

Análise de Variabilidade e Modelos de Qualidade Preditiva no contexto da Indústria Metalomecânica

Luís Miguel Barroso Costa

Dissertação de Mestrado

Orientador na FEUP: Prof.^a Maria Henriqueta Sampaio da Nóvoa

Orientador no INESC TEC: Eng. António Correia Alves



Mestrado em Engenharia e Gestão Industrial

2022-07-01

“Looking for perfection is the only way to motivate yourself.”

Ronnie O’Sullivan

Resumo

Dada a natureza específica e sensível dos produtos fabricados na indústria metalomecânica de precisão, requer-se uma atenção especial focada no cumprimento dos requisitos especificados de conformidade e qualidade do produto final. No entanto, qualquer processo, por mais que respeite os requisitos definidos, apresenta sempre alguma variabilidade inerente e, quando esta se torna acima do desejável, alguns produtos podem ser fabricados com não conformidades. Uma não-conformidade ocorre quando existe pelo menos um parâmetro do produto que não cumpre a especificação pretendida e pré-determinada pelo cliente. As causas para a ocorrência de não-conformidades podem ir desde características da matéria-prima até às condições de funcionamento das máquinas, ou ainda dever-se a uma execução defeituosa do processo de produção.

A presente dissertação nasce de uma parceria entre o INESC TEC e a JASIL, uma empresa de metalomecânica de precisão cuja principal atividade é a produção de componentes para a indústria automóvel. O projeto enquadra-se na produção de uma nova manga de eixo para veículos pesados, a ser produzida em larga escala e com elevados requisitos de qualidade por parte do cliente, o que motivou a criação de uma célula de produção destinada exclusivamente à produção da mesma.

Assim, por forma a garantir o cumprimento dos requisitos do cliente, surgiu a necessidade de, numa primeira fase, identificar eventuais fatores por detrás da variabilidade associada ao fabrico desta peça. Para tal, começou-se por avaliar o sistema de medição, focando numa característica dimensional específica da peça, a qual permitiu concluir que existe excessiva variabilidade associada ao sistema, pelo que o mesmo deveria ser aprimorado. Por outro lado, com base em métodos estatísticos, conseguiu-se perceber que há diferenças significativas entre as máquinas CNC presentes na célula de produção e que o lote de matéria-prima é um fator de preponderância mais significativa quando comparado com o operador da célula.

Na segunda fase do projeto, e dada a constante evolução da empresa no paradigma da Qualidade 4.0, o desafio consistiu em utilizar modelos preditivos para detetar antecipadamente produtos com potenciais não conformidades, por forma a evitar a produção de sucata e os custos associados. Deste modo, recolheram-se dados relativos ao processo produtivo, os quais foram pré-processados e analisados, criaram-se preditores e preparou-se o conjunto de dados por forma a executar modelos de Machine Learning. Apesar do extremo desbalanceamento que caracteriza os dados utilizados, destaca-se a obtenção de um modelo bastante promissor em termos de performance, a servir de base ao desenvolvimento de trabalhos futuros.

Variability Analysis and Predictive Quality Models in the context of the Metal-working Industry

Abstract

Given the specific and sensitive nature of the products manufactured in the precision metalworking industry, special attention is required which focuses on meeting specified requirements for compliance and quality of the final product. However, any process, no matter how much it respects the defined requirements, always presents some inherent variability and, when this becomes more than desirable, some products can be manufactured with non-conformities. A non-conformity occurs when there is at least one product parameter that does not meet the intended specification pre-determined by the customer. The causes for the occurrence of non-conformities can range from the characteristics of the raw material to the operating conditions of the machines, or even due to a defective execution of the production process.

This dissertation is the result of a partnership between INESC TEC and JASIL, a precision metalworking company whose main activity is the production of components for the automotive industry. The project is part of the production of a new axle sleeve for heavy vehicles, to be produced on a large scale and with high quality requirements from the customer, which led to the creation of a production cell destined exclusively for the production of the component.

Thus, to guarantee the fulfillment of the customer's requirements, the need arose, in a first phase, to identify possible factors behind the variability associated with the manufacture of this part. To this end, we started by evaluating the measurement system, focusing on a specific dimensional characteristic of the part, which allowed to conclude that there is excessive variability associated with the system, so it should be improved. On the other hand, based on statistical methods, it was possible to perceive that there are significant differences between the CNC machines present in the production cell and that the batch of raw material is a factor with more significant preponderance when compared to the cell operator.

In the second phase of the project and given the company's constant evolution in the Quality 4.0 paradigm, the challenge was to use predictive models to detect products with potential non-conformities in an early stage, to avoid scrap production and associated costs. This way, data related to the production process were collected, which were then pre-processed and analyzed, predictors were created, and the *dataset* was prepared in order to run Machine Learning models. Despite the extreme imbalance that characterizes the *dataset* used, it is worth mentioning the achievement of a very promising model in terms of performance, which should serve as a basis for the development of future works.

Agradecimentos

À Professora Henriqueta Nóvoa, pela enorme disponibilidade apresentada e constante apoio que permitiram não só alcançar uma dissertação com maior qualidade, como também enfrentar desafios e inseguranças inerentes a um trabalho tão relevante quanto este.

Ao Engenheiro António Correia Alves e ao Engenheiro João Silva, pelo conhecimento transmitido e por todo o apoio prestado.

À JASIL, em especial ao Sr. Filipe, ao Tiago e ao Pedro, pela preocupação em melhorar a minha experiência na empresa e me ajudarem a conhecer melhor a fábrica e o processo produtivo.

À FEUP, pela formação de enorme qualidade proporcionada e por todas as experiências vividas ao longo destes 5 anos.

Aos meus amigos, pelo convívio, partilha de experiências e constante motivação para atingir os meus objetivos.

Aos meus pais e avós, por sempre acreditarem nas minhas capacidades e pelo orgulho que manifestam em cada conquista que alcanço.

A todos estes, o meu profundo obrigado.

Índice de Conteúdos

1	Introdução	1
1.1	Enquadramento do projeto e motivação	1
1.2	O projeto na JASIL	2
1.3	Objetivos do projeto	2
1.4	Método seguido no projeto	3
1.5	Estrutura da dissertação	4
2	Enquadramento Teórico	5
2.1	Análise de Sistemas de Medição	5
2.2	Controlo Estatístico de Processo (CEP)	8
2.2.1	Cartas de Controlo	9
2.2.2	Análise de Capacidade	10
2.3	Qualidade 4.0	11
2.3.1	Qualidade Preditiva no Setor Industrial	12
2.4	Operações de maquinaria	13
2.4.1	Torneamento	13
3	Caracterização do Problema	16
3.1	Caracterização do Produto	16
3.2	Processo Produtivo	17
3.3	Sistema de Controlo de Qualidade	19
3.4	Processamento de Dados	21
3.5	Síntese	22
4	Análise de Variabilidade	24
4.1	Diagrama de Ishikawa	24
4.2	Análise do Sistema de Medição	25
4.2.1	Estudo do Tipo 1	26
4.2.2	Testes de Repetibilidade e Reprodutibilidade (R&R)	27
4.3	Análise de Variáveis	29
4.3.1	Análise Individualizada	34
4.3.2	Análise cruzada por característica	36
4.4	Síntese	40
5	Modelos de Qualidade Preditiva	41
5.1	Descrição dos dados utilizados	41
5.1.1	Pré-Processamento	41
5.1.2	Análise preliminar	42
5.1.3	Tabela Registos&Eventos	43
5.2	Criação de Preditores	43
5.3	Construção dos Modelos	44
5.3.1	Codificação dos dados	45
5.3.2	Correlação entre variáveis	45
5.3.3	Normalização	46
5.3.4	Seleção de Preditores	46
5.3.5	Separação de dados	47
5.3.6	Desbalanceamento de dados	48
5.3.7	Algoritmos utilizados	49
5.3.8	Métricas de avaliação	51
5.4	Síntese	52
6	Experimentação e Resultados	54
6.1	Logistic Regression	54
6.2	Neural Network	55
6.3	Random Forest	57
6.4	K-Nearest Neighbor	58

6.5	Extra Trees.....	58
6.6	Resultados completos.....	59
6.6.1	Discussão dos resultados.....	62
6.7	Síntese.....	64
7	Conclusões e Trabalhos Futuros	65
7.1	Conclusões	65
7.2	Trabalhos Futuros	66
	Referências	68
ANEXO A:	Processo Produtivo.....	72
ANEXO B:	Análise de Variabilidade	74
ANEXO C:	Análise Cruzada- Característica CAT12.....	80

Siglas

ANOVA	<i>Analysis of Variance</i>
AUC	<i>Area Under the Curve</i>
CNC	Controlo Numérico Computorizado
CEP	Controlo Estatístico de Processo
COPQ	<i>Cost of Poor Quality</i>
DMAIC	<i>Define, Measure, Analyze, Improve and Control</i>
ERP	<i>Enterprise Resource Planning</i>
IoT	<i>Internet of Things</i>
ISO	<i>International Organization for Standardization</i>
LSL	<i>Lower Specification Limit</i>
ML	<i>Machine Learning</i>
PAD	Posto de Aquisição de Dados
PIE	Plano de Inspeção e Ensaio
R&R	<i>Repeatability and Reproducibility</i> (Repetibilidade e Reprodutibilidade)
USL	<i>Upper Specification Limit</i>

Índice de Figuras

Figura 1: Diferença entre os conceitos de exatidão e precisão.....	6
Figura 2: Componentes que constituem a variação total de um processo	7
Figura 3: Exemplo de uma carta de controlo.....	9
Figura 4: Representação esquemática de um torno	14
Figura 5: Conjugação de diversas ferramentas no processo de torneamento	14
Figura 6: Influência da velocidade de corte no tempo de vida da ferramenta.....	15
Figura 7: Desenho técnico da peça.....	16
Figura 8: Value Stream Map simplificado do processo	19
Figura 9: Em cima, PADs do Equator (esquerda) e Vici-Vision (direita); Em baixo, software de introdução de medições manuais e ajuste de posição de ferramentas.....	20
Figura 10: Gráfico produzido pelo Equator para a característica CAT12, com limites de especificação a vermelho.....	20
Figura 11: Diagrama de Ishikawa.....	24
Figura 12: Estudo do Tipo 1 ao micrómetro	26
Figura 13: Output do Teste R&R gerado através do Minitab	27
Figura 14: Frequência dos diferentes tipos de Não Conformidades.....	30
Figura 15: Frequência das diferentes causas na origem de Não Conformidades	30
Figura 16: Distribuição de não conformidades pelas características.....	31
Figura 17: Trocas de Ferramenta na Máquina 56.....	32
Figura 18: Trocas de Ferramenta na Máquina 57.....	32
Figura 19: Trocas de Ferramenta na Máquina 217.....	32
Figura 20: À esquerda, output do teste aos desvios padrões. À direita, output do teste 2-sample t.....	33
Figura 21: Distribuição de Não Conformidades pelas 3 máquinas	35
Figura 22: Distribuição de Não Conformidades por lote de matéria-prima	35
Figura 23: Distribuição de Não Conformidades por operador	36
Figura 24: Teste à normalidade- CAT05.....	37
Figura 25: Análise de capacidade para as 3 máquinas- CAT05.....	38
Figura 26: Carta I-MR para CAT05- Máquina 56; Operador 3195	39
Figura 27: Carta I-MR para CAT05- Máquina 57; Operador 3195	39
Figura 28: Carta I-MR para CAT05- Máquina 217; Operador 3195	39
Figura 29: Número de não conformidades em peças rejeitadas	42
Figura 30: Número de não conformidades por característica.....	43
Figura 31: Esquema ilustrativo do K-Fold Cross Validation	47
Figura 32: Número de não conformidades por característica após oversampling.....	49

Figura 33: Exemplo de Curvas ROC	52
Figura 34: AUC para a totalidade das características, por algoritmo	62

Índice de Tabelas

Tabela 1: Regras de Nelson	10
Tabela 2: Operações desempenhadas pelas ferramentas de cada torreta.....	17
Tabela 3: Especificidades das características medidas na peça.....	19
Tabela 4: Representação da Tabela Características & Ferramentas.....	22
Tabela 5: Resultados do Teste R&R	28
Tabela 6: Teste ANOVA para o Estudo R&R.....	29
Tabela 7: Rejeição de peças por turno	34
Tabela 8: Tipo de problema de ML tendo em conta as variáveis dependentes	45
Tabela 9: Matriz de Confusão para Regressão Logística - CAT05.....	55
Tabela 10: Matriz de Confusão para Neural Network (Hold-out) - CAT05	55
Tabela 11: AUC por característica - Neural Network (Cross-Validation)	56
Tabela 12: Matriz de Confusão para Neural Network (Cross-Validation) - CAT05	56
Tabela 13: AUC por característica – Random Forest (Cross-Validation).....	57
Tabela 14: Matriz de Confusão para Random Forest (Cross-Validation) - CAT05.....	57
Tabela 15: AUC por característica - kNN (Cross-Validation)	58
Tabela 16: Matriz de Confusão para kNN (Cross-Validation) - CAT05	58
Tabela 17: AUC por característica – Extra Trees (Cross-Validation).....	59
Tabela 18: Matriz de Confusão para Extra Trees (Cross-Validation) - CAT05.....	59
Tabela 19: Resultados dos quatro melhores modelos, em detalhe	60

1 Introdução

Neste capítulo introdutório, é feita uma apresentação do projeto e uma contextualização do tema do estudo a realizar. Apresentam-se, também, os objetivos a atingir com a realização do mesmo.

1.1 Enquadramento do projeto e motivação

No mundo competitivo da atualidade, qualquer que seja o setor em que operam, as empresas têm revelado uma tendência crescente em adotar filosofias de melhoria contínua e eficiência que lhes permitam assegurar a sua sobrevivência no mercado global e estar sempre um passo à frente da concorrência.

Em particular, na indústria metalomecânica de precisão, a qualidade dos produtos é o principal fator diferenciador de uma empresa em relação às restantes. A noção de qualidade vem perdurando no tempo, tendo sido definida por Philip Crosby em 1970 como sendo a conformidade com os requisitos (Crosby, 1979). No entanto, qualquer processo, por mais que respeite os requisitos definidos, apresenta sempre alguma variabilidade. A variabilidade está presente já que não há dois produtos exatamente iguais, mesmo que eles possam à primeira vista parecer muito semelhantes. A sua ocorrência está relacionada com pequenas diferenças que ocorrem, por exemplo, em matérias-primas e no desempenho de operadores, equipamentos e máquinas. No fabrico de produtos, o aumento da variabilidade nos mesmos representa uma diminuição da qualidade. Quando em presença de alta variabilidade, alguns produtos podem ser fabricados com não conformidades.

Apesar de esta ser uma indústria bastante avançada, sobretudo devido a um aumento na procura de produtos em aço nos últimos anos, a ocorrência de não conformidades é ainda razoavelmente comum, dada a precisão necessária na operação deste material. Por outro lado, os custos de manufatura de produtos em aço são bastante elevados. Assim, as empresas deste setor têm feito esforços para solucionar o problema da excessiva variabilidade, sendo uma tendência crescente tentar prever que produtos devem, ou não, percorrer o processo de produção, na totalidade. Deste modo, quanto mais cedo as falhas forem detetadas, mais dinheiro pode ser economizado com o material em produção que não precisa de passar pelas restantes etapas de produção porque já foi detetado como sendo um produto com potenciais não conformidades.

A JASIL, uma empresa de metalomecânica de precisão, desenvolveu recentemente uma célula de produção destinada exclusivamente à produção de uma nova manga de eixo, a ser produzida em larga escala e com elevados requisitos de qualidade por parte do cliente. Deste modo, e por forma a respeitar esses mesmos requisitos, surge a necessidade de, primeiramente, aferir eventuais causas por detrás da variabilidade associada ao fabrico desta peça e, de seguida, abordar a tarefa preditiva de detetar produtos com potenciais não conformidades, por forma a evitar a produção de sucata e os custos associados. O objetivo é,

assim, existir mais confiança, tanto por parte da empresa como do cliente, em que o processo funcionará conforme esperado e eventuais problemas serão detetados rapidamente, reduzindo o seu impacto.

1.2 O projeto na JASIL

A JASIL é uma empresa de metalomecânica de precisão, sediada em Braga e fundada em 1948, cuja principal atividade é a produção de componentes para a indústria automóvel. Os principais produtos da JASIL são peças e acessórios para motociclos e scooters, como cambotas e bielas, que são produzidos para a marca própria ou para clientes. A empresa conta com 3 unidades de produção, 116 trabalhadores e 150 máquinas de produção diferentes. Possui distribuidores em diversos países, tais como Espanha, França e Holanda.

Em fevereiro de 2011, obteve o certificado de conformidade com a Norma NP EN ISO 9001 – Sistemas de Gestão da Qualidade – para o âmbito de conceção, desenvolvimento e produção de componentes e acessórios para veículos motorizados e bicicletas, bem como para a mecanização e montagem de componentes metálicos. Na JASIL, um rigoroso controlo de qualidade é garantido durante todo o processo de fabricação. Cada máquina ou processo está ligado ao software ERP da empresa, onde as especificações de qualidade são definidas e estão disponíveis para serem consultadas, garantindo a conformidade do produto.

Apesar dos seus mais de 70 anos de existência, continua uma empresa moderna, fruto do seu permanente investimento em novas tecnologias. Destaca-se, neste aspeto, o departamento R&D que auxilia o desenvolvimento de produtos JASIL e tem também como função ajudar clientes a desenvolver os seus próprios produtos. De salientar capacidades como desenho e estudo de produto 2D e 3D, ensaios de fadiga, impressão de protótipos em 3D e montagem de testes reais.

O desenvolvimento de novos produtos, a aposta na qualidade e o foco no produto final fazem desta empresa uma das mais conceituadas a nível europeu no fabrico de cambotas para motores.

Alinhada com a filosofia de diversificação da empresa nos últimos anos, surge a produção de um novo componente, que é o principal objeto de estudo deste trabalho, e que, conforme mencionado anteriormente, consiste numa manga de eixo. Esta peça atua como suporte das rodas de veículos pesados, conectando-a aos rolamentos, e tem como matéria-prima uma peça de aço (ISO P) forjada fornecida pelo próprio cliente e submetida a operações de corte e torneamento.

1.3 Objetivos do projeto

Sendo este um componente de custo elevado e alta criticidade, valores acima de 1% de peças rejeitadas traduzem-se em elevados custos para a empresa, conforme acordado com o cliente. Assim, o controlo de qualidade das peças é feito individualmente para a totalidade da produção, já que o processo ainda trabalha com índices de qualidade baixos.

Deste modo, por forma a se obter um melhor controlo do processo e reduzir a quantidade de sucata produzida, aumentando, assim, a eficiência e reduzindo os custos de produção, formularam-se dois grandes objetivos a serem atingidos com a realização do projeto:

- **Análise de Variabilidade** - Após uma análise exploratória dos dados disponíveis, pretende-se a identificação dos fatores influenciadores na ocorrência de não conformidades e a análise da capacidade do processo, seguindo metodologias de Controlo Estatístico de Processo;

- **Modelos de Qualidade Preditiva** - Tendo em vista a tarefa de detetar produtos com potenciais não conformidades, serão desenvolvidos modelos de Machine Learning, com o objetivo de estimar a probabilidade de ocorrência de não conformidades em função do contexto da produção. Deste modo, explorar-se-á uma possível sequência ordenada de eventos que conduz ao surgimento das mesmas. A previsão será desenvolvida tendo por base variáveis identificadas, na fase anterior, como relevantes para o processo produtivo.

1.4 Método seguido no projeto

Na organização do trabalho desenvolvido ao longo do projeto, recorreu-se à metodologia DMAIC, a *framework* usada na condução de projetos Six Sigma, que tem como objetivo melhorar, otimizar e estabilizar processos e projetos de negócios de uma forma estruturada. As etapas que constituem esta metodologia são:

- Definir – Determinam-se as principais necessidades da empresa e define-se concretamente o objetivo do processo, restringindo o seu âmbito;
- Medir – Avalia-se o sistema de medição e recolhem-se dados e informações, levantando-se possíveis causas dos problemas;
- Analisar – Analisam-se os dados recolhidos na etapa anterior, procurando identificar a origem de um problema. De seguida, analisam-se as melhores formas de contra-atacar essas causas e criam-se oportunidades de melhoria;
- Melhorar – Executa-se o plano de ação, de acordo com as necessidades do processo, e implementam-se as mudanças delineadas;
- Controlar – Estabelecem-se critérios de controlo e acompanham-se as soluções aplicadas, sempre atentando a eventuais novas melhorias.

No âmbito deste projeto, colocou-se especial ênfase nas primeiras três etapas. Assim, podemos mapear os principais objetivos a atingir em cada uma das três etapas:

- Definir
 - Conhecer o funcionamento da empresa e o processo a analisar.
 - Fazer o levantamento da situação inicial e uma revisão bibliográfica.
 - Definir detalhadamente quais os dados do processo a recolher.
- Medir
 - Quantificar o número de peças rejeitadas.
 - Identificar parâmetros críticos do processo.
 - Identificar possíveis causas para a ocorrência de não conformidades.
- Analisar
 - Analisar estatisticamente os dados recolhidos.
 - Aferir os fatores mais relevantes no surgimento de não conformidades.
 - Avaliar o controlo estatístico do processo com cartas de controlo e analisar a capacidade do processo.
 - Projetar um sistema capaz de prever produtos com potenciais não conformidades.

1.5 Estrutura da dissertação

No Capítulo 2 faz-se uma breve revisão bibliográfica incidindo em diversas áreas relevantes para o enquadramento do projeto: Análise de Sistemas de Medição, Controlo Estatístico de Processo (CEP) e breves noções de Qualidade 4.0, incluindo a aplicação de modelos de Machine Learning na área da Qualidade Preditiva. Por fim, tratando-se de um projeto inserido na indústria metalomecânica, abordam-se diversas noções acerca de Maquinagem.

No Capítulo 3 caracteriza-se o problema existente, apresentando-se a empresa, o produto e o processo produtivo em questão. Descreve-se, ainda, o sistema de controlo de qualidade em vigor e o método de processamento dos dados recolhidos no processo produtivo.

