



**Politécnico  
de Viseu**

Escola Superior  
de Tecnologia  
e Gestão de Viseu

# Sistema de Aprendizagem com Controlo de Qualidade em Processos de Montagem Industrial

Luzia Fonseca Saraiva

Trabalho de Projeto

Mestrado em Engenharia Informática - Sistemas de Informação

Trabalho efetuado sob a orientação de  
Professor Doutor João Pedro Menoita Henriques  
Professor Doutor José Luís Henriques da Silva

Fevereiro de 2025



**Politécnico  
de Viseu**

Escola Superior  
de Tecnologia  
e Gestão de Viseu

# Sistema de Aprendizagem com Controlo de Qualidade em Processos de Montagem Industrial

Luzia Fonseca Saraiva

Trabalho de Projeto

Mestrado em Engenharia Informática - Sistemas de Informação

Trabalho efetuado sob a orientação de

Professor Doutor João Pedro Menoita Henriques

Professor Doutor José Luís Henriques da Silva

Fevereiro de 2025

*Dedico este trabalho ao homem mais sábio e bondoso que conheço, o meu querido irmão.*

*Obrigada por seres o sopro que me devolveu à vida.*



# Agradecimentos

Em primeiro lugar, o meu profundo agradecimento ao meu orientador, Prof. Dr. João Pedro Menoita Henriques, pela sua paciência, orientação e apoio incondicional ao longo deste trabalho de projeto. Os seus conselhos perspicazes foram essenciais para moldar a minha pesquisa, encorajando-me sempre a ultrapassar os meus limites. Tenho muito orgulho em citá-lo como um dos responsáveis pela minha formação. Sem ele, não teria sido possível concluir este projeto.

Agradeço ao Prof. Dr. José Henriques da Silva a oportunidade de tê-lo como orientador de Investigação e Mestrado. As suas ideias foram fundamentais para o desenvolvimento deste projeto.

Aos meus pais, José e Rosa, que, sob o sol e o trabalho árduo, fizeram-me chegar até aqui pela sombra e água fresca. Que tantas vezes renunciaram aos seus próprios sonhos para que eu e o meu irmão pudéssemos realizar os nossos. Quero que saibam que esta conquista não é apenas minha, mas nossa. Tudo o que alcancei só foi possível graças ao amor, apoio e dedicação que sempre me deram.

Ao Philippe, pelo carinho e pelo apoio em todas as horas. A sua forma de ver o mundo ajudou-me a reencontrar o equilíbrio sempre que me sentia perdida.

À Alexandra e à Ana, pela amizade inestimável e pela vossa crença em mim, mesmo nos momentos em que eu própria duvidava. O vosso apoio foi essencial.

Aos meus colegas de Mestrado, Maria e Dany, por tornarem este percurso mais alegre e enriquecedor.

Este trabalho foi financiado por Fundos Nacionais através da FCT – Fundação para a Ciência e a Tecnologia, I.P., no âmbito do projeto GreenAuto, “Green Learning System with Quality Control in Industrial Assembly Processes – Innovation for the Automotive Industry”, Ref. C644867037-00000013. Ao Prof. Dr. Serafim Oliveira, expresseo o meu reconhecimento pela sua liderança, integridade e conhecimento. O seu contributo é uma referência no projeto GreenAuto e uma fonte de inspiração profissional.

Por fim, sou grata ao meu irmão, Luís, a quem dedico este trabalho. Não foi apenas um apoio ao longo desta jornada, mas a razão pela qual ainda estou aqui para percorrê-la.



# Resumo

A procura por produtos personalizados na Indústria 4.0 resulta no aumento da complexidade das tarefas e da carga cognitiva dos trabalhadores. Estes enfrentam desafios como a necessidade de competências diversificadas, a pressão para minimizar erros e a falta de clareza nas instruções. Para responder a estas exigências, este projeto integra a *Realidade Mista* (RM) e a *Visão Computacional* (VC), aliadas à *Inteligência Artificial* (IA) para a deteção de objetos (*Object Detection* (OD)), com o objetivo de apoiar a aprendizagem dos operadores no local de trabalho e dos alunos em formação vocacional. A metodologia adotada baseia-se no desenvolvimento de dois casos de uso: a montagem de um *Cilindro Pneumático* (CP) e a inspeção da ligação de cabo de *airbag*. O sistema desenvolvido proporciona suporte interativo na execução das tarefas, facilita a formação e melhora a monitorização da produção. A aplicação prática nos casos de uso confirma a adaptabilidade do sistema a diferentes cenários de formação e de controlo de qualidade. Os resultados incluem uma precisão acima de 90% na deteção de falhas críticas, como o cabo de *airbag* desligado, e um tempo de classificação na ordem de 80 milissegundos em tempo real, o que comprova a viabilidade do método proposto.

**Palavras-Chave:** Indústria 4.0, Realidade Mista, Visão Computacional, Deteção de Objetos, Inteligência Artificial e Formação.



# Abstract

The demand for customized products in Industry 4.0 results in an increase in task complexity and the cognitive load on workers. These workers face challenges such as the need for diverse skills, pressure to minimize errors, and a lack of clarity in instructions. In order to address these requirements, this project integrates Mixed Reality and Computer Vision, combined with Artificial Intelligence for Object Detection, with the objective of supporting operators in the workplace and students in vocational training. The adopted methodology is based on the development of two use cases: the assembly of a Pneumatic Cylinder and the inspection of an airbag cable connection. The developed system provides interactive support for task execution, facilitates training, and improves production monitoring. Practical application in these use cases confirms the system's adaptability to different training and quality control scenarios. The results include accuracy above 90% in detecting critical failures, such as a disconnected airbag cable, and a classification time in the order of 80 milliseconds in real time, which confirms the feasibility of the proposed method.

**Keywords:** Industry 4.0, Mixed Reality, Computer Vision, Object Detection, Artificial Intelligence and Training.



# Índice

<b>Lista de Figuras</b>	<b>ix</b>
<b>Lista de Acrónimos</b>	<b>xiii</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Enquadramento . . . . .	1
1.2 Motivação . . . . .	3
1.3 Objetivos . . . . .	4
1.4 Contribuições . . . . .	5
1.5 Estrutura do Documento . . . . .	5
1.6 Metodologia de Investigação . . . . .	5
1.7 Sumário . . . . .	6
<b>2 Estado de Arte</b>	<b>7</b>
2.1 Metodologias de Aprendizagem em Contexto Industrial . . . . .	7
2.2 Realidade Mista . . . . .	8
2.2.1 Realidade Mista no Processo de Aprendizagem na Indústria . . . . .	9
2.3 Visão Computacional . . . . .	10
2.3.1 Classificação de Imagens . . . . .	10
2.3.2 Detecção de Objetos . . . . .	12
2.3.3 Segmentação de Imagens . . . . .	12
2.4 Avaliação do Desempenho de Modelos de Detecção de Objetos . . . . .	13
2.4.1 <i>Loss Function</i> . . . . .	13
2.4.2 Matriz de Confusão . . . . .	15
2.4.3 Métricas de Avaliação . . . . .	15
2.5 Trabalhos Relacionados . . . . .	17
2.6 Ferramentas e Tecnologias . . . . .	18
2.6.1 Unity . . . . .	18
2.6.2 You Only Look Once . . . . .	19
2.6.3 Ultralytics . . . . .	20
2.6.4 Django . . . . .	20
2.6.5 Roboflow . . . . .	21
2.6.6 MySQL . . . . .	21
2.6.7 Blender . . . . .	22
2.6.8 Magic Leap . . . . .	22
2.7 Sumário . . . . .	22

<b>3</b>	<b>Conceção</b>	<b>25</b>
3.1	Análise de Requisitos . . . . .	25
3.1.1	Descrição da Proposta . . . . .	25
3.1.2	Definição de Perfis de Utilizador . . . . .	26
3.1.3	Definição de Perfis de Projeto . . . . .	26
3.1.4	Modelos de Detecção de Objetos . . . . .	27
3.1.5	Requisitos Funcionais . . . . .	27
3.1.6	Requisitos Não Funcionais . . . . .	30
3.2	Diagramas de Casos de Uso . . . . .	30
3.2.1	Casos de Uso - Aplicação de Administração . . . . .	30
3.2.2	Casos de Uso - Aplicação de Instrução Virtual . . . . .	32
3.3	Diagrama da Base de Dados . . . . .	33
3.3.1	Utilizadores . . . . .	34
3.3.2	Projetos . . . . .	35
3.3.3	Tarefas . . . . .	36
3.4	Arquitetura da Solução . . . . .	37
3.5	Plano de Trabalhos . . . . .	39
3.6	Sumário . . . . .	40
<b>4</b>	<b>Desenvolvimento</b>	<b>41</b>
4.1	Aplicação de Administração . . . . .	41
4.1.1	Estrutura . . . . .	41
4.1.2	Registo de Novo Utilizador . . . . .	42
4.1.3	Gestão de Utilizadores . . . . .	43
4.1.4	Formação . . . . .	45
4.1.5	Gestão do Controlo de Qualidade . . . . .	50
4.2	Aplicação de Instrução Virtual . . . . .	52
4.2.1	Autenticação . . . . .	53
4.2.2	Escolher Projeto . . . . .	53
4.2.3	Executar Tarefas - Projeto Formação Vocacional . . . . .	54
4.2.4	Executar Tarefas - Formação no Trabalho . . . . .	55
4.2.5	Executar Tarefas - Monitorização do Controlo de Qualidade . . . . .	57
4.2.6	<i>Application Programming Interface</i> (API) . . . . .	58
4.3	Sumário . . . . .	59
<b>5</b>	<b>Validação e Avaliação</b>	<b>61</b>
5.1	Validação da Formação com Montagem de Cilindro Pneumático . . . . .	61
5.1.1	Formação Vocacional . . . . .	61
5.1.2	Formação no Trabalho . . . . .	64
5.1.2.1	Modelo para Identificação de Componentes Individuais do Cilindro Pneumático . . . . .	67
5.1.2.2	Modelo para Validação das Tarefas com Montagem de Cilin- dro Pneumático . . . . .	69

---

5.2	Validação do Controlo de Qualidade com Ligação de Cabo de <i>Airbag</i> . . . . .	70
5.2.1	Cabo de <i>Airbag</i> . . . . .	70
5.2.2	Modelo para Reconhecer Erro(s) da Ligação de Cabo de <i>Airbag</i> . . . . .	71
5.3	Condições Laboratoriais . . . . .	72
5.4	Avaliação do Modelo para Identificação de Componentes Individuais do Cilindro Pneumático . . . . .	72
5.4.1	Resultados do Teste: Treino com 50 Épocas <i>versus</i> 100 Épocas . . . . .	73
5.4.2	Resultados do Teste: <i>Dataset</i> com Aumentação <i>versus</i> Sem Aumentação . . . . .	74
5.4.3	Resultados do Teste: <i>Dataset</i> Balanceado 70/20/10 <i>versus</i> Aleatório . . . . .	76
5.4.4	Métricas de Desempenho Após o Treino . . . . .	78
5.5	Avaliação do Modelo para Validação das Tarefas com Montagem de Cilindro Pneumático . . . . .	80
5.5.1	Métricas de Desempenho Durante o Treino . . . . .	80
5.5.2	Métricas de Desempenho Após o Treino . . . . .	81
5.6	Avaliação do Modelo para Reconhecer Erro(s) da Ligação de Cabo de <i>Airbag</i> . . . . .	82
5.6.1	Métricas de Desempenho Durante o Treino . . . . .	82
5.6.2	Métricas de Desempenho Após o Treino . . . . .	84
5.7	Discussão . . . . .	85
<b>6</b>	<b>Conclusões</b> . . . . .	<b>89</b>
6.1	Síntese . . . . .	89
6.2	Objetivos . . . . .	90
6.3	Trabalhos Futuros . . . . .	92
<b>7</b>	<b>Anexos</b> . . . . .	<b>95</b>
7.1	Descrição de Casos de Uso - Aplicação de Instrução Virtual . . . . .	95
7.2	Descrição de Casos de Uso - Aplicação de Administração . . . . .	100
7.3	Tabelas de Entidades . . . . .	108
7.4	Fluxogramas das Principais Interações com a API . . . . .	115
7.4.1	Autenticação . . . . .	115
7.4.2	Escolher Projeto . . . . .	116
7.4.3	Executar Tarefas - Formação Vocacional . . . . .	117
7.4.4	Executar Tarefas - Formação no Trabalho . . . . .	119
7.4.5	Executar Tarefas - Monitorização do Controlo de Qualidade . . . . .	120



# Lista de Figuras

2.1	<i>Virtuality continuum</i> (imagem adaptada de [30]). . . . .	8
2.2	Arquitetura CNN para classificação de imagens. Retirada de [48] . . . . .	11
2.3	Classificação vs deteção de objetos vs segmentação de instância . . . . .	13
3.1	Diagrama de casos de uso da aplicação de administração . . . . .	31
3.2	Diagrama de casos de uso da aplicação de instrução virtual . . . . .	32
3.3	Utilizadores . . . . .	34
3.4	Projetos . . . . .	35
3.5	Tarefas . . . . .	36
3.6	Arquitetura . . . . .	37
3.7	Plano das tarefas . . . . .	40
4.1	UI de <i>login</i> . . . . .	42
4.2	UI de registo . . . . .	43
4.3	UI da gestão de utilizadores . . . . .	44
4.4	Detalhes do utilizador . . . . .	44
4.5	Utilizadores pendentes de aprovação . . . . .	44
4.6	Formulário para editar utilizador e atribuir permissões . . . . .	45
4.7	UI de formação . . . . .	45
4.8	UI de formação vocacional . . . . .	46
4.9	Criar formação vocacional . . . . .	46
4.10	UI das tarefas da formação vocacional selecionada . . . . .	47
4.11	Criar uma tarefa na formação vocacional . . . . .	47
4.12	UI da formação no trabalho . . . . .	48
4.13	Criar formação no trabalho parte 1 . . . . .	48
4.14	Criar formação no trabalho parte 2 . . . . .	49
4.15	UI das tarefas da formação no trabalho selecionada . . . . .	49
4.16	Criar uma tarefa na formação no trabalho . . . . .	50
4.17	UI do controlo de qualidade . . . . .	50
4.18	Parte 2 do formulário criar controlo de qualidade . . . . .	51
4.19	UI das tarefas do controlo de qualidade selecionado . . . . .	51
4.20	Criar uma tarefa no controlo de qualidade . . . . .	52
4.21	Execução da aplicação no HMD . . . . .	52
4.22	<i>Interface</i> de autenticação com o Magic Leap . . . . .	53
4.23	Ecrã para selecionar o projeto . . . . .	54
4.24	Execução da tarefa no contexto de formação vocacional . . . . .	55

4.25	Fase de preparação na aplicação de instrução virtual . . . . .	56
4.26	Formação no trabalho com a notificação de que a tarefa não foi corretamente cumprida . . . . .	57
4.27	O operador é alertado para a não conformidade identificada no controlo . . .	58
4.28	Operações CRUD dos projetos . . . . .	59
5.1	Peças envolvidas na montagem do CP . . . . .	62
5.2	Representação das animações criadas . . . . .	64
5.3	Visão geral do <i>dataset</i> para deteção das partes envolvidas na montagem do CP	67
5.4	<i>Piston rod</i> no conjunto de dados . . . . .	67
5.5	Complexidade da anotação pela repetitividade e ambiguidade. . . . .	68
5.6	Roboflow <i>label assist</i> . . . . .	68
5.7	Anotação da décima terceira tarefa . . . . .	69
5.8	Conjunto de dados para a validação da correta execução das tarefas de mon- tagem do CP . . . . .	70
5.9	Ficha de <i>airbag</i> desligada (a) e ligada (b) . . . . .	70
5.10	Rotulagem do cabo desligado . . . . .	71
5.11	Evolução dos componentes da função de perda nas 50 épocas (a) face às 100 (b) . . . . .	73
5.12	Comparação dos valores de <i>Mean Average Precision</i> (mAP) <sub>50</sub> para 50 épocas (a) e 100 épocas (b) . . . . .	74
5.13	Variação de <i>Bounding Box Loss</i> (box_loss), <i>Classification Loss</i> (cls_loss) e <i>Distribution Focal Loss</i> (dfl_loss) em dados não aumentados (a) e aumentados (b) . . . . .	75
5.14	Valores de mAP para dados sem (a) e com (b) técnicas de aumento . . .	76
5.15	Distribuição equilibrada do conjunto de dados após a operação de rebalanci- amento . . . . .	77
5.16	Gráficos de perda relativos ao <i>dataset</i> balanceado (a) e à divisão aleatória (b)	77
5.17	Comparação do mAP entre dados equilibrados (a) e desequilibrados (b) . . .	78
5.18	classificações dos testes com um mínimo de confiança de 0.75 (a) e um limite não definido (b) . . . . .	79
5.19	Representação das curvas de <i>precision</i> (a) e <i>recall</i> (b) . . . . .	81
5.20	Matriz de confusão durante o treino (a) e nos novos dados de teste (b) . . .	81
5.21	F1-Score no treino (a) e no teste (b) . . . . .	82
5.22	Matriz de confusão normalizada durante o treino do modelo para a identificação do cabo do <i>airbag</i> desligado . . . . .	83
5.23	Gráfico <i>F1-Confidence Curve</i> referente à avaliação do modelo de deteção nos dados de validação . . . . .	83
5.24	(a) <i>Precision-Confidence Curve</i> nos dados de validação durante o treino e (b) no conjunto de teste após a conclusão . . . . .	84
5.25	<i>Recall</i> nos dados de treino (a) e teste (b) . . . . .	85
5.26	Resultados das classificações do modelo no conjunto de teste . . . . .	85

---

5.27	Representação do erro de anotação com imagens incorretamente rotuladas como pertencentes à tarefa 12 . . . . .	86
5.28	Saída da linha de comandos com as deteções realizadas pelo modelo em tempo real . . . . .	87
5.29	Dados de desempenho do aprendiz . . . . .	87
7.1	Fluxograma da API para a autenticação . . . . .	116
7.2	Fluxograma de todos os pedidos à API durante a ação seleccionar projeto . . .	117
7.3	Fluxograma de todos os pedidos à API no decorrer da execução das tarefas .	118
7.4	Fluxograma de todos os pedidos à API na fase de preparação . . . . .	119
7.5	Fluxograma de todos os pedidos à API no decorrer da execução das tarefas .	120
7.6	Fluxograma de todos os pedidos à API ao longo do controlo de qualidade . .	121



# Lista de Acrónimos

<b>AP</b>	<i>Average Precision</i>
<b>API</b>	<i>Application Programming Interface</i>
<b>box_loss</b>	<i>Bounding Box Loss</i>
<b>CIoU</b>	<i>Complete Intersection over Union</i>
<b>cls_loss</b>	<i>Classification Loss</i>
<b>CNN</b>	<i>Convolutional Neural Network</i>
<b>CP</b>	<i>Cilindro Pneumático</i>
<b>CRUD</b>	<i>Create, Read, Update, and Delete</i>
<b>DFL</b>	<i>Distance-Focal L1</i>
<b>dfl_loss</b>	<i>Distribution Focal Loss</i>
<b>DL</b>	<i>Deep Learning</i>
<b>DRF</b>	<i>Django REST Framework</i>
<b>E-ELAN</b>	<i>Extended Efficient Layer Aggregation Networks</i>
<b>ER</b>	<i>Entidade-Relacionamento</i>
<b>FN</b>	<i>False Negative</i>
<b>FP</b>	<i>False Positive</i>
<b>FPS</b>	<i>Frames Processados por Segundo</i>
<b>HMD</b>	<i>Head Mounted Display</i>
<b>HTTP</b>	<i>HyperText Transfer Protocol</i>
<b>IA</b>	<i>Inteligência Artificial</i>
<b>ILT</b>	<i>Instructor-Led Training</i>
<b>IoU</b>	<i>Intersection over Union</i>
<b>IPV</b>	<i>Instituto Politécnico de Viseu</i>
<b>IR</b>	<i>Image Recognition</i>

<b>mAP</b>	<i>Mean Average Precision</i>
<b>ML</b>	<i>Machine Learning</i>
<b>MRTK</b>	<i>Mixed Reality Toolkit</i>
<b>OD</b>	<i>Object Detection</i>
<b>OpenCV</b>	<i>Open Source Computer Vision Library</i>
<b>RA</b>	<i>Realidade Aumentada</i>
<b>REST</b>	<i>Representational State Transfer</i>
<b>RM</b>	<i>Realidade Mista</i>
<b>RV</b>	<i>Realidade Virtual</i>
<b>SDK</b>	<i>Software Development Kit</i>
<b>SSD</b>	<i>Single Shot MultiBox Detector</i>
<b>TN</b>	<i>True Negative</i>
<b>TP</b>	<i>True Positive</i>
<b>UI</b>	<i>User Interface</i>
<b>VC</b>	<i>Visão Computacional</i>
<b>VFL</b>	<i>Varifocal Loss</i>
<b>YOLO</b>	<i>You Only Look Once</i>

## Capítulo 1

# Introdução

Este capítulo faz uma introdução ao projeto com o enquadramento, explica a motivação e apresenta os objetivos. Posteriormente, aprofunda as contribuições, descreve a estrutura do documento e conclui com a metodologia de investigação.

