

Desenvolvimento de modelos de reclassificação automática de defeitos numa indústria de semicondutores

Mafalda Vieira Giesta

Dissertação de Mestrado

Orientador na FEUP: Prof. Eduardo Gil da Costa



Mestrado Integrado em Engenharia e Gestão Industrial

2021-07-20

Resumo

A indústria de semicondutores é fortemente caracterizada pelas suas elevadas e rígidas exigências. A tendência destas exigências é aumentarem cada vez mais já que tem vindo a crescer o seu peso no setor automóvel com a crescente inovação tecnológica. Assim, cada vez mais o foco para que as empresas se tornem competitivas neste mercado é produzir produtos sem defeito e máxima qualidade.

É neste contexto que surge a ferramenta de classificação automática denominada, *Automatic Defect Classification* (ADC). Esta inspeção surge como forma de automatizar o processo de reclassificação de defeitos já que, atualmente, este é feito manualmente. Para além de mais demorada, a reclassificação feita pelos operadores é bastante suscetível a erro humano e elevada variabilidade.

O projeto desenvolvido centrou-se na análise dos modelos implementados na ferramenta ADC que se encontra atualmente em produção na empresa, acompanhada da identificação de pontos de melhoria e correção. De seguida, passou pelo desenvolvimento e implementação de novos modelos para produtos *automotive* com resultados de *performance* satisfatórios. A última fase é caracterizada pela atualização e construção da ferramenta de análise de risco utilizando duas abordagens possíveis.

Os resultados obtidos comprovam a eficiência e a potencialidade desta ferramenta para a reclassificação de defeitos nesta indústria. Foi possível atingir eficiências de, aproximadamente, 87% e com taxas de deteção e não deteção de acordo com os critérios de aceitação exigidos. Em contrapartida, concluiu-se que o algoritmo base destes modelos apresenta desvantagens como, por exemplo, a falta de capacidade em identificar as características óticas dos defeitos, a complexidade do treino, a existência de janelas fixas que permitem a falha na deteção de defeitos, etc.

A construção do FMEA permitiu identificar e priorizar as ações a tomar. Das ações recomendadas destacam-se a necessidade de substituir o algoritmo atualmente em utilização e a implementação de um maior controlo na reclassificação dos operadores.

Abstract

Development of automatic defect reclassification models in a semiconductor industry

The semiconductor industry is strongly characterized by its high and strict requirements. The tendency of these demands is to increase more and more as it has been growing its weight in the automotive sector with increasing technological innovation. Thus, the focus for companies to become competitive in this market is to produce products without defects and with maximum quality.

It is in this context that the automatic classification tool called Automatic Defect Classification (ADC) appears. This inspection arises as a way to automate the process of defect reclassification since, currently, this is done manually. Besides being more time consuming, the reclassification done by operators is very susceptible to human error and high variability.

The project developed focused on the analysis of the models implemented in the ADC tool that is currently in production at the company, followed by the identification of improvement and correction points. Next, it went through the development and implementation of new models for automotive products with satisfactory performance results. The last phase is characterized by updating and building the risk analysis tool using two possible approaches.

The results obtained prove the efficiency and potential of this tool for defect reclassification in this industry. It was possible to achieve efficiencies of approximately 87% and with detection and non-detection rates in accordance with the required acceptance criteria. On the other hand, it was concluded that the base algorithm of these models has disadvantages, such as the lack of ability to identify the optical characteristics of defects, the complexity of the training, the existence of fixed windows that allow the failure of defect detection, etc.

The FMEA construction allowed the identification and prioritization of actions to be taken. The recommended actions include the need to replace the algorithm currently in use and the implementation of greater control in the reclassification of operators.

Agradecimentos

Acabo esta dissertação com uma quantidade imensurável de sentimentos. Aquele que não cabe no peito é o orgulho que tenho em concluir este curso e, desta forma, agradecer aos meus queridos pais, Carlos e Cláudia, que de tudo fizeram para que fosse feliz.

Ao meu Pai, quero agradecer por todos os valores que me passou desde criança e por me ter guiado para o ramo da Engenharia. Continua a brilhar por nós as três. À minha Mãe, obrigada por estares sempre ao meu lado para me motivar e aconselhar em todas as batalhas. És uma força da Natureza e eu admiro-te por isso. Aos dois que são o meu orgulho, os obrigados e as palavras não são suficientes.

À minha irmã, Beatriz, és um grande pilar deste meu percurso e tenho a certeza que o sabes. Agradeço-te pela paciência, o carinho e os conselhos ao longo destes anos (e não só).

Ao Gonçalo, um dos membros mais fortes da minha equipa de desafiadores, obrigada pela determinação de estares nessa equipa e, constantemente, esperares e incentivares o meu melhor. Contigo veio uma segunda família que guardo no meu coração. Aos avós, Carmela e Tomaz, e aos manos emprestados, Natacha e Tomás.

A toda a minha família que levo todos os dias no coração, grata pelo nosso pequeno círculo que tanta força tem. Sou o que sou graças a todos vocês. Aos meus tios, Luís e Susana, aos meus primos, Mariana e Tiago, e aos meus avós, Joaquim e Virgínia e Manuel e Ivone.

A todos os meus amigos que fizeram parte deste caminho, obrigada pelas noites mal dormidas, pela pureza da nossa amizade e conversas infundáveis.

Ao professor Eduardo Gil da Costa, pela orientação, pelo auxílio e pela disponibilidade ao longo de todo o projeto.

A toda equipa que me acompanhou na ATEP, mas principalmente ao meu orientador João Costa que foi incansável ao longo destes 4 meses, obrigada pelo apoio, amizade e confiança.

A Todos, Obrigada!

Pai, a tua filha é Engenheira!

Conteúdo

1	Introdução	1
1.1	Apresentação da ATEP, SA	1
1.1.1	O Grupo Amkor Technology, Inc	1
1.1.2	A Amkor Technology Portugal, SA	2
1.2	Mercado do Setor de Semicondutores	3
1.3	Contextualização do Projeto na ATEP, SA	4
1.4	Objetivos do Projeto	5
1.5	Metodologia	5
1.6	Estrutura da Dissertação	6
2	Enquadramento Teórico	7
2.1	Conceitos Base	7
2.2	<i>Automatic Defect Classification</i>	8
2.2.1	<i>Haar Cascades</i>	11
2.2.2	<i>Convolution Neural Network</i>	13
2.3	Análise de Modos de Falhas e Efeitos	14
3	Análise da Situação Inicial	19
3.1	Processo Produtivo	19
3.1.1	Tecnologia	19
3.1.2	Processo	20
3.2	Tipos de Defeitos	26
3.3	Caracterização do Problema	26
3.4	Modelos de ADC	29
3.4.1	Criação de Modelos	31
3.5	FMEA	32
3.6	Processo de Gestão de Alterações da ATEP, SA	33
4	Aplicação da Metodologia Proposta	35
4.1	Análise dos Modelos Atuais	35
4.2	Desenvolvimento de Novos Modelos	40
4.2.1	Modelo para AOI1DL2	41
4.2.2	Modelo para AOI1UBM	45
4.3	Implementação dos Novos Modelos	46
5	Análise de Resultados	47
6	Conclusão	51
6.1	Trabalho Futuro	52

A	A Cultura de QualidadePRIMEIRO	57
B	Catálogo de Falhas	59
C	Tabela Prioridade de Ação	67
D	FMEA Atual	71
E	FMEA - Metodologia Tradicional	73
F	Resultados Iterações Treino ADC	79
	F.1 AOI1DL2	79
	F.2 AOI1UBM	81
G	FMEA - Nova Metodologia	83

Acrónimos e Símbolos

AAS	Attribute Appraiser Study
ADC	Automatic Defect Classification
AIAG	Automotive Industry Action Group
AOI	Automated Optical Inspection
AP	Prioridade de Ação
ATEP	Amkor Technology Portugal, SA
DFMEA	Design FMEA
EIP	Experiment in Production
FMEA	Failure Mode and Effect Analysis
FN	False Negative
FP	False Positive
HDFO	High-Density Fan-Out
IT	Information Technology
KPI	Key Performance Indicator
LBS	Laser, Ball Attach, Singulation
NR	Not Reclassified
OSAT	Outsourced Semiconductor Assembly and Test
PC	Process Change
PFMEA	Process FMEA
RDL	ReDistribution Layer
RPN	Risk Priority Number
SBA	Solder Ball Attach
TN	True Negative
TP	True Positive
TPr	True Positive Relative
UBM	Under Bump Metallization
VDA	Verband der Automobilindustrie
WLCSP	Wafer Level Chip Scale Package
WLFO	Wafer Level Fan-Out

Lista de Figuras

1.1	Distribuição Geográfica da Amkor Technology, Inc (Amkor Technology, 2021) .	2
1.2	Cadeia Produtiva da Indústria de Semicondutores (Amkor Technology, 2021) . .	2
1.3	Cronograma do Projeto	5
2.1	<i>Wafer</i> de silício (Vítor, 2019)	7
2.2	Passos para o ADC (Breaux and Singh, 1995)	10
2.3	Exemplos de <i>features</i> relativamente à janela de deteção (Viola and Jones, 2001) .	12
2.4	Exemplos de uma deteção feita pelo <i>Haar Cascades</i> (Viola and Jones, 2001) . . .	12
2.5	Exemplos de uma deteção feita pelo <i>Haar Cascades</i> (Lee et al., 2005)	13
3.1	Tecnologias <i>Fan-In</i> (a) e <i>Fan-Out</i> (b) (Fan, 2010)	19
3.2	Lote à chegada	20
3.3	Esquema do Processo de <i>Grinding</i>	21
3.4	Esquema do Processo de Reconstrução da <i>Wafer</i>	21
3.5	Esquema da unidade com a camada de DL1	22
3.6	Esquema da unidade com as camadas de DL1 e <i>Seedlayer</i>	23
3.7	Esquema da unidade com as camadas de DL1, <i>Seedlayer</i> e <i>photoresist</i>	23
3.8	Esquema da unidade com as camadas de DL1, <i>Seedlayer</i> e Cobre	23
3.9	Esquema da unidade com as camadas de DL1, <i>Seedlayer</i> , Cobre e DL2	24
3.10	Esquema da unidade com as camadas de DL1, <i>Seedlayer</i> , Cobre, DL2 e UBM . .	24
3.11	Esquema da unidade com as camadas de DL1, <i>Seedlayer</i> , Cobre e DL2 e bola de solda	25
3.12	Exemplo de marcações	25
3.13	<i>Tray</i>	25
3.14	Inspeções AOI por camada	27
3.15	Exemplo de uma não conformidade detetada e os dois tipos de imagem	27
3.16	Modos de Risco do ADC	32
3.17	Fluxograma do Processo de Gestão de Alterações - EIP	34
4.1	KPI referentes ao ano 2020	36
4.2	Modos de Risco 2021	37
4.3	KPI referentes ao ano 2021	37
4.4	Exemplos de imagens FP	38
4.5	Exemplos de imagens FP	43
4.6	Limitações do Modelo AOI1DL2	44
A.1	Visão da política QualidadePRIMEIRO	57
B.1	Critério II.A	59

B.2	Critério II.B	60
B.3	Critério II.C.1	60
B.4	Critério II.C.2	60
B.5	Critério <i>Die Chipping</i>	61
B.6	Critério Bolhas no DL	64
B.7	Critério Defeitos na Estrutura do Cobre I.B	64
B.8	Critério Defeitos na Estrutura do Cobre II.A	64

Lista de Tabelas

1.1	Ranking, em milhões de USD, das Top10 Empresas OSAT (Wang, 2020)	4
2.1	Tabela Severidade PFMEA - Métricas ATEP	16
2.2	Tabela Ocorrência PFMEA - Métricas ATEP	16
2.3	Tabela Detecção PFMEA - Métricas ATEP	17
2.4	Vantagens e Desvantagens do FMEA (AIAG and VDA, 2019)	18
3.1	Tabela Resumo dos Produtos	26
3.2	Resultados da avaliação da performance de classificação	28
3.3	Resultados da avaliação da performance da aceitação/rejeição	29
3.4	Modos de Risco do ADC	29
3.5	Matriz de Confusão ADC	30
3.6	KPIs do ADC	30
3.7	Controlo da Mitigação do Risco	31
4.1	Resultados do QND _A durante a semana 6 e 10	38
4.2	Regras de Classificação de Unidades	40
4.3	Resultados da 5ª Iteração AOI1DL2	42
4.4	Resultados do modelo em produção AOI1DL2	43
4.5	Resultados da 6ª Iteração AOI1DL2	44
4.6	Resultados da 3ª Iteração AOI1UBM	46
5.1	Resultados do modelo final em produção AOI1DL2	47
5.2	Resultados do modelo final em produção AOI1UBM	48
5.3	Resultados Experiência <i>Haar Cascades</i> vs. <i>Deep Learning</i>	48
F.1	Resultados da 1ª Iteração AOI1DL2	79
F.2	Resultados da 2ª Iteração AOI1DL2	80
F.3	Resultados da 3ª Iteração AOI1DL2	80
F.4	Resultados da 4ª Iteração AOI1DL2	81
F.5	Resultados da 1ª Iteração AOI1UBM	82
F.6	Resultados da 2ª Iteração AOI1UBM	82

Capítulo 1

Introdução

O presente relatório foi elaborado no âmbito da unidade curricular de Dissertação realizada no 2º Semestre do 5º Ano de Engenharia e Gestão Industrial da Faculdade de Engenharia da Universidade do Porto, em ambiente empresarial na Amkor Technology Portugal, SA. No seguimento deste capítulo o projeto e a sua contextualização serão descritos, bem como a apresentação da empresa.

1.1 Apresentação da ATEP, SA

1.1.1 O Grupo Amkor Technology, Inc

A Amkor Technology, Inc foi fundada em 1968 e foca-se na montagem e teste de semicondutores¹, tornando-se integrante do mercado das OSAT (*Outsourced Semiconductor Assembly and Test*).

Atualmente, a Amkor está representada em diversas zonas geográficas distribuídas pela Ásia, América e Europa (Figura 1.1). Essas localizações diversificam-se entre sedes, fábricas, escritórios de vendas e suporte a cliente e centros de desenvolvimento de produto.

A Amkor é uma das quatro partes integrantes essenciais da cadeia de fornecimento de semicondutores (Zona amarela - Figura 1.2). Na primeira parte estão representadas as empresas que subcontratam todos os serviços de produção e dedicam-se, exclusivamente, à idealização do design dos chips; a segunda parte é constituída pelas empresas, usualmente referidas como *Front-End*, que produzem as *wafers* constituídas por silício com os chips incorporados; a terceira parte, onde se incluem empresas como a Amkor, são conhecidas como *Back-End* e são responsáveis pela montagem, que através da adição de várias camadas metálicas e poliméricas melhoram a robustez e fiabilidade dos chips, e teste; a última parte da cadeia produtiva desta indústria corresponde à implementação do produto resultante da fase anterior, normalmente chips individualizados, em circuitos integrados que terão diversas funcionalidades eletrónicas. Esta divisão permite que cada parte se foque na especialização do seu serviço e o desempenho com excelência e distinção.

¹Um semicondutor é constituído por silício, material que conduz mais eletricidade que um isolante e menos que um condutor puro. São incorporados na maioria dos equipamentos eletrónicos.




Figura 1.1: Distribuição Geográfica da Amkor Technology, Inc (Amkor Technology, 2021)



Figura 1.2: Cadeia Produtiva da Indústria de Semicondutores (Amkor Technology, 2021)

A missão da Amkor está interligada com a garantia de Fiabilidade e Confiança no produto que desenvolve para os seus clientes. Nesse sentido, pretende ser o fornecedor global de confiança de serviços fiáveis de montagem e teste, e de soluções inovadoras para empresas de microeletrónica e semicondutores que utilizem tecnologia avançada, desenvolvida através da estreita colaboração com os clientes e outros parceiros da cadeia de valor.

1.1.2 A Amkor Technology Portugal, SA

A Amkor Technology Portugal, SA (ATEP) é desde 2017, data em que foi adquirida, uma das fábricas da empresa-mãe Amkor Technology, Inc. A história desta fábrica situada em Mindelo (Vila do Conde) começa como Siemens Semicondutores em 1996. Posteriormente, passou a ser Infineon Technologies (1999) devido a um *spin-off* do ramo dos semicondutores. De seguida, foi comprada pela Qimonda (2006) que abriu insolvência em 2010, data em que a Nanium foi fundada com o objetivo de se especializar na tecnologia de *Wafer Level Fan-Out* (WLFO), acabando por ser o elemento atrativo para a Amkor que visava reforçar a sua posição no mercado.

A infraestrutura da ATEP é atualmente representada por 36.900 m^2 de áreas técnicas e sociais e 20.600 m^2 de áreas *cleanroom*. Estas últimas são salas idealizadas e construídas com o objetivo de ter, tal como o nome indica, salas limpas livres de partículas, eletricidade estática e/ou

qualquer outro tipo de contaminação. Na indústria dos semicondutores este tipo de salas torna-se fundamental já que um dos focos é a minimização e, se possível, eliminação de qualquer fator de contribuição para a geração de defeitos. A espessura das camadas aqui depositadas sobre o chip encontram-se na ordem dos nanómetros, existindo diversos tipos de contaminações que são invisíveis a olho nu e poderão comprometer o comportamento elétrico do componente ou o respetivo tempo de vida útil. Na ATEP existem três classes de salas limpas, as de: 1K, 10K e 100K (número de partículas com dimensões inferiores a $0,1 \mu\text{m}$ que poderão ser encontradas por metro cúbico). Consoante a criticidade da fase do processo em que o produto se encontra, este é transportado pelas diferentes salas.

Atualmente com mais de 600 funcionários, a empresa tem capacidade de realizar 8.000 camadas metálicas por semana. A empresa tem vários mercados finais, entre eles o *communications*, *consumer*, o *automotive*, o *security* e o *computing*. Com o passar dos anos, a ATEP tem aumentado o seu volume produtivo em produtos relacionados com o *security* e *automotive*, no entanto, o *mobile* continua a representar 70 % da produção.

A ATEP diferencia-se por ter instalações e equipamentos de reconhecida qualidade, produção com uma excelente relação custo-benefício, oferta completa ao nível da engenharia, equipa focada na qualidade altamente experiente e usa uma plataforma de IT assegurando uma total integração e rastreabilidade.

Por último, importa referir que a ATEP tem dois principais tipos de produto dentro da tecnologia de montagem em *wafer*: o *Wafer Level Chip Scale Package* (WLCSP) e o *Wafer Level Fan-Out* (WLFO) ou *High Density Fan-Out* (HDFO). Este tema será abordado no Capítulo 3. Ligados a esta tecnologia e com material em produtivo existem cinco clientes que, devido a questões de confidencialidade, serão referidos ao longo da dissertação como QND, NSV, ITG, ICN e QRV. Existem outros tipos de produtos que se encontram em fases experimentais ou de desenvolvimento e, por essa razão, não serão referidos neste documento.

1.2 Mercado do Setor de Semicondutores

Os semicondutores são a base dos sistemas e produtos utilizados diariamente pela sociedade já que estão incorporados em telemóveis, carros, equipamento médico, computadores, etc. Com a crescente utilização de produtos eletrónicos, torna-se evidente que a indústria dos semicondutores tem prosperado mantendo o foco em produzir chips cada vez mais baratos, pequenos e rápidos.

No mercado das OSAT, este negócio foi avaliado em 31,64 mil milhões de USD, em 2020, e espera-se que este valor aumente nos próximos anos, sendo este crescimento sustentado pelo aumento da procura dos produtos *automotive*, já que o mercado das *communications* se encontra saturado e em declínio (Mordor Intelligence, 2021).

Na Tabela 1.1 é possível distinguir as empresas que mais se destacam neste mercado pelas suas respetivas quotas. Como se observa, a ASE é a líder do mercado com uma quota de 22,5%, seguida pela Amkor com 20% (estes valores são referentes ao terceiro trimestre de 2020).

Tabela 1.1: Ranking, em milhões de USD, das Top10 Empresas OSAT (Wang, 2020)

<i>Ranking</i>	<i>Empresa</i>	<i>Receitas 3Q20</i>	<i>Quota de Mercado 3Q20</i>
1	ASE Technology Holding	1.520	22,5%
2	Amkor Technology	1.354	20,0%
3	Jiangsu Changjiang Electronics Tech (JECT)	982	14,5%
4	Siliconware Precision Industries (SPIL)	897	13,3%
5	Powertech Technology	647	9,6%
6	TongFu Microelectronics	398	5,9%
7	Tianshui Huatian Technology	319	4,7%
8	King Yuan Electronics	251	3,7%
9	Chipbond Technology Corporation	197	2,9%
10	ChipMOS Technologies	194	2,9%

Nota: A quota de mercado total nesta tabela inclui apenas as 10 empresas listadas.

1.3 Contextualização do Projeto na ATEP, SA

Como referido anteriormente, a ATEP tem vindo a aumentar a sua presença no mercado *automotive* e é neste sentido que surge este projeto. Dentro deste mercado, o produto pode passar por diversos sistemas implementados em automóveis como, por exemplo, sensores de travagem de emergência automática, de deteção de peões, de alerta de trânsito cruzado atrás ou à frente, de assistente de mudança de faixa, de deteção de ângulo morto, de reconhecimento gestual, *cruise control* adaptativo, etc.

Desta forma, torna-se implícita a necessidade de uma mentalidade focada em "Zero Defeitos", já que uma falha do produto em terreno poderá resultar num acidente com elevado potencial de impacto em vidas humanas ou materiais. A ATEP implementa este conceito para todos os produtos e, neste contexto, surge a sua política conhecida como QualidadePRIMEIRO (Anexo A) que se compromete a entregar produtos sem qualquer defeito e fornecer um serviço excecional para além das expectativas dos clientes.

Como consequência da introdução neste mercado e da sua exigência, tornou-se imperativo minimizar as diversas situações de risco presentes ao longo do processo produtivo. Dessa análise de risco, sobressaem-se os vários pontos de inspeção manual no qual o erro humano poderá ter elevada preponderância.

Nesse sentido, surge o *Automatic Defect Classification* (ADC), uma ferramenta de inspeção automática, que visa reduzir o risco para o cliente, auxiliando os operadores e a libertá-los deste tipo de tarefa demorada e delicada. Esta ferramenta é alimentada com modelos, sendo estes um conjunto de repositórios (conjunto de imagens relacionadas com os tipos de classificação), para os diferentes passos do processo e seus produtos. Resumidamente, a função do ADC é analisar as imagens que lhe chegam e comparar com as dos repositórios a que tem acesso, para detetar se está perante um erro ou não, e que tipo de erro representa. Ao operador, dependendo do modo de funcionamento selecionado, chegarão imagens para este conferir, manualmente, a classificação feita pela ferramenta.