No Capítulo 4 expõem-se os diversos segmentos da análise de variabilidade levada a cabo. Esboça-se, primeiramente, um Diagrama de Ishikawa, por forma a fazer um primeiro levantamento das potenciais causas para o problema existente, e de seguida analisam-se o sistema de medição (para uma dimensão específica da peça) e as variáveis intervenientes no processo, com potencial influência no surgimento de peças defeituosas.

No Capítulo 5 descreve-se a metodologia utilizada na obtenção de diversos modelos de Machine Learning com a finalidade de prever a ocorrência de não conformidades. Após a descrição dos dados utilizados e do seu pré-processamento, descrevem-se diversas etapas necessárias à aplicação dos algoritmos ML.

No Capítulo 6 apresentam-se, para os diferentes algoritmos, os procedimentos experimentais e resultados obtidos, de acordo com métricas consideradas relevantes na análise. É, ainda, feita uma análise detalhada dos resultados.

No Capítulo 7 apresentam-se as conclusões retiradas do trabalho desenvolvido e faz-se o delineamento de propostas para trabalhos futuros.

2 Enquadramento Teórico

Neste capítulo procede-se a uma breve revisão da literatura relativamente a diversos tópicos envolvidos no projeto, tais como análise de sistemas de medição, controlo de qualidade e Qualidade 4.0. Adicionalmente, tratando-se de um projeto inserido na indústria metalomecânica, abordam-se algumas noções básicas de Maquinagem, essenciais para a compreensão cabal do projeto.

2.1 Análise de Sistemas de Medição

A Medição, 2ª etapa da metodologia DMAIC, é crítica não apenas na fase inicial de um projeto, quando o problema é definido, mas também posteriormente na fase de Controlo, quando se efetuam medições com o intuito de verificar se o processo está a ter o desempenho esperado. Estando na génese da recolha e tratamento de informação relativamente a um processo, a medição assume, assim, um papel decisivo no sucesso da atividade de uma empresa. Efetuando medições de fraca qualidade, as conclusões que se obtêm a partir de um estudo podem ser tão pouco fiáveis quanto as próprias medições. Montgomery (2012) salienta este ponto, considerando ser “muito difícil monitorizar, controlar, melhorar ou gerir eficazmente um processo com um sistema de medição desadequado”, comparando a situação com uma embarcação sem radar que navega com nevoeiro: “eventualmente vai embater contra um *iceberg*”.

Na utilização de qualquer sistema de medição, pretende-se, fundamentalmente, que este seja exato e preciso, dois conceitos que importa distinguir. A exatidão refere-se à capacidade de o sistema medir, em média, valores próximos do valor verdadeiro da característica em estudo. Por seu lado, a precisão refere-se à proximidade entre duas ou mais medições, sendo uma medida da variabilidade intrínseca ao sistema de medição. A Figura 1 (Montgomery, 2012) demonstra estes dois conceitos.




Figura 1: Diferença entre os conceitos de exatidão e precisão

Adotando a formulação de Montgomery (2012), pode considerar-se que o valor obtido numa medição (y) integra, para além do valor verdadeiro (x) da dimensão em estudo, uma componente que se pode designar como erro de medição (ε). Nesta formulação, assume-se que x e ε são variáveis aleatórias independentes e que seguem distribuições normais com $\mu = 0$ e variâncias σ_P^2 e σ_{Gauge}^2 , respetivamente.

$$y = x + \varepsilon \quad (1)$$

Na variabilidade total do processo (σ_{Total}^2) estão, portanto, incluídas a variabilidade do produto (σ_P^2) e a variabilidade inerente ao sistema de medição (σ_{Gauge}^2), como se observa na Equação 2:

$$\sigma_{Total}^2 = \sigma_P^2 + \sigma_{Gauge}^2 \quad (2)$$

A variabilidade associada ao sistema de medição (σ_{Gauge}^2) contém duas componentes de natureza distinta: a repetibilidade e a reprodutibilidade (R&R). A repetibilidade pode ser definida como uma medida da variabilidade das medições que um mesmo operador obtém em várias repetições de medição da mesma característica e com o mesmo equipamento. Por seu turno, a reprodutibilidade é uma medida da variabilidade das medições obtidas quando vários operadores utilizam o mesmo equipamento para medir a mesma característica do mesmo produto (Antony *et al*, 1999). A Equação 2 transforma-se, assim, na Equação 3:

$$\sigma_{Total}^2 = \sigma_P^2 + \sigma_{Repetibilidade}^2 + \sigma_{Reprodutibilidade}^2 \quad (3)$$

Este desdobramento pode ainda ser mais detalhado já que a reprodutibilidade compreende, simultaneamente, a variação do operador (diferenças nas medições dos operadores) e a variação de operador por peça, que diz respeito à interação entre o operador e a peça. O

desdobramento da variabilidade total do processo encontra-se ilustrado na Figura 2 (Quality Trainer, 2022).




Figura 2: Componentes que constituem a variação total de um processo

A aferição da repetibilidade e reprodutibilidade presentes num sistema de medição pode basear-se na análise de cartas de controlo de amplitudes e médias de um conjunto de medições, que permitem separar os dois efeitos e individualizar as respetivas variâncias. A carta das médias permite avaliar a capacidade do sistema de medição de distinguir entre peças, enquanto a carta das amplitudes apresenta diretamente a magnitude dos erros de medição. A existência de pontos fora dos limites de controlo na carta das amplitudes sugere que o operador tem dificuldade em utilizar o instrumento de medição (Wang e Li, 2003). Contrariamente ao que se deve verificar quando as cartas de controlo são construídas para avaliar se um processo se encontra em controlo estatístico, no contexto dos testes R&R é desejável que os pontos da carta das médias se apresentem fora dos limites de controlo, pois tal significará que o equipamento de medição é capaz de distinguir as diferentes peças (Minitab, 2022). Assim, admitindo que as amostras são representativas da variação existente no processo, para um equipamento ser considerado capaz, é necessário assegurar que pelo menos metade dos pontos da carta das médias se apresentam fora dos limites de controlo (AIAG, 2010).

A partir das variabilidades associadas aos fatores detalhados na Figura 2, é possível aferir a capacidade de medição do sistema, sendo o rácio precisão-tolerância (P/T) o indicador mais comumente utilizado. Este indicador, cuja fórmula está presente na Equação 4, estabelece uma comparação entre a capacidade do sistema de medição estimada e o intervalo de tolerância da medida em análise. Nesta equação, assume-se, habitualmente, $k=6$, que corresponde ao número de desvios padrões compreendidos entre os limites naturais de tolerância de uma população normal.

$$PTR = \frac{k \times \sigma_{\text{Gauge}}}{USL - LSL} \quad (4)$$

De acordo com o AIAG (2010), um sistema de medição é aceitável quando apresenta um PTR inferior a 10%, pode ser aceitável para certas aplicações e processos quando o PTR está entre 10 e 30% e não é aceitável de todo quando este indicador toma valores superiores a 30%.

De salientar que, previamente a qualquer estudo R&R, é imperativa a realização de um estudo de enviesamento e repetibilidade. Tendo já sido abordada a noção de repetibilidade, importa, igualmente, considerar o conceito de enviesamento. O enviesamento está relacionado com exatidão e corresponde à diferença entre a média dos valores medidos e o valor verdadeiro da dimensão a estudar, podendo ser entendido como o erro sistemático do sistema de medição (AIAG, 2010). Um sistema de medição será tanto mais enviesado, quanto maior for aquela diferença.

O estudo de enviesamento e repetibilidade materializa-se, habitualmente, na realização de um Type 1 Gage Study (Estudo de Tipo 1), que se foca, assim, exclusivamente no sistema de medição. Neste estudo, um operador mede diversas vezes uma amostra de referência, cujo valor verdadeiro é conhecido. Na análise dos efeitos de enviesamento e repetibilidade, é frequente a utilização de duas métricas, representadas nas Equações 5 e 6. O C_g estabelece uma comparação entre a variabilidade das medições e uma percentagem (geralmente, 20%) da tolerância especificada, permitindo estudar o efeito de repetibilidade. Por seu turno, o C_{gk} tem, adicionalmente, em conta se as medições estão próximas do valor verdadeiro. Este índice diminui à medida que aumenta a diferença entre o valor verdadeiro e a média das medições realizadas, pelo que permite avaliar simultaneamente os efeitos de enviesamento e repetibilidade (Minitab, 2022).

$$C_g = \frac{K \times T}{L \times s} \quad (5)$$

$$C_{gk} = \frac{K/2 \times T - |\bar{x}_g - x_{ref}|}{L \times s} \quad (6)$$

Onde:

K é frequentemente 0,2 (20%);

T é a tolerância especificada para o produto;

$\bar{x}_g$ é a média das medições;

x_{ref} é o valor de referência;

L é o número de desvios padrões que se pretende considerar no cálculo dos índices (habitualmente, 6 para C_g e 3 para C_{gk});

s é o desvio padrão amostral das medições

Os sistemas de medição são considerados capazes se os índices C_g e C_{gk} forem superiores a 1,33 (AIAG, 2010).

2.2 Controlo Estatístico de Processo (CEP)

O Controlo Estatístico de Processo é uma combinação de métodos estatísticos usada para avaliar se um processo está estável, permitindo mitigar a influência de fontes de variabilidade. Esta variabilidade está associada a dois tipos de causas:

- Causas comuns - consequência natural do processo com uma distribuição estável e repetitiva ao longo do tempo, exercendo por isso pouca influência no output do processo. Sendo conhecida, a sua influência pode ser reduzida, mas nunca eliminada;
- Causas assinaláveis - surgem esporadicamente de aspetos não controláveis e não são inerentes ao processo, ocorrendo devido a variações ocasionais que influenciam o resultado de forma imprevisível. Tornam o processo instável ao longo do tempo, devendo, por isso, ser identificadas e eliminadas (Samohyl, 2009).

Sendo o Controlo Estatístico de Processo um conjunto de ferramentas de aplicação transversal para detetar a ocorrência de causas assinaláveis e eliminar a variabilidade nos processos, reconhece-se o seu potencial para analisar problemas de qualidade e melhorar o desempenho tanto do processo de produção como do produto (Montgomery, 2012).

O CEP permite aumentar a capacidade de produção sem investimento financeiro adicional em equipamentos, trabalhadores ou outras despesas e possibilita que se tomem ações preventivas antes que o produto percorra todas as etapas de produção. O CEP é, assim, um método de natureza preventiva. Consequentemente, os desvios podem ser eliminados antes que o produto seja fabricado aquém dos requisitos de qualidade. Ainda assim, é de realçar que o CEP não resolve os problemas existentes no processo, apenas os deteta para que uma solução possa ser aplicada.

Identificam-se 7 principais ferramentas utilizadas pelo CEP, designadas por Montgomery (2012) como “The Magnificent Seven”:

- Histograma
- Folha de verificação
- Diagrama de Pareto
- Diagrama de Ishikawa
- Diagrama de Dispersão
- Diagrama de Concentração de Defeitos
- Cartas de Controlo

De entre as várias ferramentas que fazem parte do CEP, as cartas de controlo são das mais importantes ao nível da análise e controlo da variabilidade.

2.2.1 Cartas de Controlo

As cartas de controlo permitem exibir graficamente a evolução de uma determinada característica ao longo dum intervalo de tempo definido ou de um conjunto de amostras recolhidas. Assim, podem ser utilizadas para monitorizar eficazmente o processo. Um exemplo de uma carta de controlo é exibido na Figura 3 e contém a linha central, que diz respeito ao valor médio da característica de qualidade representada graficamente, e os limites de controlo inferior e superior, usados para julgar se um processo está fora de controlo. Os limites de controlo são baseados na distribuição da característica de qualidade em análise, sendo normalmente definidos 3 desvios padrão acima e abaixo da linha central.




Figura 3: Exemplo de uma carta de controlo

Habitualmente, um processo é considerado como estando em controlo se todos pontos estão dentro dos limites de controlo, assumindo-se que a variabilidade exibida pelo processo é só devida a causas comuns de variação. Um processo controlado é, assim, um processo estável, sendo a estabilidade um fator essencial para a análise da capacidade do processo, ou seja, a análise da aptidão a produzir produtos que atendam às especificações do cliente (Deming, 1982).

Ainda assim, mesmo que todos os pontos obtidos estejam dentro dos limites, tal não significa necessariamente que o processo está controlado, caso seja possível detetar um padrão nas observações. Aliás, Montgomery (2012) refere que uma grande limitação das cartas de controlo é a identificação de padrões já que utiliza informação relativa ao processo “ponto-a-ponto”, desconsiderando informações que o conjunto de todos os pontos, como uma sequência, possa fornecer.

Estas sequências podem consistir num número consecutivo de pontos acima ou abaixo da linha central, bem como em séries de pontos ascendentes ou descendentes, entre outros. Deste modo, uma sequência é um indicador de que o processo pode estar fora de controlo.

A Western Electric, empresa americana com ligações ao setor industrial, propôs em 1956 algumas regras usadas em cartas de controlo para indicar padrões não aleatórios. Mais tarde, em 1984, Lloyd S. Nelson, baseado nas regras da Western Electric, propôs regras adicionais (regras 3, 4, 7 e 8). O conjunto de 8 regras, conhecido como Regras de Nelson, é de seguida listado na Tabela 1:

Tabela 1: Regras de Nelson

Regra	Descrição	Problema
1	Um ponto fora dos limites de controlo.	Amostras fora de controlo.
2	9 pontos consecutivos do mesmo lado da linha central.	Indicativo de um problema prolongado.
3	6 pontos consecutivos no sentido ascendente ou descendente.	Presença de tendências.
4	14 pontos com direção crescente e decrescente, alternadamente.	Demasiada oscilação.
5	Pelo menos 2 de 3 pontos consecutivos a mais de 2 desvios padrões da linha central, do mesmo lado.	Ligeira tendência para as amostras estarem fora de controlo.
6	Pelo menos 4 de 5 pontos consecutivos a mais de 1 desvio padrão da linha central, do mesmo lado.	Forte tendência para as amostras estarem fora de controlo.
7	15 pontos consecutivos contidos entre a linha central e 1 desvio padrão, acima e abaixo da linha central.	Falta de variabilidade.
8	8 pontos consecutivos, de ambos os lados da linha central, sem que nenhum esteja contido entre a linha central e 1 desvio padrão	Não existe aleatoriedade.

Analisando as regras apresentadas, é compreensível o uso das mesmas como complemento às cartas de controlo, por forma a decidir se um processo está em controlo ou não. No entanto, a sua utilização deve ser feita de forma cautelosa, já que recorrendo a um grande número de regras, a probabilidade de concluir que o processo não está em controlo, quando na realidade está, ou seja, o erro do tipo I, aumenta significativamente.

2.2.2 Análise de Capacidade

Apesar da sua extrema utilidade, as cartas de controlo apenas avaliam a estabilidade de um processo e ajudam a isolar ocorrências irregulares, não podendo determinar se um produto

está em conformidade com as especificações exigidas. As especificações de um processo dependem dos requisitos específicos que um cliente tem para um produto, traduzindo-se sobre a forma dos limites de especificação superior (USL) e inferior (LSL).

Conhecidas as especificações do produto e os limites de controlo do processo, a capacidade do processo, tanto de curto prazo (C_p , C_{pk}) quanto de longo prazo (P_p , P_{pk}), pode ser calculada. Considerando que o valor médio do processo (em baixo referido como Avg) e o valor médio de especificação podem não ser equivalentes, temos que:

$$C_p = \frac{USL - LSL}{6 \times \sigma_{ST}}$$

$$C_{pk} = \frac{\min(USL - Avg, Avg - LSL)}{3 \times \sigma_{ST}}$$

$$P_p = \frac{USL - LSL}{6 \times \sigma_{LT}}$$

$$P_{pk} = \frac{\min(USL - Avg, Avg - LSL)}{3 \times \sigma_{LT}}$$

De realçar que o σ_{ST} diz respeito à variação do processo a curto prazo, sendo a medida de dispersão média entre os valores de um mesmo subgrupo. Por seu lado, o σ_{LT} consiste na variação do processo a longo prazo, calculado como o desvio padrão global de todos os valores. Se o processo for estável, C_p e P_p serão iguais, assim como C_{pk} e P_{pk} . Adicionalmente, se o processo estiver centrado face ao valor alvo, C_p e C_{pk} bem como P_p e P_{pk} , serão iguais.

O uso de seis desvios padrões no cálculo de C_p e P_p decorre da metodologia *Six Sigma* que afirma que idealmente 99,99966% dos produtos devem estar em conformidade com os padrões de qualidade, oferecendo uma variedade de ferramentas para alcançar este fim.

Um processo é considerado capaz quando apresenta, para os índices apresentados, valores superiores a 1.33 (Juran *et al*, 1999).

2.3 Qualidade 4.0

Os modelos e práticas de controlo de qualidade passaram por várias etapas evolutivas ao longo dos tempos— da inspeção ao controlo, à garantia da qualidade (quality assurance), à gestão da qualidade (quality management) e à qualidade por projeto (quality by design). Estes modelos de qualidade acompanharam as várias revoluções industriais (Zonnenshain e Kenett, 2020).

Em particular, a mais recente (quarta revolução industrial) é alimentada por dados recolhidos por sensores e dispositivos da Internet das Coisas (IoT) e pelo aumento da potência computacional. A Internet das Coisas (IoT) é a extensão da conectividade da Internet em dispositivos físicos e objetos do quotidiano. Incorporados com ligação à Internet e outras formas de hardware (como sensores), esses dispositivos podem comunicar entre si e ser monitorizados e controlados remotamente (Acharjya e Geetha, 2017). As tecnologias da informação, telecomunicações e a produção estão-se progressivamente a fundir e a produção é cada vez mais autónoma.

Parece, no entanto, que nos últimos anos a disciplina da Qualidade entrou em estagnação – muito poucos modelos inovadores de qualidade vêm sendo propostos e os profissionais de qualidade nas empresas e organizações aparentemente têm perdido as suas posições de liderança. Além disso, a investigação de modelos de qualidade novos e inovadores é escassa (Zonnenshain e Kenett, 2020).

A quarta revolução industrial é, portanto, uma oportunidade para a Qualidade se tornar numa força de liderança. Inevitavelmente, as mudanças causadas pelo progresso tecnológico resultarão numa enorme transformação na maneira como muitas organizações operam diariamente. Isto exigirá uma mudança cultural que afetará quer trabalhadores quer a liderança das empresas e impactará fatores como inovação de produtos, eficiência de produção, desempenho da cadeia de abastecimento (supply chain) e, naturalmente, a qualidade. É neste aspeto que a Qualidade 4.0 tem um papel decisivo. A Qualidade 4.0 é vista como o aproveitamento da tecnologia, em conjunto com as pessoas, para melhorar a qualidade de uma organização, dos seus produtos e serviços e dos resultados que cria (Juran, 2019) (CQI, 2022).

Vários princípios sustentam esta definição de Qualidade 4.0 e aprimoram os princípios de qualidade pré-estabelecidos, que fornecem foco nas necessidades, expectativas e satisfação do consumidor (CQI, 2022). Destes, destaca-se o princípio relativo ao valor dos dados, cada vez mais um ativo estratégico nas empresas, o que exige que profissionais de qualidade tenham conhecimento em gestão de dados, engenharia de dados e análise de dados.

Os dados são o ativo mais valioso de uma empresa, com um valor real e mensurável. O seu valor não reside apenas nos dados em si, mas também nas ações que advêm dos dados e seu uso. Dados de boa qualidade são essenciais para tornar as operações eficientes, garantir a conformidade com os requisitos regulatórios, garantir tomadas de decisão eficazes e assegurar um planeamento estratégico de negócios eficaz. Por outro lado, a baixa qualidade dos dados tem um efeito cascata em todas as organizações que podem se espalhar pela cadeia de abastecimento. O impacto agravante da baixa qualidade dos dados pode não só levar a decisões de negócios erradas e baixa eficiência, como também à perda de credibilidade e reputação.

Os processos produtivos operam, geralmente, com inputs obtidos de fontes externas, muitas vezes desconhecidas de antemão. Consequentemente, a qualidade geral dos dados dentro de um sistema de informação complexo pode-se desintegrar devido à falta de controlo do processo. Como esse potencial aumenta à medida que a variedade de tipos de dados se expande, o controlo do processo sobre a qualidade dos dados é crítico (Mahanti, 2019).

Um estudo de 2018, focado principalmente no setor industrial nos EUA e na Alemanha, demonstrou que a Qualidade 4.0 ainda está num estado inicial de desenvolvimento. De facto, apenas 16% das organizações abordadas implementaram iniciativas de Qualidade 4.0 e 63% não iniciaram sequer o planeamento. Os pioneiros nesta implementação têm expectativas mais baixas para o impacto da Qualidade 4.0 devido aos desafios dessa mesma implementação, que na opinião destes consistem principalmente na falta de competências em áreas relacionadas com tecnologias digitais e nas barreiras relacionadas com os dados, abordadas anteriormente (ASQ, 2022).

2.3.1 Qualidade Preditiva no Setor Industrial

Conforme referido, os dados são o ativo mais valioso de qualquer empresa e a quantidade de dados que podem ser extraídos de sistemas industriais aumentou exponencialmente nos últimos anos devido à proliferação de sensores, dispositivos de transmissão e armazenamento de dados via Internet das Coisas (IoT). Esses dados, quando processados e analisados, podem fornecer informações e conhecimentos valiosos sobre um dado equipamento, permitindo uma

mudança de paradigma em direção à manutenção preditiva. A manutenção é fundamental para a competitividade de uma empresa, uma vez que as ações realizadas a este nível impactam diretamente aspectos como custo e qualidade dos produtos. Assim, as falhas de equipamentos precisam de ser prontamente identificadas e resolvidas, sendo esta uma tendência cada vez mais crescente na Indústria.

As ferramentas de Inteligência Artificial, em particular o Machine Learning, apresentam um enorme potencial na análise de grandes quantidades de dados, agora prontamente disponíveis, visando assim melhorar a disponibilidade dos sistemas, reduzindo os custos de manutenção, e aumentando o desempenho operacional e o suporte na tomada de decisões. No desenvolvimento de modelos de Machine Learning, a seleção dos algoritmos apropriados é essencial já que não há um algoritmo que seja universalmente melhor que os restantes. Cada problema é único e os algoritmos mais adequados devem ser selecionados e, ainda, adaptados para que a solução ótima seja alcançada.