### 1.1 Enquadramento

A crescente procura por produtos personalizados tem transformado a produção em massa, anteriormente caracterizada por linhas de montagem onde o mesmo item era fabricado de forma repetitiva e em grandes lotes, para uma abordagem que prioriza a produção de pequenas quantidades de diversos itens [1]. A montagem de produtos personalizados implica um aumento da complexidade nas operações de montagem. Apesar de a Indústria 4.0 ser descrita por Dombrowski et al. [2] como uma “rede digital inteligente, composta por pessoas, equipamentos e objetos, destinada a gerir processos de negócios e redes de criação de valor”, as máquinas, embora facilitem o processo produtivo, não eliminam a necessidade de flexibilidade e adaptabilidade dos operadores humanos na montagem manual. Isto significa que, embora os sistemas automatizados contribuam para a agilização da produção, enfrentam dificuldades em executar atividades que vão além do seu escopo predefinido, uma vez que lhes falta a criatividade e a capacidade de operar com diversas ferramentas e equipamentos, ao contrário dos seres humanos [1]. Devido a esta situação, a montagem manual continua a ser relevante e assume um papel ainda mais destacado no contexto atual, que tende, no futuro, a promover uma colaboração entre o homem e a máquina, em vez da substituição do elemento humano. Pelo contrário, o ser humano terá um papel central nas atividades industriais da quinta revolução industrial, segundo Adel [3].

O operador de montagem é o profissional que enfrenta, de forma direta, as consequências da produção de produtos personalizados. Este tipo de produto resultou num aumento significativo da complexidade da montagem manual. Segundo Miqueo et al. [4], “A montagem é o processo final para criar um produto, no qual os componentes são reunidos para formar o produto final”. Contudo, a montagem vai além da simples sequência de operações. O operador deve também interpretar novas informações, resolver problemas, gerir interações sociais, priorizar tarefas e aprender continuamente no seu ambiente de trabalho [5]. A coordenação de diversas operações complexas revela-se cognitivamente exigente e resulta no aumento da taxa de falhas.

A deteção tardia de erros causa frustração nos profissionais de montagem entrevistados por Wollter Bergman et al. [5], que se veem obrigados a efetuar ajustes em processos já atrasados. Essas falhas aumentam a pressão, intensificam a carga de trabalho e resultam em horas extraordinárias, o que gera uma perceção de falha coletiva, designada pelos próprios como “cultura de culpa”. Essa sensação agrava-se quando o trabalhador recebe montagens incorretas das fases anteriores. Adicionalmente, a prática de deslocar operadores entre linhas, principalmente para substituir colegas ausentes por doença, pode representar um desafio. A inexperiência no novo contexto, agravada pela diversidade de competências exigidas e pela versatilidade atualmente necessária nas linhas de montagem, reforça a importância da formação em contexto laboral. A aquisição das competências adequadas e a disponibilização de tempo suficiente para a execução das tarefas são requisitos essenciais para um bom fluxo de trabalho, principalmente em atividades recém-introduzidas [5]. A necessidade de “ganhar” tempo e preparação tem incentivado investigações sobre a adoção de novas tecnologias, como a *Realidade Aumentada* (RA), no âmbito da formação.

A revisão de Chiang et al. [6] destaca as várias vantagens da RA no treino vocacional, definido como “programas educacionais concebidos para que os formandos adquiram conhecimentos, competências e aptidões específicos de uma profissão”. Entre esses benefícios destacam-se a redução do tempo necessário para a formação, a diminuição da taxa de erros, a oferta de *feedback* imediato, a melhoria do desempenho, a redução da carga cognitiva, o aumento da motivação para aprender, o impacto positivo na memória a longo prazo, o aperfeiçoamento das competências de montagem e a simplificação de manuais de formação complexos. O último aspeto é crucial, pois responde à dificuldade em interpretar orientações em papel, referida em [5]. Esses documentos dificultam a compreensão sobre o movimento de determinados componentes e encontram-se frequentemente desatualizados.

Ainda que a RA tenha várias funcionalidades, a *Realidade Mista* (RM) destaca-se por as expandir. Utilizada com o *Head Mounted Display* (HMD), a RM permite a integração e interação de elementos virtuais com o mundo real, criando um ambiente onde objetos físicos e digitais coexistem e se influenciam mutuamente em tempo real. Este tipo de tecnologia facilita a aprendizagem por meio da interatividade e imersão, promovendo a adaptação e a criatividade dos aprendizes em contextos educacionais dinâmicos [7].

Com o intuito de apoiar os funcionários na resolução dos problemas identificados, propõe-se a integração da RM e da *Visão Computacional* (VC), numa solução de formação e controlo de qualidade. Ao combinar essas tecnologias, visa-se não só melhorar a precisão e a eficiência

na montagem de componentes, mas também contribuir para o bem-estar dos operadores, reduzindo as suas frustrações causadas pelo cenário atual descrito.

O presente trabalho de projeto enquadra-se no âmbito da agenda “GreenAuto: Inovação Verde para a Indústria Automóvel”, cofinanciada pelo Plano de Recuperação e Resiliência Português (referência C644867037-00000013). A sua finalidade é posicionar a indústria automóvel nacional na cadeia de valor dos veículos de baixas emissões, através da conceção de produtos inovadores. Liderada pela Peugeot Citroën Automóveis Portugal, SA (Stellantis Mangualde), a iniciativa conta com a colaboração de 37 entidades, incluindo o *Instituto Politécnico de Viseu* (IPV) [8]. A participação do IPV centra-se no desenvolvimento de sistemas de orientação de operadores com RA (PPS 15), integrado no *work package* 9, dedicado ao controlo de qualidade [9]. Um dos casos de uso desenvolvidos neste trabalho é a ligação de cabos de *airbag* no contexto automóvel, uma situação crítica reportada pelos funcionários da Stellantis Mangualde.

## 1.2 Motivação

Na secção anterior, foram identificadas as principais dificuldades enfrentadas pelos trabalhadores, nomeadamente: o aumento da complexidade das tarefas, a exigência de competências diversificadas, a pressão para evitar erros e a falta de clareza nas instruções. Em [5], concluiu-se que, para superar estas dificuldades, é essencial que os trabalhadores estejam adequadamente preparados, treinados, equipados e motivados para executar corretamente as tarefas de montagem.

Miqueo et al. [4] evidenciaram a necessidade urgente de apoiar os trabalhadores e recomendam a adoção de soluções que integrem a RA, devido à sua eficácia comprovada. Esta sugestão é reforçada tanto por Dolgui et al. [10], que demonstram que a RA pode servir de suporte direto na execução de tarefas, como por Chiang et al. [6], que indicam a sua aplicação na educação e no treino pré-laboral. Além disso, a sua utilização revela-se igualmente promissora na superação de desafios operacionais, como o efeito de “atenção dividida”. Quando os operadores seguem instruções em formato papel, são obrigados a alternar a atenção entre a análise das instruções e a execução das tarefas, o que aumenta significativamente a carga cognitiva. A RA, ao sobrepor as informações diretamente no local da peça, elimina esta alternância e, conseqüentemente, reduz tanto o esforço mental como promove a eficiência [11].

Um aspeto que despertou especial interesse e motivação para este projeto foi o testemunho dos operadores em Wollter Bergman et al. [5], onde, apesar de expressarem satisfação com a supervisão dos tutores como método de aprendizagem, também revelaram que se esforçam para apoiar os colegas, refletindo o seu espírito de união e colaboração. No entanto, para o fazerem, trabalham a um ritmo superior ao habitual, o que, a longo prazo, pode prejudicar o seu bem-estar. Essa circunstância evidencia a necessidade de maior assistência e apoio na aprendizagem no local de trabalho. A falta de acompanhamento é ainda agravada, segundo Alessa et al. [12], pela escassez de assistência especializada, frequentemente condicionada por restrições de tempo, recursos financeiros e acesso. Por conseguinte, a rotação de

trabalhadores e a introdução de atividades evidenciam a necessidade de formação contínua para garantir a flexibilidade operacional.

A aprendizagem, nesse contexto, assume um papel essencial na mitigação dos desafios identificados. Hercog et al. [13] destacam a necessidade de criar uma força de trabalho polivalente, capaz de desempenhar múltiplas tarefas, ou de investir em sistemas de apoio aos trabalhadores. Com o objetivo de fortalecer o desenvolvimento de competências e assegurar a execução precisa das tarefas sem exigir longos períodos de aprendizagem, este estudo pretende avançar a investigação sobre a visão inovadora de “ambiente de formação zero” [14], estabelecendo um novo padrão de eficiência operacional e evolução na formação industrial.

Complementarmente, a introdução de sistemas que automatizem a deteção de falhas surge como uma solução determinante para evitar erros que, quando identificados em fases avançadas, podem gerar frustração nos operadores, acarretar custos significativos para a empresa e comprometer a imagem do fabricante, especialmente se forem detetados após a comercialização [15]. Ao minimizar estas consequências, tais sistemas não só melhoram a qualidade dos produtos, como também reforçam a competitividade no mercado.

### 1.3 Objetivos

O objetivo principal do projeto é aumentar a eficiência nos processos de produção industrial. Este objetivo pode ser decomposto nos seguintes objetivos:

1. Centralizar as orientações para a execução das tarefas e os dados dos utilizadores num único sistema. Os manuais de montagem existentes são excessivamente extensos e complexos, ou as instruções em papel carecem de clareza. A criação de uma solução que apresente orientações claras, atualizadas, e que permita a intervenção dos utilizadores constituiria uma mais-valia significativa.
2. Apoiar o operador na sequência de montagem. As instruções para tarefas de manutenção, tradicionalmente, são disponibilizadas em papel e acompanhadas por assistência especializada. No entanto, restrições de tempo, disponibilidade e custo podem limitar essa assistência. Deste modo, surge a necessidade de um sistema que proporcione formação vocacional e, simultaneamente, formação no local de trabalho, particularmente para novos trabalhadores ou aqueles que enfrentam tarefas complexas e novos processos de montagem.
3. Identificação autónoma de falhas durante o processo produtivo. Os erros detetados tardiamente, especialmente numa sequência de montagem ou em componentes específicos, podem provocar frustração nos operadores, resultar em custos para a empresa e até causar danos à reputação do fabricante, principalmente se forem identificados apenas no pós-venda.
4. Melhorar a gestão de utilizadores, projetos e tarefas com uma aplicação para administradores, baseada numa *User Interface* (UI) intuitiva e numa *Application Programming Interface* (API) bem estruturada.

## 1.4 Contribuições

Este trabalho descreve as seguintes contribuições:

1. Identificar, no contexto industrial, cenários onde a RM e a VC podem ser utilizadas como ferramentas de suporte.
2. Desenvolver um protótipo operacional para o HMD, que disponibilize ao operador instruções precisas para a montagem de produtos em bancadas de trabalho especializadas.
3. Implementar a VC para validar cada fase do processo de montagem, de modo a garantir a execução correta das tarefas.
4. Conceber uma aplicação de gestão de projetos e tarefas, para funcionários, e desenvolver uma API que assegure a comunicação efetiva com a aplicação integrada no HMD;
5. Estabelecer sistemas de alerta para detetar desvios nos procedimentos operacionais e permitir a sua correção de imediato.
6. Recolher dados sobre o tempo de execução das tarefas e a ocorrência de erros, para criar uma base que suporte a melhoria contínua dos métodos produtivos.

## 1.5 Estrutura do Documento

Este documento está organizado em sete capítulos. No presente capítulo, introduz-se o tema. O Capítulo 2 expõe o estado de arte. O Capítulo 3 aborda a conceção. O Capítulo 4 descreve o desenvolvimento do sistema. O Capítulo 5 examina os resultados. O Capítulo 6 apresenta as conclusões e o último detalha os conteúdos suplementares.

## 1.6 Metodologia de Investigação

A metodologia de investigação desempenha um papel crucial na identificação e formulação do problema a resolver. A seleção criteriosa dos trabalhos relacionados contribui para a fundamentação teórica necessária para as etapas subsequentes.

No período inicial da investigação foi feita uma pesquisa bibliográfica, direcionada para artigos científicos, livros e revistas que abordam o tema do meu estudo. As palavras-chave selecionadas pela sua direta relevância com o problema de investigação são: “Indústria 4.0”, “Realidade Mista”, “Visão Computacional”, “Detecção de Objetos” e “Formação”. Para a seleção do material, adotei como critérios o número de citações, conferências reconhecidas e a indexação em bases de dados de prestígio.

De modo a abranger mais fontes optou-se por usar várias bases de dados de pesquisa académica, como b-on [16], MDPI [17], IEEE [18] e ScienceDirect [19].

## 1.7 Sumário

Este capítulo introduziu o tema do trabalho, enquadrou os desafios associados à personalização na indústria e as suas implicações na montagem manual, como o aumento da complexidade e da exigência cognitiva sobre os operadores. Apresentou a motivação, os objetivos e as principais contribuições. Por fim, expôs a estrutura geral do documento.

O capítulo seguinte apresenta o estado de arte, com a análise das tecnologias e abordagens relevantes para este projeto.

## Capítulo 2

# Estado de Arte

Neste capítulo realiza-se o estado de arte, concentrando-se em áreas essenciais como a RM e a VC. Explora-se o impacto destes conceitos na dinâmica industrial, com ênfase nas suas aplicações, desafios e contributos significativos, o que estabelece uma base teórica forte para este estudo. Abordam-se ainda as métricas de desempenho de modelos de *Object Detection* (OD), os trabalhos relacionados e as ferramentas e tecnologias relevantes.

### 2.1 Metodologias de Aprendizagem em Contexto Industrial

A abordagem tradicional consiste na transmissão direta de conhecimento e recorre a aulas teóricas, estudo de manuais técnicos e treino prático sob supervisão. Estes métodos favorecem a aquisição de competências específicas e a adesão a normas de segurança, sendo amplamente aplicado em áreas técnicas, como a formação de eletricistas industriais [20]. No entanto, apresenta fragilidades, como a ênfase na memorização a curto prazo, a aprendizagem mecânica e a desconexão entre teoria e prática. Essas limitações restringem a participação ativa dos aprendizes, a sua capacidade de desenvolver pensamento crítico, a adaptabilidade em situações que exigem originalidade e a resolução de problemas complexos [21].

Por outro lado, as metodologias modernas destacam-se pela introdução de tecnologias inovadoras que promovem um ambiente de aprendizagem mais dinâmico e colaborativo. O e-learning, implementado pela General Electric através da plataforma GE Digital Learning, possibilita o acesso flexível a conteúdos formativos [22]. A *Realidade Virtual* (RV), utilizada pela Ford para simulações de montagem e formações de segurança, permite executar práticas realistas sem riscos físicos [23]. A Siemens recorre à gamificação para treinar os colaboradores nas áreas da gestão de energia e automação, através de jogos educativos que replicam decisões estratégicas [24]. O modelo de aprendizagem mista da Bosch reforça a

consolidação do conhecimento em contexto real através da combinação de aulas *online* com sessões práticas presenciais [25]. A Toyota integra a RM com o Microsoft HoloLens 2 na formação para simular processos avançados sem interromper a produção [26]. A análise da revista Training Industry para as tendências de 2024 revela como prioridades de investimento o desenvolvimento de liderança, o *Instructor-Led Training* (ILT) e as novas tecnologias de aprendizagem [27]. Este panorama reforça a importância do ILT, que, com o recurso à RM, amplia as possibilidades do treino prático e proporciona uma formação mais eficaz e versátil.

As metodologias modernas de aprendizagem, que privilegiam abordagens ativas e centradas no aluno, podem ser complementadas pelos princípios da filosofia *Lean*. Criada pela Toyota o seu grande sucesso deve-se os seus benefícios na eliminação de desperdícios, como tempos de espera e deslocações desnecessárias [28]. Segundo Bauer et al. [29], a integração dos princípios *Lean*, tais como a remoção de atividades que não agregam valor e a promoção da melhoria contínua, é frequentemente considerada uma transformação indispensável para viabilizar a adoção dos paradigmas da Indústria 4.0. Como facilitador da aprendizagem moderna, podem ser incorporados os seus princípios de Just-in-Time (no momento certo) e Kaizen (melhoria contínua). A primeira filosofia permite que os alunos acessem ao conhecimento no momento exato em que precisam, ou seja, o conhecimento certo, atualizado e relevante deverá estar disponível assim que necessário, sem desperdício de tempo. Já o Kaizen pode ser aplicado de forma conceptual ao garantir que os processos de ensino se ajustam continuamente às necessidades dos aprendizes. Para tal é importante a participação ativa dos próprios alunos na sugestão de melhorias para aperfeiçoar o processo.

## 2.2 Realidade Mista

A RM é a sobreposição de elementos virtuais ao ambiente real, com capacidade de interagir com esses elementos. Milgram and Kishino [30] formalizaram esse conceito como uma posição intermédia num “*virtuality continuum*” (contínuo da virtualidade), um modelo teórico que representa a transição entre ambientes físicos e digitais, conforme ilustrado na Figura 2.1. Num extremo, encontra-se o ambiente real com elementos virtuais complementares, designado como RA. No limite oposto, situa-se um ambiente totalmente digital, onde encontra-se a RV. A RM situa-se entre estes dois pontos, com a combinação de componentes reais e digitais, onde é possível atuar diretamente sobre os elementos inseridos no ambiente, sem perder o contacto com o espaço físico.




Figura 2.1: *Virtuality continuum* (imagem adaptada de [30]).

A sua aplicação na indústria está a expandir-se, abrangendo diversas áreas, como os processos de aprendizagem [Guo, 2015] e ambientes de montagem para orientar os trabalhadores [31]. Este crescimento deve-se à capacidade da tecnologia em proporcionar visualizações em tempo real, simulação e interação. Quando implementada no HMD, a RM permite aos utilizadores visualizar informações e manter as mãos livres, proporcionando uma vantagem distinta em comparação com o uso de *tablets* e *smartphones*.

A RM desempenha um papel central neste trabalho, ao proporcionar instruções visuais claras e *feedback* imediato aos operadores durante o processo de montagem. Este recurso facilita a aprendizagem, melhora a execução das tarefas industriais, reduz erros e aumenta a precisão.

### 2.2.1 Realidade Mista no Processo de Aprendizagem na Indústria

A RM tem-se afirmado como um vetor de transformação na capacitação industrial, que transcende os métodos convencionais de formação. Esta secção debruça-se sobre os casos em que a RM promove a aprendizagem na indústria.

A implementação da RM possibilita a criação de ambientes formativos, nos quais a interação palpável entre os elementos virtuais e físicos nutre os formandos de aptidões especializadas, como, por exemplo, a operação de máquinas. Tal imersão, num contexto tridimensional, não só facilita a compreensão de ações complexas, como também reforça a memorização de informação técnica. Isto ocorre porque uma experiência direta tende a ter um impacto mais profundo, comparativamente às abordagens passivas de ensino (notas em papel) [32].

Na aviação, a Boeing integrou a RM na formação dos seus mecânicos e técnicos. Através de instruções visuais, passo a passo, conseguiram retirar vários proveitos a seu favor, como: melhorar a manutenção, reduzir o tempo de treino e diminuir o número de erros cometidos [33]. Já no âmbito automóvel, a Ford Motor Company utiliza o HMD HoloLens da Microsoft [34] no *design* de veículos. Desta forma, os profissionais conseguem visualizar as alterações na aparência em tempo imediato, o que agiliza a tomada de decisão [35].

Ademais, a RM é capaz de amplificar a disseminação do conhecimento com a assistência remota em tarefas procedimentais, isto é, os peritos, mesmo que estejam em diferentes localizações, têm agora a possibilidade de colaborar com os aprendizes como se estivessem no mesmo espaço físico [36]. A Porsche aplica este conceito para auxiliar e treinar os técnicos de serviço. Com recurso ao HMD, os técnicos recebem assistência visual de forma imediata, o que facilita a execução de atividades difíceis e, ainda, reduz a dependência de manuais convencionais [37].