1.4 Objetivos do Projeto

A ferramenta ADC, antes de ser capaz e autônoma, necessita ser treinada e otimizada de modo a ser colocada em produção. A presente dissertação foi desenvolvida dentro do departamento de Gestão da Qualidade com apoio do departamento de Tecnologia de Informação (IT). Os seus principais objetivos são:

- A análise da precisão e exatidão dos modelos ADC atualmente em produção.
- O desenvolvimento e implementação de novos modelos ADC para produtos *automotive* e com *Key Performance Indicators* (KPI) satisfatórios.

1.5 Metodologia

O decorrer deste projeto teve por base o cronograma que se apresenta na Figura 1.3. As primeiras semanas foram dedicadas a formações, de forma a que o fluxo produtivo da empresa fosse assimilado e produzir uma base de conhecimento forte, focada nos defeitos, com o objetivo de criar os repositórios para alimentar a ferramenta ADC.

A fase seguinte do projeto centrou-se na avaliação dos modelos da empresa já em fase produtiva através da análise comparativa entre os objetivos definidos para os diferentes KPI e os seus valores reais. Desta maneira, tornou-se possível identificar os pontos passíveis de melhoria.

A fase que se seguiu no projeto focou-se na seleção e coleção de amostras para a criação dos repositórios com recurso a ferramentas providenciadas pela ATEP. Posteriormente, produziram-se os repositórios propriamente ditos, com recurso à aplicação ADC já implementada na empresa. Realizou-se também uma contínua monitorização e atualização dos modelos até se obterem aqueles que se enquadrassem dentro dos requisitos esperados.

De notar que, na última linha do cronograma, existe um processo de gestão de alterações que atuou, paralelamente, ao longo da linha temporal. Este processo foi posto em prática sempre que a alteração ao fluxo produtivo do produto se mostrou justificada, isto é, sempre que os modelos obtiveram resultados satisfatórios e se implementou alguma alteração relativamente ao modo de operação na linha de produção. Este processo é finalizado com a atualização da análise de risco, utilizando a ferramenta FMEA (Análise de Modos de Falhas e Efeitos).




Figura 1.3: Cronograma do Projeto

1.6 Estrutura da Dissertação

A presente dissertação encontra-se dividida em seis capítulos. No primeiro capítulo foi apresentada a empresa bem como o enquadramento do projeto, os seus objetivos e a metodologia seguida. O capítulo dois remete a um enquadramento teórico ao tema abordado onde foram explorados os conceitos relacionados.

No terceiro capítulo, foi retratada a apresentação e análise da situação inicial da empresa, envolvendo a descrição do processo e da ferramenta. No capítulo seguinte, foi feita uma análise dos modelos atuais já implementados pela ferramenta e apontados os pontos de melhoria. Adicionalmente, foi descrita a aplicação da metodologia proposta em detalhe para a criação de novos modelos.

Os resultados foram discutidos e apresentados no capítulo cinco. Finalmente, no último capítulo foram apresentadas todas as conclusões e trabalho futuro sugerido decorrentes da elaboração deste projeto.

Capítulo 2

Enquadramento Teórico

Neste capítulo são explorados os conceitos teóricos que serviram de base ao desenvolvimento do projeto. Os temas em análise são a ferramenta ADC e o seu contexto e o FMEA como ferramenta de análise de risco.

2.1 Conceitos Base

Importa explorar, previamente, certos conceitos característicos desta indústria. Chakraborty (2021) define uma *wafer* (Figura 2.1) como um disco particularmente fino e constituído por silício ou qualquer outro tipo de material semiconductor. O silício é mais frequentemente usado devido à dureza e durabilidade que o caracterizam. Estas *wafers* são utilizadas para a construção de circuitos integrados e células fotovoltaicas. Nestas finalidades, a *wafer* serve como substrato. Engenheiros usam processos como *doping*², separação química com ácidos e deposição de vários materiais visando obter os circuitos integrados. Qualquer impureza que escape nesta fase, poderá resultar em chips defeituosos.




Figura 2.1: *Wafer* de silício (Vítor, 2019)

Sendo os semicondutores responsáveis por serem condutores de correntes elétrica, os chips, conhecidos pelo seu baixo custo e alto desempenho, são construídos em grande escala sobre a

²Processo de introdução de determinadas quantidades de impurezas químicas por forma a melhorar a condutividade.

wafer. Estes dispositivos são utilizados em diversos aparelhos eletrónicos e abrangem diferentes finalidades. Os termos chip, micro chip, circuito integrado e chip de silício são sinónimos.

Focando agora em todo o processo que envolve a indústria de semicondutores, a montagem em *wafer* é uma parte essencial deste processo, já que afeta o funcionamento dos chips. Nesta fase, são depositadas no produto várias camadas poliméricas e estruturas metálicas que funcionam para melhorar a robustez e redistribuir o sinal eléctrico. É possível afirmar que a sua função é proteger o chip, conectar o chip a uma placa ou outro chip e poderá ter uma participação na dissipação de energia.

Torna-se então evidente que os defeitos que aparecem nestas fases são críticos, sendo estes qualquer tipo de partícula, contaminação, falhas nas estruturas, etc. Pelo seu reduzido tamanho, são difíceis de identificar e, por essa razão, passam muitas vezes despercebidos na fase de teste (Meixner, 2021).

2.2 Automatic Defect Classification

Tendências

Atualmente, verifica-se que a tendência relativamente ao tamanho dos aparelhos eletrónicos é diminuir ao longo do tempo, levando a que o tamanho dos chips acompanhe essa tendência. Nessa lógica, Meixner (2021) afirma que a complexidade da fabricação destes chips sofre um aumento, já que, para atingir a robustez necessária, necessitam de mais camadas e, conseqüentemente, são submetidos a um maior número de processos dentro do seu fluxo produtivo. Neste sentido, Bennett et al. (1994) e Dom and Brecher (1995) explicam que, à medida que o tamanho dos aparelhos e chips diminui, o tamanho das partículas, defeitos e micro contaminações acompanham esta diminuição e, portanto, tornam-se mais difíceis de detetar devido ao limite de resolução ótica. Importa referir que estes defeitos são, normalmente, responsáveis pela falha do chip e perda de *yield*³.

Como complemento ao anteriormente referido, observa-se o aumento contínuo das exigências desta indústria e criticidade das aplicações finais o que fomenta nos produtores de semicondutores, como Tello et al. (2018) defendem, a necessidade de produzirem *wafers* sem defeitos, por forma, a melhorar a qualidade do produto, aumentar o *yield* e reduzir os custos. Desta forma, as empresas poderão tornar-se cada vez mais competitivas no mercado, implementando esforços na inspeção e na deteção de defeitos (Breux and Singh, 1995).

Importância da Deteção e Classificação de Defeitos

Segundo Tello et al. (2018) e Breux and Singh (1995), a deteção dos defeitos e a sua classificação torna-se essencial já que fornece informação útil relativamente a problemas e falhas do processo produtivo, visto que estes tendem a aglomerar nas *wafers* e a formar padrões. Para além disso, a probabilidade de ocorrência dos vários tipos de defeito está interligada com os diferentes

³De uma maneira abrangente, *yield* traduz-se no rácio entre o número total de chips "saudáveis" e o número total de chips da *wafer*.

processos. Esta metodologia permite que seja possível rastrear a fonte e a causa seja endereçada fazendo com que, idealmente, se evite a sua repetição.

Sendo que esta indústria envolve processos químicos e mecânicos de elevada complexidade e investimento que podem falhar contribuindo para chips defeituosos, torna-se clara a importância em reunir esforços para detetar e analisar com urgência estes defeitos, por forma a resolver e isolar rapidamente o problema resultando numa produção rentável e bem sucedida (Bennett et al. (1994) e Chou et al. (1996)).

Inspeção Automática e Revisão Manual

O padrão atual seguido na maior parte das fábricas de semicondutores para classificação dos defeitos passa por um processo manual depois do produto passar em máquinas especializadas, vulgarmente denominadas *Automated Optical Inspection* (AOI), para fazer uma inspeção. Esta inspeção caracteriza-se por ser, tal como o nome indica, uma inspeção visual feita de forma autónoma e baseia-se numa câmara que, autonomamente, percorre toda a *wafer* à procura de falhas e defeitos de qualidade. À medida que a câmara se move captura imagens e, posteriormente, compara-as com a imagem de referência. Se qualquer disparidade entre ambas as imagens for encontrada, a imagem captada é guardada e deixada para a revisão por parte de operadores que reclassificarão a imagem, atribuindo-lhe uma categoria (tipo de falha ou sem defeito). Por ser um teste que não envolve contacto direto com a *wafer* é uma técnica globalmente utilizada em inúmeras indústrias, incluindo a de semicondutores (Vitoriano and Amaral, 2016).

Riscos Associados à Revisão Manual

A fase da revisão manual em que o operador filtra os defeitos consoante as diversas categorias previamente definidas normalmente relacionadas com as causas e consequências dos defeitos, foi estudada por Phua and Theng (2020) que a caracterizam como um trabalho intensivo e demorado, sujeito a erro humano. Nessa linha de pensamento, Bennett et al. (1994) referem que estas razões podem levar a que, nesta etapa do processo, se desenvolva um *bottleneck*. Pessoa (2018) acrescenta ainda que, apesar deste tipo de revisão ser demorado, não previne o facto de falsos resultados estarem suscetíveis de ocorrer, visto depender da atenção, concentração, experiência e conhecimento do operador.

Em sintonia com o que foi dito anteriormente estão Breux and Singh (1995) que, adicionalmente, esclarecem o facto de existir uma necessidade de investir demasiado tempo em estabelecer um sistema de classificação, desenvolver um livro de referência e formar pessoal para reconhecer e classificar de acordo com os diferentes tipos de defeitos.

Para além do que já foi referido, este tipo de revisão traz consigo outro tipo de problema, também estudado por Breux and Singh (1995). É observada uma grande variabilidade na classificação de defeitos, não só entre os diferentes operadores mas até pelo mesmo operador de *wafer* para *wafer*. A falta de repetibilidade, quando o mesmo operador classifica de maneira diferente o mesmo defeito, também se mostra uma limitação. Estes resultados podem ser justificados pelos

diferentes julgamentos e interpretações dos classificadores mas como também pelas diferentes alturas do dia (como, por exemplo, o fim do turno ou uma linha de produção mais caótica) ou até estados de espírito, atitudes, etc.

Neste sentido, para as empresas presentes nesta indústria, já que lidam com produtos de escalas nanométricas, é necessário reduzir o máximo possível tanto os erros obtidos pelas máquinas como os associados à reclassificação manual, pois com menos falhas se pressupõem mais ganhos e todos os processos na linha de produção se baseiam na melhoria contínua. Acrescenta-se ainda a necessidade de colmatar o tempo despendido nestes tipos de tarefa para poderem melhorar a sua eficiência.

A errada reclassificação ou até mesmo a não deteção de defeitos são os principais riscos a que a indústria está sujeita. A não deteção é, no entanto, o caso mais crítico, já que o produto poderá falhar no cliente final e, dependendo da sua finalidade, a gravidade das consequências varia.

ADC

A implementação de ferramentas como o *Automatic Defect Classification* (ADC), que têm por base a inspeção automática, sem qualquer supervisão humana, surgem com o foco de minimizar todos os problemas anteriormente descritos. A base desta ferramenta passa por receber as imagens provenientes de AOI, inspecionar a imagem com o objetivo de detetar a localização do defeito na imagem, associar esse defeito a um dos repositórios caracterizados pelos diferentes tipos de defeitos existentes e, finalmente, atribuir ao defeito uma classificação (Lee et al., 2005). Na Figura 2.2 pode ser visto o seu funcionamento de forma esquematizada. Posteriormente, o operador confere o resultado do ADC consoante os diversos modos de funcionamento da ferramenta.




Figura 2.2: Passos para o ADC (Breux and Singh, 1995)

Bennett et al. (1994) defendem que o ADC traz inúmeras vantagens para a indústria como, por exemplo, inspeções/revisões mais rápidas, aumento da produção, maior tamanho da amostra, maior eficácia da classificação, diminuir a variabilidade da classificação, redução da sobrecarga de recursos, reorientação do pessoal para a análise e resolução de problemas e redução da utilização de *wafers* de teste através da utilização de *wafers* de produto. Em contrapartida, Breux and Singh (1995) para além de concordarem com as vantagens, apontam para desvantagens que possam surgir como, por exemplo, a eficácia da classificação depender substancialmente da qualidade da imagem que a ferramenta analisa, fazendo com que ruído na imagem ou diferentes colorações

(sombas) levem a uma errada classificação ou mesmo à não detecção. No entanto, como estes ruídos estão normalmente localizados nas extremidades, aconselham a que a área do defeito esteja localizada no centro da imagem.

De modo a conseguir obter-se um ADC eficiente, o passo fundamental é a transição da experiência e conhecimento do processo de humanos para máquinas e algoritmos. Neste sentido, Bennett et al. (1994) defendem que a base para o implementar passa por desenvolver algoritmos de análise de imagens que possam ser integrados em ferramentas de detecção/revisão de defeitos existentes. Idealmente, a ferramenta deve estar preparada para lidar com imagens monocromáticas ou coloridas.

Breaux and Singh (1995) acabam por concluir com o seu estudo que o ADC conduz as empresas para melhorias significativas na detecção de erros quando comparando com os operadores. Nesta mesma linha de pensamento, Chou et al. (1996) afirmam que este tipo de ferramenta oferece consistência, eficiência e repetibilidade e, por essa razão, o número de indústrias e empresas a optarem por esta solução tem vindo a aumentar substancialmente. É também argumentado que o ADC apresenta um forte impacto positivo na produtividade e na qualidade dos processos na produção de semicondutores.

2.2.1 Haar Cascades

Qualquer ferramenta ADC tem por base métodos de *machine learning* de forma a produzir as classificações automáticas esperadas. Como neste caso os classificadores implementados consistem em métodos de classificação baseados nas *Haar-like features*, a presente secção dedica-se ao enquadramento teórico destes, bem como as suas aplicações na indústria.

O primeiro *Cascade Classifier* foi desenvolvido por Viola and Jones (2001) como um sistema para detetar caras com taxas de detecção elevadas e falsos positivos baixas, a uma alta velocidade. Nos primeiros estudos feitos foram utilizados pixeis para a detecção de objetos nas imagens. No entanto, esta abordagem apresentou algumas limitações como, por exemplo, um elevado grau de dificuldade de implementação e lenta velocidade de operação. Concluiu-se que utilizar *features* em vez de pixeis como base para a detecção de objetos seria a melhor opção, tendo colmatado as limitações citadas.

Haar-like features são regiões retangulares adjacentes posicionadas numa localização específica da janela de detecção. Cada uma destas *features* é caracterizada por um valor obtido como resultado da diferença das somas dos pixeis dentro dos diferentes retângulos. Na figura 2.3 podem ser observados exemplos dessas *features*. Em (A) e (B) estão representadas *features* de dois retângulos, em (C) uma *feature* de três retângulos e em (D) de quatro retângulos.

Na fase de detecção do objeto, a janela de detecção vai percorrendo a imagem em análise e, para cada subsecção a *Haar-like feature* é calculada e comparada com um limite definido que permite fazer a distinção entre objetos e não-objetos. Na Figura 2.4 é apresentado um mesmo caso em que o algoritmo foi bem sucedido na detecção do objeto com duas *features* diferentes.




Figura 2.3: Exemplos de *features* relativamente à janela de deteção (Viola and Jones, 2001)




Figura 2.4: Exemplos de uma deteção feita pelo *Haar Cascades* (Viola and Jones, 2001)

É então possível concluir que este tipo de deteção irá necessitar de várias *features* para poder classificar da forma mais correta possível um objeto. Posto isto, todas as *features* estão organizadas num chamado *Cascade Classifier*, que servirá para apenas um tipo de defeito, de maneira a que seja possível ter um poderoso e eficiente detetor de objetos. Cada classificador exige um processo de treino, antes de ser implementado numa região de interesse, em que este é alimentado com imagens arbitrárias e do mesmo tamanho, que sejam positivas (ou seja, com o objeto) e negativas (sem o objeto) (OpenCV, 2017).

Aplicações

Dentro da indústria de semicondutores, Lee et al. (2005), embora focados nos defeitos com maior presença nas *wafers*, estudaram um algoritmo de ADC que na base da sua lógica faz uso das *Haar-like features*. Dos seus estudos fizeram parte várias experiências com o objetivo de classificar as imagens em três categorias: partículas, riscos e outros. De uma forma geral, concluem que a ferramenta tem resultados satisfatórios e que classifica de forma correta os defeitos.

No entanto, retiram que o número ideal de *features* a utilizar em cada classificador é duas, já que, como é possível observar no gráfico da Figura 2.5, à medida que mais *features* são utilizadas a performance de reclassificação melhora, mas essa melhoria satura rapidamente.

Alguns defeitos são muito semelhantes entre si e um mesmo defeito tem uma variação elevada e, por isso, verifica-se que este algoritmo para o ADC tem um pior desempenho quando tenta reclassificar entre três ou mais classes, quando comparado às suas reclassificações entre apenas duas classes.




Figura 2.5: Exemplos de uma detecção feita pelo *Haar Cascades* (Lee et al., 2005)

Kim et al. (2009) num novo estudo usando o mesmo tipo de algoritmo, mas agora apenas com o foco de classificar se o defeito se trata de um risco ou não (duas classes), acrescentam às suas conclusões que este tipo de classificadores têm melhor *performance* quando não avaliam características óticas como cores, formas e tamanhos, atingindo taxas de classificação de 85 % e de falsa detecção abaixo de 5 %.

Tendo em conta estes resultados, têm surgido modelos alternativos ao *Haar Cascades* visando melhores resultados. Phua and Theng (2020) referem que se tem verificado um aumento do foco no *deep learning* e, particularmente, em modelos denominados *Convolutional Neural Network* (CNN) pela elevada *performance* capaz de atingir, rondando a eficiência de classificação na escala dos 90% e com menos esforço, recursos e restrições a nível ótico envolvidos.

2.2.2 Convolution Neural Network

Phua and Theng (2020) estudaram, dentro da indústria dos semicondutores, a ferramenta ADC tendo por base o CNN. O foco do estudo passa por atingir uma *performance* elevada para a reclassificação de defeitos conhecidos e uma *performance* robusta em identificar defeitos não conhecidos sem necessitar de retreinar o CNN. Este último ponto é dos principais defeitos da utilização do *Haar Cascades*.

Este algoritmo de *deep learning*, conhecido pela sua autonomia na reclassificação de defeitos, tem por base a extração eficiente de *features* das imagens representativas de defeitos, localizar defeitos nas imagens por reclassificar e medir o tamanho dos defeitos nas várias camadas metálicas, reduzindo a perda de material, mão de obra e tempo de produção.

CNN são conhecidos pela sua eficácia a capturar objetos em imagens, recorrendo a menos esforço computacional. Adicionalmente, têm a capacidade de diferenciar uma grande quantidade de classes, ao contrário do algoritmo anterior. Para além disso, é um modelo de auto-aprendizagem com a mínima necessidade de intervenção humana já que a sua arquitetura lhe confere a combinação das funcionalidades de extrair *features* autonomamente e reclassificar.

Para este estudo, Phua and Theng (2020) utilizam um conjunto de dados dividido em nove classes, sendo que oito são mesmo defeitos e a outra são as imagens sem defeito. Para medir o

tamanho dos objetos deve ser disponibilizada uma escala na zona inferior das imagens utilizadas para os classificadores. Como já foi dito, é importante ter um rastreio dos defeitos para se poder atribuí-lo a uma área do processo e o tamanho pode representar um importante indicador para essa finalidade.

O treino do modelo CNN passa por, de forma similar ao *Haar Cascades*, definir as imagens que serão utilizadas e associar-lhes um tipo de defeito. Para os casos de medição é necessário traçar na região de interesse as zonas que delimitam o defeito. De notar que este processo, tanto de recolha de imagens como classificação, é feito manualmente.

Dentro das oito classes de defeitos, para apenas duas importa o tamanho do defeito e, por isso, a utilização da escala só é feita para essas por forma a reduzir o desperdício de recursos. Assim, existem três fases principais no processo de deteção e reclassificação utilizando o CNN. Primeiro reclassifica-se o defeito de acordo com as classes existentes, depois, caso a imagem seja uma das classes que merece atenção especial, a imagem é guardada e submetida ao algoritmo que irá localizar o defeito e medir certas características da imagem. A última fase trata-se de fazer o cálculo utilizando a escala e obter, assim, o tamanho real do objeto.

Este método de *deep learning* atinge eficiências acima dos 90 % para a maior parte das classes e, por isso, apresenta-se válido para ser utilizado na indústria de semicondutores para a deteção e reclassificação de defeitos. No sentido de ter os melhores resultados possíveis é importante ter uma quantidade considerável de imagens e que essa quantidade seja balanceada para cada classificador.

2.3 Análise de Modos de Falhas e Efeitos

A Análise de Modos de Falhas e Efeitos (FMEA) é utilizado como metodologia auxiliar para a redução de risco, sendo um método analítico, qualitativo, sistemático e orientado para equipas com o objetivo de:

- Reconhecer e avaliar as potenciais falhas de um produto ou processo;
- Analisar as causas e efeitos dessas falhas;
- Documentar ações preventivas e de deteção;
- Recomendar ações para reduzir o risco.

Existem atualmente duas principais abordagens utilizando o FMEA: a de *Design* (DFMEA), que aborda as fases iniciais de desenvolvimento do produto/processo, e a de Processo (PFMEA), que se foca no produto/processo já existente. Ainda que apresentem diferenças, estes FMEA seguem a mesma lógica para a sua realização, o tipo de falhas analisadas é que diverge. O DFMEA está maioritariamente ligado às falhas do produto e o PFMEA às falhas do processo. No seguimento do documento o foco será o PFMEA já que este é o que se enquadra no âmbito da dissertação.

O FMEA de Processo (PFMEA) funciona como ferramenta auxiliar de redução do risco dos processos ao:

- Identificar e avaliar as funções e requisitos do processo;

- Identificar e avaliar potenciais modos de falha relacionados com o produto ou processo, e os efeitos das potenciais falhas no processo e clientes;
- Identificar as potenciais causas;
- Identificar as variáveis do processo nas quais se devem focar os processos de controlo para redução da ocorrência ou aumento da deteção das condições da falha;
- Permitir a implementação de um sistema de prioridade para ações e controlos preventivos ou corretivos.

É aconselhável a antecipação e definição de uma periodicidade para a revisão e análise dos processos por forma a antecipar, resolver e monitorizar potenciais preocupações do processo. Esta prática irá auxiliar a equipa e, por consequência, a empresa a reduzir custos, desperdício de tempo e maior controlo sobre o seu processo.

Para um PFMEA eficiente é necessária a total compreensão do processo. Neste sentido, a General Motors Corporation et al. (2008) aconselham iniciar o seu desenvolvimento pela utilização de um fluxograma no sentido de identificar as características do produto/processo associadas a cada operação. Desta maneira, torna-se possível definir uma lista do que é suposto ou não acontecer no processo, o que serve de suporte para estabelecer o sentido da análise.

