAGHU; SRIRAM, 2017), são redes que mantêm o conceito dos perceptrons, mas possuem mais camadas de neurônios da seguinte forma:

- Contém ao menos dois tipos de camadas de neurônios, sendo uma ou mais camadas escondidas e uma camada de saída;
- As camadas escondidas seguem os mesmos conceitos da camada da rede perceptron normal, ou seja, não têm número de neurônios definidos. Para cada neurônio, as entradas são os dados iniciais ou saídas de camadas escondidas mais externas multiplicadas pelos respectivos pesos e, a saída, a combinação das entradas com a função de ativação.
- A camada de saída possui a mesma quantidade de neurônios que as saídas possíveis, ou seja, no caso de classificação, os neurônios são tantos quantas as classificações possíveis.

A acurácia de uma MLP é melhorada através do processo de se aumentar o número de camadas e/ou o número de neurônios nas camadas. A definição do número ótimo de camadas escondidas e o número de neurônios em cada uma delas, na resolução do problema proposto por este trabalho é um ponto importante a ser discutido na seção 6.2.1.

Com relação ao algoritmo de aprendizado, o explorado por este trabalho é o *backpropagation*. Neste algoritmo, a cada época, o erro é calculado a partir de valores das saídas da rede obtidos através da consideração de pesos randômicos, positivos e negativos com baixo módulo. Com estes valores de saída, calcula-se a diferença entre as mesmas e os *targets*. A partir da diferença calculada, faz-se o processo inverso, calcula-se novos erros nas camadas escondidas e consequentemente os novos pesos nos neurônios. Isso permite fechar um ciclo de iteração, o qual será repetido até que o valor do erro seja mínimo, e assim, os pesos e saídas definidos.

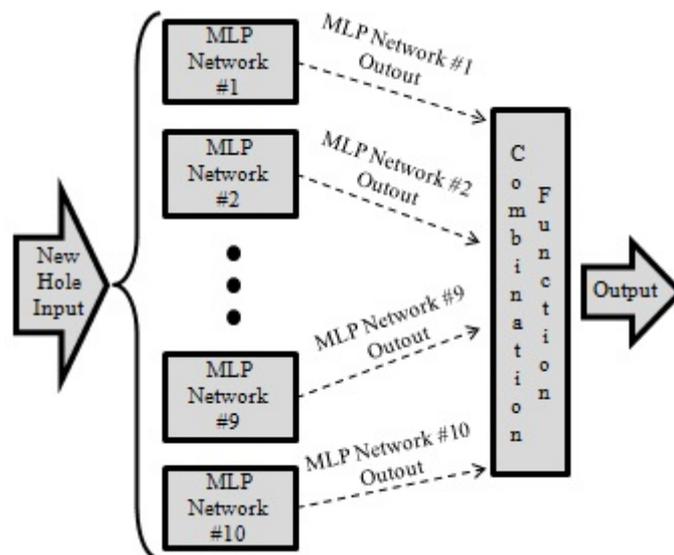
A tomada de decisões complexas pode ser beneficiada pela existência de um comitê em diversos cenários de associações de seres humanos. As casas legislativas, tribunais colegiados e comissões diretoras de empresas são bons exemplos que exemplificam o conceito de comitê. Nas redes Neurais, o mesmo conceito pode ser empregado, uma vez que diferentes redes podem ser treinadas a partir de um mesmo conjunto de dados de treinamento e produzir resultados

diferentes ao serem utilizadas em novas classificações. Isso se deve ao fato de que algumas redes podem ter melhor desempenho em um determinado conjunto de dados e a outras em outro conjunto. Segundo (Ponti Jr., 2011), os métodos de se combinar os resultados dos integrantes do comitê usando RNAs mais usados são:

- Voto majoritário;
- Voto majoritário ponderado;
- Contagem de borda;
- Média e produto das probabilidades;
- Média e mediana

Como o já citado em (MARSLAND, 2015; RAGHU; SRIRAAM, 2017), para problemas de classificação, as Redes Multi Layer Perceptron (MLP) são indicadas, portanto, 10 MLP independentes e distintas foram criadas. O método de treinamento de *back propagation* foi aplicado a partir de um conjunto de dados de treinamento exclusivo. A figura 19 mostra uma imagem esquemática e simplificada do comitê de redes MLP proposto neste trabalho

Figura 19 – Esquema de Funcionamento do Comitê de Redes MLP



Fonte: Elaborada pelo autor.

Um vez entendido o conceito geral, o desenvolvimento das rede MLP acontecerá na seguinte sequência:

- Criação de um Corpo de Prova representativo para os sinais padrão para furos bons e ruins;
- Criar a base de dados de referência de sinais para furos bons e ruins;

- Definir a arquitetura das redes MLP a serem utilizadas na resolução do problema;
- Efetuar o treinamento das redes escolhidas;
- Escolher as redes com melhor performance no treinamento com a base de dados.

5.2 Criação do Corpo de Prova Padrão

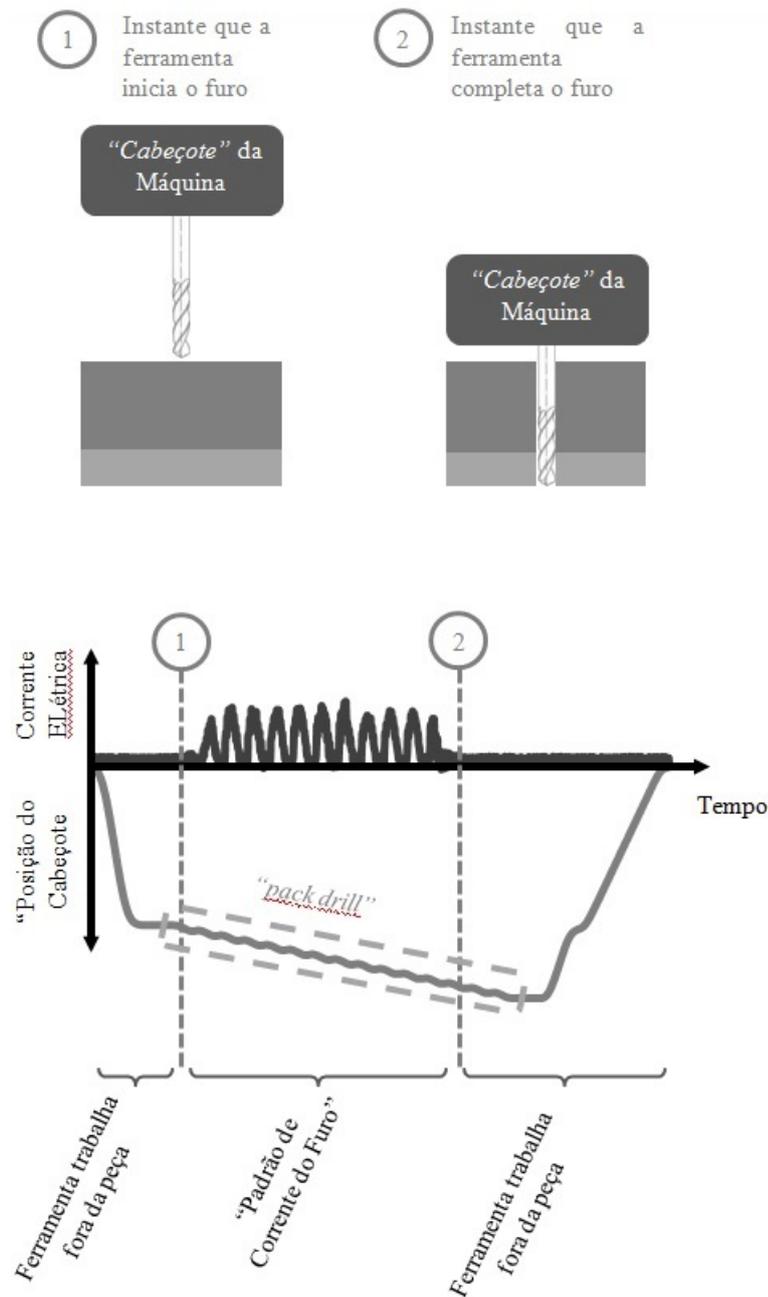
Com foco na contribuição da máquina para a qualidade da furação, o controle das velocidades de avanço e rotação são os fatores importantes. Por isso, o controlador da máquina tem como objetivo principal manter essas velocidades estáveis desde o processo de furação, e, para isso, o controlador utiliza o nível da corrente elétrica nos acionadores que movimentam e giram a ferramenta de corte.

Para evitar marcas e riscos no corpo cilíndrico do furo e promover o equilíbrio da temperatura na broca, a máquina realiza um movimento denominado *peck drill* como mencionado no Capítulo 4. Isso significa que a ferramenta de corte não passa continuamente pelo furo, mas faz avanços parciais para frente seguidos de um pequeno movimento para trás, visando eliminar a concentração de cavacos na área de corte da broca. Por causa deste movimento *peck drill*, o padrão do sinal de corrente elétrica no acionador de rotação da broca não é contínuo, mas composto por ondas como na figura 20. As ondas são formadas com o aumento do nível de corrente elétrica para manter estável a velocidade de rotação da ferramenta de corte, compensando a resistência mecânica imposta pelo contato com a peça sob um movimento de avanço do cabeçote da máquina. Da mesma forma, quando o movimento de retrocesso da *peck drill* se inicia, cessa-se a resistência mecânica e, conseqüentemente, o controlador da máquina diminui o nível de corrente elétrica, formando uma onda de corrente elétrica.

Os dados apresentados na figura 20 contém informações relevantes que são importantes para as próximas discussões neste artigo. O instante de tempo indicado por "1" marca o início do próprio processo de furação, ou seja, quando a broca começa a cortar a primeira parte da junta. Da mesma forma, o instante de tempo indicado por "2" marca o término do processo de furação, ou seja, quando a broca aparece na superfície posterior da última parte da junta. No período de tempo antes de "1" e após "2", o cabeçote de furação está se movendo para fora da junta, e o sinal de corrente elétrica não é relevante para este estudo. Porém, no período entre "1" e "2" estão todas as informações necessárias para este estudo, pois este é o período em que a broca deve estar em contato com as peças da junta, durante o movimento de avanço do *peck drill*. Concluindo, a partir deste período de tempo, do instante "1" ao instante "2", é quando é possível coletar o *Padrão de Corrente Elétrica de Furo*.

Para avaliar a qualidade dos furos, muitos fatores devem ser mantidos sob controle. Esses fatores podem ser divididos em fatores do sistema de furação e fatores externos. Os fatores do

Figura 20 – Padrão de Sinal de Corrente Elétrica para uma Furo com peck drill



Fonte: Elaborada pelo autor.

sistema de furação são aqueles relacionados aos parâmetros de corte, ou seja, aqueles que podem ser controlados pelo controlador numérico da máquina tais como:

- Perpendicularidade do Furo;
- Correta Localização do Furo na Junta;
- Velocidade de Avanço da Ferramenta de Corte;
- Velocidade de Rotação da Ferramenta de Corte;

- Movimento de *Peck Drill*;
- Vibração do Cabeçote de Furação (controlado pelo sistema da máquina).

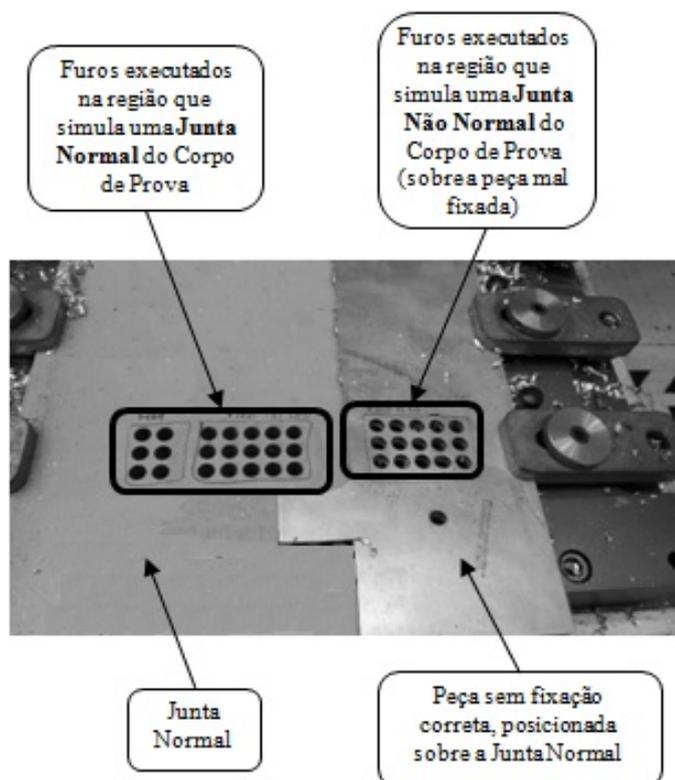
Os fatores externos estão relacionados a situações que não estão sob controle ou monitoramento da máquina tais como:

- Fixação da Junta a ser Furada;
- Desgaste da Ferramenta de Corte.

Este trabalho assume que os fatores da máquina estão sob controle e, por isso, põe foco nos fatores externos. Portanto, o comportamento do padrão do sinal da corrente elétrica em um cenário afetado por um fator externo é o ponto mais importante a ser considerado.

Para se entender como se comporta o padrão do sinal de corrente elétrica, estando o processo de furação afetado ou não por fatores externos de qualidade, foi construído um corpo de prova que visa simular as condições afetadas e não afetadas por estes fatores externos. A figura 21 mostra uma imagem do corpo de prova construído.

Figura 21 – Corpo de Prova Construído para Simular Condições Afetadas e Não Afetadas por Fatores Externos



Fonte: Elaborada pelo autor.

O corpo de prova foi construído usando uma placa de espessura de 15,8 mm (5/8 polegadas) com a mesma liga de alumínio do produto. Para simular fatores externos que afetam a condição de qualidade final dos furos, foi adicionada uma peça de chapa metálica, cobrindo uma parte do mesmo corpo de prova, como mostrado na figura 21. Esta peça de chapa metálica não foi totalmente fixada na bancada de teste da máquina, onde corpos de prova são normalmente posicionados para testes com o equipamento. Assim foi criada uma condição de estabilidade insuficiente na peça durante o processo de furação, resultando em vibração excessiva.