Apesar de ser uma área relativamente recente e ainda em desenvolvimento, diversos modelos de Machine Learning tendo em mente a aplicação da qualidade preditiva ao setor industrial foram desenvolvidos com sucesso. Destaca-se a utilização de variados algoritmos tais como *Support Vector Machine* por Rostami *et al* (2015), *Least Absolute Shrinkage and Selection Operator* (LASSO) por Melhem *et al* (2015) e *Stack Autoencoder* por Bai *et al* (2017), um algoritmo habitualmente usado na detecção de anomalias. A utilização de diversos algoritmos num mesmo projeto e sua comparação em termos de resultados foi conduzida por Lieber *et al* (2013) e por Cardoso e Ferreira (2020). A generalidade dos modelos desenvolvidos no âmbito da qualidade preditiva são de Classificação Binária já que se pretende efetuar a previsão de uma entre duas classes, tipicamente conforme (0) ou não conforme (1). Destaca-se, assim, a complexidade adicional do trabalho de Cardoso e Ferreira (2020) por se tratar de um problema de Classificação Multi-Classe já que aborda a classificação de instâncias numa de três ou mais classes, cada uma dizendo respeito a um componente de uma dada máquina, passível de ocorrência de falha.

Na JASIL, sendo uma empresa que procura continuamente a melhoria da qualidade dos seus processos, verifica-se uma evolução no sentido da Qualidade Preditiva. Destaca-se o trabalho levado a cabo por Almeida (2020) nesta mesma área, ainda que de âmbito distinto do presente trabalho, já que diz respeito a um problema de Classificação Binária (apenas uma variável dependente) que pretende prever a conformidade ou não de peças sujeitas a diferentes operações de maquinagem, tais como torneamento, forjamento, fresagem e retificação.

2.4 Operações de maquinagem

A maquinagem é o processo de fabrico mais comum para criar componentes metálicos de precisão. Trata-se de um processo de corte ou desbaste de um material para criar uma peça, e é transversal e complementar a todos os outros processos de fabrico, desde a fundição ao forjamento. A maior parte dos componentes que possuem superfícies técnicas funcionais necessitam de ser submetidos aos mais diversos processos de maquinagem, de modo a obterem a qualidade superficial e tolerâncias dimensionais exigidas para a função à qual se destinam (Fraga e Fula, 2020).

2.4.1 Torneamento

O torneamento é uma das operações mais comuns de maquinagem. Neste processo, conjugam-se os movimentos de rotação da peça e avanço da ferramenta de corte, por forma a criar peças axialmente simétricas em relação ao eixo de rotação. As peças produzidas podem apresentar características como degraus de diâmetros diferentes, furos e ranhuras. O

equipamento utilizado no processo de torneamento designa-se por torno e encontra-se representado na Figura 4.




Figura 4: Representação esquemática de um torno

O torneamento pode ser decomposto em diversos cortes básicos para a seleção de tipos de ferramentas, parâmetros de corte e também para a programação de certas operações. Isto diz respeito não só ao torneamento externo, mas também a operações mais específicas, como rosqueamento, ranhuramento e mandrilamento. A conjugação de diferentes tipos de corte na obtenção de uma peça final é ilustrada na Figura 5, onde se apresentam as diversas ferramentas utilizadas. Os parâmetros de corte no processo de torneamento consistem em velocidade de corte, expressa em metros por minuto, velocidade de rotação [rpm], profundidade de corte [mm] e avanço [mm/rotação], entre outros. A dureza do material a maquinar e os parâmetros referidos têm grande influência na vida útil da ferramenta de corte, sendo a velocidade de corte o que tem maior preponderância: aumentando a velocidade de corte, aumenta-se o aquecimento da ferramenta e o desgaste, reduzindo-se, ainda assim, o tempo de trabalho. A influência da velocidade de corte na evolução do desgaste da ferramenta encontra-se representada na Figura 6.



Figura 5: Conjugação de diversas ferramentas no processo de torneamento




Figura 6: Influência da velocidade de corte no tempo de vida da ferramenta

O fim de vida de uma ferramenta de corte pode ter diversas causas. A mais desejável é o desgaste progressivo, que se caracteriza na alteração progressiva da geometria da ferramenta e redução da eficiência de corte. Outro tipo de falha é o aquecimento excessivo da ferramenta em que o material da ferramenta amacia e deforma-se plasticamente, perdendo-se a aresta de corte afiada. Por fim, a fratura da ferramenta é um tipo de falha a evitar, surgindo quando elevadas forças de corte atuam sobre a ferramenta. Este é um tipo de falha prematura e que pode produzir dano na superfície das peças.

3 Caracterização do Problema

No presente capítulo caracteriza-se o problema existente, apresentando-se o produto e o processo produtivo em questão. Descreve-se, ainda, o sistema de controlo de qualidade em vigor, detalhando-se as diversas características dimensionais da peça recolhidas. Por fim, aborda-se o método de processamento dos dados recolhidos no processo produtivo, disponibilizados em contínuo pelo Sistema de Gestão da Qualidade da empresa.

3.1 Caracterização do Produto

A JASIL possui um elevado número de referências de produtos vendidos, muitas vezes com séries de produção pequenas, o que requer vários *setups* nas máquinas, pois cada máquina pode produzir um número muito grande de peças diferentes.

O novo componente, que é o principal objeto de estudo deste trabalho, consiste numa manga de eixo que atua como suporte das rodas de veículos pesados, conectando-a aos rolamentos. A matéria-prima usada consiste numa peça de aço (ISO P) forjada, fornecida pelo próprio cliente e submetida a operações de corte e torneamento.

O desenho técnico da manga de eixo, com a indicação das características controladas, mais à frente abordadas em detalhe, encontra-se na Figura 7.




Figura 7: Desenho técnico da peça

Atendendo aos requisitos de qualidade muito elevados e ao elevado volume de produção deste produto (i.e. 100 mil peças por ano pretendidas, número superior ao habitual), a empresa decidiu abrir uma célula de produção exclusivamente dedicada a este novo produto. O objetivo desta nova célula é o de assegurar altos padrões de qualidade ao menor custo possível, de forma a minimizar o custo de má qualidade (COPQ) para a JASIL em caso de incumprimento.

O acordo realizado com o cliente reflete-se em 3 tipologias de custos para a empresa: até 1% de peças rejeitadas, não há qualquer custo para a empresa; entre 1 e 2%, o custo corresponde à matéria-prima; acima de 2% de peças rejeitadas, a empresa é responsável pelo custo da matéria-prima bem como da peça produzida pelo cliente. De realçar que estes custos apenas se aplicam em situações em que as causas de rejeição sejam da responsabilidade da JASIL. Como será visto na Secção 4, verificam-se diversas situações em que a rejeição de peças se deve a defeitos na matéria-prima em si, e não à empresa.

3.2 Processo Produtivo

A nova célula de produção é composta por 2 robôs, 2 serrotes mecânicos e 3 tornos CNC (identificados como 56, 57 e 217), entre outros equipamentos. A linha opera 24 horas por dia, 5 dias por semana. Apesar de esta ter sido concebida para funcionar de forma automatizada, verifica-se a presença de 3 operadores em cada turno de 8 horas, para garantir o bom funcionamento da linha e realizar medições manuais recorrentes de produto acabado.

O processo, esquematizado na Figura A.1 do Anexo A, tem início quando uma peça forjada proveniente do cliente entra na célula, sendo colocada numa rampa de entrada. O robô manipula a peça e coloca-a num dos 2 serrotes, onde é realizado o corte do topo, de forma automatizada. A peça é então limpa e o diâmetro interior é testado com auxílio de um calibre. De seguida, o outro robô da célula coloca a peça num dos 3 tornos e o torneamento tem início. No torneamento, a parte exterior da manga é torneada, através de operações de desbaste e acabamento, de modo a garantir as dimensões pretendidas. É igualmente feita uma rosca numa das pontas e aberto um escatel. Cada torno consiste em 2 torretas (cima e baixo, também identificadas como 1 e 2) que incluem diversas ferramentas usadas nas operações anteriormente mencionadas. Na Tabela 2 está presente um esquema com as ferramentas presentes em cada torreta e a operação que desempenham na peça, sendo que na Figura A.2 do Anexo A podem ser observadas as várias ferramentas.

Tabela 2: Operações desempenhadas pelas ferramentas de cada torreta

Ferramenta	Torreta de cima	Torreta de baixo
T01	Desbaste	Desbaste
T03	Acabamento	Acabamento
T05	Sangramento	Rosca
T07	Cone	-----
T09	Fresa	-----
T11	Escova de arames para limpeza	-----

Frequentemente, verifica-se a acumulação de aparas dentro dos tornos, o que provoca problemas à produção. O operador monitoriza a acumulação de aparas através de câmaras colocadas no interior dos tornos e, quando verifica acumulação excessiva da mesma, vai manualmente removê-la.

Quando o torneamento se finaliza, o robô transporta a peça para a estação de gravação a laser, onde se faz a gravação do número de série. Aí são gravados na peça o ano, mês (estes 2 identificados por letras), dia, turno, a máquina que fez o torneamento e o número sequencial da peça no dia, na máquina em questão.

Após a gravação do número de série, a peça passa novamente pela operação de limpeza e em seguida é colocada no Equator, um equipamento de controlo do tipo palpador que contém uma sonda que, por contacto, determina quotas da peça, de forma automática. Em seguida a peça é encaminhada para o Vici-Vision, outro equipamento de controlo que, tal como o Equator, permite a medição automática de características incluídas no plano de inspeção e ensaio, como diâmetros e ângulos. O funcionamento do Vici-Vision consiste num prato, animado de movimento de rotação, onde é pousada a peça, permitindo a medição das quotas por tecnologia laser. A necessidade de usar vários aparelhos automáticos de medição deve-se ao facto do Equator não ser capaz de medir comprimentos eficazmente e da Vici-Vision não ser capaz de medir cotas interiores, uma vez que estas não aparecem na imagem que é tirada à peça na máquina.

Em seguida, a peça é colocada pelo robô numa das rampas de saída: conformes (OK) ou não conformes (NOK), mediante serem aceites ou rejeitadas pelo Equator e pelo Vici-Vision. Se a peça for aceite por estas 2 máquinas, são feitas as restantes medições (manuais) na zona de controlo manual. Inicialmente, o objetivo era a não necessidade de quaisquer medições manuais, fazendo-se as medições que atualmente são feitas manualmente na máquina Vici-Vision, porém, dado que o cliente não quis suportar o custo adicional, essas medições são feitas manualmente.

Ao todo, o plano de inspeção e ensaio inclui 19 características medidas na peça, 15 de forma automática (11 no Vici-Vision e 4 no Equator) e 4 de forma manual, na zona de controlo manual. De destacar que, no início de cada turno, é retirada 1 peça por máquina e são medidas características adicionais.

Depois de feitas as medições acima referidas, as peças são testadas no Magnaflux, um equipamento onde a peça é banhada por um material que contém partículas com propriedades magnéticas, fluorescentes quando iluminadas com luz ultravioleta. É assim possível, através desta tecnologia, a identificação de micro fraturas no interior da peça, não detetáveis a olho nu. De realçar que este controlo não é feito logo no início do processo já que existe a possibilidade de o processo de torneamento eliminar estas micro fraturas. Depois deste controlo é aplicado um protetor de rosca às peças, sendo posteriormente embaladas.

A Figura 8 (Value Stream Map) ilustra, de forma, simplificada, a sequência de operações envolvida no processo produtivo, bem como uma estimativa do tempo necessário a cada operação, baseado na produção de uma peça.




Figura 8: Value Stream Map simplificado do processo

Os delays entre operações estão associados ao transporte das próprias peças bem como à espera pela disponibilidade das máquinas.

3.3 Sistema de Controlo de Qualidade

Após um período inicial de um ano em que as peças eram controladas por amostragem (1 em cada 3), verifica-se, atualmente, um sistema em que todas as peças são controladas de forma individual, por forma a melhor ter em atenção os elevados requisitos de qualidade do cliente.

Como referido, em cada peça são verificadas 19 características, 15 de forma automática e 4 de forma manual, bastando apenas uma estar não conforme para a peça ser rejeitada. Estas características são apresentadas, de seguida, com mais detalhe, na Tabela 3.

Tabela 3: Especificidades das características medidas na peça

Método	Descrição Método	Característica(s)	Tipo	Tipo de Valor
Automático	Vici-Vision	CAT 01; CAT 02; CAT 03	Distância	Variável
		CAT 04; CAT 05; CAT 06; CAT 07; CAT 08; CAT 09; CAT 10; CAT 11	Diâmetro Exterior	Variável
	Equator	CAT 12	Diâmetro Interior	Variável
		CAT 13; CAT 15	Batimento	Variável
		CAT 14	Ângulo	Variável
Manual	Micrómetro	MAN 01	Distância	Variável
	Anel Roscado	MAN 02	Rosca	Atributo
	Calibre Escatel	MAN 03	Distância	Atributo
	Método Visual	VIS01 (Existência de chanfro)	Visual	Atributo

Os resultados das medições feitas pelo Equator e Vici-Vision não são integrados num único posto de aquisição de dados (PAD) (Figura 9), sendo os valores introduzidos automaticamente no respetivo PAD e depois complementadas pela introdução manual das medições feitas pelo operador. Os PADs têm indicadas as medições a fazer, o valor alvo e os 2 limites de especificação, tomados como limites de rejeição.




Figura 9: Em cima, PADs do Equator (esquerda) e Vici-Vision (direita); Em baixo, software de introdução de medições manuais e ajuste de posição de ferramentas

Existe, também, a capacidade de criar um gráfico dos valores medidos que, no entanto, não tem em consideração quaisquer limites de controlo, apenas os limites de especificação definidos pelo cliente, como se encontra ilustrado na Figura 10. Uma desvantagem desta abordagem (sem controlo estatístico) é que não é possível condicionar, através de ações preventivas, o risco de se produzir peças não conformes. Em caso de não conformidade, o operador regista qual o tipo de não conformidade ocorrido e a causa que considera ter estado na origem da mesma. Adicionalmente, está também presente no PAD do Vici-Vision uma esquematização que permite ao operador observar a que medição se refere uma determinada característica na peça. Estes PADs estão ligados ao ERP e associam as medições às ordens de fabrico.



Figura 10: Gráfico produzido pelo Equator para a característica CAT12, com limites de especificação a vermelho

O processo natural de desgaste da ferramenta, abordado na Secção 2.4.1, leva a que os operadores tenham de ter especial atenção à forma como este afeta a qualidade das peças. Sendo certo que não é concebível a troca constante de ferramenta, pelo custo elevado e constante paragem do processo, o uso excessivo leva à produção de peças não conformes, podendo mesmo conduzir à quebra de ferramentas. Para além do desgaste excessivo permitido pelo operador, a quebra da ferramenta pode também dar-se pela maquinação de um material inesperadamente muito duro, não sendo neste caso a responsabilidade imputável ao operador, mas sim ao lote de matéria-prima.

Assim, na tentativa de corrigir a posição da ferramenta ou substituí-la na altura apropriada, para evitar a sua quebra, existem alguns procedimentos definidos. Primeiramente, uma das “ferramentas” das máquinas não efetua qualquer maquinação na peça, sendo meramente uma sonda palpadora que faz uma primeira medição das características, quando termina a maquinação da peça no torno. Deste modo, o operador pode mais rapidamente ajustar o offset da ferramenta, não tendo de esperar pelas medições do Equator e Vici-Vision. De notar que a sonda existe apenas nas máquinas 56 e 57, estando ausente na máquina 217.

Por outro lado, acontecimentos como a existência de ruído durante a maquinação da peça, uma alta rugosidade na peça acabada ou, ainda, pontos fora dos limites de especificação, são sinais de alerta para os operadores, indicando a possibilidade de ser necessário o reajuste da posição da ferramenta ou a troca da mesma.

3.4 Processamento de Dados

Após a recolha dos dados, mencionada em 3.4, estes são processados automaticamente e disponibilizados em contínuo, pelo Sistema de Gestão da Qualidade da empresa, em diversas tabelas. A informação contida nestas tabelas aborda diversos aspetos essenciais a uma melhor compreensão do processo, bem como à análise de variabilidade efetuada na Secção 4.

- **Tabela PIE**

Refere-se ao Plano de Inspeção e Ensaio em vigor para a peça maquinada. Para cada uma das 19 características inclui o tipo de característica (distância, diâmetro, etc.), o tipo de valor (variável ou atributo), as tolerâncias dimensionais e o método como é medida (Equator, Vici-Vision ou Manual).

- **Tabela Registos**

Registos dos valores das características para as peças produzidas. Inclui também data e hora do registo, lote da peça, a máquina onde foi produzida, o código do operador que efetuou o registo e o número de série, entre outros. Para perceber se o valor está conforme com as especificações ou não, são incluídos os parâmetros da Tabela PIE. Em caso de não conformidade, o operador regista qual o tipo de não conformidade ocorrido e a causa provável para a mesma.

- **Tabela Eventos**

Nesta tabela registam-se as trocas de ferramenta efetuadas, quer por desgaste, quer por quebra. Para cada troca, regista-se o tipo de ferramenta (desbaste, acabamento, etc.) em questão, a máquina e torreta onde se encontra, o operador que faz a troca e a data e hora da mesma.

- **Tabela Características & Ferramentas**

Reflete a associação entre características e ferramentas, indicando que ferramenta(s) afeta(m) o valor de cada uma das características. Possui dados relativos à maioria das características e encontra-se representada, de forma simplificada, na Tabela 4.

- **Tabela Registos de Dados Controlador**

Contém um conjunto de valores adquiridos diretamente dos controladores dos tornos CNC relativos ao processo de maquinação, como velocidade do spindle, ferramentas em utilização, posição das ferramentas, offsets e binários. Dado ter surgido numa fase tardia do projeto, não foi possível incorporar os dados provenientes da mesma na análise efetuada, particularmente nos modelos de Machine Learning apresentados na Secção 5 e Secção 6.

Tabela 4: Representação da Tabela Características & Ferramentas

Característica	Ferramenta(s)- Torreta Operação Ferramenta								
CAT01	1	Desbaste	T01	1	Acabamento	T03			
CAT02	1	Desbaste	T01	1	Acabamento	T03	1	Sangrar	T05
CAT03	1	Desbaste	T01	1	Acabamento	T03	2	Desbaste	T01
CAT04	1	Desbaste	T01	1	Acabamento	T03			
CAT05	1	Desbaste	T01	1	Acabamento	T03			
CAT06	1	Desbaste	T01	1	Acabamento	T03			
CAT07	1	Desbaste	T01	1	Acabamento	T03			
CAT08	2	Desbaste	T01	2	Acabamento	T03			
CAT09	2	Desbaste	T01	2	Acabamento	T03			
CAT10	2	Desbaste	T01	2	Acabamento	T03	2	Rosca	T05
CAT11	2	Desbaste	T01	2	Acabamento	T03	2	Rosca	T05
CAT12	1	Cone	T07	2	Acabamento	T03			
CAT14	1	Cone	T07	2	Acabamento	T03			
CAT15	1	Desbaste	T01	1	Acabamento	T03	2	Acabamento	T03
MAN01	1	Fresa	T09	2	Desbaste	T01	2	Rosca	T05
MAN02	2	Desbaste	T01	2	Acabamento	T03	2	Rosca	T05
MAN03	1	Fresa	T09	2	Desbaste	T01	2	Rosca	T05

3.5 Síntese

Neste capítulo apresenta-se o produto em estudo, uma manga de eixo que atua como suporte das rodas de veículos pesados e cuja matéria-prima consiste numa peça de aço forjada, fornecida pelo próprio cliente e submetida a operações de corte e torneamento. De seguida, descreve-se detalhadamente o processo produtivo que a peça percorre, desde a sua entrada na célula de produção até ao embalamento, passando pela maquinação num dos tornos CNC.

Menciona-se ainda o sistema de controlo de qualidade em vigor para o produto em questão, onde são recolhidas 19 características em cada peça (15 de forma automática e 4 de forma manual), bastando uma não respeitar as especificações definidas para que a peça seja rejeitada. Finalmente, descreve-se o processamento de dados, os quais após serem recolhidos

são disponibilizados em contínuo pelo Sistema de Gestão da Qualidade da empresa, em diversas tabelas.

4 Análise de Variabilidade

Neste capítulo expõem-se as diversas técnicas constituintes da análise de variabilidade efetuada. Esboça-se, primeiramente, um Diagrama de Ishikawa, por forma a identificar potenciais causas para o problema existente, e de seguida analisam-se o sistema de medição (para uma dimensão específica da peça, no caso a característica MAN01) e as variáveis intervenientes no processo com potencial influência no surgimento de peças defeituosas. Estas variáveis são analisadas quer individualmente, quer de forma conjunta, por forma a identificar eventuais fatores com influência mais significativa do que outros.

4.1 Diagrama de Ishikawa

O Diagrama de Ishikawa é uma ferramenta “causa e efeito” bastante útil no Controlo de Qualidade, em que se faz um levantamento de potenciais causas possíveis para um dado problema. As causas são divididas e agrupadas de acordo com o campo a que pertencem, podendo este ser um (ou mais) dos 6 Ms de Ishikawa: Método, Máquina, Medições, Meio Ambiente, Material e Mão de Obra (Stefanovic *et al*, 2014). Em conjunto com diversos operadores e a equipa de Qualidade da empresa, realizou-se, assim, uma sessão de brainstorming por forma a identificar possíveis causas de variabilidade que contribuam para a ocorrência de não conformidades. O estudo efetuado encontra-se representado no Diagrama de Ishikawa da Figura 11.