No desenvolvimento do documento separa-se o processo pelos seus diferentes passos e define-se a respetiva função. Para cada um são discriminados os potenciais modos de falha, sendo estes definidos como a maneira que o processo pode eventualmente falhar em cumprir com os seus requisitos.

A cada modo de falha associam-se os seus potenciais efeitos tanto do ponto de vista interno (próximo passo/operação) como externo (desde que sai da fábrica até ao consumidor final). Posteriormente, estes efeitos são classificados pela sua ordem de Severidade (S), definida pelo defeito mais sério que se venha a verificar. Na Tabela 2.1 é possível analisar que, consoante o ponto de vista, esta avaliação é feita de maneira diferente. A Tabela trata-se de uma classificação adaptada à realidade da ATEP, tendo por base as tabelas da General Motors Corporation et al. (2008).

A próxima característica analisada é a potencial causa que indica como é que a falha pode ter ocorrido. Cada modo de falha poderá ter mais que uma causa e, portanto, é aconselhado que se faça a distinção entre elas já que da análise individual poderão resultar diferentes ações e controlos. A Ocorrência (O) avalia a probabilidade do conjunto causa/modo de falha ocorrer, tendo em consideração o peso que os métodos de prevenção apresentam na redução ou eliminação da causa (Tabela 2.2).

Os métodos de deteção também contribuem para esta análise de risco já que são utilizados para detetar o acontecimento da causa ou do modo de falha e desta maneira desenvolver ações corretivas. O indicador da Deteção (D) é caracterizado com o controlo de deteção mais efetivo e segue a lógica da Tabela 2.3. Idealmente, o foco de toda a análise de risco será endereçar esforços na criação de controlos preventivos e, em última análise, em controlos de deteção.

Com tudo definido, o foco da equipa para a recomendação de ações com uma ordem de prioridade definida deve ser orientado para os modos de falhas com severidades e ocorrências mais elevadas. Uma abordagem para avaliar o risco de cada um dos modos de falhas e, desta forma,

Tabela 2.1: Tabela Severidade PFMEA - Métricas ATEP

Efeito	Critério: Severidade do Efeito no Produto (Efeito no Cliente)	Ranking	Efeito	Critério: Severidade do Efeito no Produto (Efeito na Produção)
Falha no Cumprimento dos Requisitos de Segurança e/ou Regulamentares	Potencial modo de falha afeta o funcionamento seguro do veículo e/ou envolve não conformidade com requisitos legais sem aviso.	10	Falha no Cumprimento dos Requisitos de Segurança e/ou Regulamentares	Pode colocar o operador (produção ou montagem) em risco sem aviso.
	Potencial modo de falha afeta o funcionamento seguro do veículo e/ou envolve não conformidade com requisitos legais com aviso.	9		Pode colocar o operador (produção ou montagem) em risco com aviso.
Perda ou Degradação da Função Principal	Perda da função principal do veículo (veículo inoperável, não afeta a segurança do veículo).	8	Perturbação Elevada	Pode ser necessário eliminar 100% da produção afetada. Paragem da linha ou interrupção da expedição.
	Degradação da função principal do veículo (veículo operável, mas a um nível reduzido de performance).	7	Perturbação Significativa	Pode ser necessário eliminar uma porção da produção. Desvio em relação ao processo principal incluindo menor cadência da linha ou mão de obra adicional.
Perda ou Degradação da Função Secundária	Perda da função secundária do veículo (veículo operável, mas a função de conforto/conveniência inoperável).	6	Perturbação Moderada	Pode ser necessário retrabalhar 100% da produção fora da linha e aceitar (depois do processo).
	Degradação da função secundária do veículo (veículo operável, mas a função de conforto/conveniência a um nível reduzido de performance).	5		Pode ser necessário retrabalhar uma porção da produção fora da linha e aceitar (depois do processo).
Incómodo	Aparência, não relacionado com a função, mas notada pela maioria dos clientes como defeito (>75%).	4	Perturbação Moderada	Pode ser necessário retrabalhar 100% da produção na estação.
	Aparência, não relacionado com a função, mas notada por muitos clientes como defeito (>50%).	3		Pode ser necessário retrabalhar uma porção da produção na estação.
	Aparência, não relacionado com a função, mas notada por alguns clientes como defeito (<25%).	2	Perturbação Mínima	Ligeiro inconveniente para o processo, operação ou operador.
Sem Efeito	Sem efeito discernível.	1	Sem Efeito	Sem efeito discernível.

Tabela 2.2: Tabela Ocorrência PFMEA - Métricas ATEP

Probabilidade de Falha	Ranking	Número de Incidentes (por milhão)	Capacidade- Performance do Processo	Erro Humano	PAC / INP	CRM
Muito Elevada	10	>/= 100,000	</= 0.65	≥3	≥3	≥3
Elevada	9	> 50,000	> 0.65	2	2	
	8	> 20,000	> 0.78			
	7	> 10,000	> 0.86			
Moderada	6	> 2,000	> 1.03	1	1	1
	5	> 500	> 1.16			
	4	> 100	> 1.33			
Baixa	3	> 10	> 1.67	0	0	0
	2	> 1	> 2.00			
Muito Baixa	1	Falha eliminada através do controlo de prevenção	Falha eliminada através do controlo de prevenção	0	0	0

auxiliar a equipa a definir e priorizar as suas ações é recorrer ao Número da Prioridade de Risco (RPN) calculado pela equação 2.1.

$$RPN = Severidade(S) \times Ocorrência(O) \times Detecção(D) \quad (2.1)$$

No entanto, o uso de limites máximos de valores de RPN para estabelecimento de ações por si só não é uma prática recomendada para determinar a necessidade de ações já que, por exemplo,

Tabela 2.3: Tabela Detecção PFMEA - Métricas ATEP

Critério: Tipo de Controlo de Processo	Ranking	
	Na estação	Depois de Processo
Sem processo de controlo; Não será ou não pode ser detetado.	10	
Controlo Inefetivo (Ex.: auditorias aleatórias)	9	
Inspeção visual/manual/tátil/audível pelo operador.	7	8
Medição variável/atributiva (medições de característica do produto, controlo de certo/errado de um parâmetro, etc)	6	7
Medições das condições de produção na primeira produção.	5	6
Controlos Automáticos / Parte discrepante (Efeito)/ Alarme	5	6
Controlos Automáticos / Modo de Falha (Causa)/ Alarme	4	--
Controlos Automáticos / Parte discrepante (Efeito)/ Bloqueio	3	4
Controlos Automáticos / Causa/ Bloqueio	2	--
Prova de Erro/ Previne a falha	1	--

para um mesmo número de RPN, mas com severidades diferentes, a preocupação endereçada devia variar. É visto também como limitação o facto de não existir nenhum valor específico para o RPN que requeira ações obrigatoriamente, levando a que as equipas estejam focadas a justificar uma ocorrência mais baixa ou o valor da deteção para obterem RPN mais baixos.

Para a análise de risco é desejável que exista uma análise completa com os três indicadores: S, O e D. Neste sentido a *Automotive Industry Action Group* (AIAG), em parceria com a *Verband der Automobilindustrie* (VDA), desenvolveu uma metodologia de PFMEA que se caracteriza por ser uma análise mais detalhada e exaustiva que visa colmatar as limitações da abordagem anterior.

A AIAG and VDA (2019) dividem o processo de execução do PFMEA em sete passos. Num primeiro passo, denominado Planeamento e Preparação, o objetivo principal é descrever que produtos ou processos serão analisados. Neste sentido, a equipa deve começar por identificar de forma clara o projeto e definir o plano recorrendo ao método dos 5T (Intenção, Calendarização, Equipa, Tarefas e Ferramenta). Para além disso, é importante clarificar os limites da análise (o que é incluído e excluído) e identificar lições aprendidas.

O passo seguinte é a Análise da Estrutura e passa por identificar e decompor o sistema de produção em itens do processo, passos do processo e elementos de trabalho do processo. Cada um dos elementos de trabalho corresponde a uma potencial causa que pode afetar o passo do processo e pertence a um grupo dos 4M (Máquina, Homem, Material ou Ambiente). De forma concisa, o resultado desta fase é a representação do fluxo do produto ao longo do processo (item) com associação dos fatores contribuintes de cada passo.

Sendo que uma função descreve o que o item, passo ou elemento do processo se destinam a fazer, o terceiro passo é a Análise da Função e serve para garantir que as funções e requisitos pretendidos do produto ou processo são devidamente atribuídos e definidos de forma clara.

De seguida, a Análise da Falha que consiste em identificar causas, modos e efeitos das falhas e definir as respetivas relações para permitir a avaliação de risco. Esta análise é feita para cada conjunto item/ passo/ elemento do processo que, por sua vez, pode ter mais que uma possível falha

associada. Importa referir que as falhas são deduzidas das características do produto e do processo como, por exemplo, não conformidades, tarefas executadas não corretamente, atividade não intencional, atividade desnecessária.

Segue-se a Análise de Risco em que o objetivo passa por prever o risco avaliando a Severidade, a Ocorrência e a Detecção e dar prioridade à necessidade de ações. Cada combinação do modo, causa e efeito da falha é avaliada em relação ao risco de forma independente. Para a avaliação de risco são utilizados os mesmos três critérios utilizados na metodologia anterior: S, O e D (avaliados de 1 a 10 e sabendo que 10 corresponde à contribuição de risco mais elevada) embora as tabelas possam variar. No entanto, para além da discriminação do processo mais pormenorizada, o que difere entre as duas metodologias é o método utilizado para a priorização.

Recorrer ao RPN não é recomendado, como visto anteriormente, pois é dado aos três indicadores a mesma importância podendo levar a equipa à incerteza. Neste sentido, a AIAG and VDA (2019) sugerem a utilização do método de Prioridade de Ação (AP) que divide as ações pelo seu nível de prioridade elevada (H - *High*), média (M - *Medium*) e baixa (L - *Low*), dando mais ênfase à severidade, em segundo à ocorrência e por último à deteção. Com recurso às tabelas de S, O e D é possível obter a tabela do Anexo C. O H é representativo da prioridade mais elevada para revisão e ação e, nesse sentido, a equipa necessita de identificar uma ou várias ações adequadas para melhorar os controlos de deteção e/ou prevenção. De seguida, o M indica que a equipa deverá agir no mesmo sentido que o anterior. Finalmente, o L, a prioridade mais baixa, alerta para o facto de a equipa poder identificar essas ações.

A Otimização representa o penúltimo passo e tem como objetivo determinar ações para mitigar o risco e avaliar a eficácia das referidas ações. Normalmente, estas ações contribuem para a melhoria do processo ao reduzir o risco e, por isso, o PFMEA pode ser utilizado como base para melhoria contínua do processo. Finalmente, este exercício termina com a documentação dos resultados, resumindo e comunicando os resultados da atividade.

Na Tabela 2.4 é possível analisar as vantagens e limitações da ferramenta.

Tabela 2.4: Vantagens e Desvantagens do FMEA (AIAG and VDA, 2019)

Vantagens	Desvantagens
- Aumentar a qualidade, fiabilidade, capacidade de fabrico, operacionalidade e segurança dos produtos. - Aumentar a satisfação dos clientes. - Comprovar a análise de risco do produto e do processo em caso de responsabilidade pelo produto. - Reduzir alterações de última hora no desenvolvimento. - Desenvolver uma base de conhecimento na empresa, isto é, documentar as lições aprendidas. - Ajudar engenheiros a priorizar e focar na eliminação/redução de falhas/riscos.	- Ser qualitativo, não quantitativo. - É uma análise de falhas num único ponto, e não uma análise de falhas em múltiplos pontos. - Tem como base o nível de conhecimento da equipa, que pode ou não prever o desempenho futuro.

Capítulo 3

Análise da Situação Inicial

Neste capítulo é feita a análise da situação inicial, passando pelo processo produtivo, descrição do tipo de defeitos, caracterização do problema, breve descrição dos modelos atuais de ADC e descrição do processo de gestão de alterações.

3.1 Processo Produtivo

3.1.1 Tecnologia

Como já anteriormente referido, dentro da ATEP estão implementados dois tipos de tecnologia diferentes: o *Wafer Level Chip Scale Package* (WLCSP), conhecido como *Fan-In*, e o *Wafer Level Fan-Out* (WLFO), também denominado *Fan-Out*.

Na tecnologia convencional, *Fan-In*, as diversas camadas de dielétrico⁴ e estruturas metálicas são formadas nos chips enquanto estes ainda se encontram na *wafer* de silício intacta. O produto final tem o mesmo tamanho que o próprio chip. No entanto, nos últimos anos, a tecnologia *Fan-Out* tem vindo a ganhar posição no mercado e caracteriza-se pela reconstrução da *wafer* com recurso a um composto de molde, permitindo que todas as camadas e estruturas necessárias sejam aplicadas numa área maior. Na Figura 3.1 observa-se a diferença entre os dois tipos de chips.




Figura 3.1: Tecnologias *Fan-In* (a) e *Fan-Out* (b) (Fan, 2010)

⁴Um dielétrico é um isolante elétrico. Utilizados na indústria de semicondutores pois permitem que dois condutores se encontrem próximos sem risco de contacto/transferência de corrente.

Ao colocar as duas tecnologias em comparação, Fan (2010) defende que o WLFO apresenta várias vantagens em relação à tecnologia convencional como, por exemplo, a redução da espessura das estruturas, o maior número de input/output (I/O), melhor *performance* elétrica, boa *performance* térmica e processos com menos camadas.

3.1.2 Processo

O fluxo produtivo da ATEP está dividido em quatro áreas principais: a Preparação da *Wafer* (WaferPrep), a Reconstrução da *Wafer* (Recon), a Deposição das Camadas de Redistribuição (RDL) e Marcação, Soldadura das Bolas de Solda e Singularização (LBS).

A descrição do processo que se segue é de um produto *Fan-Out* com duas camadas de dielétrico e uma de cobre. De referir que o processo dos produtos *Fan-In* é idêntico, no entanto, não passa pelas duas primeiras áreas.

Preparação da Wafer

Numa primeira fase do processo, dá-se a receção dos lotes provenientes de *Front-End* constituídos por *wafers* de silício já com chips incorporados (Figura 3.2). Antes de lançar o lote na linha de produção são feitas verificações e inspeções definidas previamente consoante o produto.





Figura 3.2: Lote à chegada

Como nos passos seguintes a parte ativa da *wafer* está em contacto direto com superfícies que danificam a *performance* elétrica dos chips, o próximo passo é colocar uma película nessa superfície para proteção da mesma.

As *wafers* chegam à fábrica com uma espessura superior à necessária para que sejam suficientemente robustas e, assim, não se partirem ou danificarem com facilidade durante o transporte. Neste sentido, o passo que se segue é denominado *Grinding* (Figura 3.3) e representa o desbaste da parte não ativa da *wafer* até atingir a espessura nominal pretendida. Posteriormente, a *wafer* é montada numa moldura com adesivo com a finalidade de dar suporte aos próximos passos (*Mounting*). No fim, a película da parte ativa é removida em *Peeling*.

O último passo da área é chamado de *Dicing* em que, recorrendo a lâminas, todas as unidades/chips da *wafer* são individualizadas ficando coladas ao adesivo da moldura.


Figura 3.3: Esquema do Processo de *Grinding*

Reconstrução da Wafer

O processo nesta área encontra-se esquematizado na Figura 3.4. O primeiro passo (a) é colocar um adesivo num disco metálico, chamado *mold carrier*, que servirá de base para a reconstrução da *wafer*. Este passo é fundamental para que, no passo seguinte (b), conhecido como *Pick&Place*, ao movimentar os chips individualizados da moldura para o disco metálico, estes fiquem colados nas posições pretendidas.

De seguida (c), o *mold carrier* passa para o equipamento onde será depositado o composto de molde em cima da *wafer* e, com recurso a uma prensa, é espalhado por toda a superfície. Ainda no mesmo equipamento, é feita uma cura com o objetivo de secar o molde e, finalmente, entra numa câmara de arrefecimento onde fica em repouso.

O último passo é designado por *Debond* e é caracterizado pela remoção, primeiro (d), do *mold carrier* e, por fim (e), do adesivo. O resultado final é a *wafer* reconstituída.

Figura 3.4: Esquema do Processo de Reconstrução da *Wafer*

RDL

O RDL é a área mais crítica do processo já que é aqui que é feita a deposição das várias camadas que terão a funcionalidade de redistribuir o sinal elétrico e dar às unidades a robustez e fiabilidade necessárias. Por sua vez, a área está subdividida em quatro áreas: Metrologia, *Dry*, *Wet* e Litografia.

A primeira área onde os lotes são trabalhados é a área da Metrologia com o objetivo de ser feito o controlo do processo de *Pick&Place* através do cálculo do deslocamento dos chips face à posição teórica e dentro dos desvios permitidos. A este processo dá-se o nome de *RecDieShift*.

De seguida, os lotes são transportados para a área do *Dry* onde se faz o *PreCureFuse*. O objetivo deste passo é retirar humidade e diminuir o empeno⁵ ao colocar as *wafers* dentro de

⁵O empeno é uma característica específica do produto *Fan-Out*, já que se trata de *wafers* suportados por *Mold Compound* que sofre deformações ao ser sujeito às temperaturas elevadas dos fornos.

uma câmara fechada à temperatura e durante o tempo indicados no documento de instruções do processo. Posteriormente, acontece a limpeza da *wafer* através de plasma visando a eliminação de resíduos de dimensões nanométricas da superfície (*AsherPreFuse*).

De volta à Metrologia é feito, por amostragem, o controlo do empeno (*WarpAsherPreFuse*).

Tendo todos os passos anteriores sido concluídos, os lotes passam à área de Litografia. Nesta área, independentemente da quantidade de visitas dos lotes, o objetivo é semelhante: a deposição de dielétrico ou *photoresist*. Os dois são *photoresist*, no entanto, o primeiro fica na unidade e o segundo é totalmente removido servindo apenas de suporte para a criação das estruturas de cobre.

A primeira camada depositada é de dielétrico (DL1) e o processo tem o nome de *LithoFuse* que tem como objetivo principal a abertura de vias nas zonas de alumínio do chip de silício que permitem a passagem do sinal elétrico. Este processo inicia-se com o *Coating* que consiste em cobrir a *wafer* com um material fotossensível, denominado *photoresist*. O passo seguinte, *ExposeFuse*, tem como finalidade transferir o padrão pretendido, por incidência de luz UV, sobre a camada fotossensível. Esta transferência consiste em, dependendo do tipo de *photoresist*, positivo ou negativo, deixar certas zonas quimicamente menos robustas. Para o positivo, são as áreas expostas as menos robustas, para o negativo verifica-se o contrário. O último passo da área é sujeitar a *wafer* a um caudal contínuo de um químico que provoca reações químicas no *photoresist* e remove as áreas não pretendidas (menos robustas).

Antes de saírem da área, os lotes passam por uma inspeção (*InspFuse*) onde são verificadas as características visuais como a abertura das vias e o alinhamento. Se tudo dentro das especificações, o lote desloca-se novamente para a área de *Dry* para fazer o *CureFuse* que, tal como o nome indica, é a cura da camada de DL1.

Os lotes voltam à área de Metrologia para ser feito o controlo em volta da camada depositada. Esse controlo passa por vários testes como verificação visual de delaminações (*InspCureFuse*), medição da espessura (*DL1Measure*), medição da deslocação da unidade relativamente à matriz teórica (*DL1DieShift*) e medição do empeno (*WarpDL1*).

O processo que se segue é denominado *DescumFuse*, feito da área de *Dry*, que se caracteriza por ser um processo mecânico com principal objetivo de remover resíduos de DL1 da via. Deste processo resultam resíduos soltos pela superfície da *wafer* e, nesse sentido, surge a lavagem da parte ativa das *wafers* com recurso a água ultra-pura (*Di-water*) sob pressão (*CleanFuse*).

Posteriormente, as *wafers* são inspecionadas a 100% com o objetivo de controlar as aberturas nas vias de alumínio do chip de silício e a quantidade de partículas e contaminações (AOI1DL1). Nesta fase, o chip tem o aspeto da Figura 3.5, sendo a região verde o dielétrico e a abertura a chamada via.



Figura 3.5: Esquema da unidade com a camada de DL1

É na área de *Dry* que o próximo processo tem lugar. Este processo denomina-se por *Sputter* e caracteriza-se pela deposição de uma camada fina de Titânio e Cobre, chamada *Seedlayer*, na superfície da *wafer* (Figura 3.6), servindo para auxiliar o crescimento das estruturas de cobre. Os lotes regressam à Metrologia para controlar o empeno (*WarpSputter*).



Figura 3.6: Esquema da unidade com as camadas de DL1 e *Seedlayer*

A fase que se segue é criar as estruturas de cobre, para isso, os lotes voltam à área de Litografia para fazer o chamado *LithoTrace*. A diferença entre este e o *LitoFuse* é o *photoresist* utilizado, que é agora negativo, e o padrão pretendido. A Figura 3.7 representa o aspeto da unidade no fim do processo.



Figura 3.7: Esquema da unidade com as camadas de DL1, *Seedlayer* e *photoresist*

A próxima área visitada é a área de *Wet* onde se faz o chamado *Plating* que consiste no preenchimento das linhas, anteriormente desenhadas pela Litografia, com cobre através do processo de eletrodeposição química. Neste equipamento, cada *wafer* passa por várias câmaras, onde fará uma pré lavagem, a deposição propriamente dita e uma lavagem. De seguida, faz-se o *WetEtch* que se divide em três módulos distintos: remoção completa do *photoresist*, remoção do cobre da *Seedlayer* em excesso e remoção do Titânio da mesma. A Figura 3.8 esquematiza a unidade nesta fase do processo.



Figura 3.8: Esquema da unidade com as camadas de DL1, *Seedlayer* e Cobre

Ainda em *Wet*, é feita uma inspeção (*InspWetEtch*), por amostragem, para verificar as características visuais do processo de *Plating* e *WetEtch*. De seguida, os lotes passam para a Metrologia para fazer, novamente, o controlo de empeno (*WarpWetEtch*).

Como o objetivo, nesta fase, é colocar uma nova camada de dielétrico, é necessário fazer-se *AsherPlat* que representa a limpeza da superfície do cobre através de plasma. Como este processo é muito abrasivo, é necessário controlar o empeno novamente (*WarpAsherPlat*). Aproveitando

o facto dos lotes estarem na área de Metrologia, é feito um teste de resistência de contacto para controlo do processo de *Sputter*.

De seguida, os lotes são transferidos para a área de *Wet* para fazerem *CleanTop* que se baseia na limpeza e ativação da superfície das *wafers* de forma a prevenir possíveis delaminações da última camada de dielétrico e para garantir uma melhor aderência das bolas de solda numa fase futura. Segue para a Metrologia onde será medida a espessura de cobre (*CopperMeas*).

Os lotes seguem para a sua última passagem em Litografia onde será depositada a segunda e última camada de dielétrico (*LithoTop*). Todos os passos são semelhantes aos de *LithoFuse*. O aspeto final do chip está esquematizado na Figura 3.9.