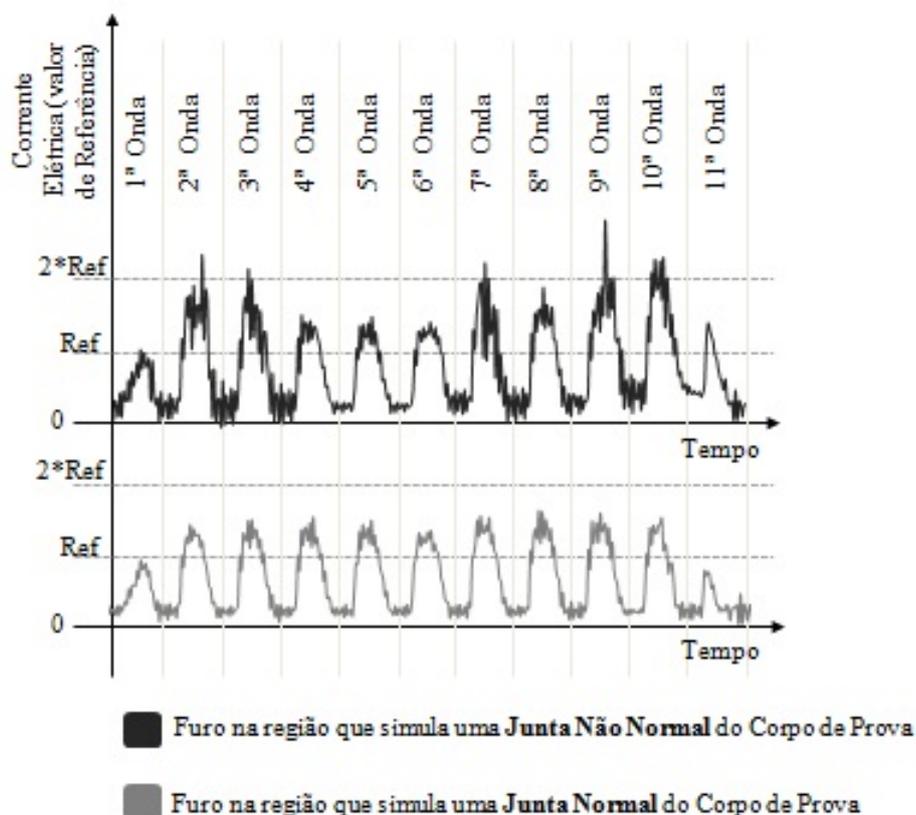
Como a peça de chapa adicional possui espessura pequena, ou seja, não possui rigidez suficiente, a vibração provocada não pode danificar a broca nem a máquina e, conseqüentemente, sua influência nos *Padrões de Corrente Elétrica* deve ser mínima. Portanto, esta região do corpo de prova irá gerar um *Padrão de Corrente Elétrica* que pode ser considerado *não aceitável*, sensível em termos de detecção, visto que este padrão não é claramente diferente do padrão *aceitável*.

O corpo de prova construído sofreu então a ação do sistema automatizado de furação, utilizando assim a mesma broca e parâmetros de corte que são normalmente aplicados ao produto para gerar dados representativos. Esta atividade de furação no corpo de prova produziu 15 furos na área normal (sem a chapa adicional) e 15 furos na área não normal, isto é, por sobre a chapa metálica adicional, conforme ilustrado na figura 21.

Como resultado da atividade de furação no corpo de prova descrito anteriormente, foram obtidos os padrões de sinal de corrente elétrica para cada um dos 15 furos *aceitáveis* e dos 15 *não aceitáveis*. A figura 22 contém um gráfico de comparação, mostrando um exemplo de um padrão de sinal de corrente elétrica para um furo *aceitável* e outro de um furo *não aceitável*. Os gráficos foram criados a partir de valores obtidos diretamente da saída de dados do controlador da máquina e normalizados para serem plotados na figura. Para auxiliar na análise, os padrões de corrente foram divididos por ondas que contêm uma crista e meia para trás e outra para frente.

Analisando os gráficos dos exemplos *aceitável* e *não aceitável*, algumas observações são importantes:

- A primeira crista é sempre consequência da distância inicial entre a máquina e a peça a ser furada, e esta distância depende de várias características como as dimensões das peças, o comprimento da broca e sua configuração no cabeçote da máquina. Por exemplo, é possível verificar a diferença, na forma e amplitude, entre as primeiras cristas dos sinais mostrados nas figuras 22 e 20. Portanto, para avaliar esta crista e gerar dados de treinamento relevantes, será necessário um grande número de corpos de prova e furos. Em termos práticos, esta crista específica representa o início de um furo onde, posteriormente ao processo de furação e anteriormente à instalação do prendedor, deverá ser feito um chanfro que possibilite o assentamento da cabeça do prendedor, a qual possui um raio de concordância inerente do seu processo de fabricação. Este chanfro possui profundidade da

Figura 22 – Padrão de Corrente para furos *Aceitáveis* e *Não Aceitáveis*

Fonte: Elaborada pelo autor.

mesma ordem de grandeza do avanço de um ciclo de *peck drill* da máquina e não possui requisitos dimensionais rígidos e, devido a isso, a primeira onda do sinal de corrente elétrica de um furo, que coincide com a região onde o chanfro será realizado, pode não ser considerada neste estudo;

- O número de cristas é consequência da espessura da junta. Considerando-se o "Corpo de Prova" utilizado para este estudo, foi visto que sua espessura é praticamente igual para todos os furos que foram realizados, lembrando que a chapa adicional tem espessura fina, cerca de 0,8mm. Entretanto, ao se furar produtos reais, espera-se encontrar espessuras variadas que irão gerar, durante o processo de furação, *Padrões de Corrente Elétrica* contendo diferentes números de cristas e vales. Este fato alerta para a grande quantidade de corpos de prova a serem construídos e furos a serem realizados para se obter uma base de dados consistente que cubra todos os tipos de *Padrões de Corrente Elétrica* possíveis, ou seja, todas as espessuras esperadas para os produtos reais a serem furados;
- A última crista, que no exemplo figura 22 é a 11ª crista, depende diretamente da espessura da junta. Por isso e pelo fato de os chanfros para instalação dos prendedores também serem feitos na superfície posterior do furo para se eliminar rebarbas, a última crista pode

também não ser considerada para este trabalho, assim como a primeira;

- Sobre os *Padrões de Corrente Elétrica* do furo executado na região normal do corpo de prova, é possível observar que as ondas elegíveis são semelhantes entre si, demonstrando uma estabilidade do processo de furação durante todo o movimento *peck drill*;
- Sobre os *Padrões de Corrente Elétrica* do furo realizado na região não normal do corpo de prova, é possível observar que as ondas elegíveis não são semelhantes. As 2^a, 3^a, 7^a, 9^a e 10^a ondas apresentam cristas e vales mais altos e ruidosos. Da mesma forma, a 4^a onda tem um vale ruidoso para trás e a 7^a onda uma para frente. Por outro lado, a 9^a onda apresenta um comportamento muito semelhante às ondas do padrão de área normal.

Compreendendo esses fatos, o próximo passo deste estudo é definir a base adequada de comparação para cobrir todos os tipos de *Padrões de Corrente Elétrica* possíveis que podem aparecer em diferentes produtos, usando o mínimo de corpos de prova quanto o possível.

5.3 Criação da Base de Dados de Treinamento

A partir das análises anteriores, decidiu-se optar pelo uso de ondas únicas, compostas por uma crista e dois vales sendo um para trás e outro para a frente, como o elemento principal para o conjunto de dados de treinamento. O conceito de criação deste conjunto de dados de treinamento é separar as ondas dos *Padrões de corrente elétrica* dos furos *aceitáveis* e identificá-los como *ondas normais*. Por outro lado, analisa-se todos os *Padrões de corrente elétrica* dos furos *não aceitáveis* e separam-se as ondas que possuem crista e/ou vales que não sejam semelhantes às *normais*, identificando-as como *ondas não normais*.

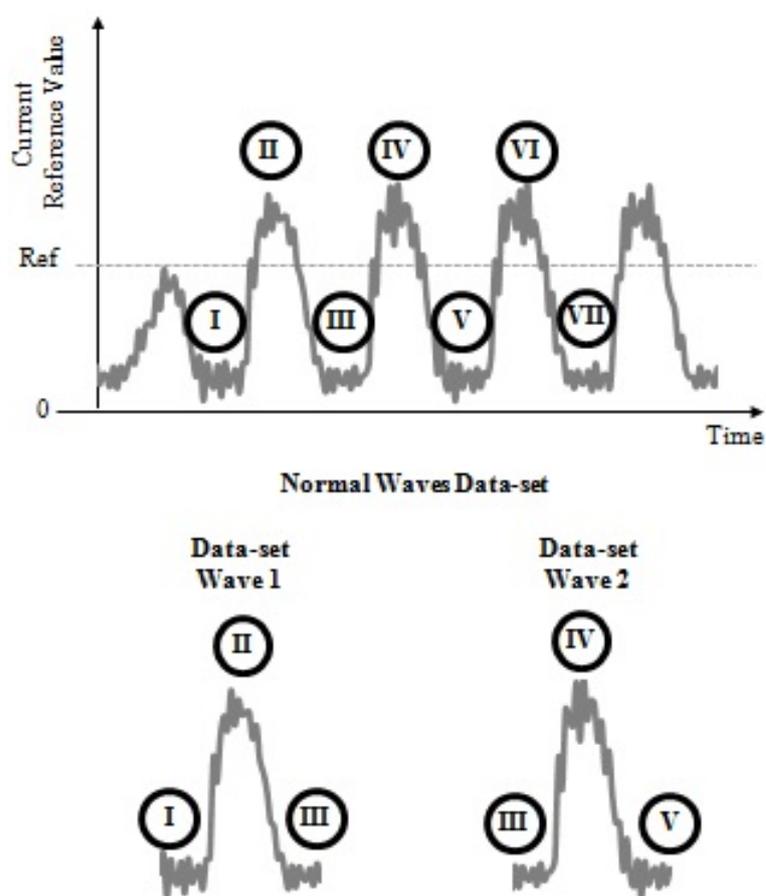
O uso de ondas únicas como objeto de classificação, e não todo o sinal de corrente de um furo, foi um método mais eficaz e otimizado para este trabalho em termos de treinamento. Pode-se verificar anteriormente que, a quantidade de ondas existentes no sinal de um determinado furo, esta diretamente relacionada com o comprimento do mesmo. Desta forma, seria necessário a fabricação de diversos corpos de prova para que sinais, contendo todas as quantidades de ondas previstas, sejam representados e, a partir destes dados de furação, as diversas redes neurais treinadas. Assim, existiriam redes neurais e comitês para cada tipo de sinal de corrente previstos, e a escolha do comitê a ser usado na classificação de um determinado furo, feita em função da quantidade de ondas de sinal de corrente elétrica, que seria determinada em um pré-processador, ou seja, em função do comprimento da junta furada.

Concluindo, o uso de ondas únicas como objeto de classificação, como o proposto por este trabalho, tem sua simplicidade em termos de treinamento comprovado pelo fato de que, não há necessidade da construção de corpos de prova de diversas espessuras, já que o padrão é obtido separando-se as ondas individualmente de cada sinal. A partir deste fato, se pode alcançar uma representatividade estatística na quantidade de amostragens mais rapidamente, e ao executar um

furo no produto, classificar o sinal, onda a onda. Com o intuito de ser conservativo, o critério adotado para se considerar o furo aceitável foi a ausência de ondas individualmente classificadas como *ondas normais*.

Assim, o conjunto de dados *ondas normais* foi gerado incluindo cada onda coletada de todos os 15 furos *aceitáveis*. A figura 23 mostra um exemplo de como essas ondas foram coletadas e inseridas no conjunto de dados *ondas normais*. Neste exemplo, uma onda do *padrão atual*, contendo a crista identificada como "II" e os vales identificados por "I" e "III", e outra contendo a crista identificada como "IV" e os vales identificados por "III" e "V" foram inseridos no conjunto de dados de treinamento *ondas normais*.

Figura 23 – Padrão de Ondas para Furos Aceitáveis



Fonte: Elaborada pelo autor.

Seguindo procedimento semelhante, o conjunto de dados *ondas não normais* foi gerado, incluindo cada onda considerada diferente do padrão normal, coletada dos dados de todos os 15 furos *não aceitáveis*. No caso das *ondas não normais*, algumas variações das ondas também foram consideradas. O Intuito da inclusão destas variações, foi gerar um conjunto de dados mais abrangente que o obtido pelo corpo de prova, criando ondas que são o resultado da combinação de cristas e vales que apresentam características *não normais*. A partir deste conceito, a figura 24 mostra um exemplo de como essas ondas foram coletadas e inseridas no conjunto de dados *ondas*

não normais. Neste exemplo, uma onda do *padrão atual*, contendo a crista identificada como "II" e os vales identificados por "I" e "III", foi inserida no conjunto de dados de treinamento *ondas normais*. A outra onda inserida, a título de exemplo, merece uma explicação especial: quando uma onda não possui todas as vales e cristas identificadas como *não normais*, é importante inseri-la no conjunto de dados, também para criar novas ondas que representam combinações e variações dos vales e cristas da onda original. Então, voltando à 24, a 2ª onda inserida no conjunto de dados *não normal*, por exemplo, foi composta pelo vale original *não normal* "V", seguido da crista *normal* "VI", conforme a onda original, porém, foi então acrescentado um outro vale *não normais* "V". Para melhorar o entendimento, a *onda original* composta pelo vale "V", crista "VI" e pelo vale "VII", como outra onda criada, por exemplo, composta pelo vale "VII", crista "VI" e vale "V" (onda original invertida) também são inseridos no conjunto de dados *não normais*. É importante esclarecer que esses exemplos têm o objetivo de esclarecer como o conjunto de dados de treinamento real foi construído.