Figura 11: Diagrama de Ishikawa

Com base na experiência dos operadores e numa reflexão envolvendo os diversos intervenientes, destacam-se como mais importantes as seguintes causas:

- Por procedimento interno, as ferramentas de desbaste e acabamento são trocadas no início de cada turno, e as restantes (fresa, rosca, entre outras) uma vez por dia, independentemente do número de peças produzido. Deste modo, podem ocorrer trocas demasiado prematuras, quando poucas peças foram produzidas, ou tardias, se o operador do turno anterior não tiver procedido à troca por desgaste, se necessária. Assim, existe espaço para a otimização deste procedimento de troca de ferramentas;
- Verifica-se a ausência de sonda na máquina 217. Dada a criticidade da mesma no ajuste do offset da ferramenta e consequente tentativa de prevenir a ocorrência de não conformidades, a sua ausência nesta máquina pode contribuir para o alto número de não conformidades verificadas na mesma;
- Nos tornos, as peças são agarradas em ambos os topos por grampos. Na presença de apara, a maquinação pode ficar dificultada, não só na atuação das ferramentas, como também dos grampos, podendo a maquinação ser feita com alguma inclinação. Torna-se, assim, fulcral controlar a acumulação de apara nestas máquinas;
- A dificuldade em medir a rosca automaticamente leva à necessidade de esta medição ser feita manualmente, o que pode levantar alguns problemas em termos da precisão das medições. Deste modo, é pertinente a análise do sistema empregue nesta medição, efetuada na Secção 4.2;
- Diferentes lotes de matéria-prima, quer por diferenças nas dimensões da forja, quer na dureza, podem resultar em peças maquinadas significativamente diferentes, no que concerne ao cumprimento das especificações. Este é talvez um dos fatores mais críticos para a existência de não conformidades, como será abordado em 4.3;
- A troca de ferramentas, para além de respeitar a frequência pré-definida, é também feita em caso de quebra ou desgaste, sendo, neste último caso, crítica a atenção do operador a sinais do mesmo. A experiência do operador e o conhecimento do processo têm um papel decisivo na prevenção de desgaste excessivo de ferramentas que conduzam à sua quebra;
- Dependendo do tipo de operação, a troca de ferramenta pode levar à existência de não conformidades após a sua ocorrência. Se no caso da fresa (T09) a troca é bastante simples e o ajuste de posição não causa problemas, a troca de ferramentas de desbaste e acabamento costuma ser bastante mais problemática, com este processo a gerar, por diversas vezes, não conformidades.

4.2 Análise do Sistema de Medição

A análise do sistema de medição focou-se na característica MAN01, uma distância medida (manualmente) com recurso a micrómetro. A razão desta escolha deve-se ao facto dos sistemas de medição empregues nas 15 características recolhidas de forma automática (Equator e ViciVision) já terem sido objeto dessa análise aquando do início de funcionamento da célula de produção, não se justificando novo estudo. Para além disso, para o período em análise, esta foi a 3ª característica que apresentou maior número de não conformidades, conforme será visto na Secção 4.3.

Esta análise baseou-se, em primeira instância, na realização de um Estudo do Tipo 1 e, posteriormente, num teste R&R. Os resultados são respetivamente apresentados nas Secções 4.2.1 e 4.2.2.

4.2.1 Estudo do Tipo 1

Para avaliar o efeito do enviesamento e repetibilidade, procedeu-se a um Estudo do Tipo 1. Atendendo às amostras padrão disponíveis e à gama de valores que a característica em estudo (MAN01) pode assumir, o Teste do Tipo 1 ao micrómetro consistiu na realização de 50 medições de um padrão de 80,85 mm. Os resultados, gerados pelo software Minitab, encontram-se ilustrados na Figura 12.




Figura 12: Estudo do Tipo 1 ao micrómetro

A média das medições situou-se nos 80,8756 mm estando-se, assim, na presença de um ligeiro enviesamento face ao valor verdadeiro de 80,875 mm. Tal observação é corroborada pelo teste t, em que a hipótese nula (H_0) indica a ausência de enviesamento e a hipótese alternativa (H_1) aponta para a presença de enviesamento. Neste teste, a hipótese nula foi rejeitada com um valor de prova de 3,3%, inferior ao nível de significância (5%), pelo que se conclui que há de facto enviesamento.

Por outro lado, em termos de repetibilidade, obtiveram-se resultados bastante positivos. Apenas 2,91% da variabilidade total das medições é atribuível ao efeito de repetibilidade, que o Minitab calcula como correspondendo a um sexto da tolerância especificada para o processo. Visto que a percentagem obtida é inferior a 10%, como recomenda o AIAG (2010), conclui-se que o micrómetro é bastante aceitável em termos de repetibilidade.

Esta última conclusão é ainda reforçada pela análise dos índices de capacidade, Cg e Cgk, que apresentam valores muito superiores à referência (1,33). No entanto, atendendo à ligeira diferença entre ambos, com o Cg a ser ligeiramente superior ao Cgk, de novo se conclui que existe algum enviesamento nas leituras do micrómetro.

4.2.2 Testes de Repetibilidade e Reprodutibilidade (R&R)

A avaliação do efeito de repetibilidade, no contexto de um Estudo do Tipo 1, está limitada pelo facto de a análise incidir sobre uma única amostra (padrão). Importa, então, analisar a repetibilidade no contexto real do processo, ou seja, medindo várias amostras da característica em estudo. Por forma a alcançar esse objetivo, pode recorrer-se a testes R&R, que, como mencionado na Secção 2.1, captam a variabilidade intrínseca ao equipamento de medição (repetibilidade) e a variabilidade inerente ao operador (reprodutibilidade).

A realização do Teste R&R à característica MAN01 implicou a seleção aleatória de 10 peças, posteriormente medidas por 3 operadores, escolhidos igualmente de forma aleatória. Cada operador mediu cada peça 3 vezes, pelo que ao todo se recolheram 90 observações. A cada peça foi atribuído um número identificativo, sendo que as mesmas foram reordenadas de forma aleatória após registadas 30 e 60 observações.

A Figura 13, gerada através do software Minitab, permite a obtenção de diversas conclusões no que concerne à variação total do processo.




Figura 13: Output do Teste R&R gerado através do Minitab

O gráfico de componentes de variação ilustra que uma parte significativa da variação total é devida ao sistema de medição (Gage R&R), o que é indesejável. Verifica-se também que o efeito de repetibilidade é ligeiramente superior ao de reprodutibilidade.

Analisando as cartas de controlo, verifica-se, relativamente à das amplitudes (R), que as medições do operador 1 têm amplitude inferior à dos restantes, pressupondo-se alguma dificuldade dos operadores 2 e 3 na utilização do sistema de medição. Para o operador 3 regista-se mesmo um valor de amplitude maior do que o esperado, com base nos limites de controlo. Já para a carta das médias (Xbar), como referido em 2.1, é conveniente a obtenção de pontos fora dos limites de controlo, o que indica a capacidade dos operadores em discernir

entre as diferentes peças. O AIAG (2010) recomenda mesmo que pelo menos 50% dos pontos se apresentem fora dos limites de controlo. Para o estudo em análise, observaram-se 7 pontos fora dos limites, o que indicia alguma dificuldade na distinção entre diferentes peças.

O efeito de reprodutibilidade pode ser avaliado pelos 2 gráficos do lado direito, mais em baixo. Analisando o gráfico que compara as medições dos operadores, verifica-se que o operador 1 tende a efetuar medições mais baixas que os outros 2. Para além disso, a variabilidade nas medições dos operadores 1 e 3 é ligeiramente superior às do operador 2, existindo mesmo 2 outliers nas medições do operador 3.

Para além do efeito operador, parece também existir uma interação peça-operador, demonstrada pelo gráfico mais abaixo. Se o sistema de medição, em si, apresentar pouco erro, então todos os operadores deverão obter, de forma consistente, resultados semelhantes ao medir as mesmas peças. Consequentemente, as linhas e os pontos do gráfico ficariam muito próximos ou sobrepostos. No entanto, isto não se verifica e, dado que a distância entre as linhas correspondentes aos operadores varia de peça para peça, podemos concluir que existe uma interação entre peça e operador.

Para além da Figura 13, o Minitab permite, igualmente, obter a Tabela 5, que corrobora a análise gráfica feita anteriormente.

Tabela 5: Resultados do Teste R&R

Source	VarComp	Contribution (of VarComp)	StdDev (SD)	Study Var (6 × SD)	Study Var (%SV)	Tolerance (SV/Toler)
Total Gage R&R	8,69E-5	61,45%	0,00932	0,05594	78,39%	13,98%
Repeatability	5,22E-5	36,88%	0,00722	0,04333	60,73%	10,83%
Reproducibility	3,48E-5	24,57%	0,00590	0,03537	49,57%	8,84%
Operador	1,51E-5	10,70%	0,00389	0,02334	32,72%	5,84%
Operador*Peça	1,96E-5	13,87%	0,00443	0,02658	37,24%	6,64%
Part-To-Part	5,45E-5	38,55%	0,00738	0,04430	62,09%	11,08%
Total Variation	1,414E-4	100,00%	0,01189	0,07135	100,00%	17,84%

O efeito conjunto da repetibilidade e reprodutibilidade apresenta um PTR de 13,98%, que, face às recomendações do AIAG (2010), não permite a aceitação imediata do equipamento de medição, conduzindo a uma análise adicional.

A contribuição do sistema de medição para a variação total é de 61,45%, muito superior aos 38,55% do efeito peça-a-peça. Analisando a variação do estudo, que consiste numa estimativa da precisão da medição, ou da variabilidade das medições, as conclusões são semelhantes, registando-se percentuais de 78,39% e 62,09% para o sistema de medição e peça-a-peça, respetivamente. Por seu lado, a coluna do percentual de tolerância mostra as diferentes fontes de variação de medição comparadas à tolerância da medida. Num cenário ideal, o percentual de tolerância do R&R total da Medição seria próximo de zero, indicando que a variação decorrente do sistema de medição é pequena em relação à tolerância, o que não acontece.

Por fim, de forma a aferir se a interação peça-operador de facto se verifica, importa realizar um teste ANOVA a 2 fatores. Os resultados encontram-se na Tabela 6.

Tabela 6: Teste ANOVA para o Estudo R&R

Source	DF	SS	MS	F	P
Peça	9	0,0054152	0,0006017	5,42021	0,001
Operador	2	0,0011303	0,0005651	5,09100	0,018
Peça * Operador	18	0,0019982	0,0001110	2,12841	0,015
Repeatability	60	0,0031293	0,0000522		
Total	89	0,0116730			

Perante um valor de prova de 1,5% verifica-se que a interação é significativa, como se suspeitava pela análise gráfica da Figura 13.

Em suma, através da análise efetuada conclui-se que existe variação excessiva no sistema de medição e que, como este não consegue produzir dados consistentes e confiáveis, deverá ser aprimorado. Esta tarefa passa, designadamente, pela implementação de metodologias de treino dos operadores que permitam uniformizar o processo de medição e melhorar a qualidade dos dados obtidos.

4.3 Análise de Variáveis

Para um período em análise de meados de fevereiro a início de abril onde, ao todo, se obtiveram registos relativos à produção de 5780 mangas de eixo, verificou-se uma taxa de rejeição de peças de 2,40% o que, tendo em conta os elevados requisitos de qualidade do cliente, traduz-se em custos elevados para a empresa. Tornou-se então necessário, após o levantamento de causas que possam estar na origem de não conformidades, a análise dos dados fornecidos pela empresa por forma a perceber quais os fatores que contribuem de forma mais significativa para as mesmas e, posteriormente, o levantamento de algumas sugestões de melhoria do processo.

Primeiramente, procurou-se perceber que tipos de não conformidades ocorrem com maior frequência e, com ainda maior relevo, quais as causas que os operadores mais frequentemente registam como estando na origem dessas mesmas não conformidades. Como referido na Secção 3.4, em caso de não conformidade, o operador regista qual o tipo de não conformidade ocorrido e a causa provável para a mesma. Deste modo, e já que existem algumas diferenças na terminologia que diferentes operadores utilizam para registar a ocorrência de não conformidades e suas causas, uniformizou-se a informação contida nas 2 colunas correspondentes na Tabela Registos, obtendo-se, posteriormente, os Gráficos de Pareto das Figuras 14 e 15. Os gráficos individualizados para cada uns dos 3 tornos podem ser consultados nas Figuras B.1 a B.6 do Anexo B.




Figura 14: Frequência dos diferentes tipos de Não Conformidades




Figura 15: Frequência das diferentes causas na origem de Não Conformidades

Relativamente à classificação de não conformidades (Figura 14), verifica-se uma maior rejeição de peças tendo por base o não cumprimento de especificações relacionado com diâmetros. Esta situação é compreensível dado que das 19 características registadas, 9 consistem em diâmetros, alguns deles com tolerâncias bastante baixas, tal como a característica CAT05, a ser abordada mais à frente.

Já no que concerne às causas prováveis das não conformidades (Figura 15), verificou-se na observação do processo e em conversa com diversos operadores que as principais causas para as mesmas se prendem com 3 situações relacionadas com as ferramentas: quebra, desgaste e troca, ocorrendo nesta última um mau ajuste da posição. No entanto, como visto anteriormente, também o lote pode estar na origem de não conformidades, quer pelas dimensões do material, quer pela dureza. A Figura 15 demonstra que quase 80% das causas prováveis registadas pelos operadores se prendem com as ferramentas. De salientar que, quando o desgaste da ferramenta está na origem de não conformidades, apenas se mencionava

a classificação da não conformidade. Não sendo efetuada qualquer menção da causa na respetiva coluna, a barra correspondente no Gráfico de Pareto toma o valor “N/A”.

Procedendo-se ao registo de 19 características para cada peça produzida, e bastando apenas uma estar não conforme para a peça ser rejeitada, é de fulcral importância compreender também a quais delas está associado um maior número de não conformidades. Pelo Gráfico de Pareto da Figura 16, verifica-se que a característica CAT05 corresponde a 20% das não conformidades registadas, o dobro da característica que ocupa o 2º lugar. Conforme visto na Secção 3.4 esta característica corresponde a um diâmetro exterior que resulta de uma operação de acabamento (Ferramenta 3). Assim, pode-se concluir que esta é a característica que apresenta o maior número de não conformidades associadas, não só em termos gerais, mas também para cada uma das máquinas, individualmente (Figuras B.7 a B.9 do Anexo B).




Figura 16: Distribuição de não conformidades pelas características

Efetuando um estudo de correlação, verifica-se que 3 das 5 características com mais não conformidades associadas (CAT05, CAT06 e CAT07) estão fortemente correlacionadas para todas as máquinas, conforme se verifica pelas Figuras B.10 a B.12 do Anexo B. Dada a similaridade entre estas 3 características (todas elas resultam de uma operação de acabamento realizada pela mesma ferramenta), confirma-se assim a criticidade do acabamento para a geometria final da peça, até porque é esta operação que lhe confere essa mesma geometria, por ser efetuada após o desbaste.

Desta forma, formulou-se a hipótese de que a ferramenta de acabamento (Ferramenta 3) não estaria a ser trocada com a frequência desejada, estando o desgaste sucessivamente acumulado a conduzir ao aparecimento de não conformidades. Esta hipótese consubstanciou-se também na verificação, através da Tabela Eventos, de que para as 3 máquinas, e nas 2 torretas de cada uma delas, a ferramenta de desbaste (Ferramenta 1) foi trocada, sensivelmente, o mesmo número de vezes em comparação com a ferramenta de acabamento, a qual, como referido, contribui mais decisivamente para a geometria final da peça. Tal observação baseia-se nos Gráficos de Pareto das Figuras 17, 18 e 19.




Figura 17: Trocas de Ferramenta na Máquina 56




Figura 18: Trocas de Ferramenta na Máquina 57




Figura 19: Trocas de Ferramenta na Máquina 217

Perante a sugestão de trocar a ferramenta de acabamento com maior frequência por comparação com a de desbaste, os operadores indicaram que a frequência de troca das 2 ferramentas é propositadamente igual, não havendo interesse prático em aumentar uma em relação à outra. Isto deve-se, na opinião dos mesmos, ao facto de as 2 ferramentas terem taxas de desgaste semelhantes e, ao aumentar a frequência de troca da ferramenta de acabamento, ir-se-iam obter situações em que a ferramenta de acabamento estava nova e a de desbaste não. Esta particularidade conduziria a um maior desgaste das duas, já que a de acabamento iria realizar na peça não só a sua operação, mas também parte da de desbaste, já em pior estado, o que traria ainda mais problemas e um maior número de trocas de ferramenta ao processo.

Por forma a verificar se estas alegações se verificam na realidade, procedeu-se a um teste two-sample t, habitualmente usado para constatar se duas amostras provêm de populações com o mesmo valor esperado. As duas amostras consideradas consistiram nos tempos até ocorrência de nova troca de ferramenta(s), tendo por base as 2 situações distintas que se pretendem confrontar: trocam-se ambas as ferramentas em simultâneo (amostra 1); apenas se troca a ferramenta de desbaste ou acabamento (amostra 2).

São condições necessárias para a realização do teste que os valores sejam independentes, aleatoriamente seleccionados de 2 populações que seguem uma distribuição normal e que os 2 grupos tenham variâncias iguais. Não sendo assegurada a normalidade de uma das amostras (a situação em que apenas se troca uma ferramenta), optou-se por prosseguir já que a dimensão da amostra era significativa, sendo superior ao tamanho recomendado (25) (JMP, 2022).

Relativamente à igualdade das variâncias, a mesma foi testada e não se rejeitou a hipótese nula (H_0), obtendo-se valores de prova de 95,3 e 44,6% nos testes de Bonett e Levene, respetivamente. Assumiu-se, deste modo, a igualdade das variâncias e procedeu-se ao teste two-sample t.

Neste teste, a hipótese nula (H_0) refere que as médias das populações são iguais ($\mu_1 - \mu_2 = 0$). Esta hipótese foi rejeitada com um valor de prova de 2,6%, obtendo-se um intervalo de confiança para a diferença entre as 2 médias de [10,4; 156,3], expresso em minutos. A Figura 20 apresenta, de forma sumária, os resultados obtidos nos 2 testes efetuados.

Test

Null hypothesis

$H_0: \sigma_1 / \sigma_2 = 1$

Alternative hypothesis

$H_1: \sigma_1 / \sigma_2 \neq 1$

Significance level

$\alpha = 0,05$

Test

Method

Statistic

DF1

DF2

P-Value

Bonett

*

0,953

Levene

0,58

1

101

0,446

Test

Null hypothesis

$H_0: \mu_1 - \mu_2 = 0$

Alternative hypothesis

$H_1: \mu_1 - \mu_2 \neq 0$

T-Value

2,30

DF

46

P-Value

0,026

Figura 20: À esquerda, output do teste aos desvios padrões. À direita, output do teste 2-sample t

Conclui-se, assim, que as alegações dos operadores têm fundamento e trocar as ferramentas de desbaste e acabamento em simultâneo permite, de facto, prolongar a vida útil das mesmas.

4.3.1 Análise Individualizada

Com recurso a técnicas de estatística descritiva, procedeu-se à análise individualizada de algumas variáveis chave no processo produtivo, identificadas no Diagrama de Ishikawa da Secção 4.1 como potenciais causas para o problema existente.

Turno

Como referido na Secção 3.2, a célula de produção opera 24 horas por dia, organizando-se em 3 turnos (manhã, tarde e noite, em diante referidos como A, B e C, respetivamente). Uma análise à rejeição de peças por turno permitiu concluir a existência de um turno com maior capacidade produtiva, simultaneamente rejeitando um menor número de peças. Os resultados encontram-se na Tabela 7.

Tabela 7: Rejeição de peças por turno

Turno	Peças Produzidas	Peças Rejeitadas	Taxa de Rejeição
A	1970	71	3,68%
B	2604	25	0,96%
C	1206	42	3,48%

Tendo a empresa já conhecimento deste facto, foi reforçada a importância de se atuar no sentido de reduzir a taxa de rejeição dos turnos A e C, sendo aplicada uma rotatividade entre turnos, em que operadores do turno B foram colocados provisoriamente nos turnos A e C, por forma a haver uma comunicação entre operadores que permita transmissão de conhecimento acerca de atuação no processo, que permita a redução das taxas de rejeição.

Máquina

Incorporando a célula de produção três equipamentos de maquinaria (tornos), importa, naturalmente, verificar se existem diferenças significativas entre estes, quanto ao número de não conformidades.

Através do gráfico de Pareto da Figura 21, verifica-se que mais de metade das não conformidades registadas provêm de peças maquinadas na Máquina 217, que é até a máquina mais recente na célula. Como referido na Secção 3.3, esta é uma máquina que, à altura da análise, não tinha ainda instalada a sonda. Verificando-se que a sonda permite efetuar uma primeira medição de algumas características (em concreto, CAT05 e CAT09), possibilitando mais rapidamente atuar sobre a posição da ferramenta, ajustando o offset, sugeriu-se, naturalmente, a inclusão de sonda nesta máquina, o que permitiria não só reduzir o número de não conformidades associadas, como também torná-la na máquina que potencialmente melhor cumpriria as especificações em relação às outras 2, hipótese a ser estudada mais à frente, na Secção 4.3.2.




Figura 21: Distribuição de Não Conformidades pelas 3 máquinas

Lote

Como verificado na Seção 4.1, o lote de matéria-prima desempenha um papel fulcral no processo produtivo. A presença de micro-fraturas no interior da peça, verificadas através do Magnaflux, pode levar à rejeição da mesma. Adicionalmente, e talvez ainda de maior importância, a excessiva dureza do material pode tornar a maquinação do mesmo não exequível, levando em alguns casos à quebra da ferramenta, prejudicial para a empresa. As variações dimensionais da forja de lote para lote contribuem igualmente para o cumprimento ou não das especificações.

A existência de diferenças entre os lotes de matéria-prima foi comprovada através do Gráfico de Pareto da Figura 22, onde se verificou que 2 lotes em específico contribuem para quase 60% das não conformidades registradas.

Perante a sinalização de diferenças entre os lotes, responsáveis da empresa referiram que a variação dentro do tratamento térmico existente no processo de forjamento levado a cabo pelo fornecedor (neste caso, também cliente) causa essas mesmas diferenças, não havendo soluções ao alcance da empresa para resolver tal situação.




Figura 22: Distribuição de Não Conformidades por lote de matéria-prima

Operador

Como visto anteriormente, o operador desempenha, também, uma influência decisiva no processo produtivo e na existência (ou não) de não conformidades. É o controlador que, recebendo sinais da sonda, toma a decisão de ajustar o offset da ferramenta. Para além disso, é também o responsável pelas trocas de ferramenta que, quando mal posicionadas na torreta, produzem não conformidades, podendo mesmo a nova ferramenta quebrar. Adicionalmente, as trocas de ferramenta partem de uma decisão do próprio operador baseado em sinais de desgaste da mesma. Estes podem ser a existência de pontos fora dos limites de especificação, a rugosidade da peça final, que apesar de conforme as especificações, pode indiciar problemas futuros caso não se atue, e o ruído da máquina na maquinação da peça. Aliás, foi indicado por diversos operadores que um fator decisivo para a antecipação de não conformidades e problemas com quebras de ferramenta é a experiência do próprio operador e a sensibilidade para os sinais mencionados.