Figura 3.9: Esquema da unidade com as camadas de DL1, *Seedlayer*, Cobre e DL2

À semelhança do processo anterior, no fim da Litografia, os lotes vão para a área de *Dry* e fazem uma cura (*CureTop*). No fim, volta à Metrologia para fazer um conjunto de medições como a espessura do dielétrico e alinhamento do processo.

Os lotes passam por *CleanRIF*, processo idêntico ao *CleanFuse*. Posteriormente, fazem AOI1DL2 que se baseia na inspeção a 100% a fim de serem encontrados possíveis defeitos em todas as estruturas e em toda a superfície da *wafer*.

Como nota final, existe uma estrutura de cobre denominada *Under Bump Metallization* (UBM) que alguns produtos possuem (Figura 3.10). Para a criação desta estrutura adota-se um processo semelhante ao de *LithoTrace* e, no fim, uma inspeção denominada AOI1UBM.



Figura 3.10: Esquema da unidade com as camadas de DL1, *Seedlayer*, Cobre, DL2 e UBM

LBS

Esta última área é responsável pela marcação das unidades, soldar as bolas de solda e posterior singularização das unidades. Antes de começar o processo propriamente dito, o primeiro passo foca-se em reforçar a cura do dielétrico (*PreReflow*) em fornos apropriados.

Os lotes são transportados para o equipamento onde farão o processo de SBA (*Solder Ball Attach*) que está subdividido em vários passos: (1) através de um *stencil* é colocado fluxo, que irá funcionar como elo de ligação, nos *pads*, sendo estes as aberturas que ficaram na camada de DL2 (*Printing*); (2) usando outro *stencil*, as bolas de solda são espalhadas em cima deste e caem nas zonas pretendidas (*Mounting*); (3) é feita uma inspeção às *wafers* e, se não for ultrapassado o limite de unidades de falha, reparação automática (*Repair/Inspection*); (4) se houver excesso

de reparações, essas *wafers* ficam retidas numa zona chamada *Middle Unloader*; (5) acontece o *Reflow*, isto é, a soldadura das bolas de solda. Na Figura 3.11 pode ser visto o aspeto final do chip.




Figura 3.11: Esquema da unidade com as camadas de DL1, *Seedlayer*, Cobre e DL2 e bola de solda

Com o objetivo de remover o excesso de fluxo, as *wafers* são lavadas (*FluxClean*). Posteriormente, a todos os chips das *wafers* é feita uma marcação com recurso a raios laser para rastreio do lado do cliente (Figura 3.12).




Figura 3.12: Exemplo de marcações

Finalmente, acontece a singularização das unidades da wafer (*Dicer*), que, de seguida, serão inspecionadas e colocadas em *trays* (Figura 3.13) (*Handler*). Ao conjunto destes passos dá-se o nome de *Singulation*.



Figura 3.13: *Tray*

Dos últimos passos em LBS, faz parte a *Gate* onde os lotes são inspecionados recorrendo a dois tipos de inspeção. Numa primeira inspeção são verificados numa amostra de todos os lotes danos visuais. A seguinte inspeção foca-se em verificar se todos os compartimentos da *tray* têm unidade. Estando tudo em conformidade dá-se o *Packing* e o *PackCheck* onde as *trays* são colocadas em embalagens, cintados e etiquetados. Tudo isto é no fim verificado.

Importa referir que cada produto tem um fluxo produtivo característico e, portanto, o processo descrito anteriormente é apenas uma generalização. Assim sendo, a Tabela 3.1 resume para os diferentes clientes os seus vários produtos e camadas respetivas.

Tabela 3.1: Tabela Resumo dos Produtos

Cientes	Produto	WLCSP	WLFO	Camadas
QND	QND _A		X	DL1 + Cu + DL2
	QND _W		X	DL1 + Cu + DL2 + UBM
	QND _T		X	DL1 + Cu + DL2 + UBM
	QND _D		X	DL1 + Cu + DL2 + UBM
NSV	NSV _S		X	DL1 + Cu + DL2
	NSV _D		X	DL1 + Cu + DL2 + UBM
ICN	ICN ₂		X	DL1 + Cu + DL2
	ICN _X		X	DL1 + Cu + DL2
	ICN _A		X	DL1 + Cu + DL2
	ICN ₅	X		DL1 + Cu + DL2 + Cu + DL3 + UBM
	ICN ₇	X		DL1 + Cu + DL2 + Cu + DL3 + UBM
	ICN ₈	X		DL1 + Cu + DL2 + Cu + DL3 + UBM
	ITG _C	X		DL1 + Cu + DL2
ITG	ITG _A		X	DL1 + Cu + DL2
	QRV ₂		X	DL1 + Cu + DL2 + UBM
QRV	QRV ₈		X	DL1 + Cu + DL2 + UBM
	QRV ₄		X	DL1 + Cu + DL2 + UBM

3.2 Tipos de Defeitos

Nesta indústria e com este tipo de material uma variedade de defeitos pode ocorrer. Neste sentido, foi desenvolvido um catálogo de falhas relativo aos produtos referidos neste documento e tendo por base o catálogo de falhas atual da ATEP, que se encontra no Anexo B.

Os defeitos com maior relevância neste projeto são Contaminações, Partículas Debaixo do Cobre, Defeitos na Estrutura do Cobre e Partículas, já que são estes que têm uma maior incidência nos produtos. No entanto, como é possível perceber pelo documento, nem sempre estes defeitos se rejeitam já que o critério de rejeição depende da dimensão e da localização do defeito.

3.3 Caracterização do Problema

O processo de inspeção e classificação de defeitos segue a lógica previamente descrita no Capítulo 2 (Inspeção Automática e Revisão Manual). Os lotes passam por diversas inspeções na área de Metrologia, sendo que existem inspeções específicas, como explicado anteriormente, onde é feita a leitura a 100% a todos os chips produtivos da *wafer* procurando defeitos ou falhas

discriminadas no catálogo de falhas ou qualquer tipo de anomalia. A essas inspeções dá-se o nome de AOI e a sua nomenclatura segue a identificação da última camada depositada. Na Figura 3.14 observam-se todas as inspeções possíveis de fazer em AOI consoante a necessidade do produto.




Figura 3.14: Inspeções AOI por camada

Importa referir que um dos problemas específicos deste processo de AOI é o facto de atualmente o equipamento devolver, por defeito, uma quantidade excessiva de alarmes que não apresentem qualquer não conformidade com a imagem de referência.

Após o processo de inspeção de cada *wafer*, os resultados (qualquer imagem onde o equipamento detetou não conformidades) são transferidos para pastas partilhadas de um servidor organizadas por equipamento, produto e receita (parâmetros de inspeção e a definição dos limites máximos dos mesmos, face à imagem de referência). Depois deste passo, os resultados são revisitos por operadores certificados. Nesta revisão, os operadores analisam as imagens e reclassificam as imagens como "Sem Falha" ou "Falha" dentro dos variados defeitos. À disposição dos operadores estão duas imagens por alarme, *BrightField* (Figura 3.15a) ou *DarkField* (Figura 3.15b), por forma a auxiliar a decisão.




Figura 3.15: Exemplo de uma não conformidade detetada e os dois tipos de imagem

O tipo de metodologia descrito possui problemas já que a probabilidade de erro humano é demasiado elevada, por diversos fatores tais como a falta de experiência, cansaço, falta de atenção, proximidade ao final de turno, etc. Estes problemas podem ter consequências mais ou menos graves. No entanto, dentro do mais grave, existe, por exemplo, a hipótese de uma reclassificação incorreta poder impedir que processos defeituosos em linha sejam detetados e corrigidos ou até mesmo a reclassificação como "Sem Defeito" fazendo com que chips defeituosos possam chegar ao cliente final.

Para de alguma forma ser avaliado o desempenho dos operadores da área e analisar a probabilidade de ocorrência de problemas como os descritos, é realizado um estudo denominado *Attribute Appraiser Study* (AAS). Neste estudo três pessoas de equipas diferentes classificam três vezes 50 alarmes previamente selecionados e misturados com alarmes de outros lotes.

Importa referir que desta análise fazem parte dois conceitos principais: a repetibilidade, quando o mesmo defeito é reclassificado de igual forma pelo mesmo operador, e a capacidade de reprodução, em que os diferentes operadores têm critérios de reclassificação idênticos. O estudo divide-se em duas análises: a *performance* da classificação e a *performance* da aceitação/rejeição.

Na Tabela 3.2 é possível observar os resultados da primeira análise. A capacidade dos operadores de reclassificar corretamente os defeitos é, em média, 86.67% e, sendo a menor taxa 84%, a taxa de erro máxima apresenta um valor de 16%. A probabilidade do mesmo operador classificar da mesma maneira nas várias tentativas é, em média, 96.67%. Finalmente, a taxa média que representa a conformidade de classificações entre equipas encontra-se nos 82.33%. Pelos critérios da ATEP, estes valores são aceitáveis mas não ideais. Adicionalmente, é possível observar que os operadores 2 e 3 são os que apresentam resultados menos positivos.

Tabela 3.2: Resultados da avaliação da performance de classificação

	Performance	Repetição	Reprodução
Operador 1	90%	100%	85%
Operador 2	86%	94%	83%
Operador 3	84%	96%	79%

Os resultados da segunda análise são apresentados na Tabela 3.3. Em média, a taxa de correta aceitação/rejeição é de 90%, a taxa de repetição da mesma categoria é 97.33% e, entre equipas, a capacidade de reproduzir a mesma classificação segue o valor de 83.33%. De uma forma geral, estes valores são melhores que os anteriores, no entanto, tal como era possível concluir anteriormente existe elevada variabilidade entre equipas.

Com o objetivo de reduzir este tipo de variabilidade e de erros que surgem, foi desenvolvida dentro da empresa uma ferramenta de classificação automática, o *Automatic Defect Classification* (ADC).

A ferramenta tem por base quatro objetivos principais: reduzir a quantidade excessiva de alarmes falsos positivos que os operadores têm de reclassificar de maneira a ter estes últimos focados nas imagens que sejam realmente falhas; identificar defeitos repetitivos (erros que se

Tabela 3.3: Resultados da avaliação da performance da aceitação/rejeição

	Performance	Repetição	Reprodução
Operador 1	94%	100%	88%
Operador 2	90%	96%	85%
Operador 3	86%	96%	77%

repetem da mesma posição em várias *wafers* do mesmo lote); melhorar a experiência diária dos operadores; e permitir a diminuição de recursos necessários em área, permitindo a alocação destes a outras áreas.

Esta ferramenta encontra-se atualmente já em produção para alguns produtos como QND_A, QND_T, QND_D, ICN₈, ICN₅ e apenas para dois passos AOI1DL2 e AOI1UBM.

3.4 Modelos de ADC

A ferramenta ADC desenvolvida acede às imagens processadas nos equipamentos de AOI e submete-as a modelos fundamentados no *Haar Cascades* que irão processar e reclassificar os alarmes. Posteriormente, consoante os processos de controlo e modo de risco (Tabela 3.4) será filtrada uma quantidade de alarmes para o operador rever. A transição entre estes modos de risco é feita pela análise da *performance* atual da ferramenta naquele modo específico.

Tabela 3.4: Modos de Risco do ADC

	(Valores Alarmes)	Modos de Risco do ADC			
		ADC 0	ADC 50	ADC 100	ADC MAX
Classificação Estabelecida pelo ADC	Bom	Revisão Manual Completa	Apenas 50% dos alarmes revistos manualmente	Apenas 100 alarmes são revistos manualmente	Sem Revisão Manual
	Falha		Revisão Manual Completa	Revisão Manual Completa	Sem Revisão Manual
	Não Reclassificado				Revisão Manual Completa

Sendo que a *performance* do ADC tem como referência as classificações do operador, o resultado é disponibilizado sob a forma de uma matriz de confusão apresentada na Tabela 3.5. Re-alçando que a ocorrência positiva é existir falha, um Positivo Verdadeiro (TP) representa os casos em que o ADC e o operador concordam com a existência e classificação da falha. Já o Positivo Verdadeiro Relativo (TP_r) retrata os casos em que ambos rejeitaram como falha apesar de terem dado classificações diferentes. As restantes classificações seguem a mesma lógica. De notar que os Falsos Negativos (FN), representativos de unidades defeituosas que não são rejeitadas pela ferramenta, são os mais críticos já que em modos de risco mais elevados os alarmes considerados sem defeito não são reavaliados.

Com os valores da matriz anterior é possível chegar aos KPI que seguem na Tabela 3.6. Estes valores irão permitir a análise da *performance* dos modelos. De notar que os critérios de avaliação

Tabela 3.5: Matriz de Confusão ADC

Avaliação Cruzada		Operador (REF)	
		Falha	Bom
ADC	Falha	TP / TPr	FP
	Bom	FN	TN

apresentados são referências internas, sendo que alguns clientes exigem outros critérios. O KPI mais crítico de todos é o *Underkill* seguindo a mesma lógica da criticidade dos FN e visando a minimização de unidades com defeito não rejeitadas e risco para cliente. Neste seguimento, o segundo KPI mais crítico é o *Recall(U)* que analisa a quantidade de unidades que deviam ser rejeitadas. O KPI de criticidade elevada que se segue é a Eficácia, já que afere a *performance* da ferramenta e o quão fiáveis são os resultados.

Tabela 3.6: KPIs do ADC

KPIs do ADC						
	KPI	Fórmula	Critérios de Aceitação			Significado
			Média	Desvio Padrão		
Análise por Alarme	Eficácia	$\frac{\sum TP + TPr + TN}{\sum \text{Todos os Alarmes}}$	▲ 80%	±	▼ 10%	Percentagem de classificações que o modelo acertou.
	Eficiência	$\frac{\sum \text{Todos os Alarmes} + NR}{\sum \text{Todos os Alarmes}}$	▲ 95%	±	▼ 5%	Percentagem de classificações que o modelo foi capaz de fazer.
	Discordância	$\frac{\sum TPr + FP + FN}{\sum \text{Todos os Alarmes}}$	▼ 20%	±	▼ 10%	Percentagem de classificações que o modelo não está em concordância com o operador (mesmo que os dois rejeitem).
	Taxa de FP	$\frac{\sum FP}{\sum \text{Todos os Alarmes}}$	▼ 10%	±	▼ 5%	Percentagem de classificações que o modelo rejeita e o operador não.
	Taxa de FN	$\frac{\sum FN}{\sum \text{Todos os Alarmes}}$	▼ 5%	±	▼ 2.5%	Percentagem de classificações que o modelo não rejeita e o operador sim.
	Recall	$\frac{\sum TP + TPr}{\sum TP + TPr + FN}$	▲ 30%	±	▼ 15%	Percentagem de classificações que o modelo rejeitou o que devia ter rejeitado.
Análise por Unidade	Underkill (U)	$\frac{\sum \text{Unidades UK(FN)}}{\sum \text{Unidades Insp}}$	▼ 0.5%	±	▼ 0.2%	Percentagem de unidades que o modelo não rejeitou e o operador sim.
	Overkill(U)	$\frac{\sum \text{Unidades OK(FP)}}{\sum \text{Unidades Insp}}$	▼ 1%	±	▼ 0.5%	Percentagem de unidades que o modelo rejeitou e o operador não.
	Recall (U)	$\frac{\sum \text{Unidades}(TP + TPr)}{\sum \text{Unidades}(TP + TPr + FN)}$	▲ 60%	±	▼ 40%	Percentagem de unidades que o modelo rejeitou o que devia ter rejeitado.

O ADC apresenta riscos para a ATEP e, por isso, ainda não lhe é transmitida toda a confiança por ser uma ferramenta que precisa de tempo para o seu treino e, assim, tornar-se mais eficaz ao longo do tempo. Neste sentido, foram criados os quatro modo de riscos já apresentados e a avaliação constante da *performance* para ser possível uma ação rápida. Para além disso, com o foco na mitigação do risco, foram desenvolvidos quatro níveis diferentes de controlo que vão alterando as quantidades de lotes para cada modo de risco e os respetivos KPI (Tabela 3.7).

Cada um dos níveis de uso tem um risco associado sendo que à medida que se evoluir na utilização destes níveis o risco aumenta e, por isso, os critérios se tornam também mais restritos.

Tabela 3.7: Controlo da Mitigação do Risco

	(Por Wafer)	Critérios de Aceitação			
		Nível de Uso 1	Nível de Uso 2	Nível de Uso 3	Nível de Uso 4
Controlo Performance	Eficácia	Λ 80% ± V 10%	Λ 85% ± V 10%	Λ 90% ± V 10%	Λ 95% ± V 5%
	Recall	Λ 30% ± V 15%	Λ 50% ± V 15%	Λ 70% ± V 15%	Λ 80% ± V 5%
	Taxa de FP	Λ 10% ± V 5%	Λ 5% ± V 5%	Λ 5% ± V 3%	Λ 3% ± V 1.5%
	Taxa de FN	Λ 5% ± V 2.5%	Λ 5% ± V 2.5%	Λ 2% ± V 2%	Λ 2% ± V 1%
	Overkill(U)	Λ 1% ± V 0.5%	Λ 0.7% ± V 0.5%	Λ 0.7% ± V 0.3%	Λ 0.4% ± V 0.2%
	Underkill (U)	Λ 0.5% ± V 0.2%	Λ 0.5% ± V 0.2%	Λ 0.3% ± V 0.1%	Λ 0.1% ± V 0.1%
Controlo Modos de Risco Acessíveis	ADC 50	17/42	21/42	21/42	21/42
	ADC 100	2/42	4/42	6/42	15/42
	ADC MAX	0	0	4/42	4/42
Controlo Nível de Risco Lote	Yield Inicial	Λ 90%	Λ 90%	Λ 70%	Λ 50%
	Yield ADC	Λ 90%	Λ 90%	Λ 85%	Λ 80%
	Total Alarmes	V 500	V 500	V 1000	V 1000
	Falha_NR	V 20%	V 40%	V 50%	V 80%

Na verdade, é possível afirmar que existem cinco tipos de controlo, já que existe uma fase inicial em que a ferramenta apenas funciona com ADC0, representativa do nível mínimo de risco. Por uma questão prática será denominado como Nível de Uso 0. Para que se passe ao nível seguinte é necessário que, para 42 lotes, os seus valores se encontrem dentro dos critérios. Para os restantes níveis de uso é obrigatório ao operador reclassificar os alarmes de outros 42 lotes utilizando o ADC com os modos de risco definidos. Importa acrescentar que os modos de risco estão disponíveis consoante aprovação do cliente. Sempre que os valores saírem dos critérios definidos, retrocede-se no nível de uso e recomeça a avaliação para outros 42 lotes.

Como nota final, para que cada lote possa ser utilizado pela ferramenta tem de cumprir com todos os requisitos das últimas quatro linhas da Tabela 3.7, sendo que o *Yield* Inicial representa a percentagem de chips não defeituosos proveniente do processo de AOI e a Falha NR são os alarmes que a ferramenta não consegue reclassificar.

3.4.1 Criação de Modelos

Para a criação dos modelos de um produto numa fase do seu processo é necessária a criação de repositórios representativos de cinco diferentes tipos de classificação: os três defeitos com maior probabilidade de ocorrência (definidos a partir da Análise de Pareto de cada um dos produtos), os restantes defeitos e os que não apresentam uma falha.

A criação destes modelos segue o esquema apresentado na Figura 3.16. Na primeira fase recolhem-se as amostras relevantes para o repositório provenientes das pastas partilhadas resultantes das inspeções AOI. De seguida, essas imagens são recortadas com o mesmo tamanho e com

foco no defeito e de maneira a que este fique posicionado no centro. Quando os cinco repositórios estiverem prontos, estes são submetidos e o IT trata da sua conversão para um modelo de *Haar Cascades*.




Figura 3.16: Modos de Risco do ADC

Os passos seguintes baseiam-se em iterações onde as variáveis são os repositórios e certos parâmetros que se tem a definir. Em cada uma destas iterações, para um conjunto de repositórios e parâmetros, a ferramenta irá fazer a reclassificação para seis lotes, que por conveniência e para uma análise comparativa eficiente deverão ser os mesmos, e apresentação dos KPI. Finalmente, quando os valores pretendidos forem atingidos é submetido um pedido para passar aquele modelo a produtivo.

Os parâmetros referidos são igualmente utilizados nos modelos criados por Viola and Jones (2001). São eles o número mínimo de vizinhos que o algoritmo deverá encontrar para considerar um defeito; quanto maior este valor, menos deteções mas maior qualidade. O mínimo tamanho que indica a menor dimensão possível que o defeito poderá ter para ser detetado. O terceiro é o fator de escala que indica o quão a imagem a ser inspecionada é diminuída.

3.5 FMEA

A implementação do ADC na linha de produção traz consigo riscos associados e, neste sentido, é fundamental que exista uma avaliação de risco. Assim, quando o ADC foi implementado pela primeira vez na empresa foi desenvolvida uma revisão do FMEA do processo de AOI que resultou na adição de um potencial modo de falha como se pode observar no Anexo D.

De notar que, atualmente, a ATEP não usa a ferramenta FMEA como a AIAG and VDA (2019) sugerem, mas esta transição inclui-se nos planos da empresa. Neste sentido, desenvolveu-se um FMEA exclusivamente focado na ferramenta para cada umas das metodologias para que, numa fase posterior, seja possível a comparação entre ambas. Assim, recorrendo às tabelas de S, O e D

apresentadas no Capítulo 2, foi feita uma análise do risco mais detalhada tendo sido dividida pelos diferentes modos de risco do ADC. Este primeiro FMEA encontra-se no Anexo E.

Pela sua análise é possível concluir que, como seria de esperar, à medida que se avança pelos modos de risco do ADC, o nível de risco aumenta substancialmente exigindo um plano de ação.

Como ações recomendadas surgem a implementação de um controlo à reclassificação do operador visto este, sendo a referência, poder influenciar negativa ou positivamente a performance da ferramenta, existindo a possibilidade do desbloqueio de modos de risco mais elevados com a confiança enviesada. Adicionalmente, para algumas limitações do atual algoritmo em uso pela ferramenta, que podem resultar em unidades com falha chegarem ao cliente, é sugerida a substituição deste para um algoritmo mais robusto, o *deep learning*.

Para além destas, nenhuma ação de recomendação adicional foi sugerida uma vez que a efetividade dos controlos de mitigação de risco é suficiente para a prevenir ou detetar o modo de falha. Isto porque, independentemente do Nível de Uso, o ADC0 tem de ser utilizado e sendo que para este modo de risco todos os alarmes são revistos pelo operador que poderá reportar qualquer tipo de anomalia que identifique. Paralelamente, os KPI dos modelos estão em constante avaliação.

3.6 Processo de Gestão de Alterações da ATEP, SA

Dentro da ATEP, tudo o que envolva alterações é previamente submetido a um processo denominado Processo de Gestão de Alterações. O objetivo deste processo é gerir as alterações passíveis de serem implementadas nos processos e, desta maneira, garantir a estabilidade do processo e a produção, a qualidade e a fiabilidade do produto.