Nogueira [38] enriquece a investigação da RM como meio para otimizar os processos de montagem industrial. Para isso, recorre a uma análise dos dados de produção e seleciona ferramentas da Power Platform da Microsoft, como o Power BI, Power Apps e Power Automate, bem como o software Microsoft Dynamics 365 Guides. Apesar dos avanços, o autor identifica a incapacidade desses *softwares* para detetar erros e fornecer alertas. Esta carência é particularmente relevante no contexto de formação no local de trabalho, onde a deteção e correção imediata de erros são essenciais para a eficácia da aprendizagem. O estudo sugere o potencial de plataformas como Unity [39] ou Unreal [40] em futuras implementações.

A criação de um ambiente de aprendizagem seguro é outra das grandes vantagens desta tecnologia. A Audi faz uso desse benefício ao simular os processos de montagem, o que permite aos trabalhadores treinarem tarefas específicas num contexto seguro, antes de as executarem na linha de montagem [41]. Também a Honeywell explora a RM em cenários de alto risco, simulando ambientes controlados de plantas químicas e refinarias para formar os seus funcionários [42]. Esta metodologia prepara-os eficazmente para emergências e reforça a sua capacidade de resposta, sem os expor a perigos reais.

Palmarini et al. [43] propuseram a criação de procedimentos de manutenção para técnicos não especialistas. Utilizaram como ferramentas o Vuforia e Unity 3D. Esse método permitiu sobrepor objetos virtuais sobre os reais, animando-os para indicar a posição e as orientações corretas. Futuramente, os autores querem explorar novas tecnologias especializadas na OD e enunciam como oportunidade a identificação de erros de montagem e desmontagem, com a finalidade de orientar com exatidão os utilizadores. Já o estudo posterior de [44] investiga a inspeção de qualidade em tempo real durante os processos de montagem, valendo-se da RM e da VC. Como coautora, contribuí para o desenvolvimento de um sistema que integra o vídeo do HMD Hololens com um servidor de reconhecimento de imagens (*Image Recognition* (IR)) para a deteção de defeitos. O *feedback* instantâneo, com hologramas, facilita a correção atempada de qualquer desvio. Este estudo demonstra e valida a importância da combinação das duas tecnologias na indústria. Para trabalhos futuros, identifica-se o potencial da validação da sequência de montagem dos componentes, com o objetivo de melhorar a qualidade do produto final, o que está alinhado com um dos principais objetivos deste projeto final de mestrado.

## 2.3 Visão Computacional

A VC investiga como as máquinas podem interpretar imagens e vídeos de forma semelhante à visão humana. Este campo inclui o IR, que se divide em três áreas principais: classificação de imagens, OD e segmentação de imagens. Estas enfrentam desafios como a complexidade dos dados e a elevada demanda computacional. No entanto, a área tem evoluído rapidamente, com o surgimento de novas soluções para superar esses obstáculos [45]. Nas secções seguintes, explora-se como cada uma é fundamental para a análise e interpretação avançada dos dados visuais.

No presente projeto a VC desempenha um papel fundamental na validação de cada etapa do processo de montagem e na identificação automática das peças necessárias para a preparação inicial do trabalho. Além disso, é utilizada no controlo de qualidade para detetar falhas que exigem a intervenção do operador e, assim, assegurar a conformidade com os padrões estabelecidos.

### 2.3.1 Classificação de Imagens

A classificação de imagens é uma das principais tarefas na VC. Consiste em identificar a categoria ou classe à qual uma imagem pertence.

Yann LeCun, desempenhou um papel fundamental ao demonstrar que, no seu estudo em 1998, as *Convolutional Neural Network* (CNN) eram altamente eficazes na classificação de dígitos escritos à mão [46]. As CNN são um tipo de rede neural de *Deep Learning* (DL), notáveis na área de *Machine Learning* (ML) pela sua capacidade de extrair automaticamente recursos de alto nível a partir de dados brutos de entrada. Especializadas no tratamento de dados estruturados em matriz, como imagens, as CNN distinguem-se pela sua habilidade em identificar e aprender autonomamente características hierárquicas complexas dos dados, tornando-as altamente eficazes em tarefas de VC e processamento de imagens [47].

A Figura 2.2 ilustra a estrutura CNN projetada para a classificação de imagens. Esta é composta por várias camadas, incluindo camadas convolucionais, camadas de *pooling* e camadas totalmente conectadas. Nas camadas convolucionais, a CNN utiliza múltiplos filtros (*kernels*) para analisar a imagem e criar diversos mapas de características intermediárias, que destacam diferentes aspectos da imagem. As camadas de *pooling* são responsáveis por reduzir as dimensões dos mapas de características, economizando recursos computacionais. Ao final da CNN, encontram-se as camadas totalmente conectadas, que funcionam como um classificador. Essas camadas processam as informações extraídas anteriormente e geram uma saída que pode ser usada para a classificação de imagens [48]. Alternativamente, essa saída pode ser transferida para redes neurais profundas subsequentes, para tarefas mais avançadas de processamento de imagens, como OD, rastreamento visual, segmentação semântica e restauração de imagens.

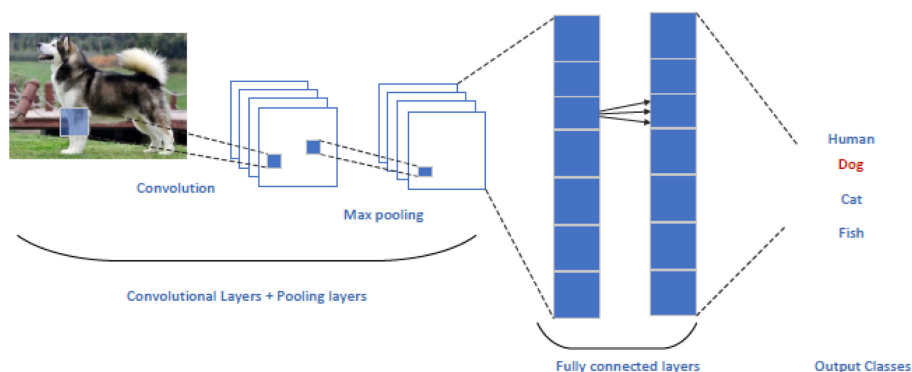


Figura 2.2: Arquitetura CNN para classificação de imagens. Retirada de [48]

A competição *ImageNet Large Scale Visual Recognition Challenge* desempenhou um papel crucial no impulso ao desenvolvimento das redes neurais, ao tirar partido do aumento da capacidade de processamento das unidades de processamento gráfico (GPU) [49]. Alex Krizhevsky, o autor da arquitetura “AlexNet”, notabilizou-se ao vencer essa competição em 2012 [50]. Essa vitória foi uma demonstração impressionante do potencial das CNN na tarefa de classificação de imagens, desencadeando um rápido desenvolvimento de redes mais profundas e eficazes. Após esse marco, surgiram notáveis CNN, como a arquitetura “GoogLeNet” [51], “VGG Net” [52] e “ResNet” [53].

### 2.3.2 Detecção de Objetos

A tarefa de OD vai além da simples classificação de imagem, pois não se limita apenas a identificar a classe à qual um objeto pertence, mas também envolve a determinação precisa de sua localização na imagem. Portanto, a OD é composta por duas etapas distintas. A primeira fase é a classificação, que consiste em identificar a classe à qual o objeto pertence e fornecer a probabilidade associada a essa classificação. A segunda tarefa é a localização, que envolve a determinação exata da posição do objeto na imagem, geralmente representada por meio de uma caixa delimitadora com rótulos correspondentes.

Os métodos de OD convencionais são divididos em duas abordagens: estágio único e dois estágios. A abordagem de dois estágios primeiro identifica os locais a serem considerados, criando um conjunto inicial de caixas delimitadoras na imagem. Em seguida, uma segunda rede é usada para classificar e ajustar a localização precisa dos objetos dentro dessas regiões delimitadas. Um exemplo representativo desta abordagem é a série *Regions with Convolutional Neural Networks* (R-CNN), que ilustra esta metodologia através da combinação de regiões selecionadas com CNN. Por outro lado, a abordagem de estágio único aplica uma única rede neural para gerar diretamente detecções em vários locais na imagem, sem a necessidade de uma etapa prévia de geração de regiões propostas. *Single Shot MultiBox Detector* (SSD) [54], a família *You Only Look Once* (YOLO) [55, 56, 57] e RetinaNet [58] são exemplos de estágio único. O método de estágio único torna a detecção mais rápida, mas geralmente resulta numa precisão de detecção um pouco inferior em comparação com a abordagem de dois estágios [59].

A OD é empregue neste projeto para identificar e contar os componentes necessários ao processo de montagem, bem como para detetar falhas no controlo de qualidade. Este método permite verificar a presença e o número exato de peças, ao contrário da classificação, que apenas categoriza a imagem como um todo.

### 2.3.3 Segmentação de Imagens

A segmentação de imagens divide uma imagem em várias regiões homogêneas para facilitar a sua análise [45]. As CNN são predominantemente aplicadas na segmentação semântica de imagens. O Mask R-CNN melhora a OD adicionando um mapa binário para cada píxel (a menor unidade de uma imagem) [60]. O DeepLabv3+ une estruturas encoder-decoder e redes neurais profundas para detalhar contornos de objetos [61]. O U-Net e suas variantes, como o LU-Net, são aplicados na segmentação de imagens médicas, permitindo uma detecção precisa mesmo com poucos dados [48].

A segmentação pode ser separada em dois tipos: semântica e de instância. A segmentação semântica atribui a cada ponto da imagem uma classe, sem distinguir os objetos individuais da mesma categoria. Por outro lado, a segmentação de instância não só classifica as regiões, como também identifica e separa os elementos distintos, o que permite contá-los e diferenciá-los, mesmo quando estes se sobrepõem [62].

A abordagem por instâncias é aplicada neste trabalho para anotar o conjunto de dados associado ao modelo de validação de tarefas. Este método permite a separação e a delimitação

precisa das regiões correspondentes aos objetos de cada classe, com o objetivo de proporcionar um nível de detalhe superior ao alcançado pela detecção.

A Figura 2.3, exemplifica cada tarefa de reconhecimento. Inicialmente, na classificação, somos capazes de identificar o que está presente na imagem por meio da classe *Cilindro Pneumático* (CP). Na tarefa de OD, não apenas identificamos a presença de um CP, mas também determinamos a sua localização, representada por uma caixa delimitadora, o que restringe a área da imagem que contém o objeto. Por fim, a segmentação de instância fornece informações detalhadas sobre os pixels que representam o objeto na imagem e permite diferenciá-lo de outros objetos da mesma classe, o que garante uma representação precisa da sua posição e dos seus contornos.




Figura 2.3: Classificação vs detecção de objetos vs segmentação de instância

## 2.4 Avaliação do Desempenho de Modelos de Detecção de Objetos

Nesta secção, são apresentadas a *loss function* (função de perda), a matriz de confusão e as métricas de avaliação, essenciais para avaliar o desempenho de modelos em tarefas de OD. A *loss function* orienta o processo de otimização durante o treino, ao alinhar as previsões com os resultados reais de forma contínua. Já as métricas, como *precision* e *recall*, são aplicadas posteriormente para medir a *performance*. Esses valores são calculados com base na matriz de confusão.

### 2.4.1 Loss Function

A função de perda mede o erro entre as previsões e os resultados reais. Valores menores indicam previsões mais precisas. Durante o treino, algoritmos como o *Gradient Descent* ajustam iterativamente os parâmetros para minimizar esse erro [63]. É composta pela *box\_loss*, *cls\_loss* e *dfl\_loss*, detalhadas em seguida:

- *Bounding Box Loss*

Responsável por melhorar o posicionamento e as dimensões das caixas delimitadoras em torno dos objetos detetados, ao calcular o desvio entre a área obtida e a verdade fundamental (*ground truth*). Aplica a métrica *Complete Intersection over Union* (CIoU), que considera a sobreposição entre a região prevista e a real, a distância euclidiana entre os seus centros e a proporção entre as respetivas dimensões (largura e altura). O cálculo do CIoU é dado pela fórmula:

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b_{\text{gt}})}{c^2} + \alpha v \quad (2.1)$$

Onde  $b$  e  $b_{\text{gt}}$  correspondem, nessa ordem, ao ponto central da delimitação estimada e do *ground truth*;  $\rho$  é a distância euclidiana entre esses pontos;  $c$  refere-se à diagonal que abrange as áreas fechadas de ambas as regiões;  $\alpha$  é um coeficiente de ajuste; e  $v$  representa a similaridade entre as proporções de largura e altura. [64]

Assim, valores menores de `box_loss` indicam que a identificação do modelo está mais próxima da posição correta do objeto.

- **Classification Loss**

Verifica a capacidade do modelo de atribuir corretamente a classe correspondente a cada objeto detetado. Esta componente é calculada com a *Varifocal Loss* (VFL), uma função de entropia cruzada ajustada que penaliza previsões incorretas e dá maior peso àquelas com maior probabilidade de acerto. É definida pela equação 2.2, em que  $q$  representa o *Intersection over Union* (IoU) entre a *bounding box* prevista e o (*ground truth*); o IoU corresponde à área de interseção entre as caixas, dividida pela área de união das duas. O parâmetro  $p$  refere-se à pontuação de confiança, ou seja, à probabilidade atribuída. [65]

$$L_{\text{cls}} = \begin{cases} -q \cdot (q \log(p) + (1 - q) \log(1 - p)), & q > 0 \\ -\alpha p^\gamma \log(1 - p), & q = 0 \end{cases} \quad (2.2)$$

Quanto menor for o valor do `cls_loss`, maior será a fiabilidade na classificação.

- **Distribution Focal Loss**

Ajusta as previsões com maior precisão ao atribuir mais peso às amostras mais desafiadoras, o que facilita a sua aprendizagem. Enquanto a `cls_loss` ajuda o modelo a identificar as categorias de objetos e a `box_loss` garante caixas delimitadoras precisas, o *Distance-Focal L1* (DFL) melhora ainda mais o desempenho, concentrando-se em exemplos difíceis de detetar ou ambíguos. Para isso ser possível, o seu cálculo (2.3), que incorpora o `dfl_loss`, representa a posição da caixa como uma distribuição geral e ajusta, com base no rótulo  $y$  que indica a posição correta, as probabilidades das suas margens através de uma função que concentra os valores previstos próximos dos verdadeiros. [64]

$$\text{DFL}(S_i, S_{i+1}) = -(y_{i+1} - y) \log(S_i) + (y - y_i) \log(S_{i+1}) \quad (2.3)$$

### 2.4.2 Matriz de Confusão

A matriz de confusão permite avaliar a precisão e os erros cometidos por um modelo na OD num determinado conjunto de dados [66]. Trata-se de uma tabela, exemplificada em 2.1, que se organiza em quatro componentes principais, descritos abaixo.

Tabela 2.1: Exemplo de Matriz de Confusão

Previsto	Real	
	Positivo	Negativo
Positivo	TP	FN
Negativo	FP	TN

- **True Positive (TP):** instâncias em que o modelo prevê corretamente a classe “Positivo”.
- **True Negative (TN):** classificações corretas da categoria “Negativo”.
- **False Positive (FP):** regista-se quando um elemento é atribuído incorretamente a uma determinada classe.
- **False Negative (FN):** acontece quando um objeto real não é detetado.

O Ultralytics YOLO incorpora funcionalidades para produzir este tipo de representações, com o objetivo de permitir que o utilizador identifique os problemas nas diversas classes [67].

As métricas apresentadas na Subsecção 2.4.3 derivam dos valores da matriz de confusão.

### 2.4.3 Métricas de Avaliação

Existem várias métricas para medir o desempenho de um modelo de VC. Segundo Kaur and Singh [68], a *Average Precision (AP)* é a mais frequentemente aplicada. A OD tem como objetivo identificar com elevada confiança a localização de elementos em imagens, através de áreas delimitadas.

A confiança (*confidence score*) é uma medida atribuída pelos modelos que indica a probabilidade estimada de uma classificação estar correta. Apenas predições com um nível de confiança superior a um *threshold* predefinido, ou seja, um valor mínimo a partir do qual uma classificação é considerada válida, são aceites. Caso contrário, são rejeitadas, o que influencia as taxas de FP e FN [69]. Cada identificação inclui a classe do objeto, a respetiva caixa delimitadora e uma pontuação de confiança entre 0 e 1.

A avaliação consiste em comparar as áreas reais, que representam a localização verdadeira dos objetos, com as áreas preditas pelo modelo, para analisar o grau de correspondência entre ambas [70]. A terminologia dos indicadores mais comuns utilizados na medição da precisão dos algoritmos de OD é explicada abaixo:

- **Precision**

A *precision* é determinada pelo quociente entre o número de amostras corretamente identificadas como positivas (TP) e o total de amostras classificadas pelo modelo como

pertencentes à classe positiva, independentemente de estarem corretas ou não (TP + FN) [71].

$$P = \frac{TP}{TP + FN} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \quad (2.4)$$

- **Recall**

O *recall* é a proporção de objetos previstos corretamente em relação a todos os objetos verdadeiros. Ele fornece uma medida de quão eficaz o modelo é em identificar todas as instâncias positivas no conjunto de dados, ao medir a sua capacidade de capturar todas as instâncias positivas presentes.

$$R = \frac{TP}{TP + FP} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \quad (2.5)$$

- **mAP**

A mAP expande o conceito de AP ao calcular a média para as várias classes de objetos [72]. Esta métrica é particularmente útil em modelos com múltiplas categorias, uma vez que permite uma avaliação abrangente da qualidade das previsões em todas elas.

$$\text{mAP} = \frac{1}{N} \sum_{i=1}^N \text{AP}_i, \quad (8)$$

- **mAP50-95**

O termo 50-95 indica que a AP é calculada para valores de IoU entre 50% e 95% [73]. O IoU quantifica a sobreposição entre a caixa delimitadora prevista e a caixa real. Este é calculado dividindo-se a área de interseção das duas caixas pela área de união, o que resulta num número entre 0 e 1, onde 1 indica uma correspondência perfeita [74]. Valores de IoU mais elevados refletem maior precisão na identificação e localização dos objetos.

- **F1-Score**

O *F1-Score*, utilizado pelo YOLOv8 na forma *Macro-F1*, combina *precision* e *recall* numa única métrica. Avalia a *performance* de cada classe separadamente e depois calcula a média dessas pontuações [75]. Esta abordagem assegura que todas as categorias têm o mesmo peso. É especialmente útil em cenários onde é essencial equilibrar FP e FN, como na monitorização da qualidade em linhas de produção [76].

$$F1_{\text{macro}} = \frac{1}{N} \sum_{i=1}^N \frac{2 \times \text{Precision}_i \times \text{Recall}_i}{\text{Precision}_i + \text{Recall}_i} \quad (2.6)$$

No âmbito do projeto, estas métricas são fundamentais para avaliar os modelos treinados com os *datasets* personalizados. Elas permitem validar as classificações e aferir se os resultados estão alinhados com os objetivos definidos.

## 2.5 Trabalhos Relacionados

Na presente secção exploram-se os trabalhos relacionados no campo da OD.

Zheng et al. [77] exploram o desafio da montagem de cabos em aeronaves, uma tarefa complexa devido aos múltiplos componentes envolvidos e à precisão exigida. Para oferecer um suporte inovador e interativo aos operadores, os autores propuseram um sistema de assistência inteligente, integrando OD e RM, com o uso do Microsoft HoloLens. Para a identificação dos cabos com base em códigos, é utilizada uma CNN, que faz o reconhecimento e a leitura através da imagem capturada pelos HMD. A implementação desta solução demonstrou melhorias significativas na eficácia da montagem, reduziu erros e aumentou a velocidade do processo. O estudo revela ainda o potencial da aplicação em ambientes industriais mais amplos.

Apostolopoulos et al. [78] abordam a necessidade de adaptar operadores a ambientes industriais híbridos e dinâmicos. Os autores apresentam um sistema de formação assente em RA, que recorre à OD para identificar objetos no local de trabalho e sobrepor-lhes hologramas e informações digitais relevantes. O método utilizado inclui a gamificação do treino para maior envolvimento, com um *design* centrado no utilizador, envolvendo os operadores no processo de desenvolvimento. A aplicação foi desenvolvida com o Unity Game engine e o *Open Source Computer Vision Library* (OpenCV) [79]. Para o futuro, é apontado como sugestão melhorar a gamificação com perfis de utilizador e um sistema de pontuação para enriquecer a experiência de formação.