Para além da diferença de experiência dos operadores entre turnos, refletida nas taxas de rejeição vistas na Tabela 7, também dentro dos próprios turnos existem diferenças na experiência dos operadores, existindo em cada um dos turnos 2 operadores sénior, que se pressupõe terem maior conhecimento do processo, e 1 júnior, ainda a adquirir experiência. A existência de diferenças entre controladores está esbatida no Gráfico Pareto da Figura 23.




Figura 23: Distribuição de Não Conformidades por operador

Verifica-se, deste modo, que 3 operadores em específico contribuem para mais de 60% das não conformidades registadas.

4.3.2 Análise cruzada por característica

Após a análise individual dos diversos fatores que podem estar na origem de não conformidades, importa, igualmente, proceder à sua análise conjunta, por forma a identificar eventuais fatores com influência mais significativa do que outros. Tendo este objetivo em mente, recorreu-se a diversas ferramentas da qualidade, como cartas de controlo e análise de capacidade.

Nesta análise cruzada, começou-se por avaliar o comportamento e interação dos diferentes fatores na variável de resposta CAT05 que, como visto anteriormente, para o período em

análise foi, de forma destacada, a característica em que se observou maior número de não conformidades (Figura 16).

A primeira preocupação foi aferir a distribuição que os dados seguem, o que condiciona a análise posterior, quer a nível de testes estatísticos que se podem realizar, quer na análise de capacidade. Deste modo, testou-se a normalidade dos dados com recurso ao Minitab, procurando perceber se seguem uma distribuição normal (Figura 24). Como o valor de prova ($<0,005$) é inferior ao nível de significância (0,05), rejeita-se a hipótese nula (que postula a normalidade dos dados) e considera-se que os dados não seguem uma distribuição normal.




Figura 24: Teste à normalidade- CAT05

No entanto, este resultado já era de algum modo expectável dada a dimensão da amostra (>5000). Verifica-se que os diversos testes à normalidade (Shapiro-Wilk, Anderson-Darling, entre outros) procuram testar a normalidade de uma forma teórica, isto é, a aproximação à curva da distribuição normal “perfeita”. Assim, em amostras de grande dimensão, e já que a potência do teste aumenta, mesmo desvios extremamente pequenos em relação à normalidade teórica, que na prática não originam quaisquer problemas, são detetados e a hipótese nula acaba por ser rejeitada (Greener, 2020). Deste modo, e até mesmo considerando que para cartas de controlo de valores individuais, desvios moderados da distribuição normal (como é o caso) não afetam significativamente os resultados das cartas (Minitab, 2022a), optou-se por efetuar a análise sem previamente proceder a qualquer transformação dos dados.

Através de uma análise de capacidade às 3 máquinas conclui-se que a máquina 217 é a que pode potencialmente melhor cumprir as especificações, designadamente na proximidade em relação ao *target*. O índice C_p , apresentado na Secção 2.2.2, reflete a capacidade do processo que pode ser alcançada se as causas especiais de variação entre subgrupos forem removidas, ou seja, a potencial capacidade do processo. Analisando a Figura 25, verifica-se que a máquina 217, sendo aquela em que o P_p é menor, possui ao mesmo tempo o maior C_p , indicando o seu maior potencial em cumprir as especificações relativamente às restantes máquinas, caso as causas especiais de variação sejam removidas do processo. Realça-se também, para as 3 máquinas, alguma disparidade entre os índices C_p e C_{pk} , o que indica que o processo não está totalmente centrado face ao objetivo. Sendo a máquina 217 aquela em que o desvio do C_{pk} é menor em relação ao C_p , conclui-se, igualmente, que nesta máquina o desvio do processo face ao *target* é menor.




Figura 25: Análise de capacidade para as 3 máquinas- CAT05

Sendo aquela que aparenta ter melhor potencialidade em cumprir as especificações, a máquina 217 é também a que, para o período em análise, regista maior número de não conformidades, como visto em 4.3.1. Estas informações, parecendo apontar em sentidos opostos, são na verdade compreensíveis dada a ausência da sonda nesta máquina que, como já se viu, é crítica no ajuste de posição das ferramentas. Deste modo, é expectável que instalando a sonda na máquina 217 se removam causas de variabilidade entre registos, contribuindo, assim, para uma melhor capacidade, até superior em comparação com as restantes máquinas, em cumprir as especificações, designadamente no que diz respeito à característica CAT05.

No Diagrama de Ishikawa da Secção 4.1 identificaram-se operador e lote de matéria-prima como 2 dos fatores potencialmente com maior impacto na existência de não conformidades. Procurou-se, então, perceber se algum deles seria mais preponderante que o outro para a ocorrência das mesmas. Para tal, seleccionou-se um dos operadores com mais não conformidades associadas (operador 3195) e analisaram-se os valores da característica em estudo (CAT05) para os diferentes lotes de onde provinham as peças produzidas. Os resultados obtidos para as 3 máquinas são apresentados nas Figuras 26, 27 e 28.

Conclui-se pela análise das cartas a maior existência de pontos fora de controlo quando o operador 3195 lida com lotes identificados na Secção 4.3.1 como tendo maior número de não conformidades associadas, destacando-se os lotes 697913_AN e 707914_AO. Por oposição, para lotes com baixo número de não conformidades associadas, este operador consegue manter um processo relativamente estável, por vezes até sem quaisquer pontos fora dos limites de controlo.




Figura 26: Carta I-MR para CAT05- Máquina 56; Operador 3195




Figura 27: Carta I-MR para CAT05- Máquina 57; Operador 3195




Figura 28: Carta I-MR para CAT05- Máquina 217; Operador 3195

Determina-se, assim, a possibilidade de o lote ter maior influência do que o operador na ocorrência de não conformidades, ao verificarem-se situações em que operadores com maior número de não conformidades associadas conseguem obter processos relativamente estáveis na presença de lotes não defeituosos.

Por forma a consolidar as hipóteses previamente lançadas, repetiu-se a análise efetuada para outras características, apresentando-se no Anexo C os resultados dessa mesma análise para a característica CAT12, a segunda com mais não conformidades associadas para o período em estudo. A análise para esta característica vem reforçar a ideia da maior preponderância do lote por comparação com o operador.

4.4 Síntese

Este capítulo principia pelo esboço de um Diagrama de Ishikawa, com o objetivo de identificar causas para o problema existente. Sendo uma das causas identificadas a dificuldade em medir a rosca automaticamente, que leva à necessidade de esta medição ser feita manualmente, analisa-se o sistema de medição para uma dimensão específica da peça, a característica MAN01. Através desta análise conclui-se que existe variabilidade excessiva associada ao sistema, pelo que o mesmo deve ser aprimorado.

De seguida, analisam-se os fatores intervenientes no processo de forma individual, onde se conclui que há diferenças internas em diversas variáveis e, posteriormente, de forma conjunta. Diversas análises estatísticas permitiram aferir que há diferenças significativas entre as máquinas CNC presentes na célula de produção e que o lote de matéria-prima é um fator de preponderância mais significativa quando comparado com o operador da célula.

5 Modelos de Qualidade Preditiva

Tendo sido identificados e analisados fatores que influenciam o surgimento de não conformidades, considerou-se igualmente de crítica importância o desenvolvimento de um modelo capaz de prever a ocorrência não conformidades em função do contexto de produção. O desenvolvimento de modelos bem-sucedidos pode contribuir para a redução da produção de peças com não conformidades, ao permitir à empresa fazer ajustes pertinentes ao processo de forma expedita, tendo por base previsões em tempo real, reduzindo, também, o desperdício de matéria-prima.

Assim, neste Capítulo é descrita a sequência de etapas que permitiu a obtenção de diversos modelos de Machine Learning com a finalidade preditiva mencionada. Na Secção 5.1 é feita uma descrição dos dados utilizados na criação dos modelos, com foco na proporção de não conformidades e no pré-processamento efetuado. A Secção 5.2 aborda a criação de preditores, inferidos através dos dados utilizados, com o intuito de auxiliar os algoritmos de Machine Learning na obtenção de previsões com maior precisão. Por fim, na Secção 5.3 descrevem-se várias técnicas e métodos utilizados na preparação dos dados, para que estes possam ser usados no treino dos modelos preditivos.

Nas diversas tarefas de tratamento de dados e obtenção de modelos de Machine Learning descritos ao longo desta Secção, recorreu-se à linguagem de programação Python. Esta é uma linguagem simples e eficiente que conta com diversos *packages* úteis na manipulação de dados tais como *pandas* e *numpy*, usados frequentemente ao longo do projeto.

5.1 Descrição dos dados utilizados

Em qualquer processo industrial, verifica-se que o fator máquina tem elevada preponderância na operação de fabrico e, por conseguinte, no sucesso ou insucesso da mesma. Tendo-se observado diferenças entre os 3 equipamentos de maquinaria presentes na célula de produção, descritas em detalhe na Secção 4.3.1, considerou-se contraproducente a construção de modelos de Machine Learning com aplicação para as 3 máquinas em simultâneo. Tal deve-se ao facto de os modelos terem de ser extremamente genéricos por forma a prever eficazmente para diferentes máquinas. Deste modo, o *dataset* utilizado, obtido com recurso à Tabela Registos (descrita na Secção 3.4), no qual constavam registos de 9010 peças, foi restringido por forma a conter informação relativa a apenas uma máquina. Selecionando-se a máquina 217, por ser a que revela maior número de não conformidades para o período em análise, passaram a constar no *dataset* registos relativos à produção de 3500 peças.

5.1.1 Pré-Processamento

Tendo-se restringido o *dataset* utilizado a registos de peças produzidas exclusivamente na Máquina 217, eliminaram-se, seguidamente, registos com valores em falta relativos ao número de série e lote de matéria-prima da peça, por forma a não prejudicar a qualidade dos

dados. Verificando-se a existência de 1 peça com número de série em falta e de 25 peças com lote em falta, o *dataset* passou, assim, a conter registos de 3474 peças.

A ausência de registos de medições de características em diversas peças foi igualmente um problema. Constatou-se a existência de 1 peça sem qualquer registo relativo às características CAT10 e CAT11, a qual foi removida. De seguida, as características adquiridas de forma manual (pelo operador) foram objeto de estudo. Diversas peças não possuíam registos das características MAN01, MAN02, MAN03 ou VIS01. Após uma análise das peças em que tal se sucedia e verificação com operadores da célula, constatou-se que, frequentemente, peças rejeitadas nos equipamentos de controlo automático (Equator e Vici-Vision) não são objeto de medições manuais, sendo retiradas da linha de produção, por forma a não congestionar o trabalho dos operadores com peças logo à partida rejeitadas. Deste modo, a remoção de peças nestas condições eliminaria, igualmente, diversas não conformidades registadas nas características adquiridas de forma automática, o que baixaria a proporção de não conformidades nos registos, sendo prejudicial para a capacidade preditiva dos modelos. Assim, optou-se por desconsiderar as características adquiridas de forma manual (MAN01, MAN02, MAN03 e VIS01) dos modelos de Machine Learning, focando exclusivamente nas 15 características adquiridas de forma automática.

Por fim, e dado que cada registo diz respeito a uma característica, procedeu-se à pivotagem da Tabela Registos, tendo por índice o “Número de Série”, passando a ter em cada instância informação relativa às 15 características mencionadas. Para esse efeito, recorreu-se à função *pivot_table* da já referida biblioteca *pandas*.

5.1.2 Análise preliminar

Para as 3473 peças consideradas, verifica-se a rejeição de 82 das mesmas, o que se traduz numa taxa de rejeição de 2.36%. A Figura 29 ilustra o número de peças rejeitadas com um dado número de não conformidades, aferindo-se, por exemplo, que 62 peças rejeitadas possuíam uma não conformidade apenas. Por seu turno, na Figura 30 apresenta-se o total de não conformidades para cada uma das 15 características a considerar.




Figura 29: Número de não conformidades em peças rejeitadas




Figura 30: Número de não conformidades por característica

Verifica-se, regra geral, um número muito reduzido de não conformidades nas diversas características. A baixa incidência dessa categoria no *dataset* (classe minoritária) leva a um extremo desbalanceamento dos dados, que será analisado na Secção 5.3.6.

5.1.3 Tabela Registos&Eventos

O procedimento de troca de ferramentas, documentado pelos operadores da empresa e posteriormente disponibilizado na Tabela Eventos, é crítico na ocorrência (ou não) de não conformidades, conforme referido na Secção 3.3. De facto, três principais razões para a ocorrência de não conformidades prendem-se com a quebra da ferramenta, o desgaste excessivo da mesma ou um ajuste incorreto da posição na sua troca. Como tal, considerou-se oportuna a junção da Tabela Registos com a Tabela Eventos, sendo as instâncias ordenadas pela coluna “Data_Hora”. Assim, obtém-se uma série temporal mais completa com a sequência de eventos que pode ter originado uma não conformidade. A Tabela resultante designa-se por Registos&Eventos e serve de base à criação de preditores, detalhada na Secção seguinte.

5.2 Criação de Preditores

A criação de preditores é uma etapa importante em qualquer projeto de Machine Learning, onde se pretende obter um conjunto de preditores através dos dados de input (*raw data*) por forma a melhorar a performance de um algoritmo na sua tarefa preditiva. Nos dados de origem, apenas se consideraram úteis na caracterização do contexto do processo produtivo os fatores lote de matéria-prima, turno e operador, tendo sido incorporados como preditores diretos nos modelos. Dado que os restantes fatores presentes na Tabela Registos&Eventos não assumem grande significado enquanto preditores diretos, diversos preditores foram sintetizados a partir desta Tabela. Os seguintes preditores foram então criados:

- **Taxa Dinâmica de Rejeição na Máquina**

Rácio entre peças rejeitadas e peças produzidas. Age como um estimador dinâmico da performance da máquina ao longo do turno, assumindo que esta se pode degradar, por exemplo, devido ao desgaste.

- **Número de Peças produzidas pelo Operador**

Número de peças anteriormente produzidas pelo operador no turno. Um operador que demonstre cansaço ou esteja ainda no início do turno pode aumentar as probabilidades da ocorrência de não conformidades.

- **Número de Peças produzidas na Máquina**

Indicador de quantas peças foram produzidas anteriormente na máquina, num dado turno. Tal como a Taxa Dinâmica de Rejeição, assume que a máquina se vai degradando ao longo do turno.

- **Número de Peças desde Troca de Ferramenta**

Utilizado para as diversas ferramentas existentes numa máquina. Uma peça produzida logo após a troca de uma ferramenta (em caso de ajuste incorreto) ou quando esta já se encontra desgastada traduz-se numa maior probabilidade de não conformidade.

- **Violação de Regras de Nelson**

Cada violação das 8 Regras de Nelson foi projetada numa janela de 14 pontos após o ponto em que se verificou uma dada violação. Deste modo, uma instância (peça produzida) em que um destes preditores tenha o valor 1 diz respeito à ocorrência de uma infração da regra numa das 14 instâncias anteriores. No cálculo dos limites de controlo, recorreu-se aos primeiros 100 pontos.

Para as 15 características, verificaram-se as 8 Regras de Nelson com recurso ao package *NelsonCheck* do Python, considerando-se, à exceção da Regra 1, como violações das regras, os pontos em que culminaram essas mesmas violações, ao invés da totalidade dos pontos necessários à infração. Assim, considerando o exemplo da Regra 2 (9 ou mais pontos consecutivamente acima ou abaixo da média) apenas o 9º ponto seria considerado (e depois projetado), no caso de a infração ter consistido em 9 pontos.

5.3 Construção dos Modelos

Em projetos de Machine Learning, o treino do modelo é um processo no qual os dados são fornecidos como entrada para um algoritmo de ML para que este possa descobrir padrões no conjunto de dados. Posteriormente, ao receber dados nunca anteriormente vistos, um modelo treinado é capaz de prever, com algum grau de precisão, o resultado dos novos dados.

Os algoritmos de Machine Learning podem ser divididos em dois tipos:

- **Regressão** - Este tipo de algoritmo concentra-se em problemas em que a variável dependente é um valor quantitativo;
- **Classificação** - Algoritmos deste tipo focam-se em problemas cuja variável dependente é discreta, devendo estar agrupada em classes.

Quer em problemas de Regressão, quer de Classificação, verifica-se a possibilidade de existir uma variável dependente ou mais do que uma. Tendo em conta o número de variáveis dependentes e a cardinalidade (número de classes) das mesmas, podem-se distinguir algoritmos Multi-Class, Multi-Label e Multi-Output, como demonstra a Tabela 8 (Kumar, 2021).

Tabela 8: Tipo de problema de ML tendo em conta as variáveis dependentes

	# de variáveis dependentes	Cardinalidade das variáveis dependentes
Classificação Multi-Class	1	>2
Classificação Multi-Label	>1	2
Classificação Multi-Output	>1	>2
Regressão Multi-Output	>1	Contínua

Dada a natureza do projeto, este enquadra-se no tipo Classificação. Mais especificamente, este é um problema de classificação binária (cardinalidade igual a 2) já que se pretende efetuar a previsão de uma entre duas classes (conforme - classificado como 0 - ou não conforme - classificado como 1). Adicionalmente, pretendendo-se prever, para cada peça, a conformidade ou não das 15 características recolhidas de forma automática, conclui-se que o número de variáveis dependentes é superior a 1, existindo, assim, um problema de Classificação Multi-Label. A maioria dos algoritmos de Classificação habitualmente usados em Machine Learning não têm a habilidade de lidar com problemas de Classificação Multi-Label. Ainda assim, foi possível a implementação de diversos algoritmos, abordados em detalhe na Secção 5.3.7.

Ao longo desta Secção, o treino dos modelos em si, bem como alguns métodos e técnicas de preparação prévios a este são descritos. Três bibliotecas foram de extrema relevância nesta fase: *pandas* para manipulação de dados e *sklearn* e *keras* para suporte a Machine Learning.

5.3.1 Codificação dos dados

Após a criação de preditores e a eliminação da instância sem registos relativos às características CAT10 e CAT11, o *dataset* passou a consistir em 3473 linhas, cada uma com 148 colunas.

Antes de prosseguir para o treino do modelo, algumas operações devem ser realizadas no conjunto de dados para que ele se torne adequado à utilização dos diferentes algoritmos ML. Uma das preparações necessárias é a codificação dos dados. A codificação é uma técnica usada para transformar dados categóricos ou outros tipos de sequências de caracteres num formato útil para um dado contexto. No âmbito deste projeto, a codificação foi realizada com o intuito de transformar alguns dados em números e foi alcançada com recurso a uma técnica designada por *One-hot encoding*. Neste método, para cada valor categórico único, uma variável binária, geralmente chamada de dummy, é criada contendo apenas 0 e 1.

Considerando as colunas existentes no *dataset*, esta técnica foi aplicada aos 3 preditores diretamente retirados dos dados de origem: lote de matéria-prima, turno e operador. Após a sua aplicação, o *dataset* resultante passou a conter 175 colunas.

5.3.2 Correlação entre variáveis

O estudo da correlação entre variáveis é frequentemente aplicado em Machine Learning durante a análise de dados, já que uma elevada correlação entre preditores introduz redundância no modelo e influencia a performance de diversos algoritmos. Assim, a análise de correlação entre as variáveis independentes permite eliminar os principais problemas de um determinado conjunto de preditores, que posteriormente podem causar danos significativos durante o treino do modelo. Dados com preditores não correlacionados têm diversos benefícios tais como um modelo mais fácil de interpretar, maior rapidez no treino do modelo e menor enviesamento nos resultados (Barai, 2020).

Com recurso ao package *numpy*, obteve-se a matriz de correlação e isolaram-se os preditores com coeficiente de Pearson superior a 0.85 entre si por forma a posteriormente serem removido do *dataset*. Identificou-se forte correlação entre 6 preditores da categoria “Número de Peças desde Troca de Ferramenta”, especificamente associados às ferramentas T01, T03 e T09 do canal 1 e T01, T03 e T05 do canal 2. Esta constatação não é de todo inesperada já que, conforme detalhado na Secção 4, é pratica corrente dos operadores da empresa trocar mais do que uma ferramenta em cada instante, sendo deste modo compreensível que os números de peças produzidas pelas diferentes ferramentas se correlacionem entre si. Mantendo-se o preditor associado à ferramenta T01 do canal 1, removeram-se os restantes, passando, assim, a constar 170 colunas no conjunto de dados.

5.3.3 Normalização

Um dos grandes problemas relacionados com dados é o facto de que o intervalo de valores pode diferir substancialmente entre variáveis. Um exemplo frequentemente usado é o da altura (em metros) e peso (em quilogramas) de uma pessoa, duas variáveis distintas. Uma unidade de variação de medida afeta mais a altura já que o intervalo de variação desta variável é menor. Tal significa que, em algoritmos que utilizam medidas de distância entre pontos (kNN e regressão logística, por exemplo), as variáveis com maior intervalo de variação, como o peso no exemplo anterior, são dominantes sobre outras variáveis em relação à função objetivo. Como resultado, a normalização de dados torna-se necessária para que todas as variáveis estejam na mesma gama de valores.

No Python, os dados normalizados são de simples obtenção, com recurso à biblioteca *sklearn*, que contém um módulo desenvolvido especificamente para dimensionamento. Neste caso, o método de programação *MinMaxScaler* foi utilizado, sendo um método que normaliza os dados utilizando o valor mínimo e máximo de uma dada variável, por forma a colocá-la num intervalo de 0 e 1. Esta transformação foi efetuada em 5 preditores: os 3 restantes após o estudo de correlação entre variáveis, bem como os preditores “Número de Peças produzidas na Máquina” e “Número de Peças produzidas pelo Operador”.

5.3.4 Seleção de Preditores

A seleção de preditores (*feature selection*), também conhecida como seleção de variáveis, é um processo no qual o número de variáveis incorporadas num modelo preditivo é reduzido. Esta seleção do subconjunto de variáveis a utilizar é fulcral já que a remoção de certas variáveis permite reduzir o esforço computacional e o tempo de treino de um modelo. Além disso, diminui igualmente o número de atributos irrelevantes que podem condicionar a performance do modelo. Durante este processo, a correlação entre cada variável de entrada e saída é calculada. Um subconjunto de variáveis é então definido e apenas as que apresentem fortes correlações são incluídas. Deste modo, quanto maior a correlação, maior o efeito de uma variável de entrada na variável de saída.