Este processo é iniciado sempre que existe algum evento que despolete a necessidade de uma alteração/mudança seja a deteção de uma falha ou de uma oportunidade de melhoria, etc. Como o produto não é propriedade da ATEP, mas sim dos seus clientes, existem dois tipos de alterações: pequenas alterações que são revistas internamente, aprovadas e prosseguem imediatamente para implementação e grandes alterações que são revistas, aprovadas internamente e não são enviadas para implementação até que o cliente as reveja e aprove.

Existe um conselho dentro da ATEP constituído por um presidente e um membro representativo de cada departamento da fábrica: Gestão da Qualidade, Investigação e Desenvolvimento, Engenharia, Manufatura, Planeamento Logístico. Este conselho junta-se para reuniões semanais regulares para discutir e analisar as propostas de alterações, e quando justificada uma reunião não regular é conduzida para avaliar um pedido de alteração e discutir possíveis alterações.

Para alguns casos, antes da alteração ser efetivamente feita no processo ou produto, existe uma fase denominada Experiência em Produção (EIP). Durante este período será avaliada a nova *performance* do processo e caso se mostre satisfatória, dá-se alteração definitiva. Na Figura 3.17 é apresentado o fluxograma deste processo. Em qualquer um dos casos, EIP ou Alteração do Processo (PC), a pessoa que solicita a alteração submete a proposta incluindo a razão, a descrição da alteração (Antes/Depois), a avaliação do fluxo, os parâmetros críticos, a análise de risco, os resultados, os documentos afetados pela mudança e a classificação da alteração.




Figura 3.17: Fluxograma do Processo de Gestão de Alterações - EIP

Capítulo 4

Aplicação da Metodologia Proposta

Neste capítulo são analisados os modelos que estão atualmente em produção e é avaliada a respetiva *performance*, é abordado o processo iterativo do desenvolvimento dos novos modelos e a implementação dos mesmos.

4.1 Análise dos Modelos Atuais

A ferramenta de classificação automática encontra-se em modo produtivo na empresa desde 2019 e para os produtos já referidos: QND_A , QND_T , QND_D , ICN_8 e ICN_5 . No entanto, nem todas as fases de inspeção em AOI estão asseguradas pela ferramenta. Para os produtos QND, o AOI1DL2 está coberto para todos os referidos e AOI1UBM para aqueles que têm a estrutura (QND_T e QND_D). Já o ICN_8 e ICN_5 são apenas suportados para AOI1DL2 apesar de terem mais camadas e inclusive UBM.

Na Figura 4.1 é possível observar a *performance* do ADC durante o ano de 2020. De uma maneira geral, é justificado afirmar que a ferramenta apresentou uma *performance* aceitável, tendo a sua eficácia aproximado-se do valor definido como limite mínimo do critério de aceitação, 80%, e o *underkill* apresentado-se maioritariamente abaixo do seu valor crítico de 0.5%. Estes dois indicadores são os mais críticos e, dessa maneira, o primeiro foco ao analisar o gráfico incidiu sobre estes. É possível afirmar que, apesar de cumprirem os requisitos, estes valores não são totalmente satisfatórios já que em algumas semanas se mostraram abaixo do esperado.

No entanto, ao analisar outros indicadores como a taxa de FP, verificou-se que a sua tendência foi violar o critério definido. Contudo, é usual prejudicar este indicador por forma a obter os valores de *underkill* desejados. Como este número elevado de FP ainda assim não afeta negativamente o *overkill*, pode-se afirmar esta violação não possui grande impacto. Outro indicador que chama à atenção é o *recall* pela sua variabilidade. No entanto, o indicador cumpre sempre o critério de aceitação, tanto na média como no desvio padrão que é, aproximadamente, 7%.

Importa referir que, para os FP, é necessário ter atenção em relação à estratégia de os aumentar visando um melhor *underkill* pois poderá acontecer que o objetivo do ADC de ter operadores mais focados no que é efetivamente falha, e libertá-los de alarmes FP que vêm em excesso de AOI, se




Figura 4.1: KPI referentes ao ano 2020

difunda. Em relação ao *recall* também dever-se-á manter um controlo apertado já que a ferramenta deveria ser estável e a variação, apesar de estar dentro dos limites, é elevada.

Passando a 2021, foi permitida uma análise mais completa, já que foi possível o acesso a dados adicionais como, por exemplo, as imagens dos diferentes lotes. À presente data o modo de risco ADC50 está disponível para todos os produtos AOI1DL2 e o ADC100 apenas para os produtos QND em AOI1DL2. Já para o AOI1UBM nenhum produto tem disponível outro modo de risco que não o ADC0.

Pela análise do gráfico da Figura 4.2, conclui-se que este ano o ADC100 ainda não foi utilizado, significando que a ferramenta não tem tido *performance* suficiente para os produtos QND. Outro indicador de que a *performance* não tem sido a esperada é o facto da maioria da utilização da ferramenta ter sido feita em ADC0.

Na Figura 4.3 estão representados os resultados da *performance* do ADC até à 16ª semana de 2021. As primeiras semanas foram críticas já que se verificou um aumento da taxa de FP, resultando na descida acentuada da eficácia. Esta situação foi analisada e as conclusões vão de encontro à limitação do *Haar Cascades* em lidar com dimensões. Neste caso, o defeito apontado são as Contaminações que a ferramenta rejeitou em excesso. Ao analisar as imagens é possível visualizar que o defeito está presente, no entanto, não tem dimensões suficientes para ser rejeitado. Outro evento que contribui para esta situação é a discordância entre a ferramenta e o operador,




Figura 4.2: Modos de Risco 2021

existindo alarmes considerados FP que deviam ser TP.




Figura 4.3: KPI referentes ao ano 2021

Os restantes KPI mantêm-se estáveis e dentro dos limites aceitáveis, à exceção dos FP que, retirando casos como anteriormente referidos, apresentam-se normalmente acima do critério e poderá ser justificado pela mesma razão do ano anterior, obter os valores esperados do *underkill*. A eficácia, de forma geral, não é satisfatória já que se encontra na sua maioria abaixo de 80%.

Sendo o produto QND_A aquele que tem maior produção dentro da ATEP e, por isso, mais de 50% da utilização da ferramenta, a próxima análise será focada no modelo para este produto.

Considerou-se apenas o período entre a 6ª e 10ª semana uma vez que é o período mais consistente e as instabilidades já foram analisadas.

Na Tabela 4.1 a coluna do Resultado indica se o valor falha os critérios de aceitação ou não e, para os casos em amarelo, se apenas um dos dois valores falhou. Retira-se da análise da tabela que, embora tanto o *underkill* como o *overkill* estejam bastante satisfatórios e a eficácia muito próximo do objetivo, as taxas de FP e FN afetam negativamente a *performance*.

Tabela 4.1: Resultados do QND_A durante a semana 6 e 10

	Média	Desvio Padrão	Resultado
Eficácia	76.66%	10.29%	X FAIL
Eficiência	100.00%	0.00%	✓ PASS
Discordância	29.42%	12.32%	X FAIL
Taxa de FP	15.48%	10.03%	X FAIL
Taxa de FN	7.87%	8.72%	X FAIL
Recall	47.88%	16.27%	! STD
Underkill(U)	0.01%	0.01%	✓ PASS
Overkill(U)	0.07%	0.18%	✓ PASS
Recall(U)	49.38%	17.44%	! AVG

Pela aplicação ADC é possível obter a discriminação de cada lote com todos os seus alarmes e as respetivas classificações do operador e da ferramenta de reclassificação automática. Aproveitando esta funcionalidade, exportou-se a folha do *Microsoft Excel* dos lotes mais críticos e, através de uma *Pivot Table*, foi feita uma análise dos defeitos que mais contribuíam para cada uma das taxas. Concluiu-se que as Contaminações representam, aproximadamente, 96% do total de FP destes lotes e que são os Defeitos na Estrutura de Cobre que mais influenciam os FN.

Explorando os repositórios destes defeitos retira-se que, para o repositório das Contaminações, existem algumas amostras pouco representativas do defeito, podendo justificar esta excessiva rejeição de alarmes. Na Figura 4.4 observam-se alguns exemplos: em (a) e (b) as amostras têm pouco contexto e as dimensões não são de rejeitar; em (c) e (d), apesar de existir contexto, não cumprem nenhum critério de rejeição, uma vez que não têm dimensão e nem tocam estruturas. Estes casos devem ser revistos e substituídos por amostras mais relevantes ao modelo.




Figura 4.4: Exemplos de imagens FP

Desta análise também se observou que dentro do repositório de Defeitos na Estrutura de Cobre não se incluem os casos de falta ou excesso de cobre, que se encontram no repositório de Outros Defeitos. Esta situação torna mais suscetível a existência de enganos a reclassificar por parte do ADC, é possível ser a causa da não detecção de alguns defeitos já que os parâmetros de cada repositório são diferentes visando lidar com as suas imagens específicas. Sendo as imagens destes defeitos muito semelhantes, os repositórios deviam ser alterados no sentido de qualquer tipo de defeito no cobre ser incluído no repositório Defeitos na Estrutura de Cobre.

A situação que mais se destaca em todos os resultados é o facto da eficiência da ferramenta se encontrar sempre nos 100%. O objetivo deste indicador é indicar a percentagem de alarmes que o modelo não consegue reclassificar por ter uma baixa confiança. No entanto, nas fases experimentais da ferramenta ao implementar um cálculo para o nível de confiança os resultados não eram suficientemente robustos e, por isso, apesar do indicador estar presente, não é feito qualquer cálculo. Isto significa que, atualmente, os modelos reclassificam todos os alarmes podendo afetar a *performance*.

Na tentativa de avaliar ações por forma a reduzir os FN por serem os mais críticos detetou-se que, ao contrário do que é proposto por Viola and Jones (2001), o algoritmo em uso na ferramenta da ATEP não varre todas as imagens com a janela de detecção. Seguindo uma estratégia direcionada para a poupança de recursos, a janela de detecção é estática no centro da imagem pois em AOI a câmara já posiciona o desvio no centro. A única exceção são os casos dos alarmes definidos como *clustered* indicando a possibilidade de existir mais do que um defeito na imagem e, para estes casos, a janela é dinâmica. Em contrapartida, esta estratégia apresenta lacunas, uma vez que nem sempre, quando se trata de um único defeito, este está centrado por falha de AOI ou, por se tratar de um defeito demasiado grande, a janela sendo estática é incapaz de detetar as alterações de textura ou padrões das extremidades do defeito, fazendo com o que número de FN aumente e a *performance* da ferramenta seja limitada.

Para estes dois problemas referidos, como ponto de melhoria, poderá ser alterado o algoritmo base da ferramenta para o *deep learning*, já que em comparação com o atual apresenta mais valias como anteriormente referido no Capítulo 2. Para estes casos específicos, o cálculo automático do indicador de confiança faz parte das funcionalidades do CNN permitindo que se possam implementar regras para determinados valores e conseguir reclassificações mais robustas. Adicionalmente, este algoritmo não utiliza janelas de detecção sendo o seu treino feito com a imagem completa, sem recortes necessários, sendo que seja esperado que haja uma melhoria da *performance*.

Como dito anteriormente, os resultados provêm da comparação entre a reclassificação do operador e da ferramenta. Esta referência não é a ideal já que os operadores são influenciados por diversos fatores e, por isso, erram algumas vezes. Na tentativa de avaliar o impacto dos operadores nos resultados da *performance*, reuniu-se a reclassificação do ADC e a folha *Excel* e reclassificaram-se manualmente todos os alarmes de um lote específico. A conclusão que se retira é que a eficácia melhorou em 10% pela descida do número de FP. Não sendo lógico rever todas as decisões do operador, aconselha-se que seja feita por amostragem e reportado aos operadores para

que sejam consciencializados dos seus erros.

Da abordagem anterior foi identificada uma limitação da ferramenta. No cálculo dos KPI no *Microsoft Excel* foi detetado que estes estavam mal calculados na ferramenta por terem fórmulas erradas. Para além disso, foi identificada uma sobrevalorização da quantidade de unidades aquando do cálculo dos indicadores por unidade. Isto porque uma mesma unidade pode ter mais do que um alarme e a esses alarmes é associado um tipo de rótulo específico, o que resulta, numa mesma unidade com um alarme FP e outro FN, tanto ser incluída no cálculo do *underkill* como do *overkill* fazendo com que os cálculos sejam enviesados. Tendo isto em conta, desenvolveram-se regras para os vários casos (Tabela 4.2) e recalcularam-se os KPI depois das regras terem sido implementadas no algoritmo.

Tabela 4.2: Regras de Classificação de Unidades

Alarmes					Rejeitada?	Class. Errada?	Underkill	Overkill	Tipo de Unidade
TP	TPr	FP	TN	FN					
0	0	0	0	0	No	No	No	No	-
0	0	0	0	1	No	Yes	Yes	No	FN
0	0	0	1	0	No	No	No	No	TN
0	0	0	1	1	No	Yes	Yes	No	FN
0	0	1	0	0	Yes	Yes	No	Yes	FP
0	0	1	0	1	Yes	Yes	No	No	TPr
0	0	1	1	0	Yes	Yes	No	Yes	FP
0	0	1	1	1	Yes	Yes	No	No	TPr
0	1	0	0	0	Yes	Yes	No	No	TPr
0	1	0	0	1	Yes	Yes	No	No	TPr
0	1	0	1	0	Yes	Yes	No	No	TPr
0	1	0	1	1	Yes	Yes	No	No	TPr
0	1	1	0	0	Yes	Yes	No	No	TPr
0	1	1	0	1	Yes	Yes	No	No	TPr
0	1	1	1	0	Yes	Yes	No	No	TPr
0	1	1	1	1	Yes	Yes	No	No	TPr
1	0	0	0	0	Yes	No	No	No	TP
1	0	0	0	1	Yes	Yes	No	No	TP
1	0	0	1	0	Yes	No	No	No	TP
1	0	0	1	1	Yes	Yes	No	No	TP
1	0	1	0	0	Yes	Yes	No	No	TP
1	0	1	0	1	Yes	Yes	No	No	TP
1	0	1	1	0	Yes	Yes	No	No	TP
1	0	1	1	1	Yes	Yes	No	No	TP
1	1	0	0	0	Yes	Yes	No	No	TP
1	1	0	0	1	Yes	Yes	No	No	TP
1	1	0	1	0	Yes	Yes	No	No	TP
1	1	0	1	1	Yes	Yes	No	No	TP
1	1	1	0	0	Yes	Yes	No	No	TP
1	1	1	0	1	Yes	Yes	No	No	TP
1	1	1	1	0	Yes	Yes	No	No	TP
1	1	1	1	1	Yes	Yes	No	No	TP

A análise feita com o produto QND deve ser feita regularmente para que haja uma avaliação recorrente da necessidade de alterar repositórios, parâmetros ou até medidas de ação na linha de produção como, por exemplo, alteração das receitas ou da iluminação em AOI já que, por vezes, o tipo de imagem afeta a ferramenta. No entanto, antes de implementar qualquer medida, as imagens devem ser analisadas para garantir se o erro é do ADC, do operador ou até de ambos.

4.2 Desenvolvimento de Novos Modelos

Durante o desenvolvimento do projeto o foco passou por desenvolver modelos ADC para os produtos *automotive*. Esta decisão é justificada por ser um setor que é acompanhado pelo aumento de exigências na indústria e pela política de Zeros Defeitos mas, sendo os operadores integrantes do processo de inspeção, existe um nível de risco que não corresponde às expectativas.

A NSV é o cliente mais significativo da ATEP deste mercado e, por isso, reflete uma maior urgência na implementação destes modelos. Para o seu produto NSV_D foram desenvolvidos dois modelos: um para AOI1DL2 e outro para AOI1UBM. Importa referir que este cliente tem critérios de aceitação mais apertados para o *underkill* (0,1% de média e desvio padrão) e para o *overkill* (1% de média e 0,2% de desvio padrão).

Para este produto os três defeitos com mais incidência são as Contaminações, Partículas Debaixo do Cobre e os Defeitos na Estrutura do Cobre (incluindo o excesso e falta de cobre). Isto significa que para a criação de um modelo são criados três repositórios para cada um destes defeitos, o repositório que englobará os restantes defeitos e o repositório referente aos casos em que não há defeito na imagem ou que o defeito não tenha dimensões para rejeitar, perfazendo um total de cinco repositórios por modelo.

4.2.1 Modelo para AOI1DL2

O primeiro modelo foi desenvolvido para AOI1DL2, ou seja, até esta fase o produto tem duas camadas de dielétrico e uma de cobre. A primeira fase da criação deste modelo passou por recolher as imagens por forma a alimentar cada um dos repositórios. É importante que a quantidade de amostras seja igual, já que é recomendado que haja balanceamento das classes de classificação de maneira a que se evite um repositório ter mais influência do que outro nas reclassificações. Nesse sentido, cada repositório é constituído por 500 imagens, número definido internamente por apresentar resultados satisfatórios. Como nota final desta fase inicial, os dois tipos de imagens (*Dark e Bright Field*) de cada alarme foram adicionados sempre que possível, já que quando a imagem é capturada em AOI é associada à mesma um parâmetro que define em qual das duas imagens o desvio foi detetado e o ADC utiliza essa imagem para classificar. Assim, ao adicionar os dois tipos de imagem o modelo tem robustez para identificar defeitos em qualquer um.

De seguida, as imagens são importadas para a aplicação ADC e são recortadas com o objetivo de extrair o defeito. Os recortes devem ter todos o mesmo tamanho, como recomendado pela documentação do algoritmo, para que não exista qualquer variabilidade no treino do modelo. O defeito deve estar posicionado no centro do recorte e, ao mesmo tempo, ter o contexto à volta para que a ferramenta seja capaz de identificar a localização do mesmo. Isto porque existem casos em que, por exemplo, uma partícula com menos de 100µm pode ser rejeitada, ou não, dependendo se toca duas estruturas de cobre ou não.

Com os repositórios, o próximo passo é submetê-los na aplicação para a criação do algoritmo que será a base de funcionamento do modelo. Posteriormente, inicia-se um processo iterativo onde as variáveis são os parâmetros já referidos: fator de escala, número mínimo de vizinhos e menor dimensão. Para este primeiro modelo foram feitas mais de 200 iterações, já que a definição destes parâmetros foi feita por aproximações e tentativas sucessivas até se obterem resultados ideais. Para além disso, mostrou-se necessário rever e alterar os repositórios algumas vezes. No Anexo F é possível consultar as melhores iterações juntamente com os parâmetros utilizados.

Para as primeiras iterações não foi encontrado um balanço ideal entre os KPI. A Tabela F.1 do Anexo F ilustra um caso em que a eficácia se mostrou aceitável. No entanto, o *underkill* e

o *overkill* ficaram longe das expectativas; adicionalmente, o *recall* que indica a percentagem de rejeição de unidades que deviam ser rejeitadas também foi demasiado baixo. Já na Tabela F.2 do Anexo F foi possível obter valores mais positivos para os últimos três indicadores que, ainda assim, falharam e não justificavam uma eficácia tão abaixo do seu limite. Os pontos fracos durante estas iterações mantiveram-se constantes para os FP, Contaminações e Outros Defeitos, e para os FN, Defeitos na Estrutura do Cobre e Partículas Debaixo do Cobre. Nesse sentido, a estratégia passou por aumentar a escala para os FP e diminuir para os FN, mas sem resultados positivos.

Com o foco de melhorar este cenário definiram-se dois planos de ação que atuaram em simultâneo. O primeiro plano tratou-se de criar um novo algoritmo com novas condições de código que pudessem ter um impacto positivo nos resultados como, por exemplo, a dimensão da janela de deteção, as *features*, etc. Tendo o novo modelo de classificação, correram-se novamente as iterações e o melhor resultado obtido está representado na Tabela F.3 do Anexo F. O segundo plano de ação (Tabela F.4 do Anexo F) passou por rever os repositórios de todos os defeitos e identificar amostras que, agora com maior experiência, não sejam tão significativas, e procurar novas imagens que venham substituí-las e que ofereçam um contributo mais forte aos seus repositórios. Posteriormente, correu-se novas validações e analisou-se os resultados obtidos. Pelas tabelas F.3 e F.4 concluiu-se que com qualquer umas das abordagens os resultados são melhores comparando com os anteriores. No entanto, foi a segunda abordagem que apresentou *underkill*, *overkill* e *recall* mais satisfatórios e, por essa razão, decidiu-se seguir com a iteração dos parâmetros visando atingir os critérios de aprovação da NSV.

No fim destas iterações, o modelo que seguiu para EIP segue os parâmetros discriminados na secção da Iteração 5 do Anexo F. A Tabela 4.3 representa os resultados finais deste modelo que apresentou um melhor equilíbrio entre *underkill* e a eficácia. O *underkill*, de todas as iterações feitas até este ponto, foi o que se encontrou mais perto do objetivo definido pelo cliente e, sendo este o principal foco por ser um produto *automotive*, a escolha do modelo é justificada.

Tabela 4.3: Resultados da 5ª Iteração AOI1DL2

	Média	Desvio Padrão	Resultado
Eficácia	68.07%	5.31%	! AVG
Eficiência	100.00%	0.00%	✓ PASS
Discordância	34.83%	7.35%	! AVG
Taxa de FP	30.05%	4.00%	X FAIL
Taxa de FN	1.88%	1.89%	✓ PASS
Recall	64.79%	7.13%	✓ PASS
Underkill(U)	0.14%	0.08%	X FAIL
Overkill(U)	2.79%	0.67%	X FAIL
Recall(U)	71.22%	8.93%	✓ PASS

Em contrapartida, a taxa de FP e, por isso, o *overkill* são indicadores que se apresentavam demasiado elevados e contribuíam de forma negativa para a eficácia. Nesse sentido realizou-se

uma análise aos casos FP e concluiu-se que estes valores não eram prejudiciais uma vez que uma elevada proporção destes alarmes tinha efetivamente um defeito mas sem dimensões suficientes, ou representavam uma falha do operador (Figura 4.5). Ao substituir estes FP para TP na folha *Excel* foi possível manter o valor de *underkill* mas aumentar a eficácia para 72% e o *recall*(U) para 78%.




Figura 4.5: Exemplos de imagens FP

Para além disso, estas iterações foram realizadas para apenas seis lotes. Passar à fase de EIP tornou-se essencial por forma a obter mais dados para uma amostra estatística mais significativa e, assim, tirar conclusões mais assertivas, não esquecendo as fragilidades da ferramenta apontadas na secção anterior.

Duas semanas depois, com mais dados e com o *feedback* dos operadores, analisaram-se os resultados provenientes da linha e para além destes não serem satisfatórios como é possível observar na Tabela 4.4, os operadores apresentaram reclamações face ao tempo de processamento dos lotes.