Executando os passos descritos, o conjunto de dados de treinamento gerado contém 135 *ondas normais* e 122 *ondas não normais*. Esse tamanho para um conjunto de dados é adequado para iniciar testes com redes neurais, conforme justificado a seguir.

5.4 Arquitetura das Redes Neurais MLP

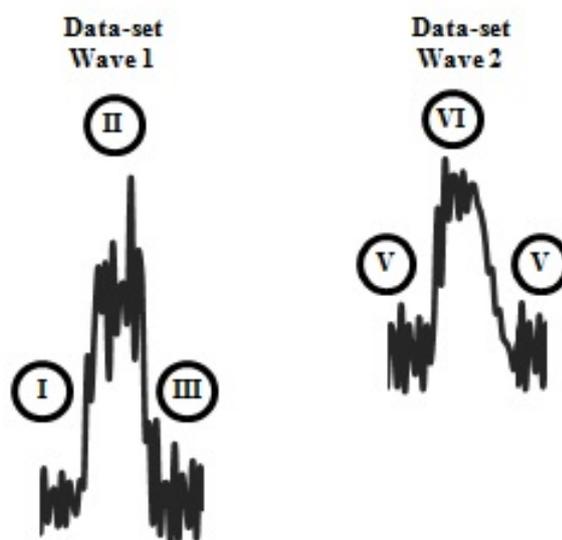
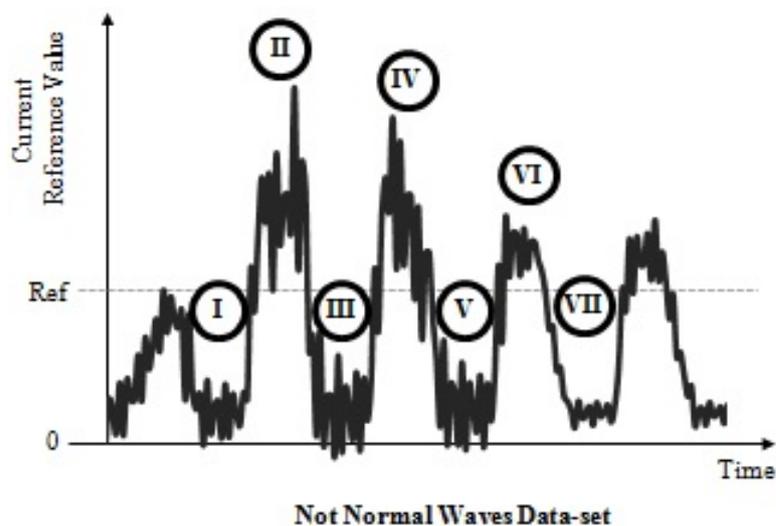
A arquitetura MLP utilizada nesta dissertação é mostrada na figura 25.

- *Input*: Uma onda padrão de corrente elétrica, que pode ser coletada de um novo furo realizado no produto, ou caso a rede esteja em fase de treinamento, do conjunto de dados de treinamento. Cada onda de entrada é coletada como uma coluna com 50 linhas, onde cada uma delas representa o nível da corrente elétrica em um tempo contado desde o início da onda;
- *Hidden Layer Block*: Um bloco de camada oculta de neurônios. Não há limites para o número de camadas ocultas na rede, nem para o número de neurônios nessas camadas. Para este trabalho, redes com uma e duas camadas ocultas foram testadas, cada uma contendo um número de neurônios variando de 1 a 200.
- *Função de Ativação*: Cada neurônio definido nas camadas escondidas irá disparar uma saída seguindo a função de ativação mostrada na equação 5.1:

$$f(x) = \left(\frac{2}{(1 - e^{-2x})} \right) - 1 \quad (5.1)$$

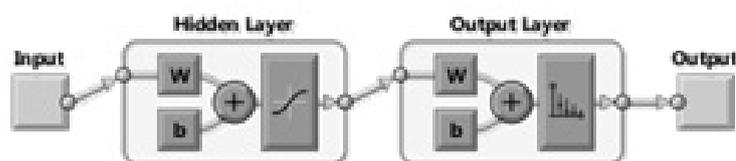
- *Output Layer*: Uma camada com dois neurônios, cuja função é dar o resultado da classificação da onda em questão. Um dos neurônios indicará a tendência da rede classificar uma determinada onda como *normal* e o outro como *não normal*.

Figura 24 – Padrão de Ondas para Furos Não Aceitáveis



Fonte: Elaborada pelo autor.

Figura 25 – Representação Esquemática de Redes Neurais MLP



Fonte: Elaborada pelo autor.

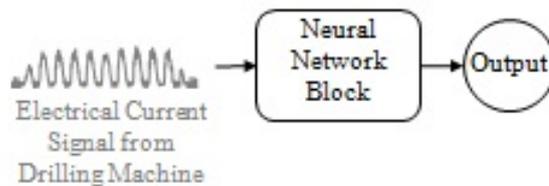
- *Output*: Para este problema de classificação, existem duas classificações possíveis para uma determinada onda a ser analisada: *onda normal* ou *onda não normal*, e como vimos anteriormente, um dos neurônios da *Output Layer* indicará a tendência da onda ser classificada como *onda normal* e o outro como *onda não normal*, de modo que, a saída dos dois neurônios são números complementares cuja soma é sempre 1. Como as saídas são

complementares, ou seja, os valores são dependentes, será considerado neste trabalho como *Output* de uma rede, apenas a saída no neurônio que indicada a tendência da onda ser classificada como *onda normal*. Desde modo, pode-se considerar que para cada onda analisada o *output* da rede através é número único, real e pertencente ao intervalo $[0,1]$, onde valores compreendidos entre $]0.5,1]$ indicam *ondas normais*, $[0,0.5[$ *ondas não normais* e o valor 0.5 uma impossibilidade de se classificar a onda com qualquer precisão. É importante pontuar neste momento que, o nível entre de incerteza na classificação de uma rede pode ser identificado verificando-se o quanto mais próximos de 0.5 são os *outputs*.

5.5 Modelo para Solucionar o Problema

Uma modelagem simples que pode ser realizada para solucionar o problema é ilustrada na figura 26.

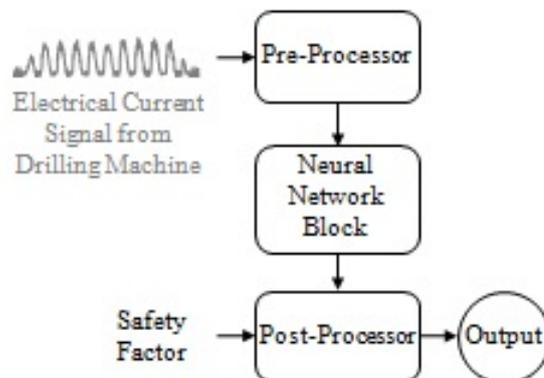
Figura 26 – Modelagem Preliminar do Problema



Fonte: Elaborada pelo autor.

Entretanto, o *padrão de corrente elétrica* não pode ser simplesmente inserido no bloco da rede neural e essas saídas não devem ser usadas sem análise posterior. Portanto, a modelagem completa para este problema é mostrada na figura 27.

Figura 27 – Modelagem Final do Problema



Fonte: Elaborada pelo autor.

A etapa chamada pré-processador recebe o *padrão de corrente elétrica* da unidade de controle da máquina como entrada. O pré-processador tem o atributo de preparar os dados para

se tornarem uma entrada para o bloco da rede neural, ou seja, transformar o sinal completo em ondas separadas, cada uma contendo uma crista e dois vales, removendo a primeira e a última onda. As funções e algoritmos descritos no capítulo 4, que determinam o início e o fim das ondas, realizam diversas verificações preliminares de qualidade e determinam o comprimento dos prendedores, são aplicados na etapa do pre-processador e após, o sinal é dividido em ondas individuais para que sejam analisadas pelas redes MLPs.

O bloco de redes neurais contém as dez redes MLP mais eficientes obtidas na etapa de treinamento. Esse bloco recebe a sequência de ondas elegíveis retornadas pelo pré-processador como entrada. Cada rede, individualmente, processa a entrada e gera sua saída diretamente para o pós-processador. Todavia, conforme discutido anteriormente na seção 5.4, a saída de cada rede neural é um número real pertencente ao intervalo $[0;1]$, representando uma tendência da onda analisada ser classificada como *normal* ou *não normal*, onde a proximidades destes valores à 0,5 representam o grau de incerteza da rede ao classificar a onda. Assim, como este trabalho aborda uma aplicação industrial, é importante propor um fator de segurança. O fator de segurança pode ser um decimal entre $[0;0,4]$, que deve indicar o nível de certeza que a rede classificou uma determinada onda como *ondas normal*, em outras palavras o quão longe o resultado está de 0,5.

Para ser conservador, se a diferença não for maior que o fator de segurança, o resultado de classificação da rede deve ser alterado como *não normal*. Para melhor explicar este conceito, propõe-se o seguinte exemplo: Considera-se que a saída de classificação de uma determinada onda por uma determinada rede neural MLP foi de 0,7. Pode-se entender que o nível de certeza deste resultado é de 0,2 (diferença entre 0,7 e 0,5). Nesse caso, se o fator de segurança estiver configurado como 0,1, esta onda será classificada como *normal*, por outro lado, caso o fator esteja configurado como 0,2, como *não normal*.

Em termos práticos, é possível afirmar que quanto mais próximos estão os valores de saída, mais incerta é a matemática da classificação da rede. Como este trabalho aborda uma aplicação industrial, é importante propor um fator de segurança. O fator de segurança pode ser um decimal entre 0,0 e 0,9 que deve ser uma referência para a diferença entre as duas saídas da rede, ou seja, pode indicar o nível de certeza que a rede classificou as informações de entrada. Para ser conservador, se a diferença não for maior que o fator de segurança, o resultado da rede deve ser determinado como *não normal*. Este fator foi aplicado a todas as saídas da rede, incluindo aquelas da função de combinação.

O bloco pós-processador recebe como entrada a resposta das dez MLPs individuais para aplicar o fator de segurança usando duas funções importantes: a *Função de combinação* e a *Análise de furo*. A *Função de Combinação* tem como principal objetivo se gerar uma resposta única de classificação, que represente o conjunto de respostas dos dez redes MLP utilizadas neste trabalho. Para isso dois principais métodos foram considerados:

- Voto Majoritário;

- Média Aritmética.

Com relação ao conceito de voto majoritário, utilizado em (VOGADO *et al.*, 2017), apesar de ser conceitualmente adequado para este tipo de problema, não permite usar o nível de certeza de cada rede na classificação, que é um importante fator a ser considerado nesse trabalho. O Nível de certeza da classificação, para este problema, dá um sentido de voto ponderado, ou seja, o voto da rede que classificou de forma mais "segura" tem mais peso na decisão, por isso, o método de comitê por média aritmética das saídas das redes MLP, gerando um senso comum da classificação de todas as redes com relação à onda analisada foi o escolhido, como o feito em (DANTAS *et al.*, 2018).

A *Função de Análise de Furo* verifica todas as ondas analisadas de um padrão de corrente elétrica de um furo, e verifica se todas elas foram classificadas como *normais*. Se esta análise for positiva, o furo é classificado como *aceitável*, porém, se houver no mínimo uma onda *não normal*, o furo deve ser classificado como *não aceitável*.

RESULTADOS

Neste capítulo serão apresentados e discutidos os resultados obtidos ao se aplicar as duas metodologias propostas nos capítulos 4 e 5.

6.1 Resultados Obtidos com a Metodologia de Medição da Espessura da Junta

Um total de 60 furos foram realizados no produto real, onde a área de furação coberta compreendeu juntas com várias espessuras diferentes, seguindo uma programação normal de furação da máquina. Os algoritmos descritos no capítulo 4 foram aplicados nos dados de consumo da corrente elétrica para a execução deste conjunto de furos. As informações retornadas pelos algoritmos estão descritas na tabela 1. Após a execução dos furos, os mesmos foram medidos com relação ao comprimento da junta em cada posição e, assim, cada prendedor a ser instalado pôde ter seu comprimento especificado. Neste momento, os resultados puderam ser comparados para se averiguar a acurácia do método, o que também consta na tabela 1.

Como o descrito no capítulo 3, os prendedores são fabricados com comprimentos variando a cada 1,6mm e a medição mecânica do comprimento do furos, para definir qual o tamanho correto do prendedor a ser instalado, é realizada com auxílio de uma escala. Essa escala mostra diretamente os tamanhos dos prendedores fabricados, ou seja, a escala é graduada a cada 1,6mm. Assim, conclui-se que com a utilização da mesma, pode se atingir uma precisão de aproximadamente 0,8mm (metade da menor divisão da escala) na determinação do comprimento correto do prendedor a ser instalado. Este nível de imprecisão na leitura de até 0,8mm é absorvida na instalação dos prendedores reais, por meio de raios de concordância, chanfros e outras características geométricas específicas, que não geram efeitos negativos de concentração de tensões e fadiga. Assim, diferenças entre os valores dos comprimentos dos furos determinados através da medida mecânica e pelo método automatizado proposto por este trabalho, o qual, por definição, é mais

preciso que o visual mecânico, que menores ou iguais a 0,8mm, podem ser desconsideradas.