Por forma a reduzir a complexidade do *dataset*, escolheu-se o PCA (*Principal Component Analysis*) como técnica de seleção de preditores. Esta é uma técnica estatística que reduz a dimensionalidade do conjunto de dados sem diminuir significativamente a precisão do modelo. No PCA são determinados os componentes principais, calculados como combinações lineares dos preditores inicialmente presentes no conjunto de dados. Após a sua aplicação, os componentes principais obtidos são capazes de explicar a maior parte da variabilidade dos dados, servindo de dados de entrada para o treino do modelo.

Neste projeto, a aplicação de PCA acabou por não se revelar particularmente vantajosa. Constatou-se que para se atingir 90% de variabilidade dos dados explicada seriam precisos 94 componentes. Não se traduzindo numa grande redução da dimensionalidade do *dataset* face

aos 170 preditores de origem, nem numa melhoria significativa da performance dos modelos, acabou por se desconsiderar esta técnica.

5.3.5 Separação de dados

A divisão dos dados em treino e teste é uma tarefa crucial em qualquer modelo de Machine Learning. Os dados de treino são, como o nome indica, aqueles em que o modelo é treinado, enquanto os dados de teste são usados por forma a perceber o desempenho do modelo em dados nunca anteriormente vistos. Como os dados de teste não são usados na fase de treino, ao usá-los para testar o modelo, é possível entender se o algoritmo foi realmente capaz de aprender os padrões escondidos no *dataset* ou não.

Habitualmente, é usada uma de duas metodologias para proceder a esta separação:

- **Hold-out** - separação do *dataset* em dois conjuntos mutuamente exclusivos: dados de treino e dados de teste. Habitualmente, 70% do conjunto de dados é usado para treino e 30% para teste;
- **K-Fold Cross Validation** - consiste em dividir o *dataset* em k subconjuntos mutuamente exclusivos do mesmo tamanho e, a partir daí, um subconjunto é utilizado para teste e os $k-1$ restantes são utilizados para estimação dos parâmetros, fazendo-se o cálculo da exatidão (*accuracy*) do modelo. Este processo é realizado k vezes de forma a alternar o subconjunto de teste. A Figura 31 mostra o esquema realizado pelo K-Fold.




Figura 31: Esquema ilustrativo do K-Fold Cross Validation

O método *Hold-out* apresenta um bom desempenho quando a quantidade de dados disponíveis é grande, sendo também vantajoso quando o tempo disponível para a execução dos modelos escasseia. Porém está apenas dependente de uma divisão treino-teste o que faz com que a sua eficiência dependa em grande medida dos pontos que pertencem a ambos os conjuntos. Por seu turno, o *K-Fold Cross Validation* permite ao modelo ser treinado em múltiplas divisões treino-teste, resultando, assim, uma melhor indicação do comportamento do modelo perante dados nunca vistos. No entanto, a sua aplicação obriga a um maior esforço computacional e tempo despendido. Para a obtenção dos modelos mais à frente referidos, ambas as metodologias foram utilizadas.

5.3.6 Desbalanceamento de dados

Um *dataset* desbalanceado é um obstáculo à performance de qualquer modelo de Machine Learning. Tal situação ocorre quando há uma baixa incidência de uma categoria (classe minoritária) dentro de um *dataset* em comparação com as restantes (classes maioritárias).

No caso em análise, como verificado na Secção 5.1.2, a taxa de rejeição de peças no conjunto de dados em análise é de apenas 2.36%, o que indicia um desbalanceamento extremo. Esta observação torna-se evidente constatando que, para os registos das 15 características de todas as peças, a percentagem de não conformidades é de apenas 0.25%.

Tendo em conta que a maioria dos algoritmos ML assumem que os dados estão balanceados e que, na maioria dos casos, o foco do problema é a classe minoritária, há a necessidade de balancear os dados. Por forma a alcançar-se esse objetivo, pode-se recorrer a 2 métodos:

- **Oversampling** - Duplicar exemplos aleatórios da classe minoritária;
- **Undersampling** - Excluir exemplos aleatórios da classe maioritária.

Por um lado, o *oversampling* pode ajudar a equilibrar a distribuição das classes, mas por outro lado a duplicação de exemplos não adiciona informações relevantes ao processo. Em relação ao *undersampling*, a eliminação de exemplos aleatórios leva à perda de informações sobre o processo. Considerando as desvantagens deste último mais prejudiciais que no caso do primeiro, optou-se pela técnica de *oversampling*.

Realça-se que, tendo em conta a natureza do problema (Classificação Multi-Label), a quantidade de técnicas de *oversampling* possíveis de encontrar na literatura é algo escassa. Ainda assim, foi possível recorrer a uma técnica desenhada especificamente para problemas de Classificação Multi-Label, designada por MLSOL (*Multi-Label Synthetic Oversampling approach based on the Local distribution of the labels*). Esta técnica sintetiza instâncias da classe minoritária, ao invés de simplesmente replicar instâncias existentes, e diferencia-se das restantes já que analisa as características locais dos exemplos da classe minoritária, em vez de se focar no desbalanceamento do *dataset* como um todo. Permite, assim, a obtenção de instâncias sintéticas mais diversas e corretamente classificadas ao nível das 15 variáveis dependentes (Liu e Tsoumakas, 2019).

Quer nos modelos em que a separação de dados foi feita através do método Hold-out, quer naqueles em que se recorreu ao K-Fold Cross Validation, o *oversampling* foi apenas aplicado aos dados de treino, por forma a manter os dados de teste inalterados e evitar a ocorrência de *overfitting*, um fenómeno em que o modelo se ajusta muito bem a um conjunto de dados anteriormente observado, mas se mostra ineficaz para prever novos resultados. Para o método Hold-out, a aplicação da técnica de *oversampling* aos dados de treino conduziu à distribuição de não conformidades ilustrada na Figura 32.




Figura 32: Número de não conformidades por característica após oversampling

Destaca-se a dificuldade em sintetizar instâncias da classe minoritária para características com reduzido número de não conformidades, tais como as CAT01 e CAT14.

5.3.7 Algoritmos utilizados

Conforme referido anteriormente, a maioria dos algoritmos usados em modelos de Machine Learning não têm a habilidade de lidar com problemas de Classificação Multi-Label. De entre aqueles que dispõem desta capacidade, selecionaram-se os seguintes por forma a serem utilizados nos modelos:

- **Logistic Regression**

Os algoritmos de regressão logística são algoritmos estatísticos que ajustam uma função logística ao conjunto de dados. Este algoritmo é frequentemente usado em problemas de Classificação Binária já que, nesses casos, a variável de saída é dicotômica, o que significa que os valores de saída possíveis são mutuamente exclusivos (Singh *et al*, 2016). Usando a regressão logística, o modelo é capaz de calcular a probabilidade de a variável dependente pertencer a uma classe particular. O facto de retornar uma probabilidade também significa que os limites entre os quais cada classe está contida podem ser facilmente modificados, se necessário. No entanto, para que este método seja bem-sucedido, os preditores com fortes correlações devem ser removidos durante o processo de seleção de preditores e deve ser fornecida ao modelo uma grande quantidade de dados (Shalizi, 2019).

- **k-Nearest Neighbors**

k-Nearest Neighbors, mais conhecido como kNN, é um algoritmo não paramétrico, frequentemente usado em situações onde o modelo procura a classe mais relacionada (Singh *et al*, 2016). É considerado um algoritmo lazy-learner já que não infere qualquer função discriminativa a partir dos dados de treino, limitando-se a memorizá-los. O princípio por trás deste método é a atribuição de uma classe para um ponto ainda não rotulado, levando em consideração os k pontos mais próximos e a classe dos mesmos. Apesar da sua facilidade de implementação, não é muito eficiente e depende fortemente do valor atribuído a k. Tendo isso em mente, é compreensível que este algoritmo seja particularmente suscetível a ruído e outliers (Bhavsar e Ganatra, 2012). Finalmente, o desempenho do kNN é muito afetado pelo tamanho dos dados, não sendo recomendado quando o *dataset* toma grandes dimensões (Islam *et al*, 2017).

- **Neural Network**

Este método consiste num conjunto de algoritmos que reconhecem padrões nos dados, conseguindo classificá-los. Uma rede neuronal pode ser entendida como um conjunto de neurónios (*nodes*) que compõem uma camada (*layer*) através da qual todos os estímulos (ou dados) passam. Cada neurónio atribui um peso ao objeto, acabando por atingir um valor que desencadeia a ativação de uma função que atribui uma classe ao objeto em análise. A complexidade das redes e, por conseguinte, o esforço computacional aumenta com o número e tamanho das camadas que “filtram” os dados, levando, no entanto, a resultados mais fiáveis.

Dado que este método utiliza valores numéricos nos seus cálculos internos, é necessário normalizar previamente os dados visto que dados com magnitudes diferentes dificultariam a análise. A principal desvantagem deste algoritmo passa por representar o conhecimento adquirido em forma de uma rede, o que dificulta a sua interpretação, bem como o facto de requerer a otimização de certos parâmetros, como o número de camadas, número de neurónios em cada camada e também a estrutura de rede (Monostori *et al*, 1996).

- **Random Forest**

Este método cria um conjunto aleatório de árvores de decisão, cada uma delas treinada num subconjunto aleatório dos dados de treino. Uma árvore de decisão é composta por uma sequência de regras que diferenciam as observações. Para prever as classes, todas as observações têm o mesmo ponto de partida e passam por várias bifurcações (com condições associadas), levando a caminhos distintos até chegar a uma “folha”, que é uma das classificações. Este método permite ao utilizador ver a estrutura da árvore, onde é possível retirar conclusões sobre as variáveis que têm um impacto significativo no estudo (Ronowicz *et al*, 2015).

No entanto, as árvores de decisão têm algumas dificuldades ao lidar com conjuntos de dados com grande dimensionalidade. Como pequenos erros se propagam pela árvore, à medida que o número de dimensões aumenta, a propagação de erros torna-se um problema maior (Xhemali *et al*, 2009). O “corte” das árvores é, geralmente, necessário nesses casos por forma a evitar a ocorrência de *overfitting* (Bhavsar e Ganatra, 2012). O algoritmo Random Forest pode ser ajustado alterando o número de árvores, a máxima profundidade de cada e o número de variáveis aleatoriamente selecionadas como candidatos em cada bifurcação, entre outros.

- **Extra Trees**

Tal como o Random Forest, consiste num conjunto de árvores de decisão, sendo que a classificação final de uma observação leva em conta as predições de todas as árvores, mais concretamente por voto maioritário. A principal diferença reside na seleção de pontos de bifurcação para dividir os nós. O Random Forest escolhe a divisão ideal enquanto o Extra Trees escolhe aleatoriamente. No entanto, após a seleção dos pontos de divisão, os dois algoritmos escolhem o melhor entre todos os subconjuntos de variáveis. Deste modo, o Extra Trees adiciona aleatoriedade, mas possui, ainda assim, uma componente de otimização. Por outro lado, o Extra Trees tem um tempo de execução substancialmente inferior ao Random Forest permitindo a obtenção de resultados praticamente idênticos, tornando-o numa melhor opção quando o tempo é um fator a ter em conta (Aznar, 2020).

5.3.8 Métricas de avaliação

A avaliação de um dado modelo é fundamental por forma a perceber se este deve ou não ser utilizado em tarefas preditivas. O *output* de um modelo de Classificação Binária, incluindo o caso em estudo de Classificação Multi-Label, pode ser dividido em 4 categorias diferentes: verdadeiro positivo (TP), verdadeiro negativo (TN), falso positivo (FP) e falso negativo (FN).

A métrica de desempenho mais genérica para classificadores binários é a exatidão (*Accuracy*), que diz respeito à proporção na qual o modelo está correto.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

No entanto, esta métrica é frequentemente enganadora, sobretudo em *datasets* que sofrem de desbalanceamento, como é o caso. Suponha-se, recorrendo a um outro exemplo, a existência de 100 observações, 90 pertencentes à classe “0” e as restantes 10 à classe “1”. Um modelo que preveja a classe “0” para os 100 pontos possui uma *Accuracy* de 90% o que, aparentemente, é um bom resultado. No entanto, este resultado esconde o facto de que o modelo nada aprendeu com os dados de treino, não tendo qualquer capacidade preditiva relativamente à classe “1” e limitando-se a prever a classe maioritária em todas as situações (Karajgi, 2021).

Deste modo, outras métricas de desempenho são necessárias para entender completamente a utilidade do modelo, destacando-se as seguintes:

- **Precision** – Fração entre verdadeiros positivos e todas as observações que o modelo previu como pertencentes à classe positiva.

$$Precision = \frac{TP}{TP + FP}$$

- **Recall** – Fração entre verdadeiros positivos e todos as observações que deveriam ter sido previstas nesta classe.

$$Recall = \frac{TP}{TP + FN}$$

- **F1 Score** – Média ponderada dos indicadores *Precision* e *Recall*, em que a contribuição de ambos é igual. Relevante quando existe desbalanceamento nos dados.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

- **AUC (Area under the ROC Curve)** – Corresponde à área abaixo da Curva ROC e representa a probabilidade de o classificador em uso prever um valor mais alto para uma amostra aleatória positiva do que para uma amostra aleatória negativa. A Curva ROC é traçada considerando a proporção de verdadeiros positivos (TPR), que equivale ao *Recall*, e a proporção de falsos positivos (FPR). Um exemplo de várias Curvas ROC encontra-se na Figura 33.




Figura 33: Exemplo de Curvas ROC

Quanto melhor o modelo, mais afastada de uma diagonal a 45° (classificador aleatório) a curva estará e, igualmente, mais perto de uma área de 1.0 abaixo da mesma.

A Precision e o Recall estão fortemente relacionados: o aumento de uma implica a diminuição da outra, e o *trade-off* entre estas duas métricas é facilmente entendível: se for pretendido um algoritmo capaz de detetar todos os exemplos positivos, então a Precision será baixa, porque para que ele possa detetar todos os positivos tem de estabelecer uma fronteira de decisão que, inevitavelmente, vai conter muitos elementos negativos. Este tipo de algoritmo é desejado, por exemplo, na deteção de doenças, uma área em que é crucial ter a garantia que em caso de o modelo prever que o paciente não tem uma doença, ele de facto não a tenha. Assim, o principal objetivo destes modelos passa por ter o menor número de Falsos Negativos possível.

Por outro lado, é possível ter elevada confiança que um dado exemplo é positivo quando o modelo prevê que é positivo (elevada Precision) se o modelo “aliviar” a sua fronteira de decisão e permitir que alguns dos exemplos positivos não sejam detetados. Um exemplo de aplicação consiste em plataformas de *streaming*, como o Youtube, com possibilidade de restringir o conteúdo apresentado a crianças. O objetivo neste caso é reduzir o número de Falsos Positivos, ou seja, se o modelo classifica um vídeo como sendo seguro para ser visualizado por crianças, este deve de facto ser seguro (Upadhyay, 2020).

No âmbito deste projeto, considera-se a não deteção de não conformidades como sendo mais crítica que a previsão de uma não conformidade que não se venha a verificar. Deste modo, será dado mais destaque ao Recall, comparativamente com a Precision, na avaliação dos modelos, a efetuar no Capítulo 6.

5.4 Síntese

Neste capítulo é feita uma descrição dos dados utilizados na criação dos modelos de Machine Learning com finalidade preditiva, sendo abordada a restrição do *dataset* a utilizar, o pré-processamento focado na ausência de alguns registos e a proporção de não conformidades, que se verificou ser bastante baixa.

Posteriormente, descreve-se a criação de preditores, inferidos através dos dados utilizados, com o intuito de auxiliar os algoritmos de Machine Learning na obtenção de previsões com maior precisão.

Por fim, verifica-se a existência de um problema de Classificação Multi-Label e descrevem-se várias técnicas e métodos utilizados na preparação dos dados, para que estes possam ser usados no treino dos modelos preditivos. Destacam-se a seleção de preditores, que se revelou infrutífera, a separação de dados e a escolha de uma técnica de balanceamento de dados específica para o problema de Classificação Multi-Label a abordar, o MLSOL. São também abordadas diversas métricas a utilizar na avaliação dos modelos, tais como Precision, Recall e AUC.

6 Experimentação e Resultados

Neste capítulo, apresentam-se os procedimentos experimentais bem como os resultados obtidos, agrupados pelo algoritmo utilizado. A execução dos modelos Logistic Regression, Random Forest, kNN e Extra Trees foi auxiliada pelo package *sklearn*, enquanto o algoritmo Neural Network foi executado com recurso ao package *keras*. A performance dos modelos é avaliada com recurso às métricas descritas na Secção 5.3.8, à exceção da Accuracy que, como referido, para *datasets* desbalanceados produz resultados enganosos.

Na Secção 6.6 apresentam-se em detalhe os resultados dos quatro melhores modelos obtidos e analisam-se as limitações indiciadas pelos mesmos.

6.1 Logistic Regression

Este algoritmo tem como requisito fundamental à sua execução a presença de elementos da classe minoritária (não conformidades) em todas as variáveis dependentes nos dados de treino. Deste modo, dado o escasso número de não conformidades em algumas variáveis dependentes, retratado na Figura 30, a separação dos dados recorrendo ao método K-Fold Cross Validation não garante o cumprimento do requisito mencionado. Isto deve-se ao facto de, ao dividir o *dataset* em *k* subconjuntos, instâncias que contêm não conformidades de características como CAT01 ou CAT14 pertencerem, eventualmente, aos dados de teste, não havendo representatividade de não conformidades das mesmas nos dados de treino.

Assim, por forma a executar com sucesso este algoritmo, a separação dos dados foi executada através do método Hold-out, onde se garantiu a presença de não conformidades das 15 características (variáveis dependentes) nos dados de treino. Após a execução de *oversampling* nos dados de treino, obteve-se a distribuição de não conformidades observada na Figura 30.

Posteriormente, e estando a preparação dos dados concluída, executou-se o algoritmo Logistic Regression, auxiliado por um modelo designado por *Classifier Chain*. Este modelo agrupa algoritmos de Classificação Binária num modelo Multi-Label capaz de explorar correlações entre variáveis dependentes. As previsões são, deste modo, feitas em cadeia, sendo que cada modelo constrói as suas previsões tendo em conta os preditores fornecidos, mas também as previsões dos modelos que o antecedem nessa mesma cadeia. A ordem pela qual as variáveis dependentes constam na cadeia é importante já que o primeiro modelo da cadeia não tem qualquer informação relativamente às restantes variáveis dependentes, enquanto o último recebe informações relativamente a todas as anteriores. No entanto, e procedendo-se à experimentação de diversas ordenações das variáveis dependentes na cadeia, verificou-se que os resultados não sofreram alterações significativas. Deste modo, esta técnica foi desconsiderada na execução dos restantes modelos.

Os resultados obtidos para o modelo com a cadeia de variáveis dependentes otimizada não foram particularmente satisfatórios. Verificou-se a incapacidade do modelo em prever a ocorrência de não conformidades, havendo até situações em que as prevê de modo incorreto

(Falsos Positivos), conforme refletido na matriz de confusão da Tabela 9, obtida para a característica CAT05.

Tabela 9: Matriz de Confusão para Regressão Logística - CAT05

		Previsto	
		0	1
Real	0	1032	1
	1	9	0

O AUC médio obtido foi de 0.27, corroborando a ideia de que o modelo não foi capaz de prever a ocorrência de não conformidades.

6.2 Neural Network

Por forma a ser utilizado em problemas de Classificação Multi-Label, este algoritmo deve respeitar três requisitos. Primeiramente, o número de neurónios na camada de *output* deve corresponder ao número de *labels* (variáveis dependentes). De seguida, a função de ativação de cada neurónio nessa camada deve ser a *Sigmoid*, uma função que prevê a probabilidade de uma instância pertencer a cada classe de uma *label*, retornando um valor entre 0 e 1. Por fim, a função de perda, que quantifica a diferença entre o resultado esperado e o previsto pelo modelo e é minimizada durante o treino do mesmo, deve ser a *binary cross-entropy* (Brownlee, 2020).

Garantidas estas 3 condições, foi feita experimentação no número de *epochs* (número de vezes que cada observação é usada), na função de ativação e número de neurónios das restantes camadas da rede e no *solver* utilizado na otimização dos pesos dos diferentes neurónios.

Os resultados obtidos, tendo previamente feito a separação dos dados através do método Hold-out, não foram satisfatórios, à semelhança sucedido com o algoritmo anterior. Na Tabela 10, apresenta-se a matriz de confusão obtida para a característica CAT05.

Tabela 10: Matriz de Confusão para Neural Network (Hold-out) - CAT05

		Previsto	
		0	1
Real	0	1021	12
	1	8	1

Por comparação com o algoritmo Logistic Regression, verifica-se uma maior capacidade de classificar observações como sendo não-conformes, no entanto apenas uma das indicadas pelo modelo se verificou na realidade. O AUC médio foi também de 0.27.

Deste modo, e procurando a obtenção de resultados mais satisfatórios, o método Hold-out foi descartado na separação dos dados, passando-se a considerar, exclusivamente, o K-Fold Cross Validation. Este método é promissor na melhoria da performance já que, como visto na Secção 5.3.5, dá oportunidade ao modelo de ser treinado em múltiplas separações treino-teste, fornecendo uma melhor indicação do seu desempenho perante dados nunca anteriormente

vistos. A separação dos dados através do K-Fold Cross Validation foi, assim, feita considerando 10 sub-conjuntos ($k=10$) e repetindo cada uma das divisões treino-teste 3 vezes.

Adicionalmente, modificou-se a função perda que, como referido, quantifica a diferença entre o resultado esperado e o previsto pelo modelo, propagando esses erros de volta aos neurónios de input por forma a otimizar diversos parâmetros da rede, num processo conhecido por *back-propagation*. Havendo um extremo desbalanceamento no conjunto de dados, verifica-se, ainda assim, que a dimensão do mesmo varia entre *labels*, conforme ilustrado na Figura 30. Esta diferença no desbalanceamento das diferentes variáveis dependentes pode ser transmitida à rede sob a forma de *class weights* por forma a penalizar os desbalanceamentos de forma adequada. Assim, recorrendo à função de perda *weighted binary cross-entropy*, cada perda (diferença entre o resultado esperado e o previsto pelo modelo) será ponderada pelo *class weight* do valor verdadeiro. A perda total será a soma de todas as perdas ponderadas, sendo este valor propagado de forma retrospectiva, no processo de *back-propagation* descrito (Bhartendu, 2021).