Tabela 4.4: Resultados do modelo em produção AOI1DL2

	Média	Desvio Padrão	Resultado
Eficácia	51.21%	8.54%	! AVG
Eficiência	100.00%	0.00%	✓ PASS
Discordância	53.17%	6.09%	! AVG
Taxa de FP	46.21%	10.28%	X FAIL
Taxa de FN	1.68%	1.74%	✓ PASS
Recall	65.35%	14.55%	✓ PASS
Underkill(U)	0.05%	0.03%	✓ PASS
Overkill(U)	6.29%	4.53%	X FAIL
Recall(U)	79.86%	12.57%	✓ PASS

Apesar do *underkill* ser satisfatório para o cliente, a eficácia resultante deste modelo era demasiado negativa. A conclusão que se retirou foi que o modelo rejeitava em excesso e, depois de uma análise mais profunda às imagens que contribuíam para a taxa de FP, decidiu-se alterar novamente os repositórios. Para estes novos repositórios foi abordada uma nova estratégia que se baseou em

adicionar amostras com defeitos mais grosseiros e, na fase de recortar, o foco foi centrar o defeito na janela e passar a não considerar tanto o contexto.

O problema do processamento dos lotes ser uma tarefa demorada foi resolvido diminuindo o tamanho das imagens provenientes de AOI, o que resultou com a janela de detecção, para os casos *clustered*, por não ter tanto espaço a percorrer, poupando tempo ao servidor.

Depois da atuação nestes dois problemas, foram feitas novas validações com os parâmetros das melhores iterações anteriores. Os resultados que se mostram mais satisfatórios e realistas face à situação são os apresentados na Tabela 4.5 que utilizaram os parâmetros da Iteração 5.

Tabela 4.5: Resultados da 6ª Iteração AOI1DL2

	Média	Desvio Padrão	Resultado
Eficácia	75.52%	4.35%	! AVG
Eficiência	100.00%	0.00%	✓ PASS
Discordância	27.74%	3.65%	! AVG
Taxa de FP	20.36%	5.85%	X FAIL
Taxa de FN	4.12%	1.93%	✓ PASS
Recall	57.50%	7.04%	✓ PASS
Underkill(U)	0.08%	0.02%	✓ PASS
Overkill(U)	0.78%	0.17%	✓ PASS
Recall(U)	65.33%	10.07%	✓ PASS

O novo modelo passou novamente a EIP. No entanto, ficou a nota que apresenta limitações face a certos casos. A provocar o aumento do *underkill* existe um defeito que pelas suas elevadas dimensões se torna difícil encaixar na janela de recorte (Figura 4.6a). Foram feitos testes para incluir este defeito nos repositórios e ser possível a sua deteção mas todos eles sem sucesso. Destes testes fizeram parte incluir as imagens sem recorte, recortar as zonas de transição entre a estrutura de cobre e o fundo escuro e alterar os parâmetros de escala e mínimo tamanho.

Finalmente, na Figura 4.6b é possível observar uma das razões da taxa elevada de FP. Algumas imagens provenientes de AOI chegam à reclassificação com este tipo de sombras e levando a que a ferramenta rejeite estes alarmes como Contaminações ou Defeitos na Estrutura de Cobre.




Figura 4.6: Limitações do Modelo AOI1DL2

4.2.2 Modelo para AOI1UBM

A criação do modelo para AOI1UBM foi um processo menos demorado quando comparando com o anterior pois, tratando-se do mesmo produto, as imagens são semelhantes e já existe uma ideia formada de como a ferramenta reage às imagens utilizados para o treino do modelo e às imagens que reclassifica. Para além disso, esta camada tem menos ruído do que a de DL2 e, por isso, tem menos alarmes e defeitos.

Na fase de alimentação dos repositórios foram reaproveitadas imagens dos repositórios de AOI1DL2 uma vez que existiam dados insuficientes para atingir as 500 imagens. Esta abordagem é justificada pela semelhança entre as imagens e, sendo esta a última oportunidade de inspecionar os lotes, pela possibilidade de rejeitar falhas não detetadas em AOI1DL2. Adicionalmente, a experiência refletiu que o recorte feito com foco em centrar o defeito e desvalorizar o contexto foi a que apresentou os melhores resultados e, nesse sentido, os recortes nesta fase seguiram a mesma lógica.

As primeiras iterações seguiram com os parâmetros escolhidos para o modelo de AOI1DL2. Os primeiros resultados não se apresentaram satisfatórios, como se observa na Tabela F.5 do Anexo F. Por essa razão, não houve tentativa de correr mais iterações, mas sim de rever os lotes consoante os indicadores. Investigando os FP estes incidiam em Contaminações, Outros Defeitos e Partículas Debaixo do Cobre, seguindo esta ordem.

Para as Contaminações, as imagens que mais apareciam eram no contexto de estruturas finas de cobre e vias e também defeitos com pequenas dimensões. Para os Outros Defeitos o problema é riscos na estrutura do UBM que apenas se rejeitam se danificarem a estrutura e o ADC não apresenta robustez suficiente para analisar a profundidade do defeito. Outro caso a contribuir para este excesso de Outros Defeitos são as partículas irrelevantes que a ferramenta rejeita. Finalmente, as Partículas Debaixo do Cobre dispararam em FP por casos como retratados na Figura 4.6b. Neste sentido, os repositórios foram revistos com o objetivo de analisar que imagens poderiam estar a causar estes FP. Algumas imagens foram substituídas e optou-se por colocar amostras mais grosseiras.

Voltando a correr o algoritmo com os parâmetros da iteração anterior, é visível que uma melhoria significativa foi alcançada (Tabela F.6 do Anexo F). Apesar do equilíbrio entre os vários indicadores se mostrar adequado, não foi este o modelo escolhido para avançar para EIP visto o *recall* não ser positivo, já que indica que apenas aproximadamente 30% das unidades que deviam ser rejeitadas estão efetivamente a ser rejeitadas. Tratando-se de um produto *automotive* não é aceitável.

Várias iterações depois, o modelo que se tornou mais aceitável e que representa melhor balanço entre o *underkill* e eficácia é o que é apresentado na Tabela 4.6 com os parâmetros da Iteração 3 de AOI1UBM no Anexo F.

Neste caso, o *recall* já apresenta um valor bastante satisfatório enquanto todos os outros parâmetros estão dentro dos limites aceitáveis, à exceção da eficácia que reduziu embora fora dos

Tabela 4.6: Resultados da 3ª Iteração AOIIUBM

	Média	Desvio Padrão	Resultado
Eficácia	75.00%	7.77%	! AVG
Eficiência	100.00%	0.00%	✓ PASS
Discordância	25.40%	7.92%	! AVG
Taxa de FP	24.56%	7.54%	X FAIL
Taxa de FN	0.45%	0.78%	✓ PASS
Recall	52.26%	23.81%	! STD
Underkill(U)	0.01%	0.01%	✓ PASS
Overkill(U)	1.28%	0.52%	X FAIL
Recall(U)	69.91%	24.96%	! AVG

limites aceitáveis foi considerado aceitável pelo excesso de rejeição. De seguida, o modelo entrou em EIP para ser possível maior conjunto de dados para uma análise mais robusta.

4.3 Implementação dos Novos Modelos

Para a passagem a EIP foi necessário passar pelo processo de Gestão de Alterações previamente descrito. Como este tipo de alteração é considerada uma grande mudança foi necessária uma aprovação do cliente. O processo começou pela reunião com o cliente onde foi introduzido o conceito da ferramenta e tendo sido aprovado o desbloqueio do modo de risco ADC0, já que não acrescenta risco ao produto. O novo processo acaba por ter o mesmo fundamento pois o operador revê todos os alarmes por forma a confirmar a reclassificação do ADC.

Posteriormente, procurou-se aprovação interna pelo conselho responsável destas alterações. Para isso preparou-se um documento onde foi descrita a diferença entre o processo novo e antigo, um resumo dos resultados experimentais até ao momento que justificam a alteração e o motivo que fundamenta esta alteração. Neste caso, a razão passa pela melhoria do tempo de processo, pela redução de custos e pela melhoria da eficiência da classificação de defeitos.

Depois desta aprovação, foi dada indicação na linha de produção, através de um documento específico, para os operadores iniciarem a reclassificação automática para o produto NSV_D. Esta EIP terá a duração de três meses.

Finalmente, o FMEA com a nova abordagem foi desenvolvido (Anexo G) seguindo a norma da AIAG and VDA (2019) para a utilização das tabelas de S, O e D. Para este documento foram mantidos os modos de falhas, causas, controlos de deteção e ações recomendadas. Da análise deste FMEA é possível concluir que não existe nenhum modo de falha com Prioridade de Ação H, significando que nenhum dos modos de falha necessita obrigatoriamente de uma ação. No entanto, sendo o FMEA uma ferramenta de análise de risco e melhoria contínua, foram identificadas ações e melhorias (já referidas) para reduzir o risco associado ao processo ADC.

Capítulo 5

Análise de Resultados

Neste capítulo será descrita a análise dos resultados finais dos modelos que à data se encontravam em fase de EIP na linha de produção da ATEP. No fim do capítulo é feita uma comparação entre as duas metodologias de FMEA.

Para o primeiro modelo na Tabela 5.1 estão representados os resultados das classificações dos lotes que passaram pelo processo de AOI1DL2 durante o mês que o modelo esteve em EIP. Estes valores são satisfatórios tendo em conta os pontos fracos da ferramenta e que a estratégia seguida passa por sacrificar a eficácia e *overkill*, no sentido de ter um nível de risco baixo para a NSV (menor *underkill* possível).

Tabela 5.1: Resultados do modelo final em produção AOI1DL2

Lotes	1	2	3	4	5	6	7	8	9	10	Média	Desvio Padrão	Resultado
Total Alarmes	383	6086	8522	622	3648	2867	1852	157	277	2965	--	--	--
Eficácia	85.64%	82.48%	98.51%	79.10%	86.65%	86.12%	90.06%	85.99%	92.42%	83.88	87.09%	5.17%	✓ PASS
Eficiência	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%	✓ PASS
Discordância	14.62%	17.68%	1.49%	21.54%	15.24%	13.88%	9.99%	17.83%	10.47%	16.32%	13.91%	5.27%	✓ PASS
Taxa de FP	14.36%	17.35%	1.49%	20.90%	12.12%	13.81%	9.77%	13.38%	6.86%	15.85%	12.59%	5.21%	X FAIL
Taxa de FN	0.00%	0.16%	0.00%	0.00%	1.23%	0.07%	0.16%	0.64%	0.72%	0.27%	0.33%	0.39%	✓ PASS
Recall	100.00%	50.00%	100.00%	100.00%	60.53%	33.33%	25.00%	85.71%	80.00%	46.67%	68.12%	27.23%	! STD
Underkill(U)	0.00%	0.08%	0.00%	0.00%	0.11%	0.02%	0.04%	0.00%	0.05%	0.05%	0.04%	0.04%	✓ PASS
Overkill(U)	4.60%	6.17%	0.66%	3.16%	2.57%	5.11%	1.90%	1.75%	0.74%	2.64%	2.93%	1.75%	X FAIL
Recall(U)	100.00%	47.37%	100.00%	100.00%	66.67%	66.67%	25.00%	100.00%	80.00%	53.33%	73.90%	25.27%	✓ PASS

Ainda assim, apesar da taxa de FP não cumprir nenhum dos critérios de aceitação, estes valores encontram-se próximos dos seus limites, significando que esta taxa não é prejudicial à performance do ADC. Adicionalmente, dentro deste grupo, foram identificados casos em que a ferramenta deteta corretamente um defeito mas os critérios de rejeição não são cumpridos e casos em que as imagens provenientes de AOI têm má qualidade levando à errada reclassificação.

A eficácia cumpre os requisitos e foi possível atingir os valores obtidos no estudo de modelos de reclassificação utilizando o *Haar Cascades* que documentaram valores de 85% para a *performance* de classificação. Já o estudo realizado pela ATEP indica que esta *performance* para os seus operadores é cerca de 86% o que questiona a relevância da implementação da ferramenta com

este algoritmo. No entanto, a ferramenta é valorizada pelo indicador mais crítico, o *underkill*, dos operadores ser o dobro do obtido pela ferramenta.

Como é possível observar pela Tabela 5.1 existe alguma variabilidade entre os lotes que depende do número de alarmes e do tipo de imagens que perfazem este conjunto de alarmes. Para além disso, esta análise é feita para apenas dez lotes e, como dito anteriormente, é necessário maior amostra para uma melhor análise.

Passando agora ao modelo de AOIUBM (Tabela 5.2), este modelo permite que sejam retiradas conclusões incorretas já que ter menos ruído significa que do total de alarmes por lote que o ADC reclassifica apenas uma quantidade residual é efetivamente um defeito. Daqui resulta um reduzido número de TP e, caso a ferramenta falhe a detetar pelo menos um desvio na imagem originando um FN, o *recall* desce significativamente já que é calculado pela divisão das unidades TP e TPr pela soma destas com o número de FN. Sendo que o *recall* apresenta o valor tabelado, isto significa que a ferramenta está a falhar na rejeição de imagens, mas como os defeitos são poucos todos os restantes indicadores estão satisfatórios.

Tabela 5.2: Resultados do modelo final em produção AOIUBM

Lotes	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	Média	Desvio Padrão	Resultado
Total Alarmes	960	96	608	2025	1183	331	148	85	1037	2298	1786	436	227	156	1739	726	2745	1009	368	1516	155	778	--	--	--
Eficácia	82.29%	95.83%	89.97%	90.77%	98.65%	94.56%	97.97%	88.24%	98.07%	95.21%	91.77%	99.08%	95.59%	100.00%	92.47%	98.21%	95.30%	99.11%	88.04%	95.71%	83.87%	98.97%	94.08%	4.95%	✓ PASS
Eficiência	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	100.00%	0.00%	✓ PASS
Discordância	17.92%	4.17%	10.36%	9.23%	1.44%	5.44%	2.03%	11.76%	2.31%	4.79%	8.29%	0.92%	4.85%	0.00%	7.53%	2.07%	4.70%	0.89%	11.96%	4.29%	17.42%	1.03%	6.06%	5.08%	✓ PASS
Taxa de FP	15.83%	3.13%	7.57%	8.89%	0.51%	4.83%	0.68%	8.24%	0.68%	4.18%	7.84%	0.46%	1.32%	0.00%	6.79%	0.14%	4.66%	0.30%	11.68%	3.96%	10.32%	0.77%	4.67%	4.35%	✓ PASS
Taxa de FN	1.88%	1.04%	2.47%	0.35%	0.85%	0.60%	1.35%	3.53%	1.25%	0.61%	0.39%	0.46%	3.08%	0.00%	0.75%	1.65%	0.04%	0.59%	0.27%	0.33%	5.81%	0.26%	1.25%	1.37%	✓ PASS
Recall	10.00%	0.00%	11.76%	0.00%	9.09%	0.00%	0.00%	0.00%	23.53%	0.00%	12.50%	0.00%	12.5%	100.00%	0.00%	14.29%	0.00%	0.00%	0.00%	16.67%	18.18%	0.00%	10.39%	20.92%	X FAIL
Underkill(U)	0.10%	0.09%	0.09%	0.05%	0.09%	0.05%	0.06%	0.28%	0.10%	0.11%	0.05%	0.03%	0.03%	0.00%	0.08%	0.18%	0.01%	0.05%	0.03%	0.04%	0.14%	0.02%	0.08%	0.06%	✓ PASS
Overkill(U)	0.38%	0.18%	0.40%	0.45%	0.06%	0.46%	0.03%	0.19%	0.05%	0.08%	0.47%	0.03%	0.03%	0.00%	0.37%	0.02%	0.44%	0.02%	0.12%	0.34%	0.46%	0.02%	0.21%	0.18%	✓ PASS
Recall(U)	18.75%	0.00%	33.33%	0.00%	9.09%	50.00%	0.00%	0.00%	23.53%	0.00%	14.29%	0.00%	33.33%	100.00%	16.67%	14.29%	0.00%	0.00%	0.00%	16.67%	40.00%	0.00%	16.82%	23.41%	!AVG

Caso se trabalhe no sentido de melhorar este *recall*, que faz parte do grupo de indicadores críticos, a taxa de FP aumenta e, por isso, a eficácia acaba a falhar o critério de aceitação por uma grande margem. Neste sentido, foi feita uma análise rápida utilizando um algoritmo de *deep learning*. Para isso, utilizaram-se as mesmas imagens utilizadas nos repositórios anteriores e correram-se os dois modelos para os mesmos lotes por forma a ser possível a comparação. Na Tabela 5.3 são apresentados os resultados.

Tabela 5.3: Resultados Experiência *Haar Cascades* vs. *Deep Learning*

	<i>Haar Cascades</i>			CNN		
	Média	Desvio Padrão	Resultado	Média	Desvio Padrão	Resultado
Eficácia	96.19%	2.71%	✓ PASS	87.92%	6.67%	✓ PASS
Recall	22.46%	29.46%	X FAIL	88.39%	12.03%	✓ PASS
Underkill (U)	0.07%	0.05%	✓ PASS	0.02%	0.02%	✓ PASS
Overkill (U)	0.17%	0.19%	✓ PASS	0.46%	0.27%	✓ PASS

De notar que estes resultados representam um teste e não foi um processo iterativo exaustivo, representando, assim, as primeiras tentativas. Estes valores para os indicadores mais críticos são

satisfatórios e retratam o potencial deste algoritmo que tem vindo a ganhar destaque na indústria. Foi possível aumentar o *recall*, mantendo todos os outros indicadores dentro dos limites de aceitação, inclusive o *underkill* diminuiu. A eficácia e *overkill* apesar de terem piorado têm valores satisfatórios para o cliente.

Comparando os dois FMEA desenvolvidos podemos concluir que estes apresentam algumas diferenças que se tornam significativas na abordagem da equipa ao risco. Enquanto que no primeiro FMEA os valores de RPN, juntamente com as regras de ação impostas pela ATEP, indicam um nível de risco elevado para uma quantidade significativa de casos e que precisam de ação imediata, o segundo FMEA acaba por não colocar tanto imediatismo de ação nesses mesmos casos. Isto porque, como dito no Capítulo 2, o método AP confere aos três indicadores de risco diferentes prioridades e importância.

Como exemplo existem os casos do ADC MAX que apresentam um nível de risco superior, como seria de esperar. Para o novo defeito, que poderá causar unidades com falha chegarem ao cliente, apesar da severidade ser caracterizada com 8, a segunda metodologia assume que um método de prevenção minimamente eficaz, tendo uma ocorrência de 4, se torna capaz de ter este modo de falha sob controlo. Já pela multiplicação usada na metodologia do primeiro FMEA, o RPN ultrapassa o valor de 100 (definido pela ATEP como o valor mínimo a partir do qual o modo de falha carece de atenção) e, por isso, necessita de ação.

Outro caso que pode ser utilizado como exemplo, ainda dentro do ADC MAX, é o último ponto dos FMEA em que um treino incorreto ou ineficaz da ferramenta pode resultar na classificação errada do defeito em causa e, dessa maneira, perde-se a rastreabilidade do processo e torna-se impossível atuar para que se evite a repetição do defeito. Para a primeira metodologia, este caso precisa de ação imediata já que o seu RPN é 160. No entanto, utilizando o AP, como a deteção é o indicador com menos prioridade, apesar do indicador da deteção apresentar 10, este caso não precisa de ação imediata uma vez que, sendo a severidade 4, se assume que a equipa se deve focar primeiramente noutras situações mais graves ou prejudiciais a esta.

Importa referir que não se verifica necessidade de recomendar ações para casos que se mostram ser críticos já que é reconhecido ao controlo de mitigação de risco a segurança suficiente pois envolve o uso dos vários modos de risco do ADC. Ou seja, mesmo que o operador utilize um modo de risco mais elevado que não tenha controlos de deteção tão efetivos e, dessa forma, apresente modos de falha críticos, o operador tem de usar o ADC0 em qualquer Nível de Uso onde poderá identificar facilmente falhas que possam estar a influenciar a ferramenta ADC. Isto porque o modelo em produção é igual independentemente do modo de risco e, assim, as falhas detetadas em ADC0 indicam falhas que acontecem também em modos de risco mais elevados.

Capítulo 6

Conclusão

Este capítulo apresenta as principais conclusões retiradas durante o desenvolvimento do projeto. No fim, serão realçadas recomendações para trabalhos futuros.

A realidade atual desta indústria é caracterizada por um aumento crescente das exigências relativamente à qualidade dos seus produtos. Adicionalmente, os chips, assim como os defeitos, têm vindo a diminuir o seu tamanho, acompanhando a redução da dimensão dos aparelhos eletrónicos. Para além disso, o mercado *automotive* tem vindo a ganhar peso nesta indústria e associado a este mercado está a política dos Zero Defeitos. Sendo os defeitos invisíveis a olho nu, torna-se claro as dificuldades que as empresas enfrentam.

Neste sentido, a empresa explora a implementação da ferramenta de reclassificação automática de defeitos, ADC, para os seus produtos dando prioridade aos *automotive*. Esta ferramenta faz uso de um algoritmo de *machine learning* denominado *Haar Cascades*.

Os desafios enfrentados ao longo do projeto foram: avaliar a *performance* dos modelos atualmente implementados na ATEP e apresentar propostas de melhoria, criação de novos modelos e, por último, a melhoria e desenvolvimento da ferramenta de análise de risco FMEA.

Relativamente aos modelos atuais, concluiu-se que existem situações pontuais que afetam a *performance* da ferramenta fazendo com que outros modos de risco, para além do ADC0, não sejam utilizados. Estes modelos têm as suas *performances* prejudicadas pelas elevadas taxas de FP e FN. No entanto, os indicadores *underkill* e *overkill* são positivos e dentro dos critérios de aceitação. Esta situação pode ser justificada pelo facto destes dois indicadores lidarem com unidades e não alarmes. Ao analisar os repositórios concluiu-se que é necessária uma revisão e alteração dos mesmo pois existem imagens pouco significativas para o efeito.

Para os modelos desenvolvidos, seguiu-se o processo pré-definido que passa pela recolha de defeitos significativos, recorte, criação de repositórios para os três defeitos com mais ocorrência, para os restantes defeitos e para os casos que não existe defeito, submetê-los para a criação do algoritmo e, finalmente, validações com a alteração dos parâmetros até obter resultados satisfatórios. Foram desenvolvidos dois modelos para o produto NSV_D, um para o passo de AOI1DL2 e o segundo para AOIUBM.

O modelo de AOI1DL2 apresentou resultados positivos e com robustez suficiente para se manterem como produtivos com um *underkill* satisfatório. No entanto, estes valores não mostram uma grande vantagem quando comparado com a *performance* dos operadores.

Para o modelo de AOI1UBM entendeu-se que precisa de melhorias pois, atualmente, o número de alarmes que rejeita e devia rejeitar é demasiado baixo não conferindo confiança suficiente para se manter produtivos. Este é um modelo que permite retirar conclusões erradas num primeiro impacto pois nesta fase o produto não apresenta muitos defeitos e, portanto, a qualquer unidade que o ADC não deteta o *recall* degrada substancialmente. No entanto, o *underkill* mantém-se positivo porque o número de unidades é muito superior ao número de unidades defeituosas.