Tendo-se explicado estes conceitos, parte-se para se determinar os resultados fornecidos pela 1, listados a seguir. Nesta tabela, os resultados estão indicados por siglas, cujos significados são:

- AR: Furos nos quais o resultado da medição mecânica foi idêntico ao da medição pelo método automatizado.
- E-: Furos nos quais o comprimento do prendedor, determinado pela medição mecânica, foi maior que o encontrado encontrado através do método automatizado. Entretanto, a diferença entre os métodos foi menor que 1,6mm. Como o visto no capítulo 3, diferenças deste tipo, se maiores que a tolerância de 0,8mm citada anteriormente nesta seção, trazem problemas estruturais, pois o corpo roscado do prendedor fica em contato com o corpo cilíndrico da junta.
- E+: Furos nos quais o comprimento do prendedor, determinado pela medição mecânica, foi menor que o encontrado encontrado através do método automatizado. Entretanto, a diferença entre os métodos foi menor que 1,6mm. Como o visto no capítulo 3, diferenças deste tipo, se maiores que a tolerância de 0,8mm citada anteriormente nesta seção, não trazem problemas estruturais, mas sim de peso, devido a necessidade de instalação de uma arruela adicional na instalação da porca ou colar, visando compensar o excesso de comprimento do prendedor instalado.
- EN08: Representa a porção dos furo E+ com erros compreendidos de até 0,8mm, ou seja, dentro da tolerância de 0,8mm citada anteriormente nesta seção. Estes erros, como o já explicado anteriormente, podem ser desconsiderados, pois a instalação dos prendedores com ambos os comprimentos indicados pelos dois métodos cumprirão os requisitos estruturais e podem, provavelmente, serem provenientes de imprecisões na leitura da escala mecânica.
- EN1: Representa a porção dos furo E+ com erros entre 0,8mm e 1,0mm, ou seja, fora da tolerância de 0,8mm citada anteriormente nesta seção. Devido a isso, estes erros não devem ser desconsiderados, porém, a instalação dos prendedores com ambos os comprimentos indicados pelos dois métodos cumprirão os requisitos estruturais, devido à características geométricas específicas dos prendedores como raios de concordância, chanfros e outras;
- EN+: Representa a porção dos furo E+ com erros superiores a 1,0mm, ou seja, fora da tolerância de 0,8mm citada anteriormente nesta seção. Devido a isso, estes erros não devem ser desconsiderados e a instalação do prendedor, definido pelo método automatizado, provavelmente terá que ser realizada com a inserção de uma arruela sob a porca ou o colar;

- AP: São os furos que podem ser considerados como aprovados pelo critério de validação do método automatizado pelo método mecânico, ou seja, são os furos AR somados com os EN08.
- II: Indica os furos que tiveram problema de qualidade no início do furo. O conceito se baseia na identificação dos furos mapeados pela função descrita na seção 4.3.4.1 que avalia a estabilidade de rotação da ferramenta de corte no início da furação.
- IV: Indica os furos que podem apresentar vales nos patamares das cristas. O conceito se baseia na identificação dos furos que apresentaram problemas encontrados pela função descrita na seção 4.3.4.4. Essa função avalia a ocorrência de vales de corrente indevidos, no topo das cristas, que seriam consequência de folgas entre as peças da junta furada;
- IR: Indica os furos que tiveram indício de limalhas em movimentos de recuos do *peck drill*. O conceito se baseia na identificação dos furos mapeados pela função descrita na seção 4.3.4.5. Essa função avalia a ocorrência de picos de corrente indevidos, no vale das ondas, que seriam consequência de limalhas ou demais resíduos da furação que não foram devidamente rejeitados pelo processo e, dessa forma, ainda estejam presentes junto à ferramenta de corte;
- IF: Tem o intuito de indicar os furos que tiveram problema de qualidade no final do furo. O conceito se baseia na identificação daqueles furos que apresentaram problemas segundo a função descrita na seção 4.3.4.6, que tem como principal objetivo verificar se o final da última crista coincide com o final do último ciclo do *peck drill*. Este cenário deve ser evitado, pois nessa situação, não é possível se afirmar que a junta foi totalmente vencida pela ferramenta de corte, podendo assim, o furo estar incompleto.

Tabela 1 – Resumos dos Resultados Obtidos pelo Método de Medição do Comprimento dos 60 Furos Realizados no Produto Real

	Resultados do Método										
	AR	E+	E-	EN08	EN1	EN+	AP	II	IV	IR	IF
Quantidade	32	18	0	13	5	0	45	0	0	0	10
Proporção	64%	36%	0%	26%	10%	0%	90%	0%	0%	0%	17%

Para se analisar melhor os resultados, propõe-se verificar o gráfico de sinal de uma algumas ondas em questão, para se entender como o resultado do Método computacional está se relacionando com o do método mecânico e a aderência do resultados dos algoritmos com o comportamento do sinal. Desta forma, a figura 28 apresenta o sinal de corrente de todo o ciclo de *peck drill* para o furo identificado como #7, no qual o método automatizado computacional determinou um comprimento da junta de 16, 15mm que equivale a um prendedor de comprimento

número 11 (padrão do fabricante de acordo com o explicado no capítulo 3). Essa determinação foi exatamente a mesma da obtida através do método mecânico manual.

Figura 28 – Sinal da Corrente x Tempo do furo #7



Fonte: Elaborada pelo autor.

Na figura em questão foram identificadas três regiões a serem discutidas:

- Região I: O sinal apresenta um pequeno pico anterior ao considerado pelo algoritmo como o início da furação em si. Este pequeno pico, ao analisarmos no detalhe, não foi considerado por não cumprir os requisitos do algoritmo, que prevê três leituras de corrente elétrica maiores que 1, 1,2 e 1,3 consecutivamente (ver seção 4.3.4.2). Este requisito, como o já discutido anteriormente, é uma proteção contra ruídos aleatórios durante a fase em que a ferramenta está rotacionando em vazio, porém, em casos como o desta corrente, poderia ser realmente um pequeno sinal do início da furação. O que percebeu-se durante as análises empíricas dos sinais de corrente elétrica de produtos anteriores é que, casos em que o sinal de início é pequeno o suficiente para se enquadrar em casos de ruído pelo critério do algoritmo, o erro prático adquirido pelo método não é maior que 0,25mm, o qual pode ser desconsiderado, visto as tolerâncias envolvidas nos processos de medição mecânica manual, já discutidas.
- Região II: O sinal apresenta uma região ruidosa em um vale de onda, que poderia sugerir uma situação de aumento de corrente devido à acúmulo de limalhas na ferramenta de corte, o que deveria ter sido acusado pela função do algoritmo descrita da seção 4.3.4.5. Analisando-se detalhadamente os dados da região, percebe-se que os mesmos não cumprem os critérios da função, de modo que não deve se caracterizar um caso grave de acúmulo de limalhas na ferramenta de corte. Caso o ruído seja significativo, deverá em algum momento

sensibilizar o comitê de redes neurais MLP, cujos resultados estão descritos na seção 6.2 a seguir.

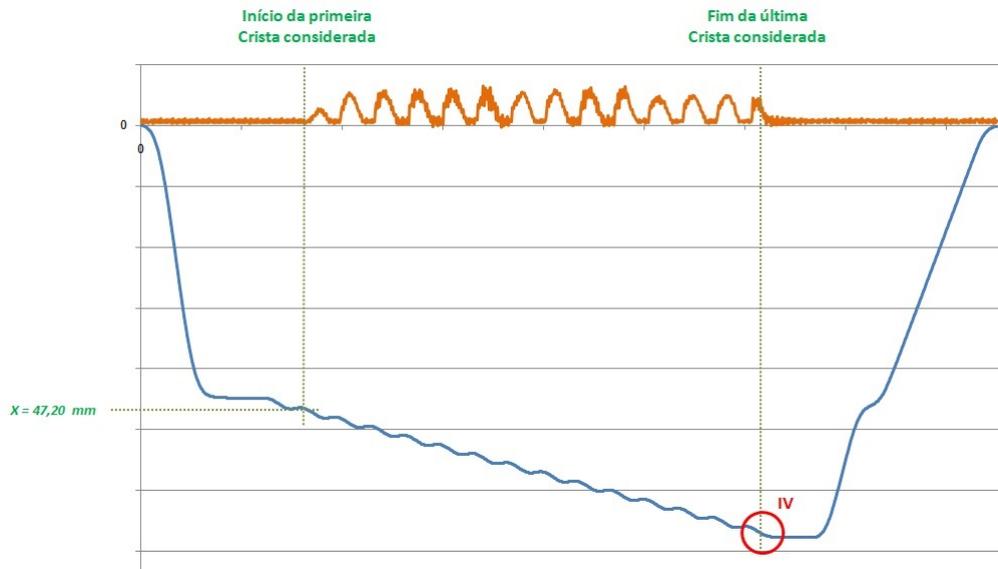
- Região III: Assim como a "Região I", esta região se caracteriza por um pico de onda que aparece no sinal da corrente após o término da furação determinado pelo método computacional. Este pico não foi considerado uma crista por não cumprir os requisitos do algoritmo que prevê três leituras de corrente elétrica maiores que 1, 1,2 e 1,3 consecutivamente (ver seção 4.3.4.2). Como explicado na "Região I", mesmo em casos em que o sinal da última crista é pequeno o suficiente para se enquadrar em casos de ruído pelo critério do algoritmo, o erro prático adquirido pelo método não é maior que 0,25mm podendo ser desconsiderado, baseado nas tolerâncias envolvidas nos processos de medição mecânica e manual já discutidas.

A figura 29 mostra o exemplo do furo 14 que é um dos que apresentaram problemas em seu final. Tais problemas foram indicados pela função descrita na seção 4.3.4.6, que tem por objetivo verificar se o final da crista coincide com o final do último ciclo do *peck drill*. Nesta figura, é possível observar, que a região demarcada como "IV" demonstra a proximidade do fim da última crista com o fim do ciclo do *peck drill*, indicando o cenário de incerteza, pois não há como se afirmar que a ferramenta venceu o pacote, já que o fim da última crista coincide com a profundidade máxima que o curso da ferramenta alcançou. Para melhor compreender esta situação pode-se observar a figura 30, onde após o término da última crista da corrente, observa-se ainda um ciclo de avanço do movimento do *peck drill* sem que haja aumento da corrente, evidenciando assim que o furo foi executado de forma completa na junta. É importante explicar que, nestas condições, o furo executado pelo sistema não deve apresentar problemas de qualidade como diâmetro fora de tolerância por exemplo. O fato do furo não ter sido completado em sua totalidade, não se caracteriza como um agente externo que irá aumentar a vibração ou outros fatores impactantes, ou seja, não afeta outros parâmetros, apenas o seu completamento em si. Este problema tem sua causa baseada em programação da máquina de furação e na variação do comprimento total da junta a ser furada, por fatores já discutidos no capítulo 3. Assim, um vez encontrado o problema, a definição do avanço máximo do cabeçote para aqueles determinados furos deve ser aumentado para a furação de um próximo produto.

Finalmente, o furo 19 ilustra a situação em que a determinação do comprimento do prendedor por via computacional ficou maior 0,3mm do que a realizada manualmente. Assim, analisando-se o sinal de corrente da onda do furo 19, mostrado na figura 30, observa-se que o instante de final da última crista, definido pela marca em roxo na região VI, está coerente com a resposta gráfica esperada. Tal instante está posicionado onde realmente parece ser o final do último patamar.

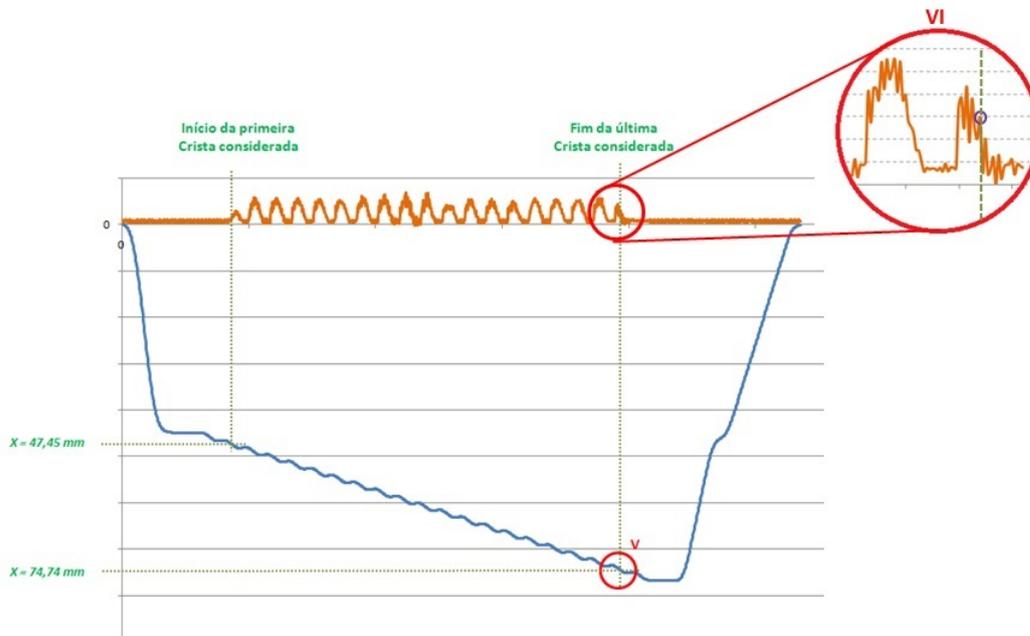
Deste modo, pode-se dizer que a pequena diferença nas medições se devem a imprecisões da leitura da escala mecânica, discretização do sinal analógico e a aproximações do algoritmo,

Figura 29 – Sinal da Corrente x Tempo do furo14



Fonte: Elaborada pelo autor.

Figura 30 – Sinal da Corrente x Tempo do furo 19



Fonte: Elaborada pelo autor.

como o cálculo da *Patamar Crista*.

Concluindo, de acordo com a tabela 1, observa-se que os algoritmos propostos têm desempenho satisfatório já que não há furos em que o algoritmo tenha calculado comprimentos maiores que o real, com erros superiores a 1,0mm (0% em EN+), tampouco furos em que o algoritmo tenha calculado comprimentos menores que o real erros (0% em E-). Além disso,

a discussão dos resultados com a exploração de alguns gráficos de corrente, demonstram o funcionamento dos algoritmos desenvolvidos para este trabalho.

6.2 Resultados Obtidos com a Metodologia de Avaliação da Qualidade do Furo

Os primeiros resultados a serem discutidos nesta seção são referentes ao treinamento das redes neurais MLP, que possibilitaram a determinação adequada da quantidade de camadas escondidas e de neurônios nas mesmas.