Zamora-Hernández et al. [80] exploram os desafios enfrentados nas fábricas durante a montagem de produtos, como a personalização em massa e a consequente complexidade crescente. Em resposta, apresentam um assistente visual que avalia as atividades de um operador durante a montagem manual. Basicamente, utilizam técnicas de VC, como o YOLO, para detetar as tarefas realizadas pelo operador, identificar as ações (segurar, apertar, bater, etc.) e cronometrar o tempo de execução dessas tarefas. Após a análise do vídeo de execução, o sistema gera um diagrama com essas informações. Os resultados obtidos em termos de precisão no início e no final da tarefa, em comparação com dados reais, incentivam os autores a considerar estudos futuros sobre o “tempo de tarefa” no *design* de trabalho.

Por último, Raj et al. [81] desenvolveram uma aplicação baseada em RM para orientar os trabalhadores de fábrica durante as tarefas de montagem. O olhar do utilizador é guiado para o objeto que deve ser apanhado e para o local onde deve ser colocado. Os hologramas de cada componente são renderizados junto às suas localizações físicas, mostrando como o produto montado deve parecer. O autor utilizou a câmara do HoloLens para capturar imagens das várias peças de montagem. Essas serviram para treinar um modelo de OD com o YOLO. O modelo foi ajustado com um *dataset* (conjunto de imagens) personalizado composto por 1657 imagens, com variações de ângulo e distância. Para detetar os erros, o autor desenvolveu um algoritmo que, em conjunto com o sistema de rastreamento manual do HMD, acompanha a posição das articulações das mãos e dos objetos. Esse algoritmo inclui um contador pré-definido que regista o número de vezes que a mão do utilizador toca em objetos físicos durante cada etapa da sequência de montagem. Este sistema representa uma abordagem inovadora, contudo, sob uma análise mais crítica, identificam-se algumas

lacunas. Uma precisão aprimorada poderia ser alcançada através do uso mais extensivo da VC, não apenas para as peças individuais, mas também para validar cada etapa da montagem e identificar os erros. Nota-se a ausência de um sistema automático de recolha do tempo de execução das tarefas, assim como de uma aplicação para análise de dados pertinentes. A inexistência de perfis de utilizador para uma experiência de RM personalizada e escalável a mais utilizadores poderá ser vista como uma limitação. Adicionalmente, o método manual de captura de fotografias no processo de reconhecimento das peças, que exige a imobilidade do utilizador, revela-se pouco prático. Uma solução mais eficaz envolveria a análise automática de imagens de vídeo em tempo real, eliminando a necessidade de intervenção manual.

As oportunidades de melhoria identificadas nesta secção, uma vez exploradas, não só valorizam o trabalho em desenvolvimento, como também revelam um amplo espectro de inovações possíveis nos sistemas de formação industrial.

## 2.6 Ferramentas e Tecnologias

Para alcançar os objetivos definidos, selecionaram-se o Unity, o You Only Look Once, o Ultralytics, o Django, o Roboflow, o MySQL, o Blender e o Magic Leap como ferramentas e tecnologias. Cada uma destas é apresentada nesta secção, juntamente com a breve explicação da sua aplicação no projeto.

### 2.6.1 Unity

O Unity é uma plataforma de desenvolvimento que permite criar jogos, aplicações e experiências em 3D em diversas áreas, como entretenimento, cinema, indústria automóvel, educação, fabricação e muitos outros fins [39]. Destaca-se pela versatilidade, pois permite desenvolver soluções dinâmicas para diversos dispositivos, como os HMD.

Vários casos de estudo demonstram a aplicação desta tecnologia na manufatura, destacando-se a criação de experiências imersivas para a perceção de produtos industriais, a melhoria da formação de operadores de empilhadoras com RV e a prevenção de falhas através de gémeos digitais [82]. A programação orientada a objetos, com *scripts* em C#, facilita a adaptação de novos programadores, familiarizados com outras linguagens semelhantes, como Java ou C++. Os ficheiros de código fornecem a lógica necessária para controlar todas as partes de uma aplicação interativa [83].

Para desenvolver a aplicação de instrução virtual proposta neste projeto, destinada a orientar a realização de tarefas, selecionou-se o Unity. Esta decisão é apoiada por vários fatores, como o conhecimento prévio desta ferramenta, a facilidade na manipulação de elementos e a agilidade na criação de soluções para diferentes HMDs. O último aspeto só é possível graças à variedade de módulos suportados, como o Android Build Support, que permite exportar as aplicações para os dispositivos Magic Leap, e o *Mixed Reality Toolkit* (MRTK), que auxilia na implementação de interações e UI de RM.

### 2.6.2 You Only Look Once

O YOLO é uma família de algoritmos que em 2015, veio revolucionar a VC ao conseguir analisar uma imagem completa com uma única passagem pela CNN e identificar múltiplos objetos. Esta metodologia inovadora permitiu atingir 45 *Frames Processados por Segundo* (FPS), tornando-a adequada para aplicações que exigem respostas rápidas. No entanto, enfrentava desafios na identificação de elementos pequenos e em cenários complexos [55].

Com a versão 2, também conhecida como YOLO9000, foram introduzidas melhorias que aumentaram a precisão e a velocidade. O nome desta versão advém da capacidade de detetar mais de 9000 categorias de objetos, alcançada através de um processo de treino inovador que combinava dados rotulados (com caixas delimitadoras) e não rotulados (dados apenas com categorias de classe). Apesar de, à data, os resultados de mAP de 19,7 no *ImageNet* serem impressionantes, as limitações observadas impulsionaram a busca por melhorias nos modelos seguintes [84].

O YOLOv3 trouxe avanços notáveis ao implementar previsões em múltiplas escalas, que melhoraram a OD de diversos tamanhos. A adoção da arquitetura *Darknet-53*, com 53 camadas convolucionais, aumentou a profundidade e a capacidade de extração de características [85].

A evolução continuou com o YOLOv4, que se concentrou em otimizar o desempenho em computadores comuns, sem a necessidade de *hardware* especializado. Para alcançar isso, foi introduzido o *CSPDarknet53*, que é a parte do algoritmo responsável por analisar as imagens de forma mais rápida e precisa. Além disso, técnicas como *bag of freebies* e *bag of specials* foram utilizadas para melhorar a sua capacidade durante a fase de treino, tornando-o mais preciso sem comprometer a velocidade [86].

A procura por melhorar a eficiência e a velocidade também se reflete na sétima versão, obtida com recurso à arquitetura *Extended Efficient Layer Aggregation Networks* (E-ELAN), que aprimora a aprendizagem ao expandir, embaralhar e combinar informações de diferentes camadas, sem perder dados importantes. Em junção com as otimizações no processo de treino, quer no pós, como a reparametrização, que simplifica a estrutura para melhorar o desempenho, quer durante, com a atribuição dinâmica de rótulos, que ajusta automaticamente as etiquetas para aumentar a precisão [87].

A versão 8 introduziu um *backbone* (parte principal da CNN que realiza a extração de características dos dados de entrada) otimizado e técnicas de normalização aprimoradas, o que resultou não só na melhoria da mAP, mas também no aumento do número de FPS. Estas características fazem desta versão uma referência em tarefas de VC com resposta rápida. Além disso, permite a implementação de modelos personalizados para diversos tipos de tarefas, como classificação, OD e segmentação [88].

Ali and Zhang [89] realçam a aplicabilidade desta tecnologia em ambientes industriais, particularmente para automatizar o controlo de qualidade e detetar defeitos durante a inspeção de produtos em tempo real. Isso permite identificar falhas, localizar peças ausentes e garantir o cumprimento dos padrões de qualidade.

Assim sendo, escolheu-se o modelo YOLO para treinar os conjuntos de dados desenvolvidos especificamente para validar tarefas, identificar peças no processo de montagem e detetar

um erro específico.

### 2.6.3 Ultralytics

A Ultralytics é uma empresa que fornece soluções avançadas em *Inteligência Artificial* (IA), especializadas em VC, que permitem aos utilizadores transformar imagens em dados úteis [90]. Uma das suas principais contribuições é o desenvolvimento contínuo do modelo YOLO, iniciado com a melhoria da terceira versão, originalmente criada por Joseph Redmon [91]. Desde então, a Ultralytics liderou a evolução do YOLO, com o lançamento sucessivo de novas versões, como o YOLOv5 e o YOLOv8, tornando-se a principal entidade responsável pelo aperfeiçoamento contínuo da CNN e uma referência na OD em tempo real.

A biblioteca disponibilizada pela Ultralytics, em Python, permite executar os modelos YOLO e oferecer ferramentas avançadas para a classificação de novos dados visuais, através da sua simples integração nos sistemas existentes [92]. Para que isso seja possível, é necessário, adicionalmente, o PyTorch, uma biblioteca de tensores otimizada para DL, que, dada a sua estrutura eficiente para treinar a CNN, acelera o processamento de grandes volumes de dados [93]. Para evitar que funcione exclusivamente com o CPU, uma vez que isso resulta em tempos de execução superiores, é essencial instalá-lo com suporte à plataforma CUDA. Desenvolvida pela NVIDIA, esta tecnologia de computação paralela permite à GPU executar milhares de cálculos em simultâneo, garantindo um desempenho mais rápido em operações complexas [94]. Mittal and Vaishay [95] reiteram que a utilização de placas gráficas acelera significativamente o treino de modelos, especialmente quando suportadas por tecnologias como o CUDA. No presente projeto, esta ferramenta foi utilizada para treinar os modelos YOLO com os *datasets* próprios e, posteriormente, para o IR.

### 2.6.4 Django

O Python é uma linguagem de programação orientada a objetos, habitualmente aplicada em áreas como desenvolvimento *web*, ciência de dados e IA [96]. Permite que os programadores trabalhem mais produtivamente, devido à sintaxe clara, e integrem sistemas mais eficazmente, dada a elevada capacidade de processamento. A escolha desta tecnologia para a componente *web* justifica-se pelo extenso conjunto de bibliotecas que são essenciais para o projeto em desenvolvimento, como o Ultralytics e o Django.

O Django é uma *framework web* que, por requerer menos código, simplifica o desenvolvimento de aplicações e reduz o tempo necessário para criá-las [97]. Para a construção de APIs RESTful bem estruturadas, pode ser complementado com a *Django REST Framework* (DRF) [98]. O *Representational State Transfer* (REST) é um estilo arquitetural que utiliza métodos *HyperText Transfer Protocol* (HTTP), como GET, POST, PUT e DELETE, para executar ações *Create, Read, Update, and Delete* (CRUD) sobre os recursos do sistema [99]. A combinação destes elementos garante o cumprimento das melhores práticas e dos padrões definidos para APIs.

Neste trabalho, aplica-se o Django para criar a aplicação de administração e o Django REST Framework para implementar a API com suporte aos conceitos de CRUD.

### 2.6.5 Roboflow

O Roboflow permite criar conjuntos de dados visuais, utilizá-los para treinar automaticamente os modelos e aplicá-los em produção via API, se desejado. O seu principal objetivo é agilizar a anotação, processo no qual as informações contextuais são adicionadas a cada imagem, por meio da identificação e delimitação de objetos específicos ou regiões de interesse. Esta rotulagem inclui a definição de categorias (por exemplo, “bicicleta” ou “cão”) e a localização exata dos objetos (através de caixas delimitadoras, polígonos ou máscaras) [100]. Este procedimento é essencial para o ML, pois disponibiliza as informações com a estrutura que os modelos utilizam para aprender a reconhecer os padrões.

Atualmente, o Roboflow conta com mais de 575 milhões de imagens anotadas pelos utilizadores. Na sua versão gratuita, os *datasets* criados ficam acessíveis à comunidade e, até ao momento, já foram registados 750 mil. Para acelerar a anotação, são disponibilizados recursos como o “*Smart Polygon*”, que, ao aplicar o modelo Segment Anything 2 da Meta AI, permite desenhar os polígonos com apenas um clique. Inclui também a funcionalidade “*Label Assistant*”, que recorre a modelos previamente treinados para pré-anotar as imagens, o que resulta numa redução do tempo necessário para essa ação, em até 95% [101].

Além disso, oferece opções de pré-processamento, que incluem operações como o redimensionamento das imagens, e de aumento de dados, que consistem em técnicas para criar variações artificiais das imagens, como rotações, inversões, alterações de brilho e contraste, permitindo gerar até cinquenta versões aumentadas de cada imagem para melhorar a generalização do modelo [102]. O Roboflow suporta ainda vários tipos de projeto de VC, como OD, segmentação de instâncias, deteção de pontos-chave (“esqueleto”) e classificação. Adicionalmente, é possível treinar até três modelos gratuitamente [103].

No contexto do projeto, a ferramenta descrita foi essencial para criar os *datasets*. O treino, contudo, não foi realizado diretamente no Roboflow, não só pela limitação de créditos disponíveis, mas também para controlar os parâmetros dessa atividade.

### 2.6.6 MySQL

O MySQL é um sistema de gestão de bases de dados relacional, concebido e suportado pela Oracle [104]. Como é de código aberto, várias funcionalidades foram desenvolvidas em cooperação com os utilizadores ao longo de mais de 25 anos, sendo utilizado em aplicações como o Facebook, Netflix, Shopify e Uber [105]. Um sistema relacional organiza e armazena informações fundamentais em tabelas separadas para maior rapidez. O modelo lógico integra entidades e colunas, que regulam os relacionamentos entre os campos, mantêm a consistência das informações e evitam a duplicação de valores. A sigla “SQL” em “MySQL” significa “Structured Query Language”, a linguagem padrão utilizada para aceder a estas estruturas, que pode ser inserida diretamente, incorporada em outros códigos ou utilizada por meio de APIs específicas.

Esta tecnologia foi utilizada no projeto para organizar, armazenar e gerir todos os dados envolvidos.

### 2.6.7 Blender

O Blender é uma ferramenta que permite criar, transformar e editar modelos 3D. Além disso, possibilita a produção de animações de alta qualidade para curtas-metragens, anúncios e outros trabalhos de multimídia [106].

Para exportar as cenas animadas, foi selecionado o tipo de ficheiro GLB em vez de outras opções, como o FBX, por causa das exigências específicas do ambiente Unity. O GLB é a versão binária do formato glTF (*GL Transmission Format*), um padrão aberto para a transmissão eficiente de modelos 3D, conforme detalhado pelo Khronos Group [107]. Este padrão binário otimizado reúne, num único ficheiro, o modelo, a animação e as texturas, o que assegura uma transferência eficiente de dados em tempo real. A escolha assegura compatibilidade com o repositório GLTFUtility [108], que interpreta estes arquivos e apresenta-os na aplicação sem necessidade de conversões adicionais. O pacote Json.NET [109] complementa a solução ao simplificar a integração dos recursos recebidos pela API e ao garantir uma abordagem eficaz para as necessidades do projeto.

No projeto, o Blender é utilizado para conceber, com agilidade, todas as animações 3D que auxiliam o processo de aprendizagem.

### 2.6.8 Magic Leap

O Magic Leap 2 é um HMD desenvolvido pela *Magic Leap, Incorporated*, com o objetivo de integrar conteúdos digitais no espaço físico do utilizador. O seu *design* ergonómico e leve, adequado a utilizações prolongadas, destaca-se dos concorrentes. O sistema é composto por um *headset*, um *compute pack* e um comando. O dispositivo possui um campo de visão de até 70° e uma resolução de 1440x1760 píxeis por olho. A unidade de computação inclui um processador AMD de quatro núcleos com arquitetura Zen 2, 16 GB de memória RAM e 256 GB de armazenamento interno. O controlador facilita o uso por meio de rastreamento ótico e sensores inerciais. Foram lançados em setembro de 2022 e aplicados em setores como saúde, manufatura e construção [110].

O equipamento apresentado desempenha um papel central neste trabalho, uma vez que é responsável pela execução da aplicação de instrução virtual num ambiente interativo, onde as instruções digitais são sobrepostas ao mundo real.

## 2.7 Sumário

Este capítulo apresentou os métodos de aprendizagem e mostrou que a RM é uma ferramenta central na formação industrial devido aos seus benefícios na execução de tarefas e na redução de erros. A VC, exemplificada pelo algoritmo YOLO, foi abordada como solução aplicada à OD e ao controlo de qualidade. Estudos relacionados evidenciaram avanços tecnológicos, identificaram limitações e sugeriram melhorias, como a inclusão de sistemas personalizados e a recolha automática de dados.

O próximo capítulo expõe o trabalho de conceção, que detalha a análise de requisitos, a definição de perfis, a modelação de casos de uso e a estrutura da base de dados. Revela

ainda a arquitetura do sistema e o plano de trabalhos, que estabelecem as bases para a implementação do protótipo.



## Capítulo 3

# Conceção

Este capítulo apresenta a conceção do projeto, com a análise de requisitos em primeiro lugar, seguida dos diagramas de casos de uso, que descrevem o planeamento das funcionalidades do sistema, e do diagrama da base de dados, que representa a estrutura das informações armazenadas. A arquitetura da solução expõe os componentes e a forma como interagem entre si, enquanto o plano de trabalhos detalha as atividades previstas.

### 3.1 Análise de Requisitos

Esta secção apresenta os requisitos funcionais e não funcionais da solução. Inicialmente, será introduzido o projeto, com a apresentação e clarificação das suas principais componentes e das respetivas funcionalidades nucleares. Posteriormente, serão descritos os requisitos de cada componente.

#### 3.1.1 Descrição da Proposta

Conforme referido na Secção 1.3, o presente projeto tem como objetivo apoiar o operador em diferentes contextos, nomeadamente na formação vocacional, em ambientes pré-laborais e na formação em contexto de trabalho, como em linhas de montagem, em situações que exigem a introdução de novas competências ou o aumento da complexidade das tarefas. Além disso, visa também reforçar o controlo de qualidade no chão de fábrica.

A abordagem proposta atua tanto como ferramenta de orientação como de supervisão, permitindo a monitorização do desempenho com base em métricas específicas, como o tempo de execução de cada tarefa. O projeto integra funcionalidades que abrangem a validação de cada etapa nas atividades formativas laborais e a identificação de erros em processos associados ao controlo de qualidade. Para complementar essas funcionalidades, incluem-se

também elementos 3D, como modelos animados, que exemplificam a reprodução das ações das tarefas, de modo a tornar o processo mais intuitivo e eficaz.

### 3.1.2 Definição de Perfis de Utilizador

Na definição dos utilizadores, foram estabelecidos dois perfis: administrador e aprendiz/operador. O administrador, com maior experiência em gestão e supervisão de tarefas, é responsável pela gestão da aplicação. Deve criar projetos e etapas nas áreas da sua especialidade e é o único com acesso a informações detalhadas, como o progresso das tarefas e os dados sobre o desempenho.

O aprendiz/operador, por outro lado, tem como função executar as tarefas atribuídas na aplicação de instrução virtual através da utilização do HMD. Este utilizador não tem acesso à aplicação de administração, onde são apresentados os dados de desempenho. A decisão de restringir a permissão a essas informações foi tomada com cautela para evitar que o aprendiz tire conclusões erradas, o que pode levá-lo a sentir-se pressionado ou injustamente criticado. O objetivo é garantir um ambiente de aprendizagem positivo, sem risco de desmotivação.

Embora o administrador tenha acesso a esses dados, a sua função é utilizá-los para analisar objetivamente o desempenho e ajustar a supervisão de forma construtiva. A avaliação é sempre realizada com o propósito de melhorar o processo e apoiar o desenvolvimento do aprendiz, sem criar um clima de julgamento, garantindo assim um sistema focado no apoio e na melhoria contínua.

### 3.1.3 Definição de Perfis de Projeto

Foram estabelecidos três perfis para os projetos: **formação vocacional**, **formação no trabalho** e **controlo de qualidade**.

O perfil de formação vocacional visa preparar os operadores de montagem para o exercício da sua profissão, com foco no desenvolvimento das competências práticas necessárias. A UI deve, por isso, apresentar instruções detalhadas e passo a passo, preferencialmente acompanhadas por objetos 3D das peças envolvidas, animados em cada etapa, exemplificando claramente os movimentos de encaixe que o operador deverá replicar.

O perfil de formação no trabalho destina-se a prestar apoio e assistência ao operador no seu ambiente de trabalho. O seu propósito é facilitar a aquisição de competências específicas ou mais complexas. Tal como no perfil anterior, deve providenciar instruções passo a passo e animações. A diferença reside nas funcionalidades de assistência, como a verificação visual da correta execução de cada tarefa antes de avançar para a próxima e o apoio na fase de preparação, garantindo a disponibilidade e quantidade adequadas das peças necessárias.