De uma maneira geral, esta ferramenta liberta a empresa de erro humano nesta fase crítica do processo que é a inspeção e deteção/classificação de defeitos. Para além disso, o processo atual de inspeção manual exige muito tempo aos operadores. Os resultados obtidos são satisfatórios e atingem o que é esperado. Em contrapartida, o algoritmo utilizado atualmente tem limitações. A primeira limitação é o facto da sua *performance*, quando comparada com a dos operadores, não ser muito significativa. Posteriormente, a definição de parâmetros torna-se um processo exaustivo e de tentativa e erro até obter resultados satisfatórios. Também foi possível observar que o ADC não lida corretamente com as características óticas do defeito, rejeitando defeitos sem dimensão de rejeição.

Finalmente, depois da melhoria do FMEA atual da ATEP relativo ao ADC, foi possível a comparação entre duas metodologias. A intenção de transitar da metodologia tradicional para a nova abordagem é justificada pois foi possível concluir que a utilização do AP em vez do RPN, como método para a priorização do plano de ações, se torna mais lógica. As equipas podem focar-se primeiro em modos de falha mais críticos, isto é, com severidades e ocorrências mais elevadas. Em contrapartida, a metodologia atual não dá uma relevância específica a cada um dos indicadores de risco e as equipas agem, maioritariamente, conforme o número de RPN.

6.1 Trabalho Futuro

Num futuro próximo, todos os modelos atualmente em produção deverão ser revistos e inspecionados por forma a identificar possíveis imagens não significativas que estejam a influenciar negativamente os seus modelos e substituí-las. Esta prática deve ser implementada para uma base sistemática, pois como possível observar os resultados entre os anos de 2020 e 2021 diferem apesar de se utilizar os mesmos modelos, sendo que o primeiro apresenta melhores resultados. Adicionalmente, por forma a estabilizar a ferramenta, todos os defeitos de excesso e falta de cobre devem ser considerados no repositório dos Defeitos na Estrutura de Cobre, pela sua semelhança em termos de contexto e dimensão e, assim, facilitar a definição dos parâmetros.

Outra melhoria possível seria implementar a criação de um algoritmo que pudesse definir de forma automatizada os parâmetros ótimos que devem ser definidos para o desenvolvimento do algoritmo. Desta maneira, seriam poupados recursos e tempo consumido.

No entanto, o *deep learning* torna-se um sistema mais robusto já que retorna *performances* mais positivas segundo os estudos de Phua and Theng (2020) e segundo o teste feito durante o projeto. Adicionalmente, este método permite à ferramenta lidar melhor com as características óticas dos defeitos, já tem implementado nas suas funcionalidades o cálculo do nível de confiança das reclassificações e não usa janelas de detecção que se mostraram como razão para algumas limitações do ADC, como o tempo de processamento e a não detecção de defeitos.

Neste seguimento, a medida mais lógica pelos resultados que se obtiveram como exemplo pela comparação entre o *Haar Cascades* e o CNN seria o desenvolvimento de um algoritmo fundamentado neste último. Posteriormente, deverá ser substituído o algoritmo de todos os modelos atualmente em produção para o CNN e os novos modelos deverão ser implementados já com este algoritmo.

Finalmente, a transição da ferramenta de análise de risco para a metodologia FMEA desenvolvida pela AIAG and VDA (2019). Esta transição deve ser feita para todos os processos dentro da empresa já que permite a equipa mais focada em modos de falha mais severos e com maior probabilidade de ocorrência.

Bibliografia

- AIAG, A. and VDA, V. (2019). *AIAG & VDA FMEA Handbook*. Automotive Industry Action Group (AIAG).
- Amkor Technology, I. (2021). Investor presentation. <https://ir.amkor.com/static-files/d5ba6238-a21f-4427-85ca-2a6836d48f01>.
- Bennett, M. H., Tobin, K. W., and Gleason, S. S. (1994). Overview of automatic defect classification. In *Proceedings of 1994 IEEE/SEMI Advanced Semiconductor Manufacturing Conference and Workshop (ASMC)*, pages 272–.
- Breaux, L. and Singh, B. (1995). Automatic defect classification system for patterned semiconductor wafers. In *Proceedings of International Symposium on Semiconductor Manufacturing*, pages 68–73.
- Chakraborty, K. (2021). Wafer. <https://www.techopedia.com/definition/2326/wafer-electronics>.
- Chou, P. B., Rao, A. R., Sturzenbecker, M. C., Wu, F. Y., and Brecher, V. H. (1996). Automatic defect classification for semiconductor manufacturing. *Machine Vision and Applications*, 9(4):201–214. Cited By :74.
- Dom, B. E. and Brecher, V. (1995). Recent advances in the automatic inspection of integrated circuits for pattern defects. *Machine Vision and Applications*, 8(1):5–19. Cited By :29.
- Fan, X. (2010). Wafer level packaging (wlp): Fan-in, fan-out and three-dimensional integration. In *2010 11th International Thermal, Mechanical Multi-Physics Simulation, and Experiments in Microelectronics and Microsystems (EuroSimE)*, pages 1–7.
- General Motors Corporation, Corporation, C., and Company, F. M. (2008). *Potential Failure Mode and Effects Analysis (FMEA): Reference Manual*. Automotive Industry Action Group (AIAG).
- Kim, H. I., Lee, S. H., and Cho, N. I. (2009). Automatic defect classification using frequency and spatial features in a boosting scheme. *IEEE Signal Processing Letters*, 16(5):374–377.
- Lee, S. H., Kim, H. I., Cho, N. I., Jeong, Y. H., Chung, K. S., and Jun, C. S. (2005). Automatic defect classification using boosting. In *Fourth International Conference on Machine Learning and Applications (ICMLA'05)*, pages 6 pp.–.
- Meixner, A. (2021). Hunting for open defects in advanced packages. <https://semiengineering.com/hunting-for-defects-in-advanced-packages>.
- Mordor Intelligence, L. (2021). Outsourced semiconductor assembly and test (osat) market - growth, trends, covid-19 impact, and forecasts (2021 - 2026). <https://www.mordorintelligence.com/industry-reports/osat-market1>.

- OpenCV (2017). Object detection: Opencv 2.4.13.4 api reference. https://docs.opencv.org/2.4/modules/objdetect/doc/cascade_classification.html.
- Pessoa, V. (2018). Exploration of machine learning techniques for automatic optical inspection. Master's thesis, Escola de Engenharia da Universidade do Minho.
- Phua, C. and Theng, L. B. (2020). Semiconductor wafer surface: Automatic defect classification with deep cnn. In *2020 IEEE REGION 10 CONFERENCE (TENCON)*, pages 714–719.
- Tello, G., Al-Jarrah, O. Y., Yoo, P. D., Al-Hammadi, Y., Muhaidat, S., and Lee, U. (2018). Deep-structured machine learning model for the recognition of mixed-defect patterns in semiconductor fabrication processes. *IEEE Transactions on Semiconductor Manufacturing*, 31(2):315–322.
- Viola, P. and Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. In *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, volume 1, pages I–511.
- Vitoriano, P. M. A. and Amaral, T. G. (2016). 3d solder joint reconstruction on smd based on 2d images. *SMT Surface Mount Technology Magazine*, 31(6):82–93. Cited By :4.
- Vítor, M. (2019). Baterias impressas em wafers de silício têm maior capacidade e menor custo. <https://pplware.sapo.pt/high-tech>.
- Wang, J. (2020). Top 10 largest osat companies' revenues exceed us6.7 billion, while amkor scores highest yoy growth, according to trendforce. <https://www.trendforce.com/presscenter/news/20201116-10553.html>.

Anexo A

A Cultura de QualidadePRIMEIRO

A política da QualidadePRIMEIRO tem por base uma forte cultura que se baseia nos seguintes pontos:

- Estar incorporada em todas as componentes de negócio e em todos os processos da Amkor.
- Ter o mesmo DNA de Qualidade em todos os colaboradores da Amkor.
- Ser o alicerce da competitividade do negócio da Amkor.
- Não comprometer a qualidade.
- Não violar os compromissos assumidos.
- Ter consciência dos desvios à normalidade.
- Começar tudo com a Qualidade em mente.



Figura A.1: Visão da política QualidadePRIMEIRO

Anexo B

Catálogo de Falhas

Falhas Gerais:

- **Partículas (até *Sputter*):** Superfície do chip contaminada com uma partícula.

Critérios:

- Partícula localizada nas vias (descobertas) → **rejeitar sempre**.
- Partícula localizada em qualquer zona → **rejeitar se > 100 µm**.

- **Partículas (depois *Sputter*):** Superfície do chip contaminada com uma partícula.

Critérios:

I. Critérios Gerais:

- A. Partículas ('soltas') sobre a camada de DL → **aceitar sempre** (B.1).




Figura B.1: Critério II.A

- B. Partícula > 100 µm (na sua maior dimensão) → **rejeitar**.

II. Critérios Particulares:

- A. Partículas **nas vias** (sob ou sobre o cobre) → **rejeitar sempre**.

B. Partículas nos *Ball Pads*:

1. Sobre o cobre:

- **Rejeitar** se defeito > 60 µm (na sua maior dimensão) ou ocupar **mais de 10% da área** do *ball pad* (B.2a).

2. Sob o cobre:

- **Rejeitar** se defeito > 150 µm (na sua maior dimensão) (B.2b).




Figura B.2: Critério II.B

C. Partículas nos traces:

1. Partículas cobertas por cobre:

- **Rejeitar** se a partícula coberta de cobre **fizer curto** com a estrutura de cobre mais próxima (isto é, juntar as duas estruturas) (B.3).




Figura B.3: Critério II.C.1

2. Partículas não cobertas por cobre (*dark/light particles*):

- **Rejeitar** se a partícula estiver **em contacto com duas estruturas** de cobre distintas (B.4).

Nota: Caso não seja possível aplicar o critério anterior, rejeitar se a largura (L) da partícula na extremidade do *trace* for maior do que a distância (d) à estrutura mais próxima.




Figura B.4: Critério II.C.2

- **Contaminação:** É visível que a superfície do chip está contaminada.

Critérios:

- Aplicar mesmo **critério** que para **Partículas**.
- Contaminações **nos pads de alumínio** é para **rejeitar sempre**.

- **Riscos:** É visível que a superfície do chip ou estruturas de RD/DL estão riscadas.

Critérios:**– Rejeitar:**

- * Riscos na zona do chip de silício.
- * Riscos por cima da camada de Top que deformem estruturas ou deixem cobre exposto.
- * Riscos por baixo do Plating que danifiquem vias ou comprometam a estrutura subjacente.
- * Riscos acima do Plating que deformem as estruturas de RDL.
- * Riscos no UBM que danifiquem a estrutura.

– Aceitar:

- * Riscos por cima do Plating que não deformem as estruturas de RDL.

- **Die/Mold Crack:** São visíveis chips partidos.

Critérios:

- **Rejeitar** sempre.

Falhas de Recon:

- **Resíduos de Tape:** Existem resíduos de *tape* no chip.

Critérios:

- Fora da área ativa → **aceitar sempre**.
- Dentro da área ativa → aplicar **critério para partículas**.

Nota: Área ativa é a zona do chip delimitada pela linha circundante (*seal ring*) mais interior.

- **Mold Flash:** Extremidade do chip encontra-se danificada por *mold compound*.

Critérios:

- Fora da área ativa → **aceitar sempre**.
- Dentro da área ativa → aplicar **critério para partículas**.

- **Die Chipping:** O corte irregular toca no *seal ring*.

Critérios:

- Rejeitar sempre que o corte chegar ao *seal ring* (B.5).




Figura B.5: Critério *Die Chipping*

- **Metal Peeling/Curling:** Metal levanta da *street* e entra na área ativa (mantendo-se preso).

Critérios:

- Rejeitar quando o pedaço de metal ultrapassar o *seal ring* ou *crack stop*.

Falhas de RDL:

- **Corrosão nos pads:** É visível corrosão na superfície dos *pads*.

Critérios:

- **Rejeitar** sempre.

- **Resíduos de SeedLayer:** Existem resíduos de *SeedLayer* na superfície da *wafer* após *WetEtch*.

Critérios:

- Se este resíduo aparecer de forma isolada, aplicar o critério de “Partículas Cobertas por Cobre”.
- Se resíduo estiver junto a pistas, estruturas ou *pads* rejeitar.

Nota: Consoante a sua severidade, os resíduos de *seedlayer* podem manifestar-se sob a forma de “salpicos” brilhantes (resíduo ténue) ou podem cobrir uma porção considerável da unidade (resíduo severo).

- **Delaminações na camada de DL1:** É visível uma delaminação entre a camada de DL1 e a superfície do chip.

Critérios:

- **Rejeitar** sempre.

- **Delaminações na camada de Litho RDL:** Parte da camada de *Litho* RDL delaminou. Se uma *wafer* com este problema prosseguir em processo dará origem a uma estrutura de cobre com um *layout* diferente do pretendido.

Critérios:

- **Rejeitar** sempre.

- **Delaminações na camada de Top DL (DL2 e DL3):** É visível uma delaminação entre a camada de *Top DL* e a superfície do *package*.

Critérios:

- **Rejeitar** sempre.

- **Desalinhamento de DL1:** Camada de DL1 (*Fuse*) não está alinhada com as estruturas subjacentes.

Critérios:

- (*Fan-out*) Rejeitar se a parte visível da camada de passivação dentro da janela no DL1 for $> 4 \mu\text{m}$.

- **Desalinhamento de RDL:** Camada de RDL não está alinhada com as estruturas subjacentes.

Critérios:

- Rejeitar se a via no DL1 não estiver 100% coberta pela linha de RDL.

- **Desalinhamento de Top DL:** Camada de Top DL não está alinhada com as estruturas subjacentes.

Critérios:

- (Fan-out) Rejeitar se a abertura do ball pad numa determinada zona estiver a menos de 8 μm da estrutura de RDL do ball pad.

- **Desalinhamento de DL2 (produtos com 3 camadas de DL):** Camada de DL2 não está alinhada com as estruturas subjacentes.

Critérios:

- (Fan-in) Vias de DL2 - Rejeitar se a abertura das vias numa determinada zona estiver a menos de 5 μm da estrutura de RDL (overlap < 5 μm).

- **Desalinhamento de UBM:** Camada de UBM não está alinhada com as estruturas subjacentes.

Critérios:

- (Fan-out) Rejeitar se o limite da camada de UBM estiver a menos de 8 μm do limite da camada de Top.

- **Bolhas no DL:** Existem bolhas na camada de DL (B.6).

Critérios:

– **Rejeitar:**

- * Bolha > 100 μm (na sua maior dimensão).
- * Bolha que esteja aberta.
- * Mais que uma bolha por unidade.
- * Bolha que cubra por completo uma estrutura de cobre, e toque em mais alguma estrutura.
- * Rejeitar se o cobre sob a bolha for muito mais brilhante que fora.

– **Aceitar:**

- * Bolha que não toque em estruturas de cobre.
- * Bolha que toque, sem cobrir por completo, até duas estruturas de cobre.
- * Bolha que cubra ou toque uma única estrutura de cobre.

- **Falta de DL:** Parte da superfície do chip não está coberta por DL.

Critérios:

- Rejeitar sempre.

- **Cracks no DL:** São visíveis fissuras (*cracks*) no DL.

Critérios:

- Rejeitar se a dimensão da fissura for > 100 μm .




Figura B.6: Critério Bolhas no DL

- **Defeitos na Estrutura do Cobre):** Existe uma estrutura de cobre que não está de acordo com o *layout* pretendido (falta ou excesso de cobre).

Critérios:

I. Falta de Cobre:

- A. **Bump pads** – Rejeitar se maior dimensão da zona danificada for $> 60 \mu\text{m}$.
- B. **Pistas interrompidas** – Rejeitar se zona danificada ultrapassar 20% da largura da pista (B.7).




Figura B.7: Critério Defeitos na Estrutura do Cobre I.B

- C. **UBM** – Rejeitar sempre.

II. Cobre em Excesso:

- A. **Protuberâncias/pontes** – Rejeitar se a maior dimensão da zona com material em excesso for $> 100 \mu\text{m}$ ou for ultrapassada metade da distância à estrutura mais próxima (B.8).




Figura B.8: Critério Defeitos na Estrutura do Cobre II.A

- **Falta de Cobre – *Plating (Missing Copper)***: Estrutura de cobre não se encontra completa devido a um processo de *Plating* incompleto ou ineficiente.

Critérios:

- Rejeitar sempre.

- **Protuberâncias de *Mold/Pimples***: São visíveis protuberâncias na superfície da *wafer* resultantes dos *fillers* que existem no *Mold Compound*.

Critérios:

- Rejeitar caso exista alguma protuberância que não fique totalmente coberta por DL (*Top Cover*).

- ***Wafer Queimada***: A *wafer* apresenta uma queimadura, após *Sputter*. Verificar os dois lados da *wafer* (inspeção visual).

Critérios:

- Rejeitar caso se verifique uma queimadura em qualquer dos lados da *wafer*.

- ***Asher Stains***: A *wafer* apresenta manchas no *backside* (lado do *mold*), após *Asher* ou RIE.

Critérios:

- Rejeitar se as manchas chegarem aos chips produtivos.

Falhas de Falhas de LBS-SBA:

- **Bolas de solda deslocadas (*Ball misplacement*)**: Uma ou mais bolas deslocadas da sua posição na *wafer*.

Critérios:

- Rejeitar sempre.

- **Bolas de solda extra (*Extra ball*)**: Duas ou mais bolas de solda juntas no mesmo *pad*.

Critérios:

- Rejeitar sempre.

- **Pontes entre bolas de solda (*Bridges*)**: Existência de uma “ponte” a ligar duas ou mais bolas de solda.

Critérios:

- Rejeitar sempre.

- **Falta bola de solda (*Missing ball*)**: Falta de uma ou mais bolas de solda.

Critérios:

- Rejeitar sempre.

Anexo C

Tabela Prioridade de Ação

A Tabela da Prioridade de Ação é utilizada para auxiliar as equipas na tomada de decisão relativamente à ordem de ação a seguir consoante o nível de prioridade das características do modo de falha. A metodologia AP dá diferente prioridade aos três indicadores de risco: Severidade, Ocorrência e Detecção.

Prioridade de Ação (AP) para DFMEA e PFMEA							
A prioridade de ação baseia-se em combinações das classificações da Severidade, Ocorrência e Detecção de modo a dar prioridade a ações para redução de risco.						Em branco até ser preenchido pelo utilizador	
Efeito	S	Previsão de Ocorrência da Causa da Falha	O	Capacidade de Detecção	D	Prioridade de Ação (AP)	Comentários
Efeito nas instalações ou no Produto Muito Elevado	9-10	Muito elevada	8-10	Baixa - Muito baixa	7-10	H	
				Moderada	5-6	H	
				Elevada	2-4	H	
				Muito elevada	1	H	
		Elevada	6-7	Baixa - Muito baixa	7-10	H	
				Moderada	5-6	H	
				Elevada	2-4	H	
				Muito elevada	1	H	
		Moderada	4-5	Baixa - Muito baixa	7-10	H	
				Moderada	5-6	H	
				Elevada	2-4	H	
				Muito elevada	1	M	
		Baixa	2-3	Baixa - Muito baixa	7-10	H	
				Moderada	5-6	M	
				Elevada	2-4	L	
				Muito elevada	1	L	
		Muito baixa	1	Muito elevada - Muito baixa	1-10	L	
Efeito nas instalações ou no Produto Elevado	7-8	Muito elevada	8-10	Baixa - Muito baixa	7-10	H	
				Moderada	5-6	H	
				Elevada	2-4	H	
				Muito elevada	1	H	
		Elevada	6-7	Baixa - Muito baixa	7-10	H	
				Moderada	5-6	H	
				Elevada	2-4	H	
				Muito elevada	1	M	
		Moderada	4-5	Baixa - Muito baixa	7-10	H	
				Moderada	5-6	M	
				Elevada	2-4	M	
				Muito elevada	1	M	
		Baixa	2-3	Baixa - Muito baixa	7-10	M	
				Moderada	5-6	M	
				Elevada	2-4	L	
				Muito elevada	1	L	
		Muito baixa	1	Muito elevada - Muito baixa	1-10	L	
Efeito nas instalações ou no Produto Moderado	4-6	Muito elevada	8-10	Baixa - Muito baixa	7-10	H	
				Moderada	5-6	H	
				Elevada	2-4	M	
				Muito elevada	1	M	
		Elevada	6-7	Baixa - Muito baixa	7-10	M	
				Moderada	5-6	M	

Efeito nas instalações ou no Produto Moderado	4-6	Elevada	6-7	Elevada	2-4	M	
				Muito elevada	1	L	
		Moderada	4-5	Baixa - Muito baixa	7-10	M	
				Moderada	5-6	L	
				Elevada	2-4	L	
				Muito elevada	1	L	
		Baixa	2-3	Baixa - Muito baixa	7-10	L	
				Moderada	5-6	L	
				Elevada	2-4	L	
				Muito elevada	1	L	
Efeito nas instalações ou no Produto Baixo	2-3	Muito elevada	8-10	Muito elevada - Muito baixa	1-10	L	
				Baixa - Muito baixa	7-10	M	
				Moderada	5-6	M	
				Elevada	2-4	L	
		Elevada	6-7	Muito elevada	1	L	
				Baixa - Muito baixa	7-10	L	
				Moderada	5-6	L	
				Elevada	2-4	L	
		Moderada	4-5	Muito elevada	1	L	
				Baixa - Muito baixa	7-10	L	
				Moderada	5-6	L	
				Elevada	2-4	L	
		Baixa	2-3	Muito elevada	1	L	
				Baixa - Muito baixa	7-10	L	
				Moderada	5-6	L	
				Elevada	2-4	L	
		Muito baixa	1	Muito elevada - Muito baixa	1-10	L	
				Muito elevada - Muito baixa	1-10	L	
Sem Efeito discernível	1	Muito baixa - Muito elevada	1-10	Muito elevada - Muito baixa	1-10	L	

Anexo D

FMEA Atual

O FMEA apresentado neste anexo é referente ao FMEA de AOI da ATEP. É apenas representado o modo de falha que envolve a ferramenta de reclassificação automática.