6.2.1 Determinação da Quantidade de Camadas Escondidas e Neurônios das Redes MLP

O algoritmo de treinamento utilizado para as redes MLP neste trabalho será o *back-propagation* e a divisão do conjunto de dados do corpo de prova para o treinamento será feito de forma randômica seguindo a proporção de 70:15:15 para o treinamento, validação e teste, respectivamente, como o feito em (CAGGIANO *et al.*, 2018). Para se determinar a quantidade otimizada de neurônios nas camadas ocultas, 200 redes foram geradas aleatoriamente para cada quantidade de neurônios de 1 a 200, usando o conjunto de dados de treinamento. Como resultado de cada configuração de neurônios, temos a média do erro e seu desvio padrão, considerando a saída da rede neural e os resultados de referência do conjunto de dados de treinamento. A figura 31 mostra a tendência de redução do erro médio de classificação nas redes MLP, considerando uma única camada escondida, em função do número de neurônios desta camada escondida.

A partir desta informação, conclui-se que esta arquitetura de rede tem uma tendência de redução do erro conforme o número de neurônios na camada escondida cresce, porém, ocorre proporcionalmente o aumento do custo computacional. A tabela 2 mostra os melhores resultados em termos de erros, desvio padrão médio e quantidades de neurônios. Para cada linha da tabela, foi também incluída a informação da proporção das 200 redes treinadas que obtiveram eficiência máxima no treinamento com os dados do corpo de prova.

Também foram geradas 200 redes aleatoriamente para configurações com duas camadas escondidas. As combinações testadas, foram determinadas a partir de quantidades próximas as de neurônios mais eficazes nas redes com uma única camada, variando tal quantidade entre a primeira e segunda camadas. Os melhores resultados obtidos são mostrados na tabela 3:

A partir destes resultados, optou-se inicialmente por escolher as 10 arquiteturas de das Redes MLP que apresentaram os melhores resultados, em termos de erro e desvio padrão médios, nos testes realizados. Contudo, observou-se que a diferença entre os erros e desvios é pequena. Assim, optou-se por selecionar entre as melhores redes aquelas com arquiteturas diversificadas, considerando uma e duas camadas escondidas, além de uma quantidade de neurônios mais

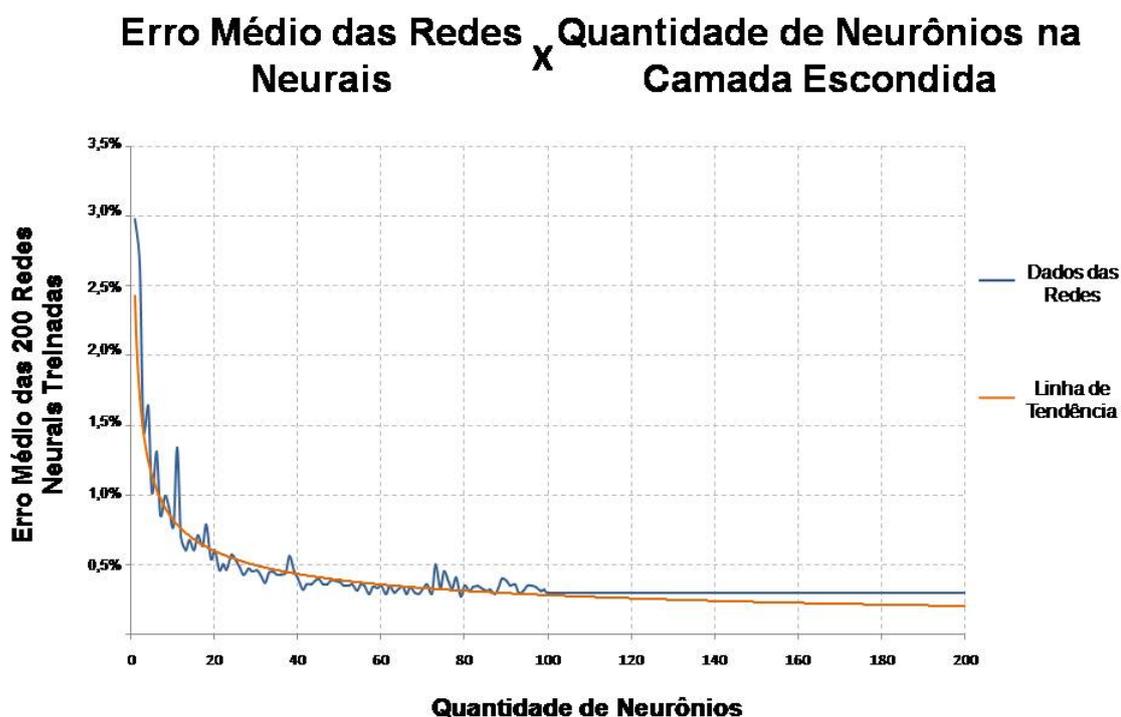
Tabela 2 – Arquiteturas das Redes MLP com Simples Camada que apresentaram os Melhores Resultados Estatísticos de Erro

ID Rede Neural	Quantidade de Neurônios		Resultados		
	Camada Escondida	Erro Médio	Desvio Padrão	Redes Erro Nulo	
MLP #1	79	0,27%	0,43 %	60 %	
MLP #2	57	0,29%	0,41 %	56 %	
MLP #3	61	0,29%	0,42 %	54 %	
MLP #4	66	0,29%	0,42 %	56 %	
MLP #5	72	0,29%	0,42 %	54 %	
MLP #6	63	0,30%	0,36 %	49 %	
MLP #7	68	0,30%	0,41 %	51 %	
MLP #8	85	0,31%	0,40%	49 %	
MLP #9	94	0,31%	0,42%	51 %	
MLP #10	41	0,32%	0,40%	49 %	

Tabela 3 – Arquiteturas das Redes MLP com Dupla Camada que apresentaram os Melhores Resultados Estatísticos de Erro

ID Rede Neural	Quantidade de Neurônios		Resultados		
	Camada Escondida 1	Camada Escondida 2	Erro Médio	Desvio Padrão	Redes Erro Nulo
MLP #1	100	98	0,22%	0,35%	63%
MLP #2	100	99	0,23%	0,36%	62%
MLP #3	97	100	0,24%	0,39%	62%
MLP #4	100	102	0,24%	0,40%	62%
MLP #5	200	201	0,24%	0,48%	66%
MLP #6	81	80	0,25%	0,36%	59%
MLP #7	103	100	0,25%	0,37%	59%
MLP #8	100	100	0,26%	0,41%	59%
MLP #9	81	79	0,26%	0,42%	59%
MLP #10	80	70	0,26%	0,43%	63%

Figura 31 – Gráfico do Erro médio em Função da Quantidade de Neurônios



Fonte: Elaborada pelo autor.

diferenciadas. As 10 redes selecionadas formam o comitê de redes neurais utilizado neste trabalho e estão listadas na tabela 4. Temos sete redes MLP com duas camadas e três com uma única camada escondida.

A tabela anterior mostra que a eficiência das redes tem uma saturação de erro médio em torno de 0,25%. O fato do resultado do erro médio das 200 redes #5 treinadas (220 neurônios na primeira camada escondida e 201 na última) ser igual a 0,24%, ou seja, um valor que não representa diferença relevante para a média citada, nem para as demais redes, confirma a saturação.

Assim, uma vez definida a topografia das redes, deve-se então escolher uma, dentre as 200 redes treinadas para cada um destas topografias para formar o comitê. Estas redes tem como requisito ter obtido acerto máximo na análise dos dados de treinamento, teste e validação. Em outras palavras, para cada uma das topografias escolhidas, uma dentre as 200 redes treinadas deve ser escolhida, ou seja, com todos os parâmetros definidos (pesos, bias, etc), de modo que como resultado final tenhamos 10 redes treinadas, cada uma representando uma das 10 configurações escolhidas, para compor o comitê.

Como exemplo, é necessário se determinar qual será a rede representante da topologia

Tabela 4 – Arquiteturas das Redes MLP com os Melhores Resultados Estatísticos de Erro

ID Rede Neural	Quantidade de Neurônios		Resultados		
	Camada Escondida 1	Camada Escondida 2	Erro Médio	Desvio Padrão	Redes Erro Nulo
MLP #1	100	98	0,22%	0,35%	63%
MLP #2	100	99	0,23%	0,36%	62%
MLP #3	97	100	0,24%	0,39%	62%
MLP #4	100	102	0,24%	0,40%	62%
MLP #5	200	201	0,24%	0,48%	66%
MLP #6	103	100	0,25%	0,37%	59%
MLP #7	80	70	0,26%	0,43%	63%
MLP #8	N/A*	79	0,27%	0,43%	60%
MLP #9	N/A*	94	0,31%	0,42%	51%
MLP #10	N/A*	41	0,32%	0,40%	49%

*"N/A": Não Aplicável.

de camada escondida única contendo 79 neurônios. Assim, procurou-se uma rede com camada escondida única contendo 79 neurônios dentre as 200 que fizeram o seu treinamento. Assim, escolheu uma destas redes treinadas, cuja matriz de confusão referente ao resultado do seu treinamento está identificada como 7 na tabela 4, está mostrada na figura 32.

6.3 Resultados Obtidos com as Redes MLP Definidas no Produto Final

Um total de 60 furos foram realizados no produto real, onde a área de furação coberta compreendeu juntas com espessuras diferentes, seguindo uma programação normal de furação da máquina. É importante lembrar que o material do produto, a ferramenta e os parâmetros de corte foram os mesmos usados para gerar o conjunto de dados de treinamento. Após a furação, todos os furos foram medidos, inspecionados e aprovados por um inspetor de qualidade humano, então, nenhum, ou ao menos, poucos furos deveriam ser classificados como *não aceitáveis* pela modelagem proposta.

Durante o processo de furação, o *padrão de corrente elétrica* foi coletado de todos os furos e analisado por todos os blocos do modelo, como mostrado na figura 27. Seguindo a próxima etapa do método proposto, o pré-processador enviou as ondas referentes a cada um dos 60 furos para serem analisadas pelo bloco de rede neural, totalizando 835 ondas. Deste total de furos, a tabela 6.3 mostra como cada uma das redes MLP classificou, individualmente, as ondas de 9 furos selecionados como exemplo. Estes 9 furos foram selecionados para a discussão pois,

Figura 32 – Tabela de Confusão da Rede MLP com Simples Camada de 79 Neurônios



Fonte: Elaborada pelo autor.

apresentam ao menos uma onda classificada como *não normais* por alguma das redes MLP, o que implica em uma classificação de *não aceitável* para o respectivo furo. Os 51 furos restantes não apresentaram nenhuma onda classificada como *não normal*, ou seja, foram classificados como bons pelo comitê de redes MLP por unanimidade.

A tabela 6.3 mostra o número de identificação de cada um dos 9 furos exemplificados juntamente com a informação da quantidade de ondas classificadas por furo, ou seja, quantas ondas existiam em seu sinal de furação, as quais foram separadas pelo pré-processador e enviadas ao bloco de redes MLP (lembrando que a quantidade de ondas é proporcional ao comprimento da junta furada). A tabela 6.3 traz ainda, para cada um dos 9 furos, quantas das suas ondas foram classificadas como *não normais* por cada uma das redes MLP. Note que nesta etapa, os resultados ainda não foram submetidos ao bloco do pós-processador, de forma que se pode analisar o comportamento das redes sem nenhuma ação do comitê, tão pouco de qualquer fator de segurança. Para melhor compreender a classificação realizada pelas redes MLP, considerando os furos #7, #23, #35, #38 e #39 onde mais redes MLP indicaram ondas *não normais*, construiu-se a tabela 6 que apresentam o número sequencial das cristas classificadas como *não normais* dentro

Tabela 5 – Resultados Individuais das Redes MLP - Furos Contendo Ondas Não Normais

Contagem de Ondas "Não Normais"									
ID do Furo	#7	#16	#21	#23	#33	#35	#38	#39	#60
Total de Ondas (Info)	9	16	18	18	17	19	17	16	16
MLP #1	0	0	1	2	0	1	2	1	0
MLP #2	1	1	0	2	0	1	1	1	1
MLP #3	0	0	0	0	0	1	0	0	0
MLP #4	1	0	1	1	0	1	2	1	0
MLP #5	1	1	0	2	0	1	2	1	1
MLP #6	1	0	0	2	0	1	0	0	0
MLP #7	0	0	0	2	1	1	0	0	0
MLP #8	0	0	0	0	1	1	0	0	0
MLP #9	0	0	0	0	0	1	0	0	0
MLP #10	0	0	0	1	0	2	0	0	0

do sinal de corrente de um dos citados furos.

Tabela 6 – Resultados Individuais das Redes MLP - Posição das Ondas Não Normais

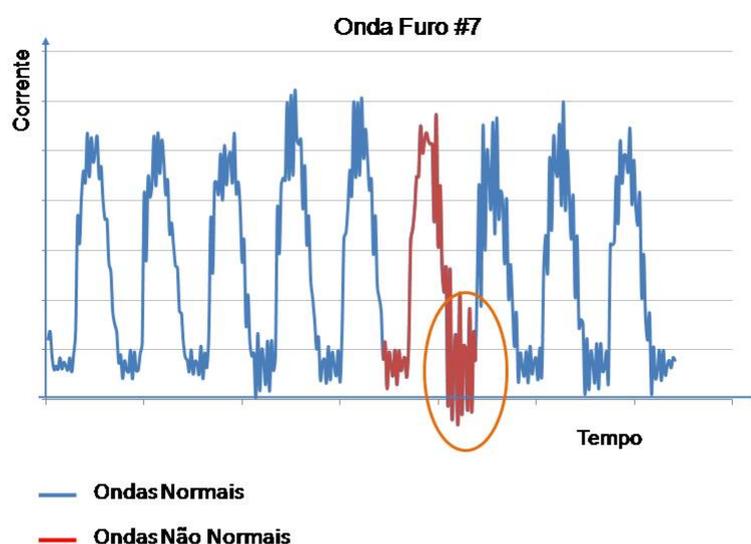
Posição das Ondas "Não Normais"					
ID do Furo	#7	#23	#35	#38	#39
MLP #1	0	15 ^a e 18 ^a	16 ^a	17 ^a e 18 ^a	16 ^a
MLP #2	6 ^a	15 ^a e 18 ^a	16 ^a	17 ^a	16 ^a
MLP #3	0	0	16 ^a	0	0
MLP #4	6 ^a	18 ^a	16 ^a	17 ^a e 18 ^a	16 ^a
MLP #5	6 ^a	15 ^a e 18 ^a	16 ^a	17 ^a e 18 ^a	16 ^a
MLP #6	6 ^a	15 ^a e 18 ^a	16 ^a	0	0
MLP #7	0	15 ^a e 18 ^a	16 ^a	0	0
MLP #8	0	0	16 ^a	0	0
MLP #9	0	0	16 ^a	0	0
MLP #10	0	18 ^a	16 ^a e 17 ^a	0	0

Os dados da tabela 6 indicam o grau de coerência entre a classificação das redes, confirmando o correto treinamento na base de dados do corpo de prova. Observa-se na tabela 6.3 que as redes MLP#2, MLP#4, MLP#5 e MLP#6 encontraram, cada um, um onda *não normal* no sinal de corrente do furo #7. A tabela 6 destaca o fato destas redes, já citadas, apontarem a mesma onda como a *não normal* no conjunto de ondas do sinal de corrente do furo #7.