O perfil de controlo de qualidade tem como objetivo monitorizar e alertar o operador quando é detetado um erro predefinido. Este é particularmente relevante para estações de trabalho críticas, onde a ocorrência de falhas é mais frequente. Assim, a UI adota uma abordagem distinta, permitindo que o operador se concentre inteiramente na sua atividade, sem precisar de interagir com a aplicação ou ser sobrecarregado com informações visuais desnecessárias. A ideia é mostrar apenas o essencial no momento certo (Just-in-Time), de forma a prevenir a deteção tardia de erros e as suas consequências.

### 3.1.4 Modelos de Detecção de Objetos

Tanto na formação no trabalho como no controlo de qualidade, propõe-se a criação de modelos de OD com o objetivo de automatizar os processos através de VC.

No âmbito da formação no trabalho, podem ser desenvolvidos dois modelos com finalidades distintas: o **Modelo para Identificação de Componentes Individuais** e o **Modelo para Validação das Tarefas**. O primeiro tem como função a identificação de peças, uma vez que a montagem de um componente implica frequentemente a sua decomposição em partes menores. Este modelo, treinado com os componentes individuais a serem utilizadas na fase de preparação, deve identificar, através das imagens capturadas pelo HMD, tanto a presença de cada peça na mesa de trabalho como a sua contagem. O seu objetivo é automatizar a etapa de preparação, que consiste na verificação dos materiais. O segundo modelo, o Modelo para Validação das Tarefas, tem como propósito garantir que cada tarefa foi corretamente realizada. O seu conteúdo deve refletir com precisão o estado de conclusão de cada fase do processo. Pretende-se não só assegurar o cumprimento das instruções, mas também impedir o avanço para a etapa seguinte sem que a anterior esteja completamente concluída. Em caso de não conformidade, o utilizador será notificado, e o erro será registado e refletido na sua avaliação de desempenho.

No contexto do controlo de qualidade, é necessário desenvolver um **Modelo para Reconhecer Erro(s)** que identifique falhas e alerte o operador para a sua ocorrência. Este modelo deve ser treinado para identificar erros críticos e frequentes, que requerem uma verificação especial. A decisão de optar por um modelo especializado em encontrar falhas baseia-se na necessidade de evitar falsos alarmes. Se fosse utilizado um modelo de validação, que confirmasse apenas se algo está correto, qualquer situação diferente do esperado seria tratada como erro. Isto incluiria casos de “*no detection*”, causados pelo movimento do utilizador com o HMD, que pode ocluir o objeto ou alterar totalmente a cena. Assim, um Modelo para Reconhecer Erro(s), focado em identificar erros reais, é preferível, pois só emite alertas quando há problemas concretos.

### 3.1.5 Requisitos Funcionais

Os requisitos funcionais definem as funcionalidades que o sistema deve implementar para atender aos requisitos dos utilizadores. Após a análise, foram identificados três componentes principais: um componente para a gestão de dados, representado por uma aplicação de administração, um componente destinado à execução de tarefas com o uso do HMD através de uma aplicação de instrução virtual e, por fim, um componente encarregado de realizar a comunicação entre os dois primeiros, além da deteção dos modelos de OD (API).

A aplicação de administração destina-se aos gestores do sistema, sendo a componente principal, pois é aqui que se realiza toda a gestão dos dados armazenados, incluindo utilizadores, projetos e tarefas, que são registados na base de dados e posteriormente disponibilizados para a aplicação de instrução virtual através da API. A tabela 3.1 apresenta os requisitos definidos para este módulo.

Os utilizadores desempenham um papel crucial na personalização do sistema, dado que os diferentes perfis concedem acesso a diferentes aplicações. Esta funcionalidade permite,

posteriormente, criar tarefas específicas para cada utilizador aprendiz e acompanhar o seu desempenho ao executá-las. O utilizador com perfil de administrador é também designado responsável pelo projeto, garantindo que haja alguém encarregado de gerir e fornecer orientação adicional ao aprendiz, caso necessário.

Os projetos têm como objetivo representar um conjunto de tarefas relacionadas a um caso de uso específico. Esta abordagem visa a segregação de diferentes processos de montagem e controlo de qualidade, permitindo, num contexto de formação ou industrial, a combinação de vários produtos distintos.

As tarefas devem ser integradas em cada projeto, sendo responsáveis pela definição das orientações a seguir pelo utilizador, desde a apresentação de instruções claras sobre o que deve ser realizado, passando pela exemplificação por meio de animações, até à especificação das classes a detetar nos projetos de visão relacionados com a tarefa. Adicionalmente, desempenham um papel essencial na recolha de dados de desempenho, como o tempo de execução e a identificação de eventuais erros.

N.º	Nome	Descrição
1	Criar novo utilizador	Adicionar nome completo, nome de utilizador, e-mail, palavra-passe e outras informações relevantes.
2	Autenticação	Entrar na aplicação com o nome de utilizador e palavra-passe.
3	Listagem de utilizadores	Listagem dos utilizadores numa lista, com filtragem por perfil de utilizador.
4	Ver detalhes do utilizador	Mostrar todas as informações básicas do utilizador.
5	Editar utilizador	Editar os detalhes do utilizador e atribuir o perfil.
6	Eliminar utilizador	Remoção de um utilizador do sistema.
7	Criar novo projeto	Adicionar nome, descrição, nível de prioridade, utilizador responsável (administrador) e outras informações relevantes.
8	Adicionar modelos (se necessário)	Carregar o ficheiro .pt do modelo e o ficheiro data.yaml correspondente para os três tipos de modelos: peças, validação e erros.
9	Listagem dos projetos	Listar os projetos nos separadores respetivos, de acordo com o tipo: formação vocacional, formação no trabalho e controlo de qualidade.
10	Ver detalhes do projeto	Mostrar todas as informações básicas do projeto.
11	Editar projeto	Permitir a edição dos detalhes do projeto.
12	Eliminar projeto	Remover um projeto do sistema.

Tabela 3.1: Requisitos funcionais da aplicação de administração

N.º	Nome	Descrição
13	Criar nova tarefa	Adicionar nome, descrição detalhada, atribuir ao(s) utilizador(es) (aprendizes), animação explicativa, selecionar classes (se aplicável), entre outros.
14	Listagem das tarefas	Exibir todas as tarefas associadas ao respetivo projeto, com indicação do utilizador responsável e estado atual (por fazer, concluída).
15	Mostrar desempenho	Apresentar os resultados obtidos após a execução da tarefa, como o tempo despendido.
16	Ver detalhes da tarefa	Exibir todas as informações básicas da tarefa.
17	Editar tarefa	Permitir a edição dos detalhes da tarefa.
18	Eliminar tarefa	Remover uma tarefa do sistema.

Tabela 3.1: Requisitos funcionais da aplicação de administração

A Tabela 3.2 reúne os requisitos funcionais delineados para a aplicação de instrução virtual.

N.º	Nome	Descrição
1	Autenticação	Permitir ao utilizador aceder à aplicação através de nome de utilizador e palavra-passe.
2	Listagem dos projetos	Exibir até dois projetos atribuídos ao utilizador, ordenados de acordo com o nível de prioridade, para que possa selecionar um.
3	Ambiente de formação vocacional	Se o projeto for de formação vocacional, as tarefas devem ser apresentadas passo a passo, incluindo animações (se disponíveis) para melhor orientação.
4	Ambiente de formação no trabalho	Para este tipo de projeto, o sistema deve primeiro apresentar uma etapa de preparação automática, com modelos de peças (se aplicável). Depois, as tarefas serão apresentadas para validação uma a uma. Se uma tarefa não for concluída corretamente, deve ser gerado um erro.
5	Ambiente de controlo de qualidade	Caso seja detetado um erro, deve ser emitido um alerta com instruções claras sobre como corrigir o problema.

Tabela 3.2: Requisitos funcionais da aplicação de instrução virtual

N.º	Nome	Descrição
6	Interação através de gestos manuais	Permitir que os utilizadores interajam com objetos virtuais no ambiente de RM, utilizando gestos manuais para manipular e controlar os elementos.

Tabela 3.2: Requisitos funcionais da aplicação de instrução virtual

### 3.1.6 Requisitos Não Funcionais

Os requisitos não funcionais, ao contrário dos funcionais, não estão diretamente relacionados com as funções específicas do sistema. No entanto, representam aspetos essenciais para a sua usabilidade e eficiência. As considerações tomadas em conta são:

- Instruções claras e de fácil leitura;
- Permitir uma interação sem esforço e facilitada através de gestos com os dedos;
- Formulários fáceis de usar e navegar;
- Apresentação de dados de forma compreensível e concisa;
- Assegurar uma interação imediata entre o utilizador e os objetos virtuais;
- Garantir a segurança através de *tokens* de autenticação para proteger as comunicações e os acessos.
- O *design* deve ser consistente para proporcionar uma experiência familiar.

Este conjunto de requisitos assegura que a experiência do utilizador seja intuitiva e eficiente.

## 3.2 Diagramas de Casos de Uso

Os diagramas de casos de uso identificam as interações do utilizador com o sistema, permitindo definir os passos necessários para alcançar objetivos específicos. Neste capítulo, foram delineados dois tipos de utilizadores: o utilizador aprendiz/operador e o administrador. Estes dois tipos de utilizadores são considerados os principais atores na execução dos casos de uso. Na mesma secção, menciona-se que a solução se divide em três componentes principais, das quais duas são interativas para o utilizador: a aplicação de administração e a aplicação de instrução virtual. Para cada uma destas componentes, foram elaborados os respetivos casos de uso e as suas descrições.

### 3.2.1 Casos de Uso - Aplicação de Administração

A Tabela 3.3 tem como intuito listar os atores, os casos de uso em que estão envolvidos, os seus objetivos e os requisitos correspondentes definidos na Secção 3.1.5. Os casos de uso

representados na Figura 3.1 ajudaram a definir o fluxo de eventos da aplicação *web*, sendo que a descrição detalhada destes pode ser consultada nos Anexos, na Secção 7.2.

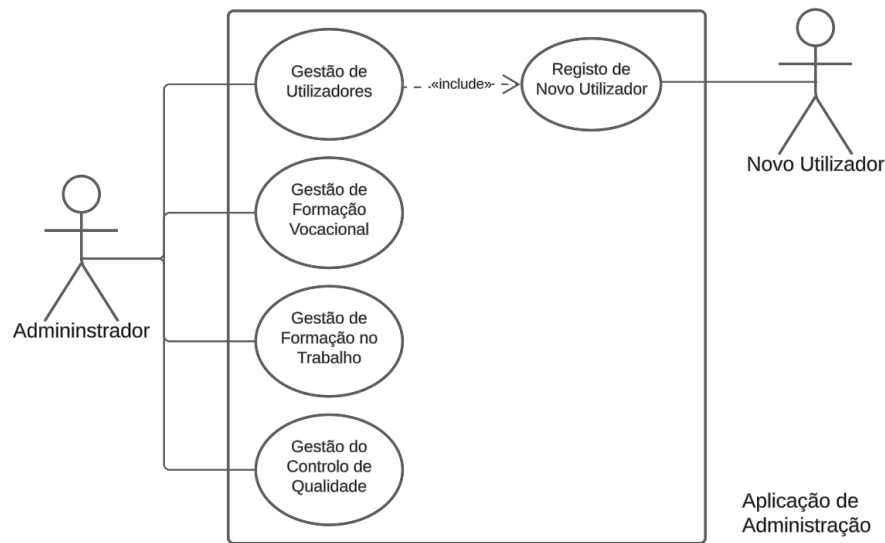


Figura 3.1: Diagrama de casos de uso da aplicação de administração

Tabela 3.3: Atores e respetivos casos de uso da aplicação de administração

Atores	Caso de Uso	Objetivos	Requisitos
Novo Utilizador	Registo de Novo Utilizador	1. Efetuar o registo no sistema, com a definição das informações pessoais e das credenciais de acesso. A autenticação é possível após a atribuição do perfil.	1 e 2.
Administrador	Gestão de Utilizadores	2. Gerir os utilizadores do sistema, atribuindo-lhes o perfil adequado, de forma a assegurar que cada um disponha das permissões apropriadas às suas funções, bem como alterar as informações necessárias e remover contas.	3, 4, 5 e 6.
	Gestão de Formação Vocacional	3. Facultar a possibilidade de criar, estruturar, atualizar e supervisionar os projetos de formação vocacional, o que inclui a definição de tarefas específicas e a respetiva atribuição a aprendizes.	7, 9, 10, 11, 12, 13, 14, 15, 16, 17 e 18.

Atores	Caso de Uso	Objetivos	Requisitos
	Gestão de Formação no Trabalho	4. Gerir projetos de formação prática em contexto laboral, com a criação de tarefas específicas e a sua atribuição a operadores para execução.	7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17 e 18.
	Gestão do Controlo de Qualidade	5. Gestão de projetos de controlo de qualidade, nomeadamente especificar as inconformidades a serem verificadas automaticamente e delegar as tarefas correspondentes aos operadores.	7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17 e 18.

### 3.2.2 Casos de Uso - Aplicação de Instrução Virtual

A Tabela 3.4 tem como objetivo definir os atores, os casos de uso em que estes participam e a correspondência com os requisitos estabelecidos na Secção 3.1.5. Os casos de uso apresentados na Figura 3.2 delinearam Sequência de ações da aplicação e são detalhados nos Anexos, na secção 7.1.

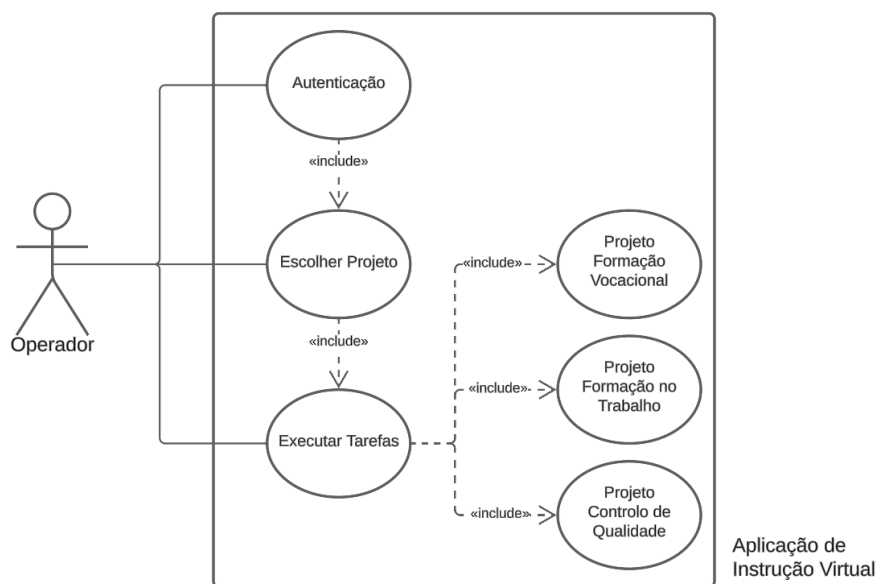


Figura 3.2: Diagrama de casos de uso da aplicação de instrução virtual

Tabela 3.4: Ator e os seus casos de uso na aplicação de instrução virtual

<b>Ator</b>	<b>Caso de Uso</b>	<b>Objetivos</b>	<b>Requisitos</b>
Aprendiz/ Operador	Autenticação	O objetivo é garantir que o utilizador possa aceder ao sistema através de um processo de autenticação no qual fornece o nome de utilizador e palavra-passe.	1 e 6.
	Escolher Projeto	A finalidade é permitir que o utilizador selecione um projeto no qual tenha tarefas a executar.	2 e 6.
	Executar Tarefas	O propósito é que o utilizador execute as tarefas associadas a um projeto previamente selecionado. Estas dependem do tipo de projeto escolhido (Projeto Formação Vocacional, Projeto Formação no Trabalho ou Projeto Controlo de Qualidade).	3, 4, 5 e 6.

### 3.3 Diagrama da Base de Dados

Na presente secção é exposto o esquema da base de dados da solução proposta. De forma a facilitar a sua compreensão e simplificar a complexidade do número de entidades e relações, este foi dividido em três diagramas menores, organizados pelas funcionalidades chave: utilizadores, projetos e tarefas. Para mais detalhes sobre cada entidade, consultar os Anexos, Secção 7.3.

### 3.3.1 Utilizadores

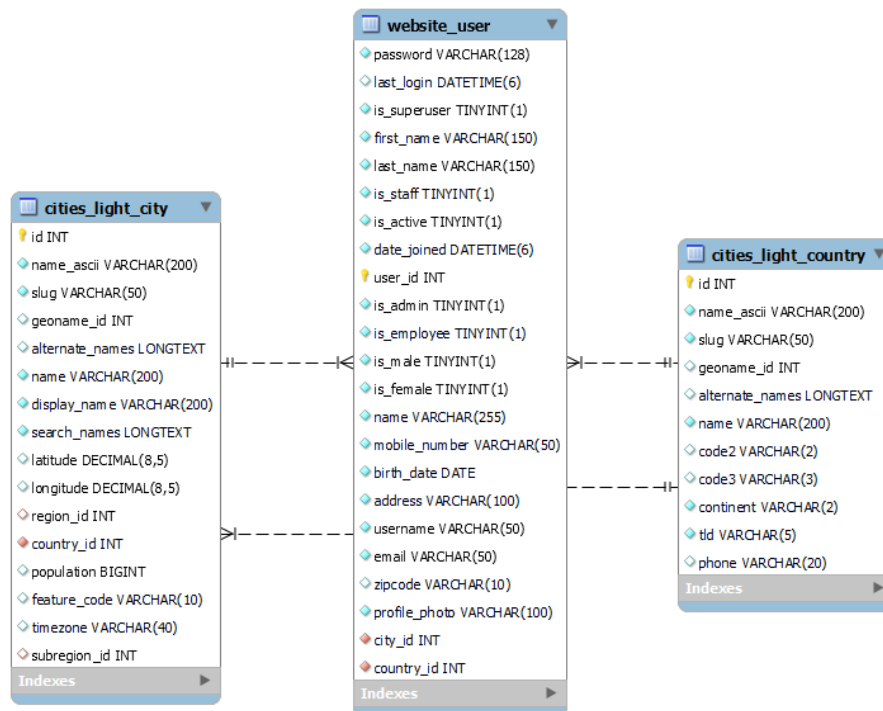


Figura 3.3: Utilizadores

A Figura 3.3 apresenta o diagrama *Entidade-Relacionamento* (ER) correspondente à funcionalidade Utilizadores. A entidade “Website User” foi pensada com o objetivo de organizar todas as informações dos utilizadores. Esta armazena os dados essenciais, como o nome, e-mail, país, cidade, entre outros, conforme ilustrado. Para gerir as informações de localização, a entidade principal está associada às entidades “Citties light City” e “Citties light Country”, que guardam, respetivamente, os dados das cidades e dos países.