Procedendo, posteriormente, à otimização de parâmetros descrita anteriormente, obtém-se para o melhor modelo um AUC médio de 0.62, uma melhoria significativa face aos modelos anteriores. O AUC individualizado para cada característica (*label*) é apresentado na Tabela 11, enquanto na Tabela 12 está reproduzida a matriz de confusão para a característica CAT05.

Tabela 11: AUC por característica - Neural Network (Cross-Validation)

CAT01	CAT02	CAT03	CAT04	CAT05	CAT06	CAT07	CAT08
0.5	0.659	0.5	0.5	0.764	0.567	0.595	0.659
CAT09	CAT10	CAT11	CAT12	CAT13	CAT14	CAT15	
0.803	0.553	0.776	0.854	0.573	0.5	0.5	

Tabela 12: Matriz de Confusão para Neural Network (Cross-Validation) - CAT05

		Previsto	
		0	1
Real	0	8197	2117
	1	28	77

Em algumas características, verifica-se um valor de AUC igual 0.5, o que indica a incapacidade do modelo de distinguir entre as duas classes (conforme e não conforme). Ainda assim, salientam-se valores superior a 0.80 para as CAT09 e CAT12, indicando uma boa distinção entre classes.

Considerando, por outro lado, o total de iterações usadas no K-Fold Cross Validation, verifica-se uma previsão correta de 73% das não conformidades com que o modelo se deparou na CAT05, correspondendo a um valor de Recall bastante elevado. Tal foi obtido, no entanto, à custa de um decréscimo de Precision (4%), evidenciando o *trade-off* entre estas duas métricas, descrito na Secção 5.3.8. Ainda assim, tratando-se de um projeto em que é dado mais valor ao Recall comparativamente com a Precision, o decréscimo nesta última métrica não é, de todo, preocupante.

Este é assim um modelo bastante promissor, encontrando-se reproduzidos na Secção 6.6 os resultados obtidos para as restantes características e considerando as diversas métricas.

6.3 Random Forest

Após a separação dos dados com recurso ao K-Fold Cross Validation, procedeu-se à experimentação iterativa de diversos parâmetros, por forma a otimizar o modelo. Apresentam-se, de seguida, os valores otimizados dos diferentes parâmetros bem como o significado dos mesmos:

- **Número de estimadores** (*n_estimators*): 200
Número de árvores de decisão geradas pelo modelo.
- **Profundidade máxima** (*max_depth*): 20
Número máximo de divisões (bifurcações) em cada árvore.
- **Bootstrap**: False
Opção de usar amostras por bootstrap na construção das árvores. Por tomar o valor “False”, todo o *dataset* foi utilizado na construção de cada árvore.
- **Número máximo de preditores**: “Sqrt”
“Sqrt” corresponde a uma abreviatura de “Raiz quadrada”. Deste modo, o número máximo de preditores considerados para cada bifurcação é a raiz quadrada do total de preditores.

Os resultados para o modelo descrito são bastante inferiores aos obtidos para o algoritmo anterior, destacando-se um AUC médio de 0.54. A Tabela 13 contém o AUC para cada característica enquanto na Tabela 14 é apresentada a matriz de confusão para a característica CAT05.

Tabela 13: AUC por característica – Random Forest (Cross-Validation)

CAT01	CAT02	CAT03	CAT04	CAT05	CAT06	CAT07	CAT08
0.5	0.5	0.5	0.5	0.613	0.561	0.518	0.5
CAT09	CAT10	CAT11	CAT12	CAT13	CAT14	CAT15	
0.678	0.5	0.5	0.688	0.5	0.5	0.5	

Tabela 14: Matriz de Confusão para Random Forest (Cross-Validation) - CAT05

		Previsto	
		0	1
Real	0	10284	30
	1	81	24

Comparativamente com o algoritmo Neural Network, com K-Fold Cross Validation e weighted binary cross-entropy, registam-se diferenças significativas na capacidade preditiva relativamente a algumas características, aumentando de 5 para 10 o número de CATs com

AUC igual a 0.5. O Recall para a característica CAT05 desceu de forma acentuada, passando para 23%. Trata-se, assim, de um modelo de performance bastante inferior em relação ao anteriormente apresentado.

Na Secção 6.6, apresentam-se os resultados obtidos relativos a este modelo para a totalidade das características e considerando as diversas métricas.

6.4 K-Nearest Neighbor

Na utilização deste algoritmo, o único parâmetro a considerar na sua otimização é o número de vizinhos (k) de cada instância a ter em conta na classificação da mesma. Após a experimentação de diversos valores, concluiu-se que a otimização ocorre para um valor de k=10. Os resultados obtidos para este modelo encontram-se parcialmente representados na Tabela 15, que contém o AUC individualizado para cada característica, e na Tabela 16, onde se apresenta a matriz de confusão para a característica CAT05. O AUC médio obtido é de 0.53.

Tabela 15: AUC por característica - kNN (Cross-Validation)

CAT01	CAT02	CAT03	CAT04	CAT05	CAT06	CAT07	CAT08
0.5	0.5	0.5	0.5	0.583	0.5	0.5	0.5
CAT09	CAT10	CAT11	CAT12	CAT13	CAT14	CAT15	
0.714	0.5	0.5	0.636	0.5	0.5	0.5	

Tabela 16: Matriz de Confusão para kNN (Cross-Validation) - CAT05

		Previsto	
		0	1
Real	0	10264	50
	1	88	17

Sendo um modelo de performance bastante inferior ao Neural Network, verifica-se, também, um ligeiro decréscimo na qualidade dos resultados comparativamente ao modelo anterior, obtido com recurso ao Random Forest. Apesar de um AUC bastante aceitável para a característica CAT09, regista-se a incapacidade do modelo de prever não conformidades para algumas características que inclusive o Random Forest foi capaz de prever, designadamente as CAT06 e CAT07.

A Secção 6.6 inclui os resultados obtidos relativos a este modelo, para a totalidade das características e tendo em consideração as diversas métricas.

6.5 Extra Trees

Tratando-se de um algoritmo bastante similar ao Random Forest, conforme observado na Secção 5.3.7, a otimização dos parâmetros é também semelhante. Deste modo, obtiveram-se para o modelo otimizado os mesmos valores de parâmetros do algoritmo Random Forest, à exceção do número de estimadores, onde se registaram 100 árvores de decisão geradas.

Os resultados são igualmente similares aos do modelo obtido através de Random Forest, observando-se, inclusive, uma melhoria na capacidade preditiva em certas características. O AUC médio foi superior ao dos três modelos anteriores, sendo de 0.55. A Tabela 17 apresenta o AUC para cada característica, enquanto na Tabela 18 está reproduzida a matriz de confusão para a característica CAT05.

Tabela 17: AUC por característica – Extra Trees (Cross-Validation)

CAT01	CAT02	CAT03	CAT04	CAT05	CAT06	CAT07	CAT08
0.5	0.5	0.5	0.5	0.637	0.561	0.611	0.5
CAT09	CAT10	CAT11	CAT12	CAT13	CAT14	CAT15	
0.678	0.5	0.5	0.731	0.5	0.5	0.5	

Tabela 18: Matriz de Confusão para Extra Trees (Cross-Validation) - CAT05

		Previsto	
		0	1
Real	0	10287	27
	1	76	29

Este modelo, apesar de bastante longe, em termos de performance, do obtido com recurso ao algoritmo Neural Network, possui resultados interessantes, quando comparado com os dois anteriores (Random Forest e kNN). Destaca-se, no caso da característica CAT05, um Recall superior aos dois modelos mencionados, registando-se um valor de 28%. De salientar, igualmente, o elevado AUC nas características CAT09 e CAT12, especialmente nesta última.

Os resultados obtidos para as restantes características e considerando as diversas métricas são apresentados na Secção 6.6.

6.6 Resultados completos

Conforme observado nas Secções anteriores, os quatro modelos que apresentaram melhor performance tiveram como método de separação de dados o K-Fold Cross Validation. Por forma a permitir uma melhor visualização dos resultados obtidos para estes modelos e uma comparação entre os mesmos, a Tabela 19 reproduz, para cada característica e modelo, a sua performance considerando as métricas Precision, Recall, F1 Score e AUC. Destacam-se a laranja valores de AUC entre 0.6 e 0.7, que refletem uma pobre discriminação entre classes, a amarelo, valores entre 0.7 e 0.8, que indicam uma discriminação aceitável e, finalmente, a verde, valores entre 0.8 e 0.9, refletindo uma boa discriminação entre classes (Klopotek *et al*, 2005). O valor de Support diz respeito ao número de ocorrências da classe minoritária (não conformidades), para o total de iterações do K-Fold Cross Validation.

O Gráfico da Figura 34 permite, de forma expedita, comparar os valores de AUC, destacando-se a azul os superiores a 0.5.

Tabela 19: Resultados dos quatro melhores modelos, em detalhe

Característica	Algoritmo	Precision	Recall	F1-Score	AUC	Support
CAT01	Neural Network	0	0	0	0,5	3
	Random Forest	0	0	0	0,5	3
	kNN	0	0	0	0,5	3
	Extra Trees	0	0	0	0,5	3
CAT02	Neural Network	0,03	0,33	0,05	0,659	15
	Random Forest	0	0	0	0,5	15
	kNN	0	0	0	0,5	15
	Extra Trees	0	0	0	0,5	15
CAT03	Neural Network	0	0	0	0,5	9
	Random Forest	0	0	0	0,5	9
	kNN	0	0	0	0,5	9
	Extra Trees	0	0	0	0,5	9
CAT04	Neural Network	0	0	0	0,5	9
	Random Forest	0	0	0	0,5	9
	kNN	0	0	0	0,5	9
	Extra Trees	0	0	0	0,5	9
CAT05	Neural Network	0,04	0,73	0,07	0,764	105
	Random Forest	0,44	0,23	0,30	0,613	105
	kNN	0,28	0,17	0,21	0,583	105
	Extra Trees	0,52	0,28	0,36	0,637	105
CAT06	Neural Network	0,01	0,18	0,02	0,567	33
	Random Forest	0,67	0,12	0,21	0,561	33
	kNN	0	0	0	0,5	33
	Extra Trees	0,5	0,12	0,2	0,561	33
CAT07	Neural Network	0,02	0,22	0,03	0,595	27
	Random Forest	0,20	0,04	0,06	0,518	27
	kNN	0	0	0	0,5	27
	Extra Trees	0,67	0,22	0,33	0,611	27
CAT08	Neural Network	0,03	0,33	0,05	0,659	12
	Random Forest	0	0	0	0,5	12
	kNN	0	0	0	0,5	12
	Extra Trees	0	0	0	0,5	12
CAT09	Neural Network	0,07	0,64	0,12	0,803	42
	Random Forest	0,52	0,36	0,42	0,678	42
	kNN	0,64	0,43	0,51	0,714	42
	Extra Trees	0,52	0,36	0,42	0,678	42
CAT10	Neural Network	0,02	0,11	0,03	0,553	9

	Random Forest	0	0	0	0,5	9
	kNN	0	0	0	0,5	9
	Extra Trees	0	0	0	0,5	9
CAT11	Neural Network	0,06	0,57	0,10	0,776	21
	Random Forest	0	0	0	0,5	21
	kNN	0	0	0	0,5	21
	Extra Trees	0	0	0	0,5	21
CAT12	Neural Network	0,07	0,78	0,12	0,854	69
	Random Forest	0,62	0,38	0,47	0,688	69
	kNN	0,33	0,28	0,3	0,636	69
	Extra Trees	0,62	0,46	0,53	0,731	69
CAT13	Neural Network	0,01	0,20	0,02	0,573	30
	Random Forest	0	0	0	0,5	30
	kNN	0	0	0	0,5	30
	Extra Trees	0	0	0	0,5	30
CAT14	Neural Network	0	0	0	0,5	3
	Random Forest	0	0	0	0,5	3
	kNN	0	0	0	0,5	3
	Extra Trees	0	0	0	0,5	3
CAT15	Neural Network	0	0	0	0,5	6
	Random Forest	0	0	0	0,5	6
	kNN	0	0	0	0,5	6
	Extra Trees	0	0	0	0,5	6




Figura 34: AUC para a totalidade das características, por algoritmo

6.6.1 Discussão dos resultados

Apesar de alguns indicadores de que o modelo obtido com Neural Network é bastante promissor, os resultados apresentados na Secção anterior são na globalidade relativamente insatisfatórios, evidenciando a incapacidade dos modelos na previsão da ocorrência de não conformidades. Isto deve-se, principalmente, ao extremo desbalanceamento do conjunto de dados que serve de base à construção e execução dos quatro modelos. De facto, e conforme mencionado na Secção 5.3.6, uma percentagem de não conformidades de 0.25%, quando considerados os registos das 15 características de todas as peças incluídas no *dataset*, é manifestamente insuficiente.

Uma hipótese lançada por forma a mitigar, em parte, este problema foi a de aumentar o limite de especificação inferior e diminuir o limite de especificação superior das 15 características, estreitando, assim, os limites por forma a forçar o surgimento de um maior número de não conformidades nos dados. Tal hipótese foi rebatida por responsáveis da empresa que afirmaram a criticidade de manter os limites de especificação inalterados, já que é nestes que os operadores da linha de produção se baseiam quando executam o ajuste de offset às ferramentas dos 3 equipamentos de maquinaria, crucial para o desenrolar do processo produtivo. Assim, manipular os limites de especificação, para além de controverso do ponto de vista da qualidade, seria desvinculativo do processo real e os modelos desenvolvidos não seriam capazes de responder satisfatoriamente quando aplicados ao chão de fábrica.

Assim, durante a fase de preparação de dados, e conforme referido na Secção 5.3.6, procurou-se solucionar esta situação com base numa técnica de *oversampling* desenhada especificamente para problemas Multi-Label. Ainda assim, o ML-SOL apenas solucionou este problema parcialmente, dadas as dificuldades naturais em sintetizar instâncias da classe minoritária para características com um muito reduzido número de não conformidades, como acontece nas CAT01 e CAT14, que apenas registam a ocorrência de uma não conformidade

(Figura 30 e Figura 32). Por outro lado, nas características onde o *oversampling* teve maior eficácia, a sintetização de novas instâncias apenas contemplou a classe minoritária, não levando em consideração instâncias classificadas como conformes. Tal situação pode ter originado a sobreposição de classes, levando à criação de observações ambíguas. Para além desta situação, podemos ainda estar perante uma criação de dados não representativos do processo real de fabricação da peça.

Deste modo, e tendo em conta que um modelo de Machine Learning apenas consegue prever baseado nos dados que recebeu na fase de treino, não se origina, na grande maioria das características, uma representatividade da classe minoritária (não conformidades) que permita ao modelo “aprender” padrões que estejam na origem dessa mesma classe e adaptar-se a novas instâncias recebidas na fase de teste. Isto torna-se ainda mais crítico para uma situação tão particular como é a ocorrência de não conformidades numa linha de produção.

Uma análise por característica permite comprovar a extrema importância de existir, no conjunto de dados, essa mesma representatividade da classe minoritária, refletida numa percentagem superior de não conformidades. Verifica-se que, para características com baixo Support, indicando um baixo número de ocorrências de não conformidades, a Precision e o Recall são iguais a 0 e o AUC é de 0.5, o que se traduz numa incapacidade de os modelos distinguirem entre classes, acabando sempre por prever uma conformidade (classe maioritária).

Por outro lado, em características com alguma representatividade, tais como CAT05, CAT09 e CAT12, destaca-se a capacidade de os modelos detetarem algumas não conformidades (embora sempre com Recall reduzido, à exceção do modelo com Neural Network), chegando-se a obter valores de AUC superiores a 0.7. Deste modo, salienta-se a habilidade de os modelos aferirem padrões que estão na base da ocorrência de não conformidades nessas mesmas características. De notar que a CAT05, apesar de ser a que possui maior representatividade de entre as três características mencionadas, origina piores resultados, para todas as métricas, que as CAT09 e CAT12. Assim, é possível formular a hipótese de que os modelos não conseguem detetar padrões que levem a não conformidades na característica CAT05, o que sugere alguma aleatoriedade na ocorrência das mesmas nesta característica.

Analisando a performance dos diversos algoritmos, evidencia-se a clara superioridade do Neural Network, muito devida à utilização de uma função perda apropriada para problemas de Classificação Multi-Label em que exista desbalanceamento no conjunto de dados. Este modelo mostrou-se capaz de prever não conformidades em características que nenhum outro conseguiu, tais como as CAT02, CAT08 e CAT11. Adicionalmente, nas características com maior Support, obteve valores de Recall muito interessantes, ainda que à custa da métrica Precision, num trade-off que acaba por ser extremamente benéfico tendo em conta o objetivo mencionado de obter o mínimo possível de Falsos Negativos. Considerando os quatro modelos comparados, este é assim o mais promissor, de forma destacada.

Nos restantes algoritmos, destaca-se a obtenção de resultados interessantes em algumas métricas por parte do Extra Trees, superando por diversas situações o Random Forest. Estes resultados tornam-se ainda mais valorizáveis considerando que este é um algoritmo de baixa exigência computacional e até mais simples que o Random Forest. Por fim, o kNN foi, para a generalidade das características, o pior dos 4 modelos, não conseguindo, inclusive, prever não conformidades nas CAT06 e CAT07.

Por forma a serem obtidos resultados ainda mais promissores, mencionou-se anteriormente a necessidade de uma maior representatividade de não conformidades no conjunto de dados, alcançável através de uma maior percentagem de ocorrência das mesmas. No entanto, tal situação iria, naturalmente, contra a filosofia da empresa de progressivamente reduzir a taxa de peças defeituosas. Ainda assim, e tratando-se de uma área operacional em que novos dados surgem em contínuo, a percentagem de não conformidades necessária ao sucesso dos modelos

pode, a qualquer momento, verificar-se neste processo produtivo ou, no limite, noutros processos de fabricação decorrentes na empresa e para os quais ela considere que os modelos podem ser aplicáveis.

Por outro lado, outra situação propícia à melhoria dos resultados é a reflexão acerca de alguns preditores utilizados e a inclusão de novos. A viabilidade da utilização de preditores relacionados com o tempo de vida das ferramentas deve ser analisada atentamente. Conforme referido na Secção 4, as ferramentas de desbaste e acabamento são trocadas no início de cada turno e as restantes uma vez por dia. Para além disso, em diversas ocasiões, a troca de uma ferramenta que quebrou ou se desgastou em excesso leva à troca, em simultâneo, de diversas outras ferramentas que estavam ainda operacionais. Assim, estas situações de possível troca prematura de ferramentas constituem um obstáculo à procura de analisar o tempo de vida das mesmas e a sua relação com a ocorrência de não conformidades.

Relativamente à utilização de novos preditores, a incorporação da Tabela Registo de Dados Controlador, apresentada na Secção 3.4, permitiria a obtenção de preditores que traduzem o estado dos equipamentos de maquinaria. Esta informação, descrita através de diversos parâmetros como velocidade do spindle, temperatura, binário e offsets, seria potencialmente enriquecedora na obtenção de padrões que levam à ocorrência de não conformidades e, por conseguinte, na melhoria de performance dos modelos.

6.7 Síntese

Neste capítulo apresentam-se os procedimentos experimentais bem como os resultados obtidos, agrupados pelos algoritmos utilizados, os quais foram Logistic Regression, Neural Network, Random Forest, kNN e Extra Trees.

De seguida, apresentam-se em detalhe os resultados dos quatro melhores modelos obtidos, que tiveram como técnica de separação de dados o K-Fold Cross Validation. A Tabela 19 apresenta diversas métricas consideradas na avaliação dos mesmos e a Figura 34 permite uma comparação expedita dos valores de AUC. Por fim, analisam-se os resultados, destacando a performance bastante promissora do Neural Network, e discutem-se melhorias possíveis na metodologia, com destaque para a possível inclusão da Tabela Registo de Dados Controlador.

7 Conclusões e Trabalhos Futuros

Este capítulo encontra-se dividido em duas partes. A Secção 7.1 apresenta as principais conclusões obtidas com a realização deste projeto, enquanto na Secção 7.2 são delineadas diversas possibilidades de trabalhos futuros que permitam complementar o trabalho desenvolvido.

7.1 Conclusões

O presente trabalho procurou atingir dois principais objetivos. Primeiramente, recorrendo a técnicas de análise de dados e metodologias de Controlo Estatístico de Processo, procedeu-se à identificação dos principais fatores na origem da variabilidade associada ao fabrico da peça em estudo e, por conseguinte, da ocorrência de não conformidades. De seguida, fazendo uso de algoritmos de Machine Learning, abordou-se a tarefa preditiva de desenvolver modelos que permitam detetar produtos com potenciais não conformidades, por forma a evitar a produção de sucata e incorrer nos custos associados. Em suma, procurou-se atingir um processo estável, que funcione conforme esperado, e em que eventuais problemas são detetados rapidamente, reduzindo o seu impacto no processo produtivo.

Após a caracterização do sistema de controlo de qualidade implementado, em que se verifica a recolha de 19 características na peça, bastando uma estar não conforme para a peça ser rejeitada, verificou-se que uma causa de variabilidade poderia estar na recolha de uma dessas medições. Constatou-se que a dificuldade em medir a rosca automaticamente leva à necessidade de esta medição ser feita manualmente, o que pode levantar alguns problemas em termos da precisão das medições. Deste modo, procedeu-se à análise do sistema empregue nesta medição, através de Estudos do Tipo 1 e Gage R&R, que revelaram a existência de variação excessiva no sistema de medição, expressa nas componentes de repetibilidade e reprodutibilidade. Assim, a melhoria deste sistema de medição torna-se crucial dado que este não consegue produzir dados consistentes e confiáveis.