Ainda com base nos resultados mostrados acima, a figura 33 destaca a sexta onda do sinal de corrente do furo #7. Esta onda foi classificada como ruim por 4 redes do bloco MLP (MLP#2, MLP#4, MLP#5 e MLP#6). É importante observar que esta onda apresenta uma particularidade, principalmente no vale posterior à sua crista, que se encontra indicado pela elipse laranja. Essa observação foi mencionado na figura 28 da seção 6.1 e discutida como área "II". A figura 34

mostra o sinal de corrente do furo #35 onde é possível fazer uma análise análoga à realizada para o furo #7. A 16ª onda, identificada com a cor vermelha, aparenta realmente ser diferenciada, por um pico acima do padrão em sua crista, e também por um vale muito ruidoso posterior à citada crista. A 17ª onda, destacada com a cor verde, foi citada apenas por uma das redes MLP, a MLP #10, apresentando um destaque mais discreto. Com relação ao furo #23, que também foi citado de forma relevante na tabela, observamos a sua corrente na figura 35. Nota-se que a 15ª onda, indicada em vermelho na figura em questão, possui um pico excessivo em sua crista, que parece estar realmente em destaque das demais, o que parece justificar o porque das redes MLP a classificarem como não normal. Já a 18ª onda, indicada em verde na figura, tem destaque discreto.

Figura 33 – Sinal de Corrente do Furo 7 - Destaque à Onda Não Normal

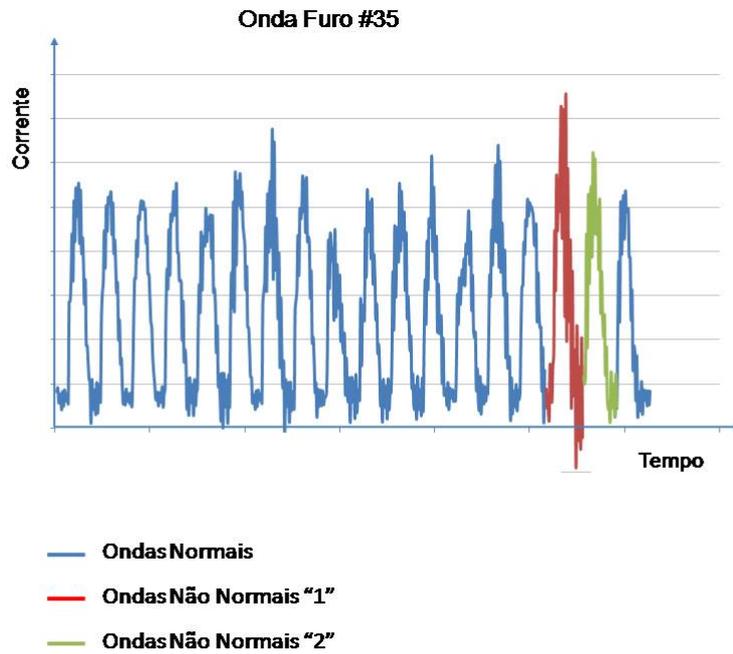


Fonte: Elaborada pelo autor.

Devemos lembrar que todos os 60 furos foram aprovados pela medição mecânica manual, ou seja, deveriam ter sido classificados como bons pelas redes neurais. Por isso, discutimos agora os resultados finais do método proposto ao considerar o bloco "pós-processador". Como descrito na seção 5.5, o pós-processador é o sistema que vai avaliar o resultado das redes neurais MLP a partir do fator de segurança adotado. Deste modo, aplica-se a média aritmética dos resultados das redes individuais, onda a onda. A partir dos furos previamente citados como possíveis *não aceitáveis* na tabela 6.3, obtém-se os resultados finais mostrados na tabela 7:

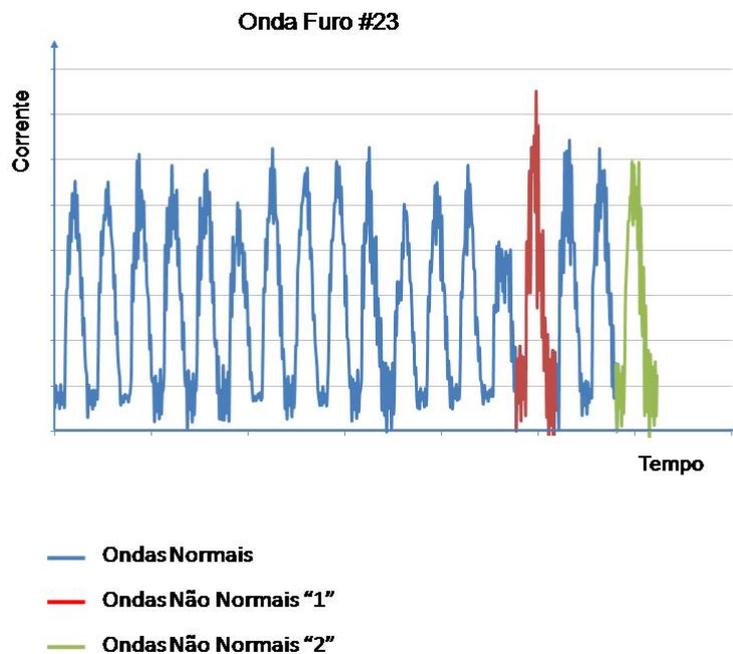
O comitê faz uso da média aritmética nos resultados individuais das redes MLP, que tem como princípio considerar o senso da maioria. Todavia, levando-se em conta o grau de certeza de classificação das redes, observa-se que apenas os furos #23 e #35 seriam considerados

Figura 34 – Sinal de Corrente do Furo 35 - Destaque às Ondas Não Normais



Fonte: Elaborada pelo autor.

Figura 35 – Sinal de Corrente do Furo 23 - Destaque às Ondas Não Normais



Fonte: Elaborada pelo autor.

não aceitáveis pelo modelo com comitê e deveriam ter sua inspeção manual realizada. Com

Tabela 7 – Resultados das Redes MLP e Comitê - Furos Contendo Ondas Não Normais

Contagem de Ondas "Não Normais"									
ID do Furo	#7	#16	#21	#23	#33	#35	#38	#39	#60
MLP #1	0	0	1	2	0	1	2	1	0
MLP #2	1	1	0	2	0	1	1	1	1
MLP #3	0	0	0	0	0	1	0	0	0
MLP #4	1	0	1	1	0	1	2	1	0
MLP #5	1	1	0	2	0	1	2	1	1
MLP #6	1	0	0	2	0	1	0	0	0
MLP #7	0	0	0	2	1	1	0	0	0
MLP #8	0	0	0	0	1	1	0	0	0
MLP #9	0	0	0	0	0	1	0	0	0
MLP #10	0	0	0	1	0	2	0	0	0
Comitê (Sem Fator Segurança)	0	0	0	1	0	1	0	0	0

relação às ondas que permaneceram classificadas como *não normais*, após a tratativa das saídas individuais de cada rede MLP pelo comitê, temos a tabela 8

Tabela 8 – Resultados das Redes MLP e Comitê - Posição das Ondas Não Normais

Posição das Ondas "Não Normais"					
ID do Furo	#7	#23	#35	#38	#39
MLP #1	0	15 ^a e 18 ^a	16 ^a	17 ^a e 18 ^a	16 ^a
MLP #2	6 ^a	15 ^a e 18 ^a	16 ^a	17 ^a	16 ^a
MLP #3	0	0	16 ^a	0	0
MLP #4	6 ^a	18 ^a	16 ^a	17 ^a e 18 ^a	16 ^a
MLP #5	6 ^a	15 ^a e 18 ^a	16 ^a	17 ^a e 18 ^a	16 ^a
MLP #6	6 ^a	15 ^a e 18 ^a	16 ^a	0	0
MLP #7	0	15 ^a e 18 ^a	16 ^a	0	0
MLP #8	0	0	16 ^a	0	0
MLP #9	0	0	16 ^a	0	0
MLP #10	0	18 ^a	16 ^a e 17 ^a	0	0
Comitê (Sem Fator Segurança)	0	15 ^a	16 ^a	0	0

Para melhor compreender a ação do comitê, vamos analisar a tabela 9 que mostra a saída numérica de cada uma das nove ondas que compõe o sinal de onda do furo #7, analisadas por cada uma das redes MLP. As tabelas 10 e 11 apresentam os mesmos dados para as 18 ondas que formam o furo #35.

Avaliando as tabelas 9, 10 e 11, temos que a análise do furo se inicia em cada onda que é proveniente da etapa do pré-processador. A partir do pré-processamento desses dados, cada rede MLP faz a análise de classificação onda por onda, atribuindo um número na saída entre [0;1,0] para cada uma das ondas analisadas. Lembre-se que números pertencentes ao intervalo [0,5;1,0]

Tabela 9 – Resultados das Redes MLP e Comitê - Onda do Furo 7

Valor Número de Saída das Redes MLP por Onda - Furo #7									
Onda	#1	#2	#3	#4	#5	#6	#7	#8	#9
MLP #1	1,00	1,00	0,99	0,99	1,00	0,79	0,99	0,99	0,99
MLP #2	1,00	1,00	1,00	1,00	1,00	0,38	0,96	1,00	1,00
MLP #3	1,00	1,00	1,00	1,00	1,00	0,94	0,99	1,00	1,00
MLP #4	1,00	1,00	1,00	1,00	1,00	0,23	0,99	1,00	1,00
MLP #5	1,00	1,00	1,00	1,00	1,00	0,14	0,99	1,00	1,00
MLP #6	1,00	1,00	0,99	0,99	1,00	0,41	0,99	0,99	0,99
MLP #7	1,00	1,00	1,00	0,99	1,00	0,90	0,99	0,99	0,99
MLP #8	1,00	1,00	1,00	1,00	1,00	0,96	0,99	1,00	1,00
MLP #9	0,99	0,99	0,99	0,99	0,99	0,68	0,98	0,99	0,99
MLP #10	1,00	1,00	1,00	1,00	1,00	0,70	0,91	1,00	1,00
Comitê *	1,00	1,00	0,99	0,99	1,00	0,61	0,98	0,99	0,99

*: Sem aplicação do Fator de Segurança.

Tabela 10 – Resultados das Redes MLP e Comitê - Onda do Furo 35

Valor Número de Saída das Redes MLP por Onda - Furo #35									
Onda	#1	#2	#3	#4	#5	#6	#7	#8	#9
MLP #1	1,00	1,00	0,99	0,99	0,99	0,99	0,99	1,00	1,00
MLP #2	1,00	1,00	1,00	1,00	1,00	0,99	1,00	1,00	1,00
MLP #3	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
MLP #4	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
MLP #5	1,00	1,00	1,00	1,00	1,00	0,99	1,00	1,00	1,00
MLP #6	1,00	1,00	0,99	0,99	0,99	0,99	0,99	0,99	1,00
MLP #7	1,00	1,00	0,99	0,99	0,99	0,99	0,99	1,00	1,00
MLP #8	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
MLP #9	0,99	0,99	0,99	0,99	0,99	0,99	0,98	0,99	1,00
MLP #10	1,00	1,00	1,00	1,00	0,99	0,99	1,00	1,00	1,00
Comitê *	1,00	1,00	0,99	0,99	0,99	0,99	0,99	1,00	1,00

*: Sem aplicação do Fator de Segurança.

Tabela 11 – Resultados das Redes MLP e Comitê - Ondas do Furo 35 - Continuação

Valor Número de Saída das Redes MLP por Onda - Furo #35									
Onda	#10	#11	#12	#13	#14	#15	#16	#17	#18
MLP #1	1,00	1,00	1,00	1,00	0,99	0,99	0,00	0,74	1,00
MLP #2	1,00	1,00	1,00	1,00	1,00	1,00	0,00	0,86	1,00
MLP #3	1,00	1,00	1,00	1,00	1,00	1,00	0,01	0,67	1,00
MLP #4	1,00	1,00	1,00	1,00	1,00	1,00	0,00	0,96	1,00
MLP #5	1,00	1,00	1,00	1,00	1,00	0,99	0,00	0,80	1,00
MLP #6	1,00	1,00	1,00	1,00	0,99	0,99	0,09	0,99	1,00
MLP #7	1,00	1,00	1,00	1,00	0,99	0,99	0,01	0,97	1,00
MLP #8	1,00	1,00	1,00	1,00	1,00	1,00	0,01	0,99	1,00
MLP #9	1,00	0,99	1,00	1,00	0,99	0,99	0,16	0,94	0,99
MLP #10	1,00	1,00	1,00	1,00	1,00	1,00	0,00	0,46	1,00
Comitê *	1,00	1,00	1,00	1,00	0,99	0,99	0,03	0,83	1,00

*: Sem aplicação do Fator de Segurança.

indicam ondas *normais* e ao intervalo [0,0 ; 0,5] ondas *não normais*. A partir desta etapa, o comitê calcula a média aritmética das saídas de cada rede MLP, para cada onda analisada de um determinado furo. Logo, a tabela 9 mostra todas as saídas numéricas para cada uma das 9 ondas que compunham o sinal de corrente deste furo. Por exemplo, as quatro redes MLP#2, MLP#4, MLP#5 e MLP#6 indicam a 6ª onda como *não normal*.