Product Name / Process Flow Name Automatic Optical Inspection (AOI 2D/3D)						Code / ID / Rev / Package				FMEA Original Date			FMEA Revision Date			Prepared by:								
Core Team Members										Process Responsibility RDL			Plant / Resp. Organization ATEP											
Scope of FMEA						Requirements & Specs																		
Operation-Number / Element ID	Characteristic: Customer Requirements/ Function/ Module / Process step	Potential Failure Mode	Potential Effect(s) of Failure	Severity	Class C	Potential Cause(s) / Mechanism(s) of Failure	Prevention Method: Current Design or Process Controls	Occurrence	Detection Method: Current Design or Process Controls	Detection	R P N	Recommended Actions	Responsibility	Target Completion Date	Severity	Occurrence	Detection	RPN target	Actions Taken / Evidence of improvement / Comments	Date of Actions Taken	Severity	Occurrence	Detection	R P N
100% 2D Insp (All Equip)	Inspection Review	Automatic Defect Classification with incorrect Quality Criteria	Product with failures	6		Incorrect or Insufficient Statistical Training of ADC system	Auto System Control - HIP (ADC system continuous performance evaluation)	3	1) Product Characteristic Control - IP (Yield) 2) AOI - PP (Inspection Redundancy - 100 %) 3) Electrical Test	4	72	Reviewed - No actions to be implemented (risk mitigated through automated controls)												

(1) When there are several controls within one failure mode, **Bold font** indicates the most effective control, the one that stipulates the Detectability index. Controls should also be described by the order defined on the Process Flow.

Anexo E

FMEA - Metodologia Tradicional

O FMEA apresentado neste anexo foi desenvolvido utilizando a metodologia tradicional (General Motors Corporation et al., 2008) e utilizando o RPN como método de priorização de ações.

Para a elaboração do documento foram analisados os modos de falha associados a cada um dos modos de risco da ferramenta ADC implementada na ATEP. Antes disso, foram também analisados os modos de falha mais abrangentes a toda a ferramenta, como, por exemplo, a falha da aplicação ou errada seleção de modos de risco.

Product Name / Process Flow Name				Code / ID / Rev / Package				Original FMEA Date			FMEA Revision Date			Prepared by:										
Core Team Members											Process Responsibility			Plant / Resp. Organization										
Scope of FMEA				Requirements & Specs																				
Operation- Number / Element ID	Characteristic: Customer Requirements/ Function/ Module / Process step	Potential Failure Mode	Potential Effect(s) of Failure	Severity	Class C	Potential Cause(s) / Mechanism(s) of Failure	Prevention Method: Current Design or Process Controls	Occurrence	Detection Method: Current Design or Process Controls	Detection	R P N	Recommended Actions	Responsibility	Target Completion Date	Severity	Occurrence	Detection	RPN target	Actions Taken / Evidence of improvement / Comments	Date of Actions Taken	Severity	Occurrence	Detection	RPN
100% 2D Insp (All Equip)	Review Mode Selection	Wrong Selection of ADC Review Mode	Failing Units Reaching Customer Overkill	8		Software Issue	Different Usage Levels based on ADC Recent Performance (Each UL has a number of lots allowed for each RM)	1	1) AOI - PP (Inspection Redundancy - 100 %) 2) Electrical Test	6	48													
100% 2D Insp (All Equip)	Inspection Review (ADC)	Wrong Availability of ADC Review Mode (High confidence)	Failing Units Reaching Customer Overkill	8		Wrong Classification Criteria of Operator, resulting in biased KPIs for ADC	1) Procedure Definition/ Operator Training (30- PI006296) 2) MSA Control (Attribute Appraisal Study (AAS) - 30- PI006036)	3	1) AOI - PP (Inspection Redundancy - 100 %) 2) Electrical Test	6	144	Implement "2nd pair of eyes" control and use it as reference for ADC results	Proc.Eng.	21CW30	7	2	4	56						
100% 2D Insp (All Equip)	Inspection Review (ADC)	Wrong Availability of ADC Review Mode (Low Confidence)	Bottleneck Cycle Time Reduction	2		Wrong Classification Criteria of Operator, resulting in biased KPIs for ADC	1) Procedure Definition/ Operator Training (30- PI006296) 2) MSA Control (Attribute Appraisal Study (AAS) - 30- PI006036)	3	1) AOI - PP (Inspection Redundancy - 100 %) 2) Electrical Test	6	36	Implement "2nd pair of eyes" control and use it as reference for ADC results	Proc.Eng.	21CW30	2	2	4	16						
100% 2D Insp (All Equip)	Inspection Review (ADC)	ADC Review Not Possible	Bottleneck on Production	2		Server Breakdown	1) AOI - IP (100%) 2) Server Redundancy	1	Auto System Control - HIP (Unavailable Tool)	1	2													
100% 2D Insp (All Equip)	Inspection Review (ADC0)	Wrong ADC Classification	Reject a Good Unit - Unnecessary Yield Loss (Overkill)	4		Incorrect or Insufficient Statistical Training of ADC system	Auto System Control - AIP (ADC System Continuous Performance Evaluation)	1	1) Procedure Definition/Operator Training (Operator Revision 100%) 2) Product Characteristic Control - IP (Yield)	7	28													
100% 2D Insp (All Equip)	Inspection Review (ADC0)	Wrong ADC Classification	Failing Units Reaching Customer	8		Absence of ADC Minimum Score in the Classification	Auto System Control - AIP (ADC System Continuous Performance Evaluation)	1	1) Procedure Definition/Operator Training (Operator Revision 100%) 2) AOI - PP (Inspection Redundancy - 100%) 3) Electrical Test	6	48	Change the ADC algorithm to Deep Learning.	IT	21CW33	1		48							
100% 2D Insp (All Equip)	Inspection Review (ADC0)	Wrong ADC Classification	Failing Units Reaching Customer	8		ADC Window Not Dynamic for Non Clustered Alarms	Auto System Control - AIP (ADC System Continuous Performance Evaluation)	1	1) Procedure Definition/Operator Training (Operator Revision 100%) 2) AOI - PP (Inspection Redundancy - 100%) 3) Electrical Test	6	48	Change the ADC algorithm to Deep Learning.	IT	21CW33	2		96							
100% 2D Insp (All Equip)	Inspection Review (ADC0)	Wrong ADC Classification	Failing Units Reaching Customer	8		Incorrect or Insufficient Statistical Training of ADC system	Auto System Control - AIP (ADC System Continuous Performance Evaluation)	1	1) Procedure Definition/Operator Training (Operator Revision 100%) 2) AOI - PP (Inspection Redundancy - 100%) 3) Electrical Test	6	48													

100% 2D Insp (All Equip)	Inspection Review (ADC MAX)	Wrong ADC Classification	Reject a Good Unit - Unnecessary Yield Loss (Overkill)	4	Incorrect or Insufficient Statistical Training of ADC system	1) Auto System Control - AIP (ADC System Continuous Performance Evaluation) 2) Auto System Control - HIP (Blocks RM based on KPIs)	4	Product Characteristic Control - IP (Yield)	9	144										
100% 2D Insp (All Equip)	Inspection Review (ADC MAX)	Wrong ADC Classification	Failing Units Reaching Customer	8	Absence of ADC Minimum Score in the Classification	1) Auto System Control - AIP (ADC System Continuous Performance Evaluation) 2) Auto System Control - HIP (Blocks RM based on KPIs)	4	1) AOI - PP (Inspection Redundancy - 100%) 2) Electrical Test	6	192	Change the ADC algorithm to Deep Learning.	IT	21CW33	1	48					
100% 2D Insp (All Equip)	Inspection Review (ADC MAX)	Wrong ADC Classification	Failing Units Reaching Customer	8	ADC Window Not Dynamic for Non Clustered Alarms	1) Auto System Control - AIP (ADC System Continuous Performance Evaluation) 2) Auto System Control - HIP (Blocks RM based on KPIs)	4	1) AOI - PP (Inspection Redundancy - 100%) 2) Electrical Test	6	192	Change the ADC algorithm to Deep Learning.	IT	21CW33	2	96					
100% 2D Insp (All Equip)	Inspection Review (ADC MAX)	Wrong ADC Classification	Failing Units Reaching Customer	8	Incorrect or Insufficient Statistical Training of ADC system	1) Auto System Control - AIP (ADC System Continuous Performance Evaluation) 2) Auto System Control - HIP (Blocks RM based on KPIs)	4	1) AOI - PP (Inspection Redundancy - 100%) 2) Electrical Test	6	192										
100% 2D Insp (All Equip)	Inspection Review (ADC MAX)	Wrong ADC Classification	Failing Units Reaching Customer	8	New Defect Type not included in ADC Data.	1) Auto System Control - AIP (ADC System Continuous Performance Evaluation) 2) Auto System Control - HIP (Blocks RM based on KPIs)	4	1) AOI - PP (Inspection Redundancy - 100%) 2) Electrical Test	6	192										
100% 2D Insp (All Equip)	Inspection Review (ADC MAX)	Wrong ADC Classification	Process Track Loss (Rejection with Wrong Detractor)	4	Incorrect or Insufficient Statistical Training of ADC system	1) Auto System Control - AIP (ADC System Continuous Performance Evaluation) 2) Auto System Control - HIP (Blocks RM based on KPIs)	4	No Control	10	160										

Anexo F

Resultados Iterações Treino ADC

F.1 AOI1DL2

Esta secção destina-se a representar os melhores resultados durante o treino do modelo do produto NSV_D em AOI1DL2. Para cada iteração são inicialmente descritos os parâmetros utilizados e, posteriormente, a tabela de resultados.

Iteração 1

Parâmetros:

- **Bons:** Fator de escala (FE): 1.1; Mínimo de vizinhos (MV): 0; Mínimo tamanho (MT): 0;
- **Contaminações:** FE: 10.1; MV: 300; MT: 120;
- **Defeitos na Estrutura do Cobre:** FE: 10.1; MV: 250; MT: 180;
- **Partículas Debaixo do Cobre:** FE: 7.1; MV: 200; MT: 100;
- **Outros:** FE: 9.1; MV: 100; MT: 70.

Tabela F.1: Resultados da 1ª Iteração AOI1DL2

	Média	Desvio Padrão	Resultado
Eficácia	86.70%	5.72%	✓ PASS
Eficiência	100.00%	0.00%	✓ PASS
Discordância	14.18%	6.18%	✓ PASS
Taxa de FP	9.11%	3.80%	✓ PASS
Taxa de FN	4.19%	3.88%	! STD
Recall	20.23%	15.87%	X FAIL
Underkill(U)	0.35%	0.20%	X FAIL
Overkill(U)	0.92%	0.41%	! STD
Recall(U)	26.78%	18.76%	! AVG

Iteração 2

Parâmetros:

- **Bons:** FE: 1.1; MV: 0; MT: 0;
- **Contaminações:** FE: 20.1; MV: 15; MT: 80;
- **Defeitos na Estrutura do Cobre:** FE: 9.1; MV: 10; MT: 50;

- **Partículas Debaixo do Cobre:** FE: 9.1; MV: 10; MT: 100;
- **Outros:** FE: 8.1; MV: 10; MT: 50.

Tabela F.2: Resultados da 2ª Iteração AOI1DL2

	Média	Desvio Padrão	Resultado
Eficácia	67.81%	11.96%	X FAIL
Eficiência	100.00%	0.00%	✓ PASS
Discordância	34.07%	13.14%	X FAIL
Taxa de FP	29.20%	9.30%	X FAIL
Taxa de FN	2.99%	3.06%	! STD
Recall	46.84%	11.45%	✓ PASS
Underkill(U)	0.17%	0.08%	! AVG
Overkill(U)	2.99%	0.64%	X FAIL
Recall(U)	59.84%	10.93%	! AVG

Iteração 3

Parâmetros:

- **Bons:** FE: 1.1; MV: 0; MT: 0;
- **Contaminações:** FE: 10.1; MV: 500; MT: 300;
- **Defeitos na Estrutura do Cobre:** FE: 10.1; MV: 250; MT: 80;
- **Partículas Debaixo do Cobre:** FE: 9.1; MV: 200; MT: 90;
- **Outros:** FE: 9.1; MV: 20; MT: 70.

Tabela F.3: Resultados da 3ª Iteração AOI1DL2

	Média	Desvio Padrão	Resultado
Eficácia	68.90%	4.72%	! AVG
Eficiência	100.00%	0.00%	✓ PASS
Discordância	33.76%	5.17%	! AVG
Taxa de FP	28.78%	5.47%	X FAIL
Taxa de FN	2.32%	2.33%	✓ PASS
Recall	58.27%	9.27%	✓ PASS
Underkill(U)	0.18%	0.11%	X FAIL
Overkill(U)	2.61%	0.76%	X FAIL
Recall(U)	62.18%	10.18%	✓ PASS

Iteração 4

Parâmetros:

- **Bons:** FE: 10.1; MV: 100; MT: 80;
- **Contaminações:** FE: 10.1; MV: 400; MT: 80;
- **Defeitos na Estrutura do Cobre:** FE: 15.1; MV: 100; MT: 80;
- **Partículas Debaixo do Cobre:** FE: 20.1; MV: 300; MT: 80;

- **Outros:** FE: 15.1; MV: 100; MT: 70.

Tabela F.4: Resultados da 4ª Iteração AOI1DL2

	Média	Desvio Padrão	Resultado
Eficácia	77.19%	4.72%	! AVG
Eficiência	100.00%	0.00%	✓ PASS
Discordância	25.22%	6.05%	! AVG
Taxa de FP	20.42%	3.51%	! AVG
Taxa de FN	2.38%	2.80%	! STD
Recall	54.90%	15.20%	! STD
Underkill(U)	0.17%	0.11%	X FAIL
Overkill(U)	1.73%	0.38%	X FAIL
Recall(U)	63.38%	16.50%	✓ PASS

Iteração 5

Parâmetros:

- **Bons:** FE: 10.1; MV: 100; MT: 80;
- **Contaminações:** FE: 10.1; MV: 100; MT: 80;
- **Defeitos na Estrutura do Cobre:** FE: 15.1; MV: 100; MT: 80;
- **Partículas Debaixo do Cobre:** FE: 20.1; MV: 150; MT: 80;
- **Outros:** FE: 15.1; MV: 100; MT: 80.

F.2 AOI1UBM

Esta secção destina-se a representar os melhores resultados durante o treino do modelo do produto NSV_D em AOI1UBM. Para cada iteração são inicialmente descritos os parâmetros utilizados e, posteriormente, a tabela de resultados.

Iteração 1

Parâmetros:

- **Bons:** FE: 10.1; MV: 100; MT: 80;
- **Contaminações:** FE: 10.1; MV: 100; MT: 80;
- **Defeitos na Estrutura do Cobre:** FE: 15.1; MV: 100; MT: 80;
- **Partículas Debaixo do Cobre:** FE: 20.1; MV: 150; MT: 80;
- **Outros:** FE: 15.1; MV: 100; MT: 80.

Iteração 2

Parâmetros: Repetem-se os parâmetros da iteração 1.

Iteração 3

Parâmetros:

- **Bons:** FE: 10.1; MV: 100; MT: 80;
- **Contaminações:** FE: 10.1; MV: 100; MT: 80;

- **Defeitos na Estrutura do Cobre:** FE: 12.1; MV: 100; MT: 80;
- **Partículas Debaixo do Cobre:** FE: 18.1; MV: 150; MT: 80;
- **Outros:** FE: 11.1; MV: 100; MT: 80.

Tabela F.5: Resultados da 1ª Iteração AOI1UBM

	Média	Desvio Padrão	Resultado
Eficácia	38.35%	6.83%	! AVG
Eficiência	100.00%	0.00%	✓ PASS
Discordância	61.77%	6.85%	! AVG
Taxa de FP	61.38%	6.66%	X FAIL
Taxa de FN	0.26%	0.27%	✓ PASS
Recall	33.47%	27.97%	! STD
Underkill(U)	0.01%	0.00%	✓ PASS
Overkill(U)	4.11%	0.71%	X FAIL
Recall(U)	48.33%	24.09%	! AVG

Tabela F.6: Resultados da 2ª Iteração AOI1UBM

	Média	Desvio Padrão	Resultado
Eficácia	80.15%	7.22%	✓ PASS
Eficiência	100.00%	0.00%	✓ PASS
Discordância	19.90%	7.21%	✓ PASS
Taxa de FP	19.69%	7.16%	X FAIL
Taxa de FN	0.16%	0.08%	✓ PASS
Recall	32.50%	34.19%	! STD
Underkill(U)	0.02%	0.00%	✓ PASS
Overkill(U)	1.11%	0.35%	X FAIL
Recall(U)	32.5%	34.19%	! AVG

Anexo G

FMEA - Nova Metodologia

O FMEA apresentado neste anexo foi desenvolvido utilizando a metodologia proposta pela AIAG and VDA (2019) e utilizando o AP como método de priorização de ações.

∞ Para a elaboração do documento foram utilizados os mesmos modos de falha que os descritos no FMEA da Metodologia Tradicional. No entanto, foi necessária a descrição mais pormenorizada do processo incluindo o item, passo e elemento e, posteriormente, descritas as suas funções.

Para a utilização da tabela AP foram utilizadas as mesmas tabelas para a Severidade, Ocorrência e Detecção que a metodologia anterior já que, ao comparar as tabelas propostas pela documentação desta nova abordagem e as tabelas atualmente em utilização na ATEP, não se justificou a substituição das tabelas pela similaridade entre elas.

PLANNING & PREPARATION (STEP 1)																												
Company Name			Plant Location			Subject			PFMEA ID Number			Process Responsibility																
Customer Name			Model Year/Platform			PFMEA Start Date			PFMEA Revision Date			Confidentiality Level																
Cross-Functional Team																												
STRUCTURE ANALYSIS (STEP 2)			FUNCTION ANALYSIS (STEP 3)			FAILURE ANALYSIS (STEP 4)			RISK ANALYSIS (STEP 5)					OPTIMIZATION (STEP 6)														
1.Process Item	2.Process Step	3.Process Work Element	1.Function of the Process Item	2.Function of the Process Step and Product Characteristic	3.Function of the Process Work Element and Process Characteristic	1.Failure Effects(FE)	Severity(S) of FE	2.Failure Mode (FM) of the Process Step	3.Failure Cause (FC) of the Work Element	Current Prevention controls (PC) of FC	Occurrence (O) of FC	Current Detection controls (DC) of FC or FM	Detection (D) of FC/FM	PFMEA AP	Special Characteristics Filter Code (Optional)	Prevention Action	Detection Action	Responsible Person's Name	Target Completion Date	Status	Action Taken with Pointer to Evidence	Completion Date	Severity(S)	Occurrence (O)	Detection (D)	Special Characteristics	PFMEA AP	Remarks
100% 2D Inspection	Review Mode Selection	ADC Tool	Lot Inspection, Collection and Reclassification of Samples (Alarms)	Selection of the Review Mode that will be used for the Alarm Classification	Make available only the Review Mode that can be used	Failing Units Reaching Customer Overkill	8	Wrong Selection of ADC Review Mode	Software Issue	Different Usage Levels based on ADC Recent Performance (Each UL has a number of lots allowed for each RM)	1	1) AOI - PP (Inspection Redundancy - 100 %) 2) Electrical Test	6	L														
100% 2D Inspection	Inspection Review (ADC)	Operator	Lot Inspection and Collection of Samples (Alarms)	Alarm Classification using Automatic Defect Classification (4 Review Mode Available according to client)	Operator Reclassifies the Alarms based on the ADC Review Mode choosen.	Failing Units Reaching Customer Overkill	8	Wrong Availability of ADC Review Mode (High Confidence)	Wrong Classification Criteria of Operator, resulting in biased KPIs for ADC.	1) Procedure Definition/ Operator Training (30-PI006296) 2) MSA Control (Attribute Appraisal Study (AAS) - 30-PI006036)	3	1) AOI - PP (Inspection Redundancy - 100 %) 2) Electrical Test	6	M		Implement "2nd pair of eyes" control and use it as reference for ADC results	Implement "2nd pair of eyes" control and use it as reference for ADC results	Proc.Eng.	21CW30	Pending Decision			8	2	4	L		
100% 2D Inspection	Inspection Review (ADC)	Operator	Lot Inspection and Collection of Samples (Alarms)	Alarm Classification using Automatic Defect Classification (4 Review Mode Available according to client)	Operator Reclassifies the Alarms based on the ADC Review Mode choosen.	Bottleneck Cycle Time Reduction	2	Wrong Availability of ADC Review Mode (Low Confidence)	Wrong Classification Criteria of Operator, resulting in biased KPIs for ADC.	1) Procedure Definition/ Operator Training (30-PI006296) 2) MSA Control (Attribute Appraisal Study (AAS) - 30-PI006036)	3	1) AOI - PP (Inspection Redundancy - 100 %) 2) Electrical Test	6	L		Implement "2nd pair of eyes" control and use it as reference for ADC results	Implement "2nd pair of eyes" control and use it as reference for ADC results	Proc.Eng.	21CW30	Pending Decision			2	2	4	L		
100% 2D Inspection	Inspection Review (ADC)	ADC Tool	Lot Inspection and Collection of Samples (Alarms)	Alarm Classification using Automatic Defect Classification (4 Review Mode Available according to client)	Classifies the Alarms within the Categories Available/Trained using ML Algorithms	Bottleneck on Production	2	ADC Review Not Possible	Server Breakdown	1) AOI - IP (100%) 2) Server Redundancy	1	Auto System Control - HIP (Unavailable Tool)	1	L														
100% 2D Inspection	Inspection Review (ADC0)	ADC Tool	Lot Inspection and Collection of Samples (Alarms)	Alarm Classification using ADC0 (All classifications reviewed by operator)	Classifies the Alarms within the Categories Available/Trained using ML Algorithms	Reject a Good Unit - Unnecessary Yield Loss (Overkill)	4	Wrong ADC Classification	Incorrect or Insufficient Statistical Training of ADC System	Auto System Control - AIP (ADC System Continuous Performance Evaluation)	2	1) Procedure Definition/Operator Training (Operator Revision 100%) 2) Product Characteristic Control - IP (Yield)	7	L														
100% 2D Inspection	Inspection Review (ADC0)	ADC Tool	Lot Inspection and Collection of Samples (Alarms)	Alarm Classification using ADC0 (All classifications reviewed by operator)	Classifies the Alarms within the Categories Available/Trained using ML Algorithms	Failing Units Reaching Customer	8	Wrong ADC Classification	Fail to classify alarms with a Low Minimum Score in the Classification as Not Reclassified	Auto System Control - AIP (ADC System Continuous Performance Evaluation)	1	1) Procedure Definition/Operator Training (Operator Revision 100%) 2) AOI - PP (Inspection Redundancy - 100%) 3) Electrical Test	6	L		Change the ADC algorithm to Deep Learning.		IT	21CW33	Pending Implementation			8	1	6	L		
100% 2D Inspection	Inspection Review (ADC0)	ADC Tool	Lot Inspection and Collection of Samples (Alarms)	Alarm Classification using ADC0 (All classifications reviewed by operator)	Classifies the Alarms within the Categories Available/Trained using ML Algorithms	Failing Units Reaching Customer	8	Wrong ADC Classification	ADC Window Not Dynamic for Non Clustered Alarms	Auto System Control - AIP (ADC System Continuous Performance Evaluation)	1	1) Procedure Definition/Operator Training (Operator Revision 100%) 2) AOI - PP (Inspection Redundancy - 100%) 3) Electrical Test	6	L		Change the ADC algorithm to Deep Learning.		IT	21CW33	Pending Implementation			8	1	6	L		

[illegible]

[illegible]