A análise de variáveis permitiu dar continuidade à identificação de fatores influenciadores de não conformidades. Primeiramente, através de uma análise individualizada, verificou-se a existência de diferenças internas em diversas variáveis intervenientes no processo. Exemplo disso é o fator “Máquina”, em que uma das três máquinas, identificada como 217, foi responsável por mais de metade das não conformidades ocorridas no período em análise. Concluiu-se que tal se deve, muito provavelmente, à não existência de sonda nesta máquina, que permite efetuar uma primeira medição de algumas características, possibilitando mais rapidamente atuar sobre a posição da ferramenta. Ainda assim, a análise de capacidade às 3 máquinas revelou que esta é a máquina com maior potencial para cumprir os requisitos especificados, designadamente no que toca a uma característica especificada na análise. Posteriormente, procedeu-se à análise conjunta de diversos fatores, por forma a identificar eventuais fatores com influência mais significativa do que outros. Agrupando as variáveis “Lote” e “Operador”, concluiu-se a possibilidade de o lote ter maior influência do que o

operador na ocorrência de não conformidades, ao verificarem-se situações em que operadores com maior número de não conformidades associadas conseguem obter processos relativamente estáveis na presença de lotes não defeituosos.

Após a análise de variabilidade, e tendo em conta o segundo grande objetivo do projeto, procedeu-se ao desenvolvimento de modelos capazes de prever a ocorrência não conformidades em função do contexto de produção. Foram descritas diversas etapas prévias à execução dos modelos tais como a caracterização dos dados utilizados na criação dos mesmos, com foco na proporção de não conformidades, o pré-processamento efetuado e a criação de preditores, inferidos através dos dados utilizados. Exploraram-se, ainda, várias técnicas e metodologias utilizadas na preparação dos dados, para que estes possam ser usados no treino dos modelos preditivos. Destacam-se a seleção de preditores, que se revelou infrutífera, a separação de dados e a escolha de uma técnica de balanceamento de dados específica para o problema de Classificação Multi-Label a abordar, em que se pretende prever o valor de 15 variáveis dependentes, correspondente à conformidade ou não.

Estando o processamento dos dados concluído, decorreram diversos procedimentos experimentais, apoiados em algoritmos de Machine Learning como Logistic Regression, Neural Network, Random Forest, kNN e Extra Trees. Ainda que se verifique que o modelo obtido através do algoritmo Neural Network é bastante promissor, registando uma performance significativamente superior à dos restantes, os resultados obtidos para as diversas variáveis dependentes não foram na generalidade particularmente satisfatórios. Consta-se que tal se deve, principalmente, ao extremo desbalanceamento do conjunto de dados que serve de base à construção e execução dos quatro modelos, traduzido numa percentagem de não conformidades de 0.25%, quando considerados os registos das 15 características de todas as peças. A falta de representatividade da classe minoritária (não conformidades) não permite ao modelo “aprender” padrões que estejam na origem dessa mesma classe e adaptar-se a novas instâncias recebidas na fase de teste. Para as escassas características com alguma representatividade, verificou-se a capacidade de os modelos detetarem algumas não conformidades, chegando-se a obter valores de AUC superiores a 0.7.

Conforme referido, verifica-se, ainda assim, uma clara superioridade do Neural Network, causada pela utilização de uma função perda apropriada para problemas de Classificação Multi-Label em que exista desbalanceamento no conjunto de dados. Este modelo mostrou-se capaz de prever não conformidades em características que nenhum outro conseguiu e, nas características com maior Support, obteve valores de Recall muito interessantes, ainda que à custa da métrica Precision. Este trade-off revela-se extremamente benéfico tendo em conta o objetivo de obter o mínimo possível de Falsos Negativos. Considerando os quatro modelos comparados, este é assim o mais promissor, de forma destacada, e aquele que deve servir de base ao desenvolvimento de trabalhos futuros.

7.2 Trabalhos Futuros

Tendo-se atingido os objetivos propostos no desenvolvimento deste projeto, há, ainda assim, espaço a trabalhos futuros que permitam complementar o trabalho desenvolvido, designadamente na melhoria dos resultados obtidos nos modelos de qualidade preditiva.

Primeiramente, e focando na análise do sistema de medição efetuada, concluiu-se que deve ter lugar a implementação de metodologias de treino dos operadores que permitam uniformizar o processo de medição e melhorar a qualidade dos dados obtidos. Assim, é igualmente importante conduzir uma nova análise após a implementação das metodologias referidas, por forma a verificar se houve, de facto, uma melhoria nos resultados, expressa numa diminuição de repetibilidade e reprodutibilidade. Adicionalmente, e não sendo a rosca a única

característica recolhida manualmente, existe a possibilidade de se analisarem os sistemas de medição empregues nas restantes características aferidas manualmente, que consistem em 3 variáveis do tipo atributo.

No que diz respeito aos modelos de qualidade preditiva, verifica-se que, tal como em qualquer projeto de Machine Learning, há sempre espaço para melhorias. Primeiramente, a exploração de outros algoritmos de Machine Learning, compatíveis com problemas Multi-Label, é algo a considerar, assim como a otimização dos parâmetros dos algoritmos utilizados, um processo interminável que permite melhorar a performance dos modelos. Por outro lado, a reflexão acerca de alguns preditores utilizados e a inclusão de novos deve também ter lugar. A incorporação da Tabela Registo de Dados Controlador, apresentada na Secção 3.4, é, sem dúvida, uma possibilidade a explorar já que permitiria a obtenção de preditores que traduzem o estado dos equipamentos de maquinaria. Esta informação, descrita através de diversos parâmetros como velocidade do spindle, binário e offsets, seria potencialmente enriquecedora na obtenção de padrões que levam à ocorrência de não conformidades, consistindo, ao mesmo tempo, numa iniciativa relevante no âmbito da Qualidade 4.0.

Por fim, e tirando proveito da recolha de dados de produção em tempo real, sugere-se o desenvolvimento de um sistema que permita a visualização de cartas de controlo, índices de capacidade de processo e mais algumas análises em tempo real. Este sistema permitiria detetar rapidamente tendências no processo e desvios dos resultados relativamente a limites de controlo calculados para as 19 características dimensionais verificadas. Os potenciais ajustes efetuados no processo produtivo seriam, assim, mais eficazes por se basearem numa análise estatística mais completa, beneficiando simultaneamente os índices de qualidade.

Referências

- A. Singh, N. Thakur, and A. Sharma. A review of supervised machine learning algorithms. In 2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom), pages 1310–1315, 2016.
- Acharjya, Debi & Geetha, M.. (2017). Internet of Things: Novel Advances and Envisioned Applications. DOI:10.1007/978-3-319-53472-5.
- AIAG, Automotive Industry Action Group. 2010. Measurement System Analysis - Reference Manual. 4.^a ed.
- Almeida, António. (2020). *Data-Driven Models for Predictive Quality in Precision Metalworking*. [Tese de Mestrado, Faculdade de Engenharia da Universidade do Porto]. <https://hdl.handle.net/10216/132710>
- Antony, Jiju, Graeme Knowles e Paul Roberts. 1999. "Gauge Capability Analysis: Classical Versus ANOVA". Quality Assurance n.º 6 (3):173-181.
- ASQ, 2022. Learn About Quality: Quality 4.0, ultimo acesso: março 2022, <https://asq.org/quality-resources/quality-4-0>
- Avigdor Zonnenshain & Ron S. Kenett (2020) Quality 4.0—the challenging future of quality engineering, Quality Engineering, 32:4, 614-626, DOI:10.1080/08982112.2019.1706744
- Aznar, Pablo. 2020. What is the difference between Extra Trees and Random Forest?, último acesso: junho 2022, <https://quantdare.com/what-is-the-difference-between-extra-trees-and-random-forest/>
- Bai, Yun, Zhenzhong Sun, Jun Deng, Lin Li, Jianyu Long, and Chuan Li. “Manufacturing Quality Prediction Using Intelligent Learning Approaches: A Comparative Study.” Sustainability 10, no. 2 (2017): 85
- Barai, Abhishek. 2020. Correlation and Machine Learning, ultimo acesso: junho 2022, <https://medium.com/analytics-vidhya/correlation-and-machine-learning-fee0ffc5faac>
- Bhartendu, T. 2021. Modified Cross-Entropy loss for multi-label classification and handling imbalanced data, ultimo acesso: junho 2022, <https://medium.com/@matrixB/modified-cross-entropy-loss-for-multi-label-classification-with-class-a8afede21eb9>
- Brownlee, Jason. 2020. Multi-Label Classification with Deep Learning, ultimo acesso: junho 2022, <https://machinelearningmastery.com/multi-label-classification-with-deep-learning/>
- Cardoso, D.; Ferreira, L. Application of Predictive Maintenance Concepts Using Artificial Intelligence Tools. Appl. Sci. 2021, 11, 18. <https://dx.doi.org/10.3390/app11010018>
- Cosma Rohilla Shaliz. Advanced Data Analysis from an Elementary Point of View (Chapter 12). Cambridge University Press, 2019.
- CQI, 2022. Quality 4.0, último acesso: março 2022, <https://www.quality.org/quality-4-point-0>

Crosby, P.B. (1979) *Quality Is Free: The Art of Making Quality Certain*. McGraw-Hill, New York

Daniela XHEMALI, Christopher J. HINDE, and Roger G. STONE. Naive bayes vs. decision trees vs. neural networks in the classification of training web pages, September 2009.

Deming, W. E. (1982). *Quality, productivity, and competitive position*. MIT Press.

Fraga, T.; Fula, D. Maquinagem com maior precisão e sem desperdício? Modelação numérica pode ser a solução, último acesso: abril 2022, <http://www.inegi.pt/pt/noticias/maquinagem-com-maior-precisao-e-sem-desperdicio-modelacao-numerica-pode-ser-a-solucao/>

Hetal Bhavsar and Amit Ganatra. A comparative study of training algorithms for supervised machine learning. *International Journal of Soft Computing and Engineering (IJSCE)*, 2, 01 2012.

JMP Statistical Discovery, 2022. The Two-Sample t-Test, ultimo acesso: abril 2022, https://www.jmp.com/en_ch/statistics-knowledge-portal/t-test/two-sample-t-test.html

Joanna Ronowicz, Markus Thommes, Peter Kleinebudde, and Jerzy Kryszinski. A data mining approach to optimize pellets manufacturing process based on a decision tree algorithm. *European Journal of Pharmaceutical Sciences*, 73:44–48, 2015

Juran, J. M., Godfrey, a B., Hoogstoel, R. E., & Schilling, E. G. (1999). *Juran ' S Quality Handbook*. Training for Quality, 1(3).

Juran, 2019. Quality 4.0: The Future of Quality?, ultimo acesso: março 2022, <https://www.juran.com/blog/quality-4-0-the-future-of-quality/>

Karajgi, Aniruddha. 2021. Evaluating Multi-label Classifiers, ultimo acesso: junho 2022, <https://towardsdatascience.com/evaluating-multi-label-classifiers-a31be83da6ea>

Kłopotek, M., Trojanowski, K. and Wierzchoń, S., 2005. *Intelligent Information Processing and Web Mining*. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg.

Kumar, Satyam. 2021. Essential guide to Multi-Class and Multi-Output Algorithms in Python, último acesso: maio 2022, <https://towardsdatascience.com/essential-guide-to-multi-class-and-multi-output-algorithms-in-python-3041fea55214>

L. Monostori, A. Markus, H. Van Brussel, and E. Westkämpfer. Machine learning approaches to manufacturing. *CIRP Annals*, 45(2):675–712, 1996.

Lieber, Daniel, Marco Stolpe, Benedikt Konrad, Jochen Deuse, and Katharina Morik. "Quality Prediction in Interlinked Manufacturing Processes Based on Supervised and Unsupervised Machine Learning." *Procedia CIRP* 7 (2013): 193–98.

Liu, Bin, and Grigorios Tsoumakas. "Synthetic oversampling of multi-label data based on local label distribution." *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*. Springer, Cham, 2019.

M. J. Islam, Q. M. J. Wu, M. Ahmadi, and M. A. Sid-Ahmed. Investigating the performance of naive- bayes classifiers and k- nearest neighbor classifiers. In *2007 International Conference on Convergence Information Technology (ICCIT 2007)*, pages 1541–1546, 2007

Mahanti, R. 2019. *Data quality: Dimensions, measurement, strategy, management and governance*. Milwaukee: ASQ Quality Press.

Melhem, Mariam, Bouchra Ananou, Mohand Djeziri, Mustapha Ouladsine and Jacques Pinaton. "Product's Quality Prediction with respect to equipments data." *IFAC-PapersOnLine* 48 (2015): 78-84.

Minitab, LLC, 2022. "A type 1 gage study assesses the capability of a measurement process". último acesso: março 2022, <https://support.minitab.com/en-us/minitab/19/help-and-how-to/quality-and-process-improvement/measurement-system-analysis/supporting-topics/other-gage-studies-and-measures/type-1-gage-study/>

Minitab, LLC, 2022. "Normality assumptions for control charts". último acesso: abril 2022, <https://support.minitab.com/en-us/minitab/19/help-and-how-to/quality-and-process-improvement/control-charts/supporting-topics/data/normality-assumptions-for-control-charts/>

Montgomery, Douglas C. 2012. Introduction to statistical quality control. 7.^a ed.: Wiley

Quality Trainer by Minitab, LLC, 2021, último acesso: março 2022, <https://qualitytrainer.minitab.com>.

Rostami, Hamidey, Jean-Yves Dantan, and Lazhar Homri. "Review of Data Mining Applications for Quality Assessment in Manufacturing Industry: Support Vector Machines." International Journal of Metrology and Quality Engineering 6, no. 4 (2015): 401.

Samohyl, R. W. (2009). Controle Estatístico de Qualidade. Elsevier

Slobodan Stefanovic; Imre Kiss; Damjan Stanojevic; Nenad Janjic. Analysis of technological process of cutting logs using ishikawa diagram. Acta Technica Corviniensis - Bulletin of Engineering, 7:93–98, 2014.

Upadhyay, Amit. 2020. Precision/Recall Tradeoff, ultimo acesso: junho 2022, <https://medium.com/analytics-vidhya/precision-recall-tradeoff-79e892d43134>

Wang, Fu-Kwun e Eldon Y. Li. 2003. "Confidence intervals in repeatability and reproducibility using the Bootstrap method". Total Quality Management & Business Excellence n.º 14 (3):341-354.

ANEXO A: Processo Produtivo




Figura A.1- Esquematização do fluxo de material nos equipamentos da célula

Ferramentas

Canal 1



Tool 1



Tool 3



Tool 5



Tool 7



Tool 9



Tool 11



Tool 13

Canal 2



Tool 1



Tool 3



Tool 5

Figura A.2- Ferramentas envolvidas na maquinagem da peça

ANEXO B: Análise de Variabilidade




Figura B.1 - Frequência dos diferentes tipos de Não Conformidades- Máquina 56




Figura B.2 - Frequência dos diferentes tipos de Não Conformidades- Máquina 57




Figura B.3 - Frequência dos diferentes tipos de Não Conformidades- Máquina 217




Figura B.4 - Frequência das diferentes causas na origem de Não Conformidades- Máquina 56




Figura B.5 - Frequência das diferentes causas na origem de Não Conformidades- Máquina 57




Figura B.6 - Frequência das diferentes causas na origem de Não Conformidades- Máquina 217




Figura B.7 - Distribuição de não conformidades pelas características- Máquina 56




Figura B.8 - Distribuição de não conformidades pelas características- Máquina 57




Figura B.9 - Distribuição de não conformidades pelas características- Máquina 217

	CAT01	CAT02	CAT03	CAT04	CAT05	CAT06	CAT07	CAT08	CAT09	CAT10	CAT11	CAT12	CAT13	CAT14	CAT15	MAN01
CAT01	1															
CAT02	-0,07644	1														
CAT03	-0,14881	-0,22095	1													
CAT04	0,320414	0,021456	-0,16358	1												
CAT05	0,248763	0,008729	-0,08451	0,802875	1											
CAT06	0,270178	0,031609	-0,07662	0,693884	0,848774	1										
CAT07	0,203682	0,005826	0,029848	0,6211	0,789137	0,91909	1									
CAT08	-0,06649	-0,13094	0,088982	0,017134	0,117088	0,136378	0,167422	1								
CAT09	-0,07322	-0,10472	0,002524	0,047028	0,101139	0,09707	0,093606	0,773737	1							
CAT10	0,058103	-0,03936	-0,08266	0,033111	0,044279	0,065644	0,079032	0,05734	0,002365	1						
CAT11	0,095872	0,006642	0,017893	0,072841	0,085183	0,089311	0,118056	0,03947	-0,00395	0,584558	1					
CAT12	0,038833	0,002489	-0,06828	0,006243	-0,00314	0,018439	0,001517	-0,00593	-0,01423	0,069264	0,006262	1				
CAT13	-0,02677	0,124945	-0,01917	-0,07149	-0,06248	-0,06533	-0,08447	-0,07969	-0,05041	-0,03177	-0,00769	0,003592	1			
CAT14	-0,01431	0,007468	0,007749	-0,02252	-0,02052	-0,05129	-0,05288	-0,00258	-0,03437	-0,02027	-0,01785	-0,04137	0,011021	1		
CAT15	-0,02825	0,02941	0,016881	-0,02601	-0,01609	-0,02531	-0,03414	-0,01852	-0,02303	0,005941	-0,02296	-0,0323	0,456857	-0,01507	1	
MAN01	-0,00056	0,025905	0,000611	-0,01754	-0,00574	0,014894	0,010304	0,008009	0,003086	0,009668	0,009299	0,007396	-0,00448	-0,02526	0,01592	1

Figura B.10 - Correlação entre categorias para Máquina 56

	CAT01	CAT02	CAT03	CAT04	CAT05	CAT06	CAT07	CAT08	CAT09	CAT10	CAT11	CAT12	CAT13	CAT14	CAT15	MAN01
CAT01	1															
CAT02	-0,92118	1														
CAT03	-0,91919	0,999816	1													
CAT04	-0,91856	0,999822	0,999989	1												
CAT05	-0,91894	0,999821	0,999992	0,999997	1											
CAT06	-0,91865	0,999819	0,99999	0,999996	0,999998	1										
CAT07	-0,91817	0,999822	0,999985	0,999995	0,999995	0,999998	1									
CAT08	-0,91868	0,999805	0,999977	0,999984	0,99998	0,999976	0,999974	1								
CAT09	-0,56823	0,707963	0,707022	0,707956	0,706838	0,706657	0,707129	0,710079	1							
CAT10	-0,00522	-0,00162	-0,00157	-0,00165	-0,00161	-0,00158	-0,0016	-0,00156	-0,00289	1						
CAT11	-0,00554	-0,00163	-0,00158	-0,00166	-0,00162	-0,00158	-0,00161	-0,00157	-0,00534	0,999993	1					
CAT12	-0,91733	0,998824	0,999137	0,999138	0,999141	0,999134	0,999128	0,999154	0,706011	-0,00206	-0,00206	1				
CAT13	-0,0274	0,009304	0,007854	0,008265	0,008393	0,008393	0,00834	0,008238	-0,02959	0,023185	0,023417	0,007625	1			
CAT14	-0,91452	0,998162	0,998358	0,99836	0,99834	0,998338	0,998343	0,99831	0,704682	-0,00145	-0,00144	0,997427	0,007713	1		
CAT15	-0,00758	-0,00503	-0,00632	-0,00568	-0,00559	-0,0056	-0,00568	-0,00564	-0,02626	0,004993	0,005148	-0,00472	0,895985	-0,00812	1	
MAN01	-0,01472	-0,00151	-0,00176	-0,00188	-0,00187	-0,00184	-0,00191	-0,00165	-0,00253	0,406567	0,406572	-0,00287	0,012806	-0,00142	0,006025	1

Figura B11 - Correlação entre categorias para Máquina 57

	CAT01	CAT02	CAT03	CAT04	CAT05	CAT06	CAT07	CAT08	CAT09	CAT10	CAT11	CAT12	CAT13	CAT14	CAT15	MAN01
CAT01	1															
CAT02	-0,16657	1														
CAT03	-0,02736	-0,33724	1													
CAT04	0,133532	-0,03111	-0,00426	1												
CAT05	0,119396	-0,02051	-0,04107	0,72721	1											
CAT06	0,108097	-0,02728	-0,0067	0,722805	0,948235	1										
CAT07	0,099442	-0,04158	-0,00344	0,703998	0,948345	0,964203	1									
CAT08	-0,01908	-0,13302	0,091139	0,228348	0,160367	0,18608	0,173234	1								
CAT09	-0,00784	-0,08113	0,055112	0,124739	0,166723	0,176473	0,162131	0,872065	1							
CAT10	0,041199	-0,06367	0,005634	-0,12634	-0,20634	-0,19527	-0,20288	0,347047	0,386068	1						
CAT11	0,082056	-0,11591	0,040812	0,082335	0,097581	0,097868	0,098884	0,208952	0,256051	0,702972	1					
CAT12	-0,01015	-0,09343	-0,01452	-0,02268	0,020555	0,01316	0,017397	-0,02533	0,020894	0,027671	0,078355	1				
CAT13	0,056484	-0,04753	0,064702	-0,00291	0,016782	0,009243	0,002096	-0,01107	-0,00035	0,008877	-0,01253	-0,07258	1			
CAT14	-0,00715	-0,01043	-0,0589	-0,03124	0,007085	-0,01256	-0,02588	-0,01081	0,015469	0,039731	0,014007	-0,11371	0,054686	1		
CAT15	-0,00775	-0,0317	0,029755	-0,02445	0,002289	-0,00249	-0,00606	-0,04377	-0,02903	-0,02614	-0,04299	-0,00233	0,616086	0,02705	1	
MAN01	-0,00279	0,029626	0,026461	-0,00333	-0,0105	-0,00672	-0,00916	-0,01176	-0,01193	0,006428	-0,00419	0,024082	-0,14575	-0,00751	-0,22959	1

Figura B.12 - Correlação entre categorias para Máquina 217

ANEXO C: Análise Cruzada- Característica CAT12




Figura C.1 - Teste à normalidade- CAT12




Figura C.2 - Análise de capacidade para as 3 máquinas- CAT12




Figura C.3 - Carta I-MR para CAT12- Máquina 56; Operador 3236




Figura C.4 - Carta I-MR para CAT12- Máquina 57; Operador 3236




Figura C.5 - Carta I-MR para CAT12- Máquina 217; Operador 3236