Os valores da média calculada pelo comitê se encontram na última linha da matriz e representam a média por coluna da matriz. Assim, no caso do furo #7, pode-se perceber que a média das classificações realizadas pelas 10 redes MLP para a onda em questão (6ª onda) #6 foi de 0,61, ou seja, apesar de 4 redes a classificarem como *não normal* o senso comum, através do comitê, a classificou como *normal*. Com esse resultado, o pós-processador classificaria o furo#7 como *aceitável* já que o critério é simplesmente a não existência de nenhuma onda classificado como *não normal*.

De forma análoga, observando-se as tabelas 10 e 11, temos que a aplicação da média pelo comitê foi suficiente para deixar a onda #17 classificada como *normal*, porém, insuficiente para a onda 16, o qual permaneceu classificada como *não normal*. Com esse resultado, para este furo específico, o pós-processador continuaria classificando o furo#35 como *não aceitável* já que o critério é simplesmente a existência de ao menos um onda classificado como *não normal*.

Com estes últimos resultados, conclui-se que o método em si indicaria apenas os furos #23 e #35 para serem inspecionados manualmente, representando um acerto de 96,7%, visto que na realidade todos os furos estão aprovados. Em termos de ondas, estes 60 furos geraram 835 ondas para serem analisadas pelo modelo. Destas, apenas 2 foram consideradas *não aceitáveis*, indicando uma assertividade 99,7%.

Por se tratar de uma estrutura primária aeronáutica, como já mencionado na seção 5.5,

propõe-se a utilização de um coeficiente de segurança com o intuito de se explorar algum grau de incerteza na classificação de uma determinada onda, ao se obter os dados finais do comitê. Se fosse adotado apenas o conceito de voto majoritário, teríamos todas os #9 furos inicialmente discutidos na tabela 6.3. Logo, devemos definir valor do coeficiente de segurança mais adequado. A tabela 12 mostra os resultados da classificação final do comitê (pós-processador) usando fatores de segurança de 0,0 a 0,5, para se entender o grau de sensibilidade deste fator.

Tabela 12 – Resultado Final do Modelo de Avaliação da Qualidade dos 60 Furos Executados no Produto Real

	Fatores de Segurança					
	0.00	0.10	0.15	0.20	0.25	0.30
Avaliação do Comitê Furos Ruins	2	2	3	7	9	9
Assertividade do Comitê	96,7%	96,7%	95,0%	88,3%	85%	85%
ID dos Furos Ruins	#23 #35	#23 #35	#7 #23 #35	#7 #21 #23 #33 #35 #38 #39	#7 #16 #21 #23 #33 #35 #38 #39 #60	#7 #16 #21 #23 #33 #35 #38 #39 #60

Os resultados estão organizados de modo a apresentar a quantidade de furos classificados como *não aceitáveis* e também o ID dos mesmos para cada configuração de fator de segurança. A assertividade, como já descrito neste trabalho, foi calculada considerando que o modelo deveria ter classificado todos os furos como *aceitáveis* já que a inspeção mecânica manual dos mesmos chegou a este resultado. Os valores listados indicam a importância de se utilizar um coeficiente de segurança coerente, para se manter sob controle qualquer imprecisão proveniente de modelos e aproximações matemáticas.

Nesse contexto, foi adotado um fator de segurança de 0.15 que reprova ondas caso a certeza de classificação por parte do comitê não seja maior que 65:35 e, conseqüentemente, indica a inspeção mecânica manual do furo em questão. Este fator proposto se mostra adequado ao fazer com que o comitê indique para análise os furos #7, #23, e #35, alcançando uma assertividade de 95% no processo de previsão de erros no processo de furação. Conforme o observado na tabela 12, ao se aumentar mais os valores do fator de segurança, volta-se a obter o cenário de aprovação próximo dos classificados pelas redes MLP de forma independente, como listado na tabela 6.3. Assim, com estes fatores maiores, volta-se à condições próximas ao cenário de não utilização do

comitê, perdendo-se a abordagem conceitual de senso comum entre as redes MLP discutida.

Para se melhor visualizar a ação do fator do comitê, pode-se recuperar a análise da tabela 9. Nela, pode-se observar que a onda #6 obteve um classificação numérica de 0,61, ou seja, com razão de certeza em aproximadamente 60:40. Assim, ao se aplicar o conceito do coeficiente de segurança de 0,15, todas as ondas que não cumprirem o requisito mínimo de razão de certeza de 65:35, esta onda será considerada como não normal e o furo conseqüentemente não aceitável.

CONCLUSÕES

A presente dissertação estudou e propôs métodos capazes de determinar de forma automática a qualidade dos furos executados pelas máquinas que impactam nos prendedores alocados em tais furos. Assim, o objetivo estabelecido consistia em desenvolver metodologias capazes de reduzir o tempo de medição manual ao aferir de forma mais acurada a qualidade dos furos gerados. Para isso duas abordagens foram adotadas para solucionar o problema. Primeiro, foram definidos algoritmos capazes de extrair informações relevantes a partir do consumo da corrente elétrica dos acionadores da ferramenta de corte. Em seguida, análise dos dados obtidos por um comitê de redes neurais para avaliar a qualidade e necessidade de inspeção dos furos gerados.

Até onde a literatura foi revisada neste trabalho, não foram encontradas abordagens aplicando comitê de redes neurais para se determinar a qualidade final de furos por meio da leitura e análise do comportamento dos parâmetros de corte. Todavia, alguns trabalhos revisados direcionaram e embasaram o desenvolvimento desta dissertação ao estabelecerem conceitos relevantes. Esse foi o caso da pesquisa reportada em (CAGGIANO *et al.*, 2018) e em (PATRA *et al.*, 2017) que buscam determinar a condição de desgaste da ferramenta a partir de dados que indicam seu modo de trabalho, ou seja, a partir de como a ferramenta está sendo exposta ao desgaste que se quer prever. Trata-se de uma relevante validação do conceito de se utilizar da leitura dos parâmetros de funcionamento da máquina e, a partir deles, prever condições que estejam correlacionadas como o desgaste da ferramenta de corte no citado artigo ou com a qualidade e o comprimento do furo nesta dissertação.

Os autores em (DANTAS *et al.*, 2018) mencionam a utilização de comitê de redes neurais, cuja regra de combinação dos resultados é baseada em média aritmética, regra também adotada nesta dissertação. Esta citação trouxe segurança para o emprego da média aritmética como função de combinação dos resultados no comitê. Finalmente, em (RUIZ *et al.*, 2020) e (SACCO *et al.*, 2020), os autores propõem a utilização de redes neurais para inspeção de atividades produtivas,

porém, via classificação de imagens. Portanto, entende-se que estes e outros artigos citados no capítulo 2, têm pontos em comum com este trabalho e vieram, de alguma forma, auxiliar e direcionar o desenvolvimento dos métodos aqui utilizados.

Com relação a determinação do comprimento dos furos executados pelo sistema furação, pode-se concluir que os algoritmos propostos por este trabalho são eficientes e trouxeram resultados coerentes com os encontrados no produto real, ao compará-los com a medição mecânica. De acordo com a tabela 1, não há furos em que o algoritmo tenha calculado comprimentos maiores que o real, com erros superiores a 1,0mm (0% em EN+), tampouco furos em que o algoritmo tenha calculado comprimentos menores que o real (0% em E-). Logo, os resultados obtidos revelaram que, não houve necessidade de inserção de arruelas na instalação dos prendedores tão pouco riscos estruturais, fatos que ocorreriam caso os erros citados anteriormente tivessem sido encontrados, o que indica o cumprimento com os requisitos estruturais referentes à instalação dos prendedores, conforme o descrito na seção 3.3.1.

Além disso, a discussão dos resultados, com a análise de alguns gráficos da corrente em função do tempo, demonstram o correto funcionamento dos algoritmos desenvolvidos para este trabalho. Foi possível verificar que a determinação do início e fim das ondas ocorreu da forma esperada, comprovando que a lógica determinada para se tratar os sinais, está de acordo com o que ocorre na realidade. Concluindo, avaliando novamente os resultados da tabela 1, o método demonstrou uma acurácia considerada de 90% sendo que, os 10% restantes, não causaram problemas de instalação dos prendedores no produto. Sendo assim, o método se comprova em termos de lógica de funcionamento, uma vez que tratou os sinais do modo esperado e retorna resultados com precisão satisfatória e segurança suficiente para que continue a ser utilizado e testado no ambiente produtivo.

Com relação à metodologia de avaliação da qualidade do furo, a partir dos resultados obtidos, é possível entender a importância de se usar a função de combinação, ou seja, o comitê de redes MLP frente à redes individuais. Mesmo que as redes MLP #3 e MLP #9 pareçam mais precisas, na análise dos 60 furos realizados no produto real, conforme o descrito na seção 6.3, o fato das outras redes apresentarem informações diferentes não pode ser desconsiderado.

Isso se justifica pelo fato de que todas as redes selecionadas para o comitê foram treinadas usando o mesmo conjunto de dados e com 100% de precisão. Assim, não se pode excluir a possibilidade das redes MLP #3 e MLP #9 terem sido mais precisas para este conjunto de dados mas, podem não apresentar a mesma qualidade de classificação para um próximo e diferente conjunto de dados. Assim, todas as diferenças observadas entre as redes, ao analisar novas ondas, devem ser um problema de sensibilidade e, dependendo da característica da onda, uma ou outra rede pode ter o melhor desempenho. Portanto, o uso do bom senso entre todas as redes é o correto para este tipo de problema, ou seja, o uso do comitê.

Um fator de segurança foi proposto e utilizado e os testes do produto revelam que sua aplicação é importante no tipo de problema aqui abordado. Observou-se que fatores maiores que

0,15 são excessivos, pois a Função de Combinação, nesses casos, apresenta o pior caso de todos. Se todos os sentidos tenderem demais, o bom senso pode ser demasiadamente afetado. Desta forma, a ideia é usar um fator de segurança de 0,15 sobre a saída da Função de Combinação.

Concluindo, as redes MLP demonstraram boa eficiência na classificação de sinais elétricos. A tabela 12 mostra que o modelo final proposto para a utilização, aplicando fator de segurança de 0,15, alcançou uma eficiência de 95% nos dados avaliados com 3 furos falsos negativos entre os 60 analisados no produto real. Se considerarmos a eficiência com base em ondas, a precisão do método seria maior que 99%, uma vez que o método classificou apenas 4 ondas de forma incorreta. Logo, ocorreram 4 falsos negativos, sendo 1 no furo #7, 2 no furo #23 e 1 no furo#35 dentre as 835 analisadas no total. Assim, o método proposto nesta dissertação, para se classificar os furos quanto a qualidade, demonstrou eficácia para solucionar o problema proposto, com precisão satisfatória para se classificar os furos conforme os requisitos descritos na seção 3.3.2. Desta forma o método tem condições de ser utilizado na produção, e as amostragens por inspeções mecânicas podem ser cada vez mais espaçadas, conforme esta metodologia vá se comprovando robusta.

Por fim, ainda com relação ao modelo de classificação dos furos quanto a sua qualidade, nota-se a falta de amostras negativas, ou seja, de furos comprovadamente ruins no produto, que traria possibilidade de se avaliar o comportamento da metodologia nestas condições. Porém, do ponto de vista prático, não se pode induzir estes erros no produto para se validar o modelo, havendo assim a necessidade de espera que eventos desse tipo venham de fato ocorrer. Portanto, a opção seria a indução de erros em um corpo de prova, o que já foi feito e descrito nesta dissertação, para a criação dos dados de treinamento e, por este motivo, este procedimento não foi repetido.

Uma análise geral da utilização dos dois métodos revela que erros em torno de 10% e 5% na determinação do comprimento e classificação quanto à qualidade respectivamente, não podem ser considerados como um resultado ruim, principalmente por serem conservativos, ou seja, a favor da segurança. Ao se considerar a classificação quanto à qualidade, mesmo que um furo *aceitável* seja incorretamente considerado *não aceitável* pelo modelo, isso implicaria na necessidade de inspeção manual do mesmo. Considerando-se a assertividade do método de aproximadamente 5%, como o mostrado na tabela 12, entende-se que, as citadas atividades de inspeção manual seriam realizadas apenas nestes mesmos 5% dos furos, percentual o qual, já representa uma relevante economia de tempo.

Destaca-se que esse método não se caracteriza como amostragem pois todos os furos são verificados pela modelagem. Na medição do comprimento, não há erros com valores que ultrapassem a tolerância prevista na instalação dos prendedores, mesmo se considerarmos que há necessidade de instalação de arruelas em 10% dos prendedores instalados. Tal percentual ainda representa um ganho relevante de horas de trabalho com a medição manual de comprimentos. Por isso, as metodologias aqui propostas e avaliadas tem grande potencial de aplicação na linha

de produção de montagem de estruturas aeronáuticas e, por isso, devem continuar a serem testadas em produtos reais até que, os resultados destes testes, mostrem que estas metodologias apresentem a robustez necessária para que sejam consideradas aptas para que sejam aplicadas de forma definitiva e em série, na linha produtiva.

Com relação a próximos passos e trabalhos futuros, as duas metodologias podem ser testadas e utilizadas por outros tipos de máquinas de furação automatizadas, que praticam diferentes movimentos de *peck drill*, em qualquer tipo de diâmetro, com todos os tipos de ferramentas de corte e com as diversas espessuras de juntas praticadas. Uma avaliação dessa abrangência de uso é um importante estudo a ser conduzido, pois implica em grandes desafios. Por exemplo, diâmetros menores podem causar alteração mais sensíveis à corrente, visto que o esforço de corte é menor, o que pode dificultar a precisão e acurácia dos métodos. Por outro lado, diâmetros maiores muitas vezes requerem um movimento de *peck drill* com avanço muito pequeno, o que pode deixar a onda muito estreita, afetando também a eficiência e acuracidade dos métodos.