## 3.3.2 Projetos

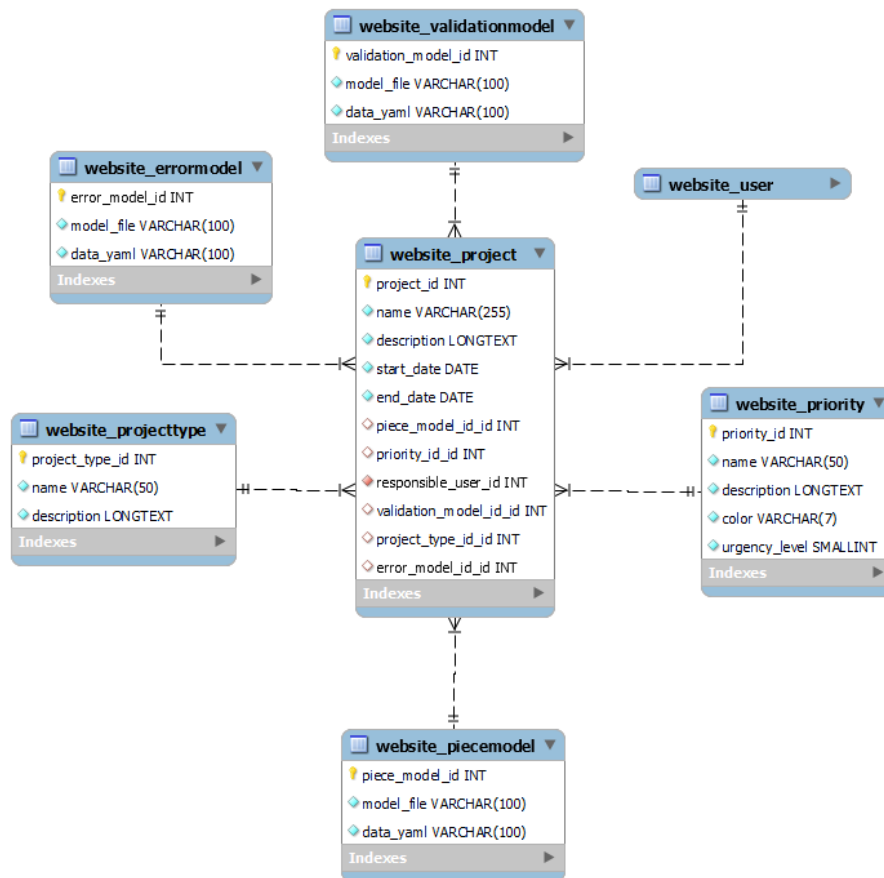


Figura 3.4: Projetos

O diagrama da funcionalidade de projetos é ilustrado na Figura 3.4. A entidade “Project” foi criada para facilitar a gestão, compreendendo campos como nome, descrição, data de início e data de fim. Os restantes estão vinculados às entidades “Priority”, “Project Type”, “Piece Model”, “Error Model”, “Validation Model” e “User”. A entidade “Priority” armazena os vários níveis de prioridade atribuídos aos projetos, como normal ou urgente. Cada projeto pode receber apenas uma prioridade, mas vários projetos podem partilhar a mesma. A regra N-1 assegura que os administradores classifiquem os projetos baseados na sua prioridade. A entidade “Project Type” define o tipo de projeto, o que permite distinguir entre diferentes categorias, como “formação” e “controlo de qualidade”. Graças a esta entidade, é possível moldar cada projeto conforme os seus requisitos específicos. Tal como a “Priority”, a relação com a entidade “Project” é de N-1, permitindo que um tipo de projeto esteja associado a vários projetos, mas cada projeto só pode ter um tipo.

As entidades “Piece Model”, “Error Model”, e “Validation Model” agregam os modelos de OD aos projetos. A “Model Piece” contém os dados relacionados com os componentes que o sistema deve identificar durante a execução das tarefas. A “Model Error” contém informações sobre os erros que o sistema deve detetar, enquanto a “Validation Model” guarda os critérios para validar a correta realização das tarefas. Estas entidades são elementares para

a automação dos processos tanto de formação no trabalho como de controlo de qualidade, uma vez que permitem que o sistema verifique automaticamente as peças, valide as tarefas e identifique erros conforme os modelos predefinidos.

Para a correta supervisão dos projetos, é necessário atribuir um utilizador responsável. Este, representado na entidade “User”, terá a responsabilidade de acompanhar o progresso do projeto e fornecer o apoio necessário.

### 3.3.3 Tarefas

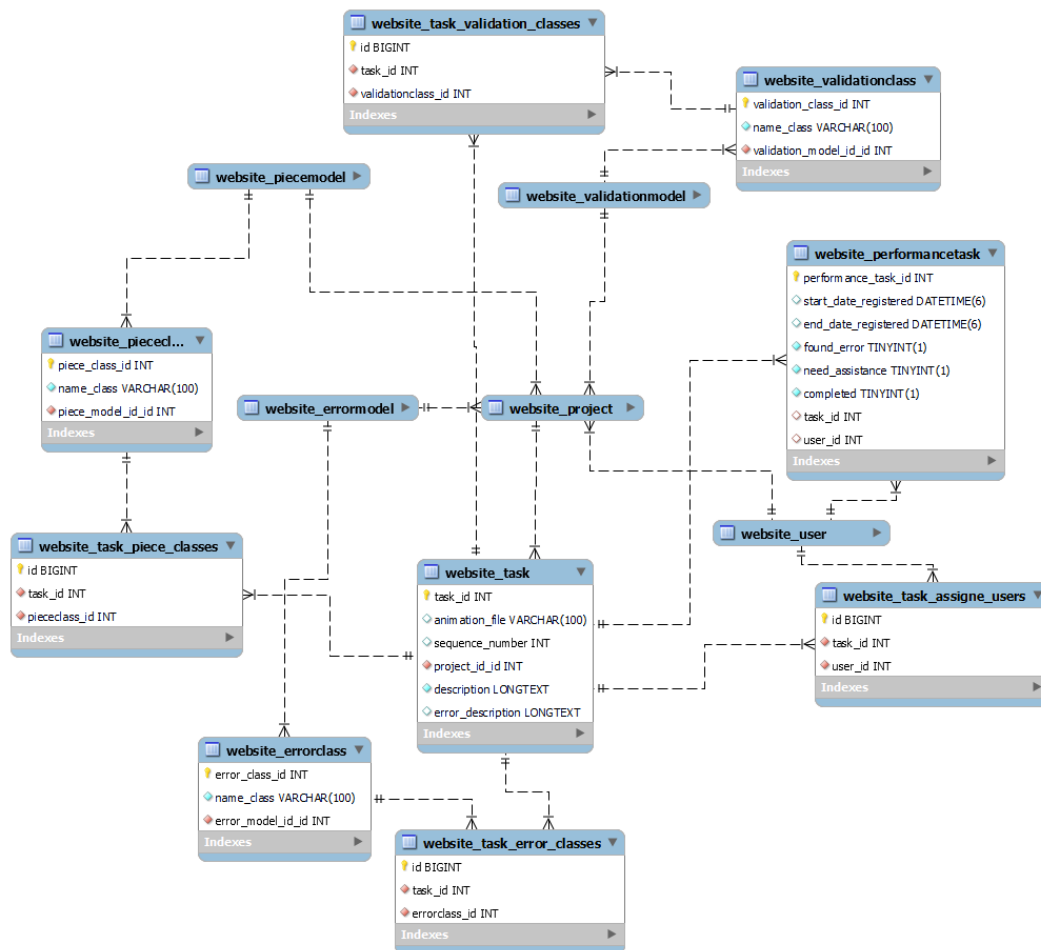


Figura 3.5: Tarefas

A Figura 3.5 exemplifica o diagrama da funcionalidade de tarefas, tendo como ponto central a entidade “Task”. O propósito desta entidade é armazenar todas as informações relacionadas com as tarefas, como a descrição, o número de sequência, o ficheiro da animação, a mensagem de correção de erro e o projeto a que pertencem. A comunicação entre as entidades “Project” e “Task” é importante não só para associar as tarefas ao projeto, mas também para processar os modelos e as classes na criação e execução das tarefas. Como mencionado anteriormente na seção 3.3.2, os modelos são armazenados em três entidades: “Model Error”, “Model Piece” e “Model Validation”. Estas entidades estão interligadas à entidade “Projects”, permitindo uma gestão integrada dos dados. As entidades “Model...”

recebem um ficheiro chamado “data.yaml”, que contém todas as classes do modelo. Estas classes são então inseridas nas entidades correspondentes: “Validation Class”, “Error Class” e “Piece Class”. Elas são essenciais para identificar o objeto que deve ser detetado pelo modelo. Para garantir que cada tarefa referencia a classe correta, são utilizadas entidades intermediárias: “Task Validation Class”, “Task Piece Class” e “Task Error Class”. Estas suportam uma ligação N-N, permitindo que as classes possam ser reutilizadas em várias tarefas.

O mesmo tipo de relação N-N associa as entidades “Task” e “User”, visto que uma tarefa pode ser atribuída a vários utilizadores e cada utilizador pode ter várias tarefas designadas. Para isso, é necessária a entidade intermediária “Task Assigne Users”, que regista as tarefas e os respetivos utilizadores associados. Embora as tarefas possam ser atribuídas a vários utilizadores, o desempenho individual de cada um em cada tarefa é armazenado na entidade “Performance Task”, de forma isolada. Esta entidades inclui campos como data de início, data de fim, conclusão, entre outros indicadores.

### 3.4 Arquitetura da Solução

Esta secção apresenta os componentes da arquitetura, as suas funcionalidades e as tecnologias envolvidas. A Figura 3.6 (a) representa a estrutura proposta e a interação entre os diferentes módulos, enquanto a Figura (b) ilustra as ferramentas associadas. A arquitetura inclui uma aplicação de instrução virtual, utilizada por operadores e aprendizes, uma aplicação de administração, dedicada à gestão de utilizadores e projetos, uma API que intermedia a ligação entre os componentes, uma base de dados que centraliza a informação e um módulo de OD responsável pela classificação de imagens. Todos estes elementos comunicam entre si.

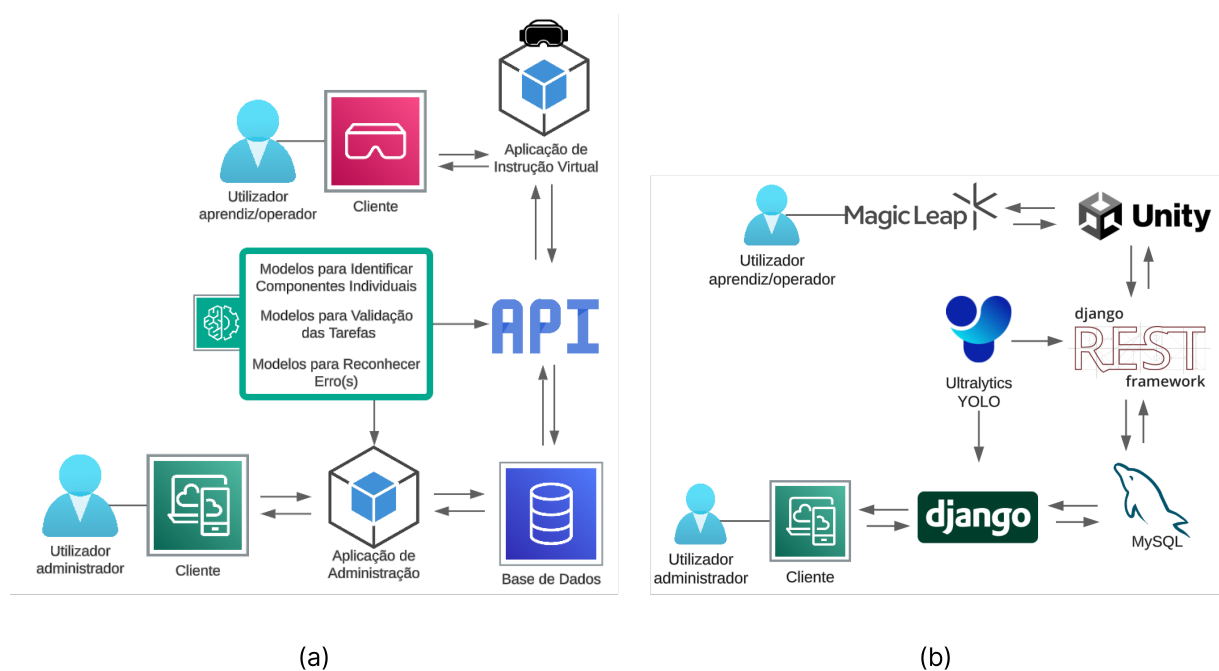


Figura 3.6: Arquitetura

A componente de administração disponibiliza uma *interface web* onde os administradores podem criar e gerir projetos e tarefas, bem como atribuir responsabilidades aos aprendizes. Quando um projeto exige a OD, os modelos YOLO e os ficheiros data.yaml, são armazenados na aplicação, e o respetivo caminho é registado na base de dados, juntamente com as restantes informações básicas.

A aplicação de instrução virtual constitui o ponto de interação dos operadores e aprendizes com o sistema, através de um HMD Magic Leap. Para facilitar a integração dos elementos interativos e do *hand tracking*, esta foi desenvolvida com recurso ao MRTK. Em alguns casos, recorre-se à câmara do dispositivo para capturar imagens em tempo real, utilizadas para validar a presença de peças, verificar a correta execução das tarefas ou detetar erros durante a inspeção de qualidade.

A API REST, desenvolvida em Python com Django Rest Framework, desempenha um papel central na comunicação entre os diferentes módulos. A aplicação de instrução virtual interage com a API através de UnityWebRequest, que solicitam informações sobre os projetos e tarefas atribuídas ao utilizador e, nos casos em que há validação visual, cedem imagens para análise e aguardam a resposta.

A OD é realizada por um serviço dedicado que integra modelos YOLO treinados para diferentes finalidades. Estes modelos dividem-se em três categorias principais: identificação de peças, validação da execução de tarefas e deteção de erros. O primeiro modelo permite identificar os componentes necessários à montagem, garantindo a sua presença antes da execução da tarefa. O segundo verifica se cada etapa foi corretamente concluída, assegurando que as peças foram encaixadas de acordo com as instruções. O terceiro modelo destina-se à identificação de falhas e permite detetar erros durante a inspeção de qualidade.

Quando a aplicação de instrução virtual deteta a necessidade de validação visual, a “CV Camera” do HMD Magic Leap inicia automaticamente a captura de imagens. Estas são processadas e enviadas para a API REST através de pedidos HTTP, sendo codificadas em Base64 para otimizar a transmissão. A API processa então as imagens de acordo com o modelo YOLO associado ao projeto e devolve os resultados à aplicação de instrução virtual. Se a imagem contiver os elementos esperados, o utilizador pode avançar para a etapa seguinte. Caso contrário, o sistema emite um alerta a indicar a necessidade de correção antes de prosseguir.

A arquitetura foi concebida para ser versátil, permitindo que a aplicação de instrução virtual funcione mesmo em contextos onde não haja modelos YOLO treinados. Para estas condições, foi desenvolvida uma alternativa adequada baseada exclusivamente em instruções textuais e animações 3D, utilizadas no contexto de formação vocacional. Assim, a aplicação mantém a sua capacidade de fornecer suporte à aprendizagem, independentemente da existência de um modelo de deteção previamente treinado. Esta versatilidade reforça a abrangência e polivalência do sistema, garantindo a adaptação a diferentes cenários e requisitos. Independentemente do tipo de projeto, os resultados das tarefas realizadas, que incluem o estado da execução, o tempo despendido e a deteção de erros, são registados na base de dados e ficam acessíveis na aplicação de administração

A distribuição equilibrada do processamento foi uma prioridade no desenvolvimento da

arquitetura. Enquanto a aplicação de instrução virtual executa operações mais leves no HMD, como a captura e envio de imagens, as tarefas computacionalmente mais exigentes, como a execução dos modelos YOLO, são processadas pela API. Esta abordagem reduz a sobrecarga do *headset* e garante um desempenho fluido.

Além de assegurar um funcionamento eficiente, a API foi concebida para garantir a escalabilidade do sistema. A configuração apresentada permite a introdução de novas funcionalidades sem comprometer os componentes existentes. Adicionalmente, o sistema está preparado para suportar a introdução de novas aplicações de execução para diferentes HMDs, como os HoloLens ou até dispositivos móveis.

A flexibilidade da arquitetura e a combinação de tecnologias interligadas garantem uma solução escalável e adaptável a diferentes contextos de utilização.

## 3.5 Plano de Trabalhos

O plano de trabalho, detalhado na Figura 3.7, estrutura-se em cinco fases essenciais: pesquisa, caso de estudo, análise de resultados, implementação de melhorias e revisão do documento. As semanas ilustradas a branco no cronograma indicam interrupções planeadas, devidas a fatores externos como períodos de férias. Este planeamento iniciou-se em outubro de 2023 e estende-se até fevereiro de 2025.

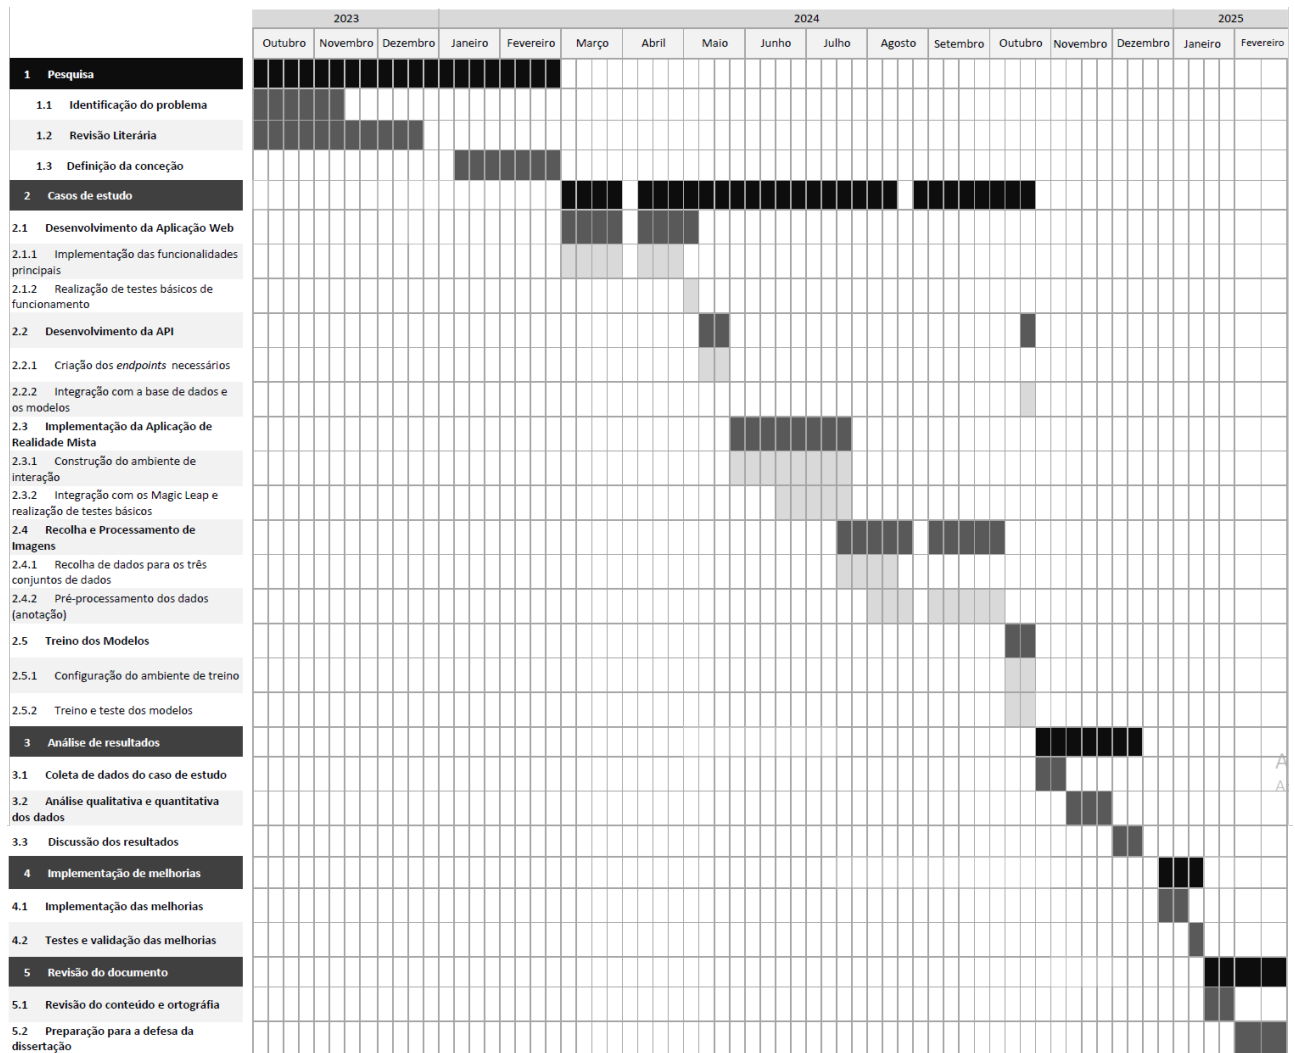


Figura 3.7: Plano das tarefas

## 3.6 Sumário

Este capítulo expôs o planeamento do sistema, com a definição dos requisitos, a descrição dos casos de uso, a arquitetura e o diagrama da base de dados. A proposta integra uma plataforma *web* para gestão de utilizadores, projetos e tarefas, uma aplicação de instrução virtual para execução de tarefas e supervisão, uma API que assegura a comunicação entre os componentes e modelos de OD destinados à identificação de peças, validação de etapas e deteção de inconformidades. Esta estratégia estabelece as bases para a formação vocacional, no trabalho e controlo de qualidade.

O capítulo seguinte descreve a implementação do sistema, desde a criação das aplicações até à integração eficaz de todos os componentes.

## Capítulo 4

# Desenvolvimento

Ao longo do projeto, foram implementadas uma Aplicação de Administração, uma Aplicação de Instrução Virtual e uma API, cujo desenvolvimento é detalhado neste capítulo. Os casos de uso desenvolvidos são apresentados com a respetiva nomenclatura e na ordem previamente definida.

### 4.1 Aplicação de Administração

Nesta secção, será apresentado o trabalho desenvolvido para cada caso de uso identificado na Secção 3.2.

#### 4.1.1 Estrutura

Para a aplicação de administração, de acordo com os requisitos descritos no Capítulo 3, a estrutura é a seguinte:

- Autenticação
  - Registo de Novo Utilizador
- Gestão de Utilizadores
- Formação
  - Gestão de Formação Vocacional
  - Gestão de Formação no Trabalho
- Gestão do Controlo de Qualidade

### 4.1.2 Registo de Novo Utilizador

Para realizar a autenticação na aplicação de administração, é necessário não só ter uma conta, como também permissões de administrador. Conforme demonstrado na Figura 4.1, são inseridos o nome e a palavra-passe.

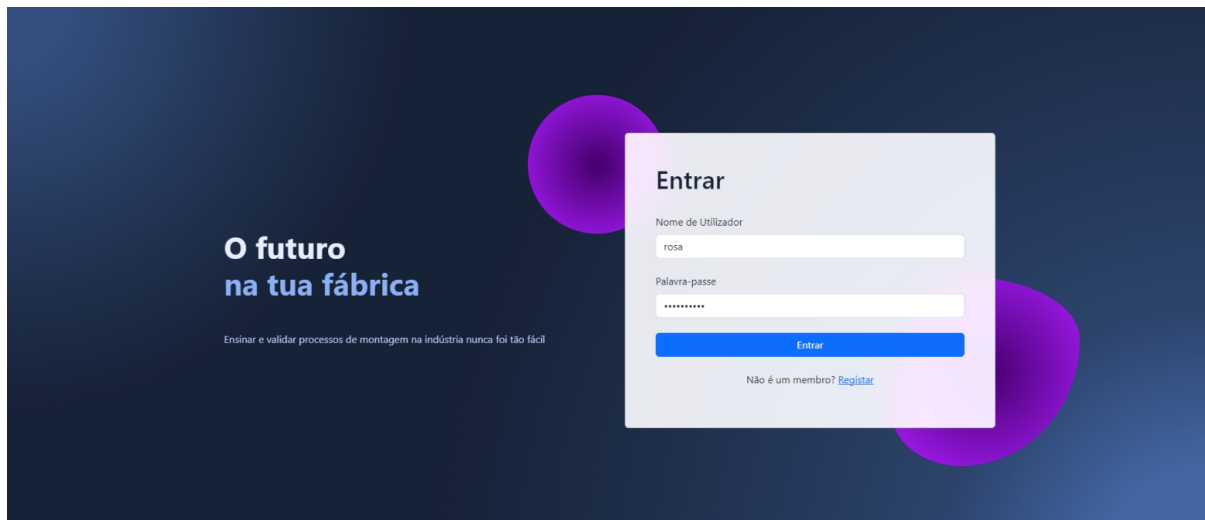
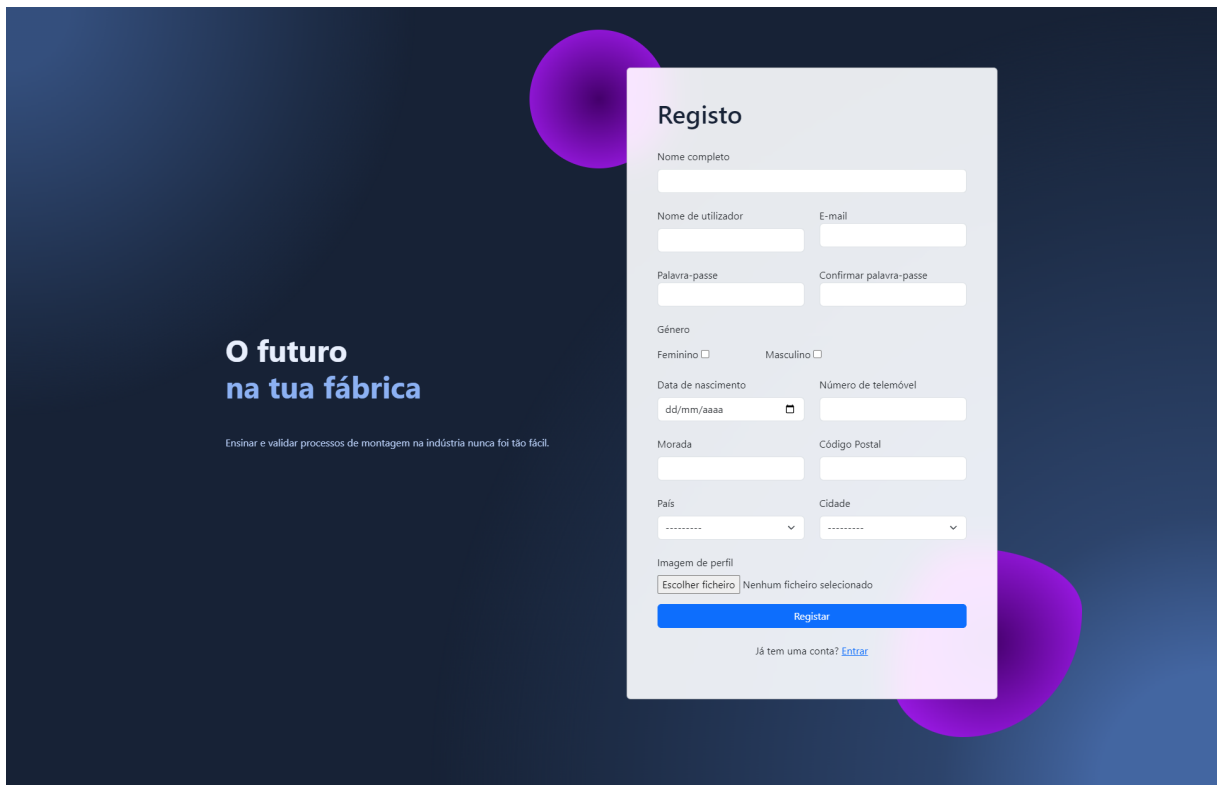


Figura 4.1: UI de *login*

No caso de novos utilizadores, faz-se o registo através do formulário acessível na opção “Registar” da UI de *login*. A Figura 4.2 apresenta as informações básicas a serem preenchidas. Após concluir a ação, os privilégios necessários para aceder ficam pendentes até que lhe seja atribuído o tipo de perfil.



The image shows a registration form titled "Registo" overlaid on a dark blue background with purple circles. The form contains the following fields and options:

- Nome completo:
- Nome de utilizador:
- E-mail:
- Palavra-passe:
- Confirmar palavra-passe:
- Género:  Feminino  Masculino
- Data de nascimento:
- Número de telemóvel:
- Morada:
- Código Postal:
- País:
- Cidade:
- Imagem de perfil:  Nenhum ficheiro selecionado


At the bottom of the form, there is a blue "Registar" button and a link: "Já tem uma conta? [Entrar](#)".

On the left side of the background, there is text: "O futuro na tua fábrica" and "Ensinar e validar processos de montagem na indústria nunca foi tão fácil."

Figura 4.2: UI de registo

### 4.1.3 Gestão de Utilizadores

Na UI destinada à gestão de utilizadores, obtêm-se as informações relativas, conforme a Figura 4.3. Na Figura 4.4 constam os detalhes do utilizador selecionado ao clicar em “Detalhes”. Os dados são apresentados numa listagem, a qual é possível filtrar pelo tipo de perfil: Administradores, Aprendizes/Operadores e Utilizadores pendentes. A última opção, ilustrada na Figura 4.5, tem como objetivo não só identificar quem está à espera de aprovação, como também atribuir as permissões por meio da ação “Editar”, demonstrada na Figura 4.6, que representa o formulário de edição onde é possível selecionar o tipo.

Green Auto Utilizadores Formação Qualidade Sair Rosa Maria Fonseca 

Administradores Aprendizes/Operadores Utilizadores Pendentes












Perfil	Nome	Número de telemóvel	E-mail	Ações
	Luzia Saraiva	962008726	luziasaraiva@gmail.com	<a href="#">Detalhes</a> <a href="#">Editar</a> <a href="#">Eliminar</a>
	Ana Correia	910442369	anac@gmail.com	<a href="#">Detalhes</a> <a href="#">Editar</a> <a href="#">Eliminar</a>
	Rosa Maria Fonseca	934001287	rosafonseca@gmail.com	<a href="#">Detalhes</a> <a href="#">Editar</a> <a href="#">Eliminar</a>
	Fábio Carlos Sousa	931969512	fabioccs@gmail.com	<a href="#">Detalhes</a> <a href="#">Editar</a> <a href="#">Eliminar</a>
	Marco Oliveira	918834771	marco@gmail.com	<a href="#">Detalhes</a> <a href="#">Editar</a> <a href="#">Eliminar</a>
	José Correia	91334691	josec@gmail.com	<a href="#">Detalhes</a> <a href="#">Editar</a> <a href="#">Eliminar</a>

Figura 4.3: UI da gestão de utilizadores

Green Auto Utilizadores Formação Qualidade Sair Rosa Maria Fonseca 

Administradores Aprendizes/Operadores Utilizadores Pendentes


Perfil	Nome	Número de telemóvel	E-mail	Ações
	Luzia Saraiva			<a href="#">Detalhes</a> <a href="#">Editar</a> <a href="#">Eliminar</a>
	Fábio Carlos Sousa			<a href="#">Detalhes</a> <a href="#">Editar</a> <a href="#">Eliminar</a>
	Marco Oliveira			<a href="#">Detalhes</a> <a href="#">Editar</a> <a href="#">Eliminar</a>

 Luzia Saraiva ✕

Nome de utilizador: luzia  
 E-mail: luziasaraiva@gmail.com  
 Número de telemóvel: 962008726  
 Data de nascimento: 1999-08-17  
 Endereço: Rua do cemitério 360  
 País: Portugal  
 Cidade: Viseu, Viseu, Portugal  
 Código postal: 3560-085

[Fechar](#)

Figura 4.4: Detalhes do utilizador

Green Auto Utilizadores Formação Qualidade Sair Rosa Maria Fonseca 

Administradores Aprendizes/Operadores Utilizadores Pendentes


Perfil	Nome	Número de telemóvel	E-mail	Ações
	José Correia	91334691	josec@gmail.com	<a href="#">Detalhes</a> <a href="#">Editar</a> <a href="#">Eliminar</a>

Figura 4.5: Utilizadores pendentes de aprovação

The screenshot shows a web interface for editing a user. At the top, there is a navigation bar with 'Green Auto' and menu items: 'Utilizadores', 'Formação', 'Qualidade', and 'Sair'. The user's name 'Rosa Maria Fonseca' is displayed in the top right. The form contains the following fields:

- Nome completo: José Correia
- Nome de utilizador: jose
- E-mail: josec@gmail.com
- Género:  Feminino,  Masculino
- Data de nascimento: 11/05/1987
- Número de telemóvel: 91334691
- Morada: Avenida da Bélgica
- Código Postal: 3510-159
- Pais: Portugal
- Cidade: Viseu, Viseu, Portugal
- Permissões do utilizador:  Administrador,  Aprendiz/Operador

At the bottom right, there is a link: 'Ativar o Windows. Acceda a Definições para ativar o Windows.'

Figura 4.6: Formulário para editar utilizador e atribuir permissões

#### 4.1.4 Formação

Na área de formação, são dispostos os dois tipos de formação disponíveis: formação vocacional e formação no trabalho. Esta UI, ilustrada na Figura 4.7, tem o propósito de informar o utilizador sobre em que consiste cada oferta e de tomar a decisão sobre qual deseja explorar. O botão “Saber mais” dá acesso a cada uma das vertentes, apresentadas em seguida.

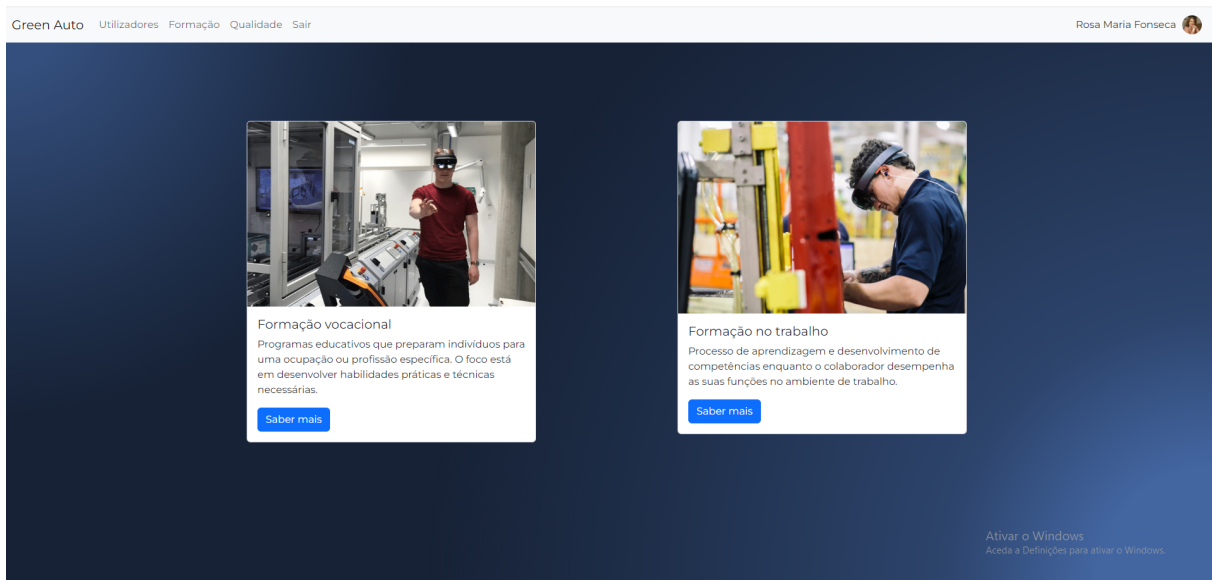


Figura 4.7: UI de formação

#### Gestão de Formação Vocacional

Na UI dedicada à formação vocacional, encontram-se as formações disponíveis, acompanhadas pelas informações fornecidas pelo administrador no momento da sua criação, conforme ilustrado na Figura 4.8.

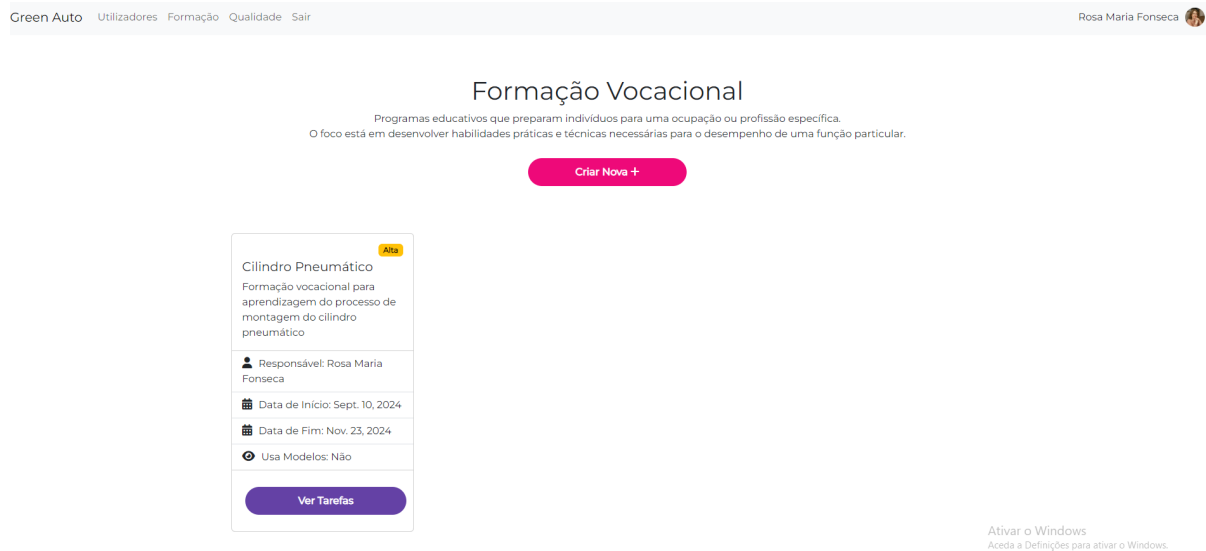


Figura 4.8: UI de formação vocacional

Para adicionar uma nova formação, o utilizador opta por “Criar nova”, o que abre o formulário, representado na 4.9. Nele são solicitadas as informações essenciais: o nome, o nível de prioridade (urgente, alta, normal ou baixa), uma breve descrição, a seleção do utilizador responsável, que prestará apoio ao aprendiz na aplicação de instrução virtual durante a execução das tarefas, assim como a data de início e a data de fim.

Figura 4.9: Criar formação vocacional

Para gerir as tarefas, o utilizador deve escolher “Ver tarefas”, o que o redireciona para a UI observada na Figura 4.10. Nesta UI, é possível visualizar todas as tarefas previamente adicionadas e criar novas. De acordo com a Figura 4.11, o administrador pode inserir uma descrição clara e detalhada da instrução, uma animação (em formato GLB) para exemplificar o resultado a replicar e, ainda, atribuí-la.

Ordem	Descrição	Atribuída	Animação	Opções
1	Encaixar o cilindro na câmara inferior.	Luzia Saraiva		Editar
2	Inserir o piston rod dentro do cilindro, mantendo a haste do lado de fora.	Luzia Saraiva		Editar

Figura 4.10: UI das tarefas da formação vocacional selecionada

**Criar Tarefas**  
Cilindro Pneumático

**TAREFA**  
5

Descrição de como realizar a tarefa

Animação (formato .glt)

Procurar

Utilizadores

Selecionar Utilizadores

- Luzia Saraiva
- Fábio Carlos Sousa
- Marco Oliveira

Adicionar Mais Tarefas
Concluir

Figura 4.11: Criar uma tarefa na formação vocacional

### Gestão de Formação no Trabalho

A Figura 4.12 ilustra a área de formação no trabalho, com uma estrutura similar à da formação vocacional apresentada na Secção 4.1.4. Também é possível visualizar as formações que já foram criadas e, caso se deseje, criar uma nova. O formulário nesta situação é distinto, encontrando-se dividido em duas etapas, representadas, respetivamente, nas Figuras 4.13 e 4.14. A primeira etapa consiste nos detalhes da formação, enquanto a segunda parte refere-se à adição dos modelos de VC. Para adicionar os modelos, o administrador realiza o *upload* do modelo YOLO no formato “.pt”, tradicionalmente utilizado, e do ficheiro “data.yaml”, que contém as classes do modelo. Este ficheiro é sempre gerado durante a criação de um *dataset*, o que elimina a necessidade de retrabalho e torna mais prático a sua importação em vez de escrever todas as classes manualmente.



Figura 4.12: UI da formação no trabalho

### Criar Formação No Trabalho

1 2

DETALHES DA FORMAÇÃO ADICIONAR OS MODELOS

#### DETALHES DA FORMAÇÃO

Nome do Projeto Prioridade

Nome Nível

Descrição

Escreva uma visão geral do projeto, destacando os principais objetivos e qualquer informação relevante...

Utilizador Responsável

Selecionar Utilizador

Data Inicio Data Fim

dd/mm/aaaa dd/mm/aaaa

[Próximo](#)

Figura 4.13: Criar formação no trabalho parte 1

Figura 4.14: Criar formação no trabalho parte 2

Na Figura 4.15 a lista de tarefas mostra a peça e a validação que lhe foram concedidas no momento da criação. Assim, o formulário para adicionar a tarefa também requer que sejam selecionadas as classes para ambos os casos, conforme ilustrado na Figura 4.16.