Testes de hipótese podem ser inseridos como comprovação da eficiência da metodologia de determinação do comprimento da junta, para serem aplicados nos próximos produtos a serem furados com o processo atual ou para desenvolvimentos posteriores.

Como uma ação adicional para a melhoria contínua, o conjunto de dados de treinamento pode ser dinâmico, de forma que novas ondas possam ser inseridas nele conforme novos produtos são furados. A precisão do modelo certamente aumentará ao se utilizar mais dados provenientes de novos furos do produto. Esta ação também completa o conjunto de dados de treinamento, visto que inicialmente não houve oportunidade de matéria-prima para se realizar mais furos em corpos de prova, iniciando-se os testes no produto real com as redes treinadas com um volume mínimo de dados de treinamento.

Uma proposta de critério para se elencar as ondas a serem futuramente inseridas no conjunto de dados de treinamento seria apenas as que se mostrarem em desacordo com as medições mecânicas, como as discutidas na seção 6.3, que foram classificadas como *não normais* pelo comitê nos furos 7, 23 e 35. Entretanto, para trabalhar a favor da segurança, deve-se implementar ainda um sistema que atue em paralelo, formando *clusters*, através de um classificador não supervisionado, inicialmente com as ondas do conjunto de dados de treinamento e após, com as ondas geradas a partir dos novos furos realizados no produto real. É previsto que as novas ondas sejam classificadas nos *clusters* já existentes, gerados pelo conjunto de dados de treinamento. Caso algum *cluster* novo seja criado pelo classificador, a partir de uma nova onda analisada, isso indicaria que esta onda deva ser inserida no conjunto de dados de treinamento. Assim, o respectivo furo seria inspecionado mecanicamente e o *cluster* oficializado. Desta forma o sistema como um todo ficaria protegido de sinais que sejam demasiadamente diferentes dos até então existentes no conjunto de dados de treinamento.

Para se aumentar a segurança do método, pode-se também utilizar mais redes MLP no

comitê, como por exemplo todas as redes testadas, considerando-se as diversas arquiteturas (quantidades de neurônios em uma ou duas camadas escondidas) que tenham obtido erro nulo em sua fase de treinamento. Este cenário representaria a máxima diversidade, e teria-se a possibilidade de se estudar a quantidade ótima de redes MLP neste comitê, para se obter o resultado correto com o menor custo computacional possível.

Um importante desenvolvimento a se explorar é a integração entre os dois métodos discutidos neste trabalho, ou seja, o de determinação do comprimento e o da qualidade de um furo. Observou-se que qualquer tipo de ruído excessivo pode causar imprecisões na determinação do comprimento da junta. Desta forma, deve-se integrar os métodos de modo que qualquer irregularidade identificada no processo interrompa ou crie automaticamente um alerta, sugerindo a necessidade de inspeção mecânica do furo, tanto quanto ao seu comprimento quanto à sua qualidade (diâmetro). Isto significa que um método poderia avisar ao outro da ocorrência de uma irregularidade.

Outro importante desenvolvimento seria relacionado ao aumento da precisão e confiabilidade dos métodos, envolvendo a aquisição de novas máquinas com novos sensores, como acelerômetros para medição direta de vibração, termopares para medição da temperatura em pontos estratégicos do cabeçote e até microfones para aquisição de sinais sonoros dos processos (muito sensíveis à falta de óleo na furação por exemplo), já estão sendo inseridos nas especificações de novos equipamentos em virtude dos conceitos provenientes da indústria 4.0. Assim, com estes recursos instalados e disponíveis, pode-se ter mais dados a serem tratados por novas redes e pelo comitê. Nesse caso, novos corpos de prova seriam fabricados para avaliação do comportamento dos sinais gerados por estes novos sensores, frente a cenários simulando diversos fatores externos, como peças das juntas mal fixadas, falta de lubrificação na ferramenta de corte, sobre aquecimento do cabeçote, entre outros, proporcionando que os respectivos algoritmos de aprendizado de máquina sejam treinados. No caso do comitê, uma média ponderada entre as classificações poderia se considerada, e o funcionamento integrado das duas metodologias, como o já citado nos parágrafos anteriores, traria um aumento de acuracidade e segurança no processo como um todo.

REFERÊNCIAS

AAMIR, M.; GIASIN, K.; TOLOUEI-RAD, M.; VAFADAR, A. A review: drilling performance and hole quality of aluminium alloys for aerospace applications. **Journal of Materials Research and Technology**, v. 9, n. 6, p. 12484 – 12500, 2020. ISSN 2238-7854. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S2238785420317270>>. Citado na página 28.

ANAC. **Regulamento Brasileiro de Aviação Civil. RBAC nº 25, Emenda 136. REQUISITOS DE AERONAVEGABILIDADE: AVIÕES CATEGORIA TRANSPORTE**. [S.l.], 2014. Disponível em: <<https://www.anac.gov.br/assuntos/legislacao/legislacao-1/boletim-de-pessoal/2009/16s/rbac-25-2013-22-04-2009>>. Citado na página 39.

ANG, E. C.; SUANDI, S. A. Smart manufacturing with an artificial neural network to predict manufacturing healthiness. In: **2019 IEEE 15th International Colloquium on Signal Processing Its Applications (CSPA)**. [S.l.: s.n.], 2019. p. 120–123. Citado na página 32.

AZEVEDO, M. **Transformação Digital na Indústria: Indústria 4.0 e a Rede de Água Inteligente no Brasil**. Dissertação (Mestrado) — Escola Politécnica da Universidade de São Paulo, São Paulo, 2017. Citado nas páginas 22, 38 e 39.

BRAGA, A. d. P.; CARVALHO, A. P. d. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais, Teorias e Aplicações**. Travesso do Ouvidor, 11, Rio de Janeiro, Rio de Janeiro: LTC - Livros Técnicos e Científicos Editora S.A., 2007. Citado na página 65.

CAGGIANO, A.; RIMPAULT, X.; TETI, R.; BALAZINSKI, M.; JEAN-FRANÇOIS. Machine learning approach based on fractal analysis for optimal tool life exploitation in cfrp composite drilling for aeronautical assembly. **CIRP Annals**, v. 67, n. 1, p. 483 – 486, 2018. ISSN 0007-8506. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0007850618300593>>. Citado nas páginas 29, 30, 34, 87 e 101.

CARVALHO, V. M. d. S.; GUEDES, E. B.; SALAME, M. F. A. Classificação de ervas daninhas em culturas agrícolas com comitês de redes neurais convolucionais. In: **Base de Dados da Pesquisa Agropecuária (BDPA)**. [S.l.: s.n.], 2020. Citado nas páginas 32, 33 e 34.

DANTAS, D.; ARRIEL, T. G.; CALEGARIO, N.; LACERDA, W. S. Comparação entre redes neurais artificiais e comitê de redes na estimação do volume individual de árvores de eucalyptus/artificial neural networks committee in the estimation of the individual volume of eucalyptus trees. **Caderno de Ciências Agrárias**, v. 10, n. 1, p. 01–06, jul. 2018. Citado nas páginas 32, 33, 34, 80 e 101.

DAOUD, M.; MAYO, M. A survey of neural network-based cancer prediction models from microarray data. **Artificial Intelligence in Medicine**, v. 97, p. 204 – 214, 2019. ISSN 0933-3657. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0933365717305067>>. Citado na página 32.

FRANK, A. G.; DALENOGARE, L. S.; AYALA, N. F. Industry 4.0 technologies: Implementation patterns in manufacturing companies. **International Journal of Production Economics**, Elsevier, v. 210, p. 15–26, 2019. Citado na página 27.

HINTZE, W.; CLAUSEN, R.; SCHÜTTE, C.; KROLL, K. Evaluation of the total cutting force in drilling of CFRP: a novel experimental method for the analysis of the cutting mechanism. **Production Engineering**, Springer, v. 12, n. 3, p. 431–440, 2018. Citado na página 28.

LEE, J.; BAGHERI, B.; KAO, H.-A. A cyber-physical systems architecture for industry 4.0-based manufacturing systems. **Manufacturing letters**, Elsevier, v. 3, p. 18–23, 2015. Citado na página 27.

LEE, K.-P.; WU, B.-H.; PENG, S.-L. Deep-learning-based fault detection and diagnosis of air-handling units. **Building and Environment**, v. 157, p. 24 – 33, 2019. ISSN 0360-1323. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0360132319302732>>. Citado na página 32.

LIU, H.; CHEN, C.; LV, X.; WU, X.; LIU, M. Deterministic wind energy forecasting: A review of intelligent predictors and auxiliary methods. **Energy Conversion and Management**, v. 195, p. 328 – 345, 2019. ISSN 0196-8904. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0196890419305655>>. Citado na página 32.

MALLA, P.; COBURN, W.; KEEGAN, K.; YU, X.-H. Power system fault detection and classification using wavelet transform and artificial neural networks. In: LU, H.; TANG, H.; WANG, Z. (Ed.). **Advances in Neural Networks – ISNN 2019**. Cham: Springer International Publishing, 2019. p. 266–272. Citado na página 32.

MANOHAR, K.; HOGAN, T.; BUTTRICK, J.; BANERJEE, A. G.; KUTZ, J. N.; BRUNTON, S. L. Predicting shim gaps in aircraft assembly with machine learning and sparse sensing. **Journal of Manufacturing Systems**, v. 48, p. 87 – 95, 2018. ISSN 0278-6125. Special Issue on Smart Manufacturing. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0278612518300116>>. Citado nas páginas 29, 30 e 34.

MARSLAND, S. **Machine learning: an algorithmic perspective**. [S.l.]: CRC press, 2015. Citado nas páginas 64, 67 e 68.

MEI, B.; ZHU, W.; KE, Y. Positioning variation analysis and control for automated drilling in aircraft manufacturing. **Assembly Automation**, Emerald Publishing Limited, 2018. Citado na página 28.

PATRA, K.; JHA, A.; SZALAY, T.; RANJAN, J.; MONOSTORI, L. Artificial neural network based tool condition monitoring in micro mechanical peck drilling using thrust force signals. **Precision Engineering**, v. 48, p. 279–291, 2017. ISSN 0141-6359. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0141635916304470>>. Citado nas páginas 29, 30 e 101.

Ponti Jr., M. P. Combining classifiers: From the creation of ensembles to the decision fusion. In: **2011 24th SIBGRAPI Conference on Graphics, Patterns, and Images Tutorials**. [S.l.: s.n.], 2011. p. 1–10. Citado na página 68.

PREEZ, A. du; OOSTHUIZEN, G. A. Machine learning in cutting processes as enabler for smart sustainable manufacturing. **Procedia Manufacturing**, v. 33, p. 810–817, 2019. ISSN 2351-9789. Sustainable Manufacturing for Global Circular Economy: Proceedings of the 16th Global Conference on Sustainable Manufacturing. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2351978919305839>>. Citado na página 27.

PREUVENEERS, D.; ILIE-ZUDOR, E. The intelligent industry of the future: A survey on emerging trends, research challenges and opportunities in industry 4.0. **Journal of Ambient Intelligence and Smart Environments**, IOS Press, v. 9, n. 3, p. 287–298, 2017. Citado na página 27.

RAGHU, S.; SRIRAAM, N. Optimal configuration of multilayer perceptron neural network classifier for recognition of intracranial epileptic seizures. **Expert Systems with Applications**, v. 89, p. 205 – 221, 2017. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417417305067>>. Citado nas páginas 32, 67 e 68.

RUIZ, L.; TORRES, M.; GÓMEZ, A.; DÍAZ, S.; GONZÁLEZ, J. M.; CAVAS, F. Detection and classification of aircraft fixation elements during manufacturing processes using a convolutional neural network. **Applied Sciences**, v. 10, n. 19, 2020. ISSN 2076-3417. Disponível em: <<https://www.mdpi.com/2076-3417/10/19/6856>>. Citado nas páginas 29, 31, 34 e 101.

SACCO, C.; RADWAN, A. B.; ANDERSON, A.; HARIK, R.; GREGORY, E. Machine learning in composites manufacturing: A case study of automated fiber placement inspection. **Composite Structures**, v. 250, p. 112514, 2020. ISSN 0263-8223. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0263822320313659>>. Citado nas páginas 29, 31, 32, 34 e 101.

SUN, Y.; XUE, B.; ZHANG, M.; YEN, G. G. Evolving deep convolutional neural networks for image classification. **IEEE Transactions on Evolutionary Computation**, v. 24, n. 2, p. 394–407, 2020. Citado na página 32.

THOROGOOD, J. *et al.* Automation in drilling: Future evolution and lessons from aviation. **SPE Drilling & Completion**, Society of Petroleum Engineers, v. 28, n. 02, p. 194–202, 2013. Citado na página 28.

VOGADO, L.; VERAS, R.; ANDRADE, A.; SANTOS, L.; AIRES, K.; MACHADO, V. Um sistema de diagnóstico de leucemia utilizando cnn's pré-treinadas e um comitê de classificadores. In: **Anais do XVII Workshop de Informática Médica**. [S.l.: s.n.], 2017. Citado nas páginas 32, 33, 34 e 80.

ZHANG, X.; MING, X.; LIU, Z.; YIN, D.; CHEN, Z.; CHANG, Y. A reference framework and overall planning of industrial artificial intelligence (i-ai) for new application scenarios. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 101, n. 9-12, p. 2367–2389, 2019. Citado nas páginas 27 e 29.

ZHANG, Y.; CHANG, J.; FAN, D.; TIAN, H. Research on intelligent control algorithm for automatic drilling of vehicle-mounted rig. In: IOP PUBLISHING. **Journal of Physics: Conference Series**. [S.l.], 2020. v. 1650, n. 3, p. 032037. Citado na página 29.