Green Auto Utilizadores Formação Qualidade Sair Rosa Maria Fonseca

### Todas as Tarefas CILINDRO PNEUMÁTICO PRO

Adicionar Novas Tarefas +


Ordem	Descrição	Atribuída	Peça	Validação	Animação	Opções
1	Encaixar o cylinder tube na head cover.	Luzia Saraiva	cylindertube, headcover	pctask1	sem	<a href="#">Editar</a>
2	Inserir o piston rod dentro do cilindro, mantendo a haste do lado de fora.	Luzia Saraiva	pistonrod	pctask2		<a href="#">Editar</a>
3	Colocar a peça rod cover na haste do piston rod.	Luzia Saraiva	rodcover	pctask3	sem	<a href="#">Editar</a>
4	Apertar completamente a rod end nut, com movimentos de rotação, na extremidade da haste.	Luzia Saraiva	rodendnut	pctask4	sem	<a href="#">Editar</a>
5	Inserir o 1.º tie rod pelo head cover, na entrada superior mais distante e depois girá-lo até apertar por completo.	Luzia Saraiva	tierod	pctask5	sem	<a href="#">Editar</a>
6	Inserir o 2.º tie rod pelo head cover, na entrada superior mais próxima, e depois roda até apertá-lo por completo.	Luzia Saraiva	tierod	pctask6	sem	<a href="#">Editar</a>
7	Inserir o 3.º tie rod pelo head cover, na entrada superior mais próxima, e depois roda até apertá-lo por completo.	Luzia Saraiva	tierod	pctask7	sem	<a href="#">Editar</a>
8	Inserir o 4.º tie rod pelo head cover, na entrada superior mais próxima, e depois roda até apertá-lo por completo.	Luzia Saraiva	tierod	pctask8	sem	<a href="#">Editar</a>
9	Inserir a 1.ª nut do tie rod pelo head cover, na entrada superior mais distante, depois girá-la, mas não apertar por completo.	Luzia Saraiva	tierodnut	pctask9	sem	<a href="#">Editar</a>
10	Inserir a 2.ª nut do tie rod pelo head cover, na entrada superior mais distante, depois girá-la, mas não apertar por completo.	Luzia Saraiva	tierodnut	pctask10	sem	<a href="#">Editar</a>
11	Inserir a 3.ª nut do tie rod pelo head cover, na entrada superior mais distante, depois girá-la, mas não apertar por completo.	Luzia Saraiva	tierodnut	pctask11	sem	<a href="#">Editar</a>
12	Inserir a 2.ª nut do tie rod pelo head cover, na entrada superior mais distante, depois girá-la, mas não apertar por completo.	Luzia Saraiva	tierodnut	pctask11	sem	<a href="#">Editar</a>
13	Com a ajuda da allen key, apertar definitivamente as tie rod nut em forma de cruz, seguindo a mesma ordem - começar pela porca superior mais distante, depois pela porca oposta, em seguida pela porca superior mais próxima e, por fim, pela porca oposta.	Luzia Saraiva	allenkey	pctask13	sem	<a href="#">Editar</a> <a href="#">Apagar</a>

Figura 4.15: UI das tarefas da formação no trabalho selecionada

**Criar Tarefas**  
Cilindro Pneumático Pro

**TAREFA 14**

Descrição de como realizar a tarefa

Animação (formato glib)  
 Carregar Animação Procurar

Utilizadores

Selecionar Utilizadores  
 Luíza Saraiva  
 Fábio Carlos Sousa  
 Marco Oliveira

Peças

Selecionar Peças  
 allenkey  
 cylindertube  
 headcover  
 pistonrod

A validar

Selecionar Validar  
 pctask1  
 pctask10  
 pctask11  
 pctask12

Adicionar Mais Tarefas Concluir

Figura 4.16: Criar uma tarefa na formação no trabalho

#### 4.1.5 Gestão do Controlo de Qualidade

A Figura 4.17 representa a área de qualidade, que mantém um *design* uniforme com as restantes áreas, o que facilita o uso devido ao ambiente familiar criado. Esta UI permite visualizar os controlos de qualidade estabelecidos, adicionar novos, aceder às tarefas existentes e criar outras.

Green Auto Utilizadores Formação Qualidade Sair Rosa Maria Fonseca

**Controlo de Qualidade**

Solução de monitorização em segundo plano que deteta erros sem interferir nas tarefas do operador. Funciona de forma automática e silenciosa, alertando apenas quando ocorre um erro, minimizando a sobrecarga cognitiva.

Criar Novo +

**Fichas do Airbag** Urgente  
 Controlo de qualidade para o erro de ficha do airbag desligada

Responsável: Rosa Maria Fonseca

Data de Início: Oct. 8, 2024

Data de Fim: Oct. 31, 2024

Usa Modelos: Sim

Ver Tarefas

Ativar o Windows  
 Acceda a Definições para ativar o Windows.

Figura 4.17: UI do controlo de qualidade

Distingue-se das UIs de formação pelos elementos específicos dedicados à deteção de erros no controlo de qualidade, como o cabo do airbag desligado. Na Figura 4.18 observa-se o formulário para criar um novo controlo, que se divide em duas etapas: os detalhes e a

adição de modelos. Neste caso, solicita-se apenas um modelo treinado para identificar erros no processo de qualidade. O modelo deve estar no formato (.pt) e ser acompanhado pelo ficheiro “data.yaml”, que contém todas as classes para a identificação dos erros, as quais serão associadas às tarefas.



The screenshot shows a web interface for creating a quality control task. The main heading is 'Criar Controlo de Qualidade'. Below it, there are two steps: '1 DETALHES DO CONTROLO DE QUALIDADE' and '2 ADICIONAR O MODELO'. The current step is 'ADICIONAR O MODELO', which is titled 'Modelo para Reconhecer Erros'. It contains two input fields: 'Modelo (formato .pt)' and 'Data (formato yaml)'. Each field has a 'Carregar' button and a search icon. At the bottom of the form, there are two buttons: 'Anterior' (blue) and 'Criar Projeto' (red).

Figura 4.18: Parte 2 do formulário criar controlo de qualidade

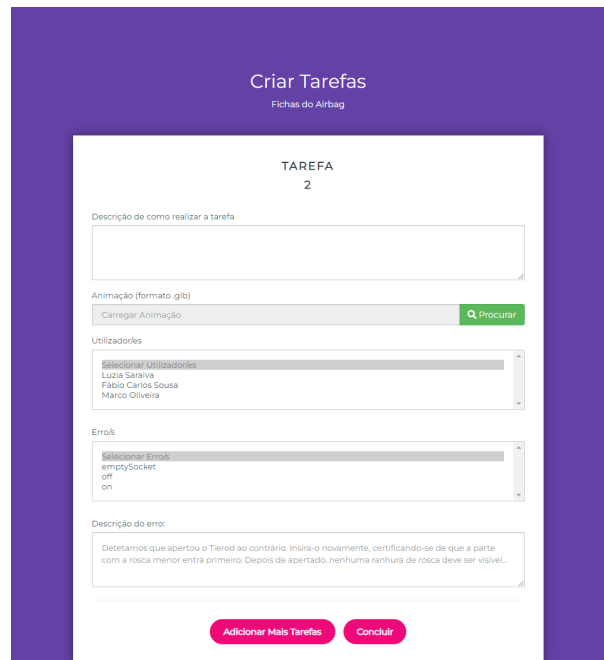
Ao criar uma tarefa, é também necessário selecionar a classe de erro a identificar e redigir uma instrução sobre como o corrigir, de acordo com a Figura 4.20. As listas de tarefas mostram os valores introduzidos nos campos anteriores, conforme ilustrado na Figura 4.19.

**Todas as Tarefas**  
**FICHAS DO AIRBAG**

[Adicionar Novas Tarefas +](#)

Ordem	Descrição	Atribuída	Erro	Instrução de Correção	Opções
1	Detetar se o cabo do airbag está desligado	Luzia Saraiva	Off	Na conexão da ficha do airbag do tipo	<a href="#">Editar</a> <a href="#">Apagar</a>

Figura 4.19: UI das tarefas do controlo de qualidade selecionado



Criar Tarefas  
Fichas do Airbag

TAREFA  
2

Descrição de como realizar a tarefa

Animação (formato .gltf)  
Carregar Animação

Utilizadores

Selecionar Utilizadores  
Lucia Saravia  
Fábio Carlos Sousa  
Marco Oliveira

Erros

Selecionar Erros  
emptySocket  
off  
on

Descrição do erro:  
Detetamos que apertou o Tierod ao contrário. Insira-o novamente, certificando-se de que a parte com a rosca menor entra primeiro. Depois de apertado, nenhuma ranhura de rosca deve ser visível...

Adicionar Mais Tarefas Concluir

Figura 4.20: Criar uma tarefa no controlo de qualidade

## 4.2 Aplicação de Instrução Virtual

Esta secção descreve o processo de desenvolvimento da aplicação de instrução virtual para o HMD Magic Leap, conforme ilustrado na Figura 4.21, que retrata um momento de interação durante os testes.



Figura 4.21: Execução da aplicação no HMD

A aplicação foi desenvolvida no Unity com base num projeto do tipo “3D (Built-in Render Pipeline) Core”. A configuração inicial contou com o Magic Leap Setup Tool, da Unity Asset Store, e com a instalação da *Software Development Kit* (SDK) oficial através do Magic Leap

Hub, versão 3, o que permitiu garantir a compatibilidade com o Magic Leap. A ativação do XR Plugin Management e a definição do Magic Leap Provider foram realizadas manualmente nas definições do projeto. A aplicação encontra-se organizada por cenas distintas, cada uma responsável por uma fase funcional: autenticação do utilizador, seleção do projeto, execução das tarefas de formação e controlo de qualidade.

As interações em RM são suportadas pelo MRTK 3 que permite a deteção de gestos manuais sem necessidade de controladores físicos. A *interface* gráfica foi desenvolvida com elementos padrão da UI do Unity, como botões e campos de texto. Para a introdução de dados textuais, foi utilizado o Magic Leap XR Keyboard, que disponibiliza um teclado virtual.

A comunicação com a API externa é efetuada por meio de pedidos HTTP, através da classe UnityWebRequest, disponibilizada pelo Unity.

### 4.2.1 Autenticação

Ao iniciar a aplicação de instrução virtual, o operador visualiza a *interface* de *login*, conforme ilustrado na Figura 4.22. Por meio de campos de entrada do tipo InputField, do Unity, são-lhe solicitados o nome de utilizador e a palavra-passe. Quando o InputField é selecionado, surge automaticamente o teclado virtual. Isso é possível com o método OpenKeyboard(), que é acionado pelos eventos onSelect previamente configurados.

Após preenchidas todas as informações necessárias e pressionado o botão “Entrar”, estas são organizadas num formulário codificado, que é transmitido para a API. Essa comunicação realiza-se através do método UnityWebRequest.Post(). A API ao receber o pedido, procede à validação das credenciais na base de dados. Em caso de sucesso, cria um JSON Web Token de acesso e devolve-o à aplicação de instrução, permitindo ao aprendiz prosseguir para o ecrã seguinte.

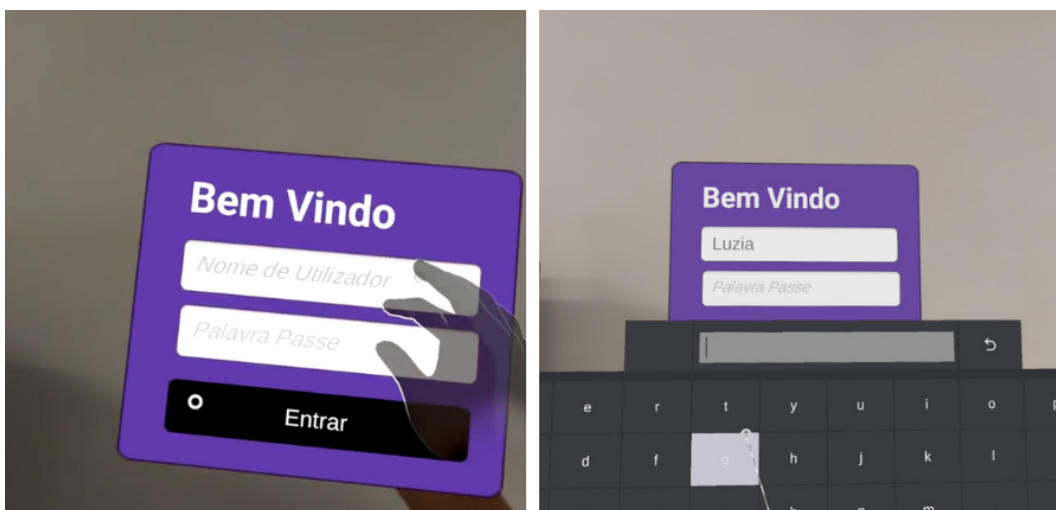


Figura 4.22: *Interface* de autenticação com o Magic Leap

### 4.2.2 Escolher Projeto

Após a autenticação bem-sucedida a experiência do operador é personalizada. É exibida uma mensagem de boas-vindas com o seu nome e uma explicação clara de que deverá escolher

um conjunto de tarefas a realizar. Para obter essas informações, a aplicação de instrução faz um pedido `UnityWebRequest.Get()` à API, que retorna os projetos, nos quais existem tarefas para realizar e designadas ao utilizador em questão. Para isso, é feita uma filtragem de acordo com os seguintes critérios: o campo “`assigne_users`”, da base de dados, deve corresponder ao ID do utilizador autenticado e o campo “`completed`” deve conter o valor 0 (falso). Após esta verificação, os projetos associados às tarefas são ordenados pelo nível de prioridade, do nível “urgente” ao “baixa”. Caso dois projetos tenham a mesma prioridade, a ordenação é feita pela data de conclusão, com preferência para as que têm a data mais próxima. São apresentados no máximo dois projetos para não sobrecarregar o aprendiz.

O utilizador escolhe a formação ou o controlo de qualidade desejado ao clicar na respetiva opção. Para assegurar um retorno visual inequívoco, o botão correspondente muda para verde após a seleção, o que confirma que a escolha foi efetuada com êxito, como demonstrado na Figura 4.23. A aplicação ativa imediatamente o botão “Entrar”, permitindo o início das tarefas.

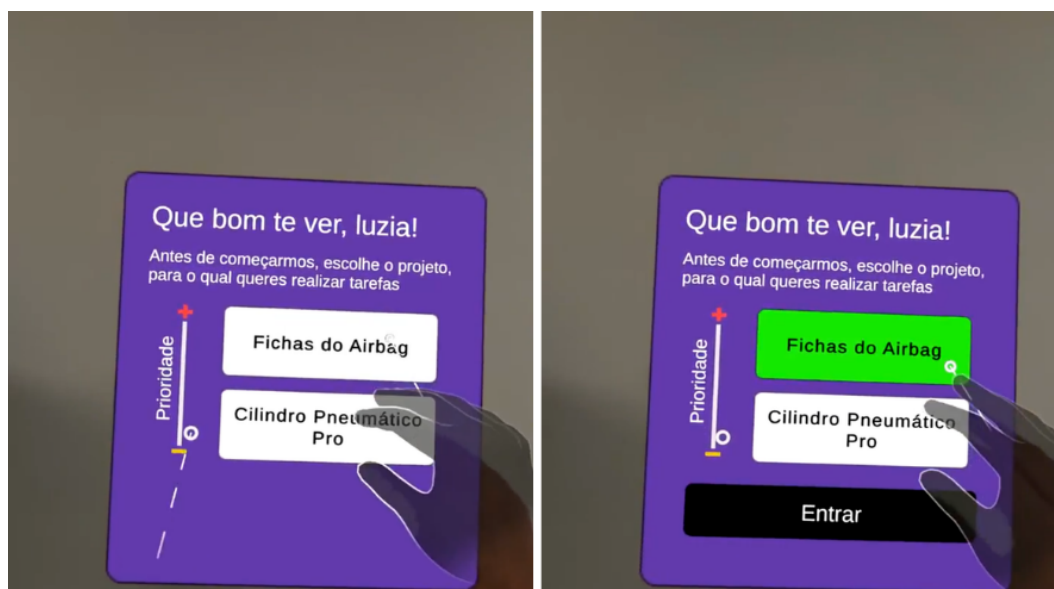


Figura 4.23: Ecrã para selecionar o projeto

### 4.2.3 Executar Tarefas - Projeto Formação Vocacional

Assim que o utilizador seleciona uma formação vocacional, o processo para obter as orientações necessárias é iniciado. Primeiro é realizado um pedido à API através de um método HTTP GET, que devolve as tarefas em formato JSON, incluindo dados como o identificador da tarefa, a descrição, o número de sequência e o ficheiro da animação correspondente. Depois são convertidos para objetos manipuláveis no Unity, em que através da *deserialization*, o conteúdo recebido é transformado em instâncias de uma classe. Após essa organização a *interface* é atualizada com esses valores, como apresentado na Figura 4.24. A descrição da tarefa e o respetivo número surgem através de componentes de texto do tipo “Text – TextMeshPro”.

Quando a tarefa possui um modelo 3D, a aplicação efetua o seu carregamento no ambiente Unity e realiza os ajustes necessários ao nível da posição, escala e orientação. Caso esse

modelo inclua uma animação, esta é reproduzida automaticamente e com um comportamento repetitivo.

Para acompanhar o desempenho do utilizador, procede-se ao registo dos tempos de início e fim de cada etapa. Assim que as instruções surgem ao operador, a data é guardada localmente, no formato padrão (ISO 8601). Em seguida, a aplicação envia essa informação para a API através de um pedido HTTP do tipo PATCH, que atualiza o atributo “start\_date\_registered” da entidade “Performance”, correspondente ao identificador da tarefa atual. Quando a tarefa é concluída e o botão “Próxima” é selecionado, a data de conclusão é igualmente atualizada e o atributo “completed” assume o valor de 1 (verdadeiro).

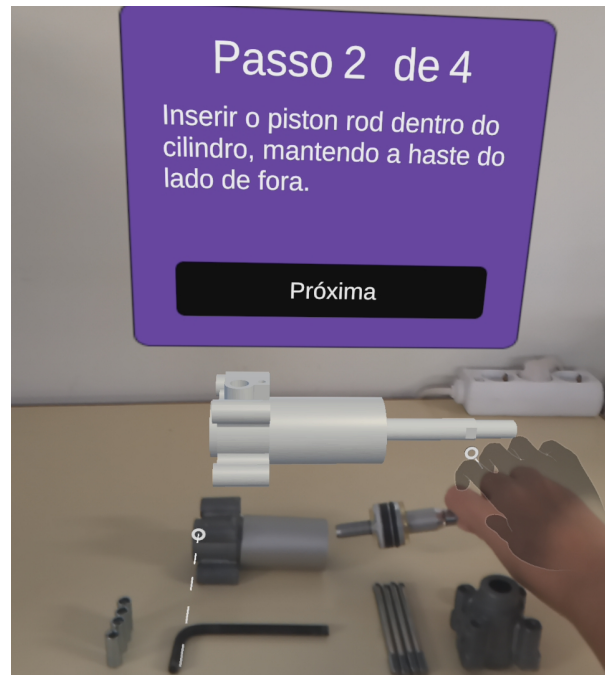


Figura 4.24: Execução da tarefa no contexto de formação vocacional

#### 4.2.4 Executar Tarefas - Formação no Trabalho

A preferência por um projeto do tipo formação no trabalho apresenta duas variações, uma vez que a seleção do modelo de peças e do modelo de validação é opcional.

No cenário em que é fornecido o primeiro modelo e as classes das peças são designadas nas tarefas, a *interface* de preparação é exibida antes do início da execução do trabalho. Conforme indicado na Figura 4.25, a UI contém a lista completa de todas as peças necessárias e as respetivas quantidades. Após a obtenção desta informação, o próximo passo no sistema consiste em garantir a prontidão da câmara de VC do Magic Leap para utilização. Esta câmara apenas funcionará se todas as permissões de acesso tiverem sido previamente concedidas à aplicação. Assim que a acessibilidade é confirmada, estabelece-se a ligação. De seguida, inicia-se o processo de captura de imagens a uma taxa de 30 FPS. Contudo, para evitar atrasos no processamento e reduzir a latência, a aplicação não armazena todos os *frames* capturados. Apenas o *frame* mais recente é guardado num *array*, garantindo que a aplicação utiliza sempre a imagem mais atualizada possível antes de a enviar para a API. Assim que um *frame* está pronto, converte-se para o formato “base64”, uma codificação que

permite enviar a imagem como parte de um pedido HTTP. A imagem é enviada para a API através do UnityWebRequest, constituindo o novo dado de entrada do modelo atribuído ao projeto. Com base no resultado da classificação, se a peça for encontrada na quantidade correta, os valores no ecrã atualizam-se e passam a ter a cor verde. Para as peças que possuem mais do que uma unidade, como os *tie rods*, apenas se validam as identificações em que toda a quantidade é detetada no mesmo dado visual. Desta forma, os quatro *tie rods* devem ser identificados na mesma imagem, pois a soma das deteções em imagens diferentes poderia conduzir a contagens erradas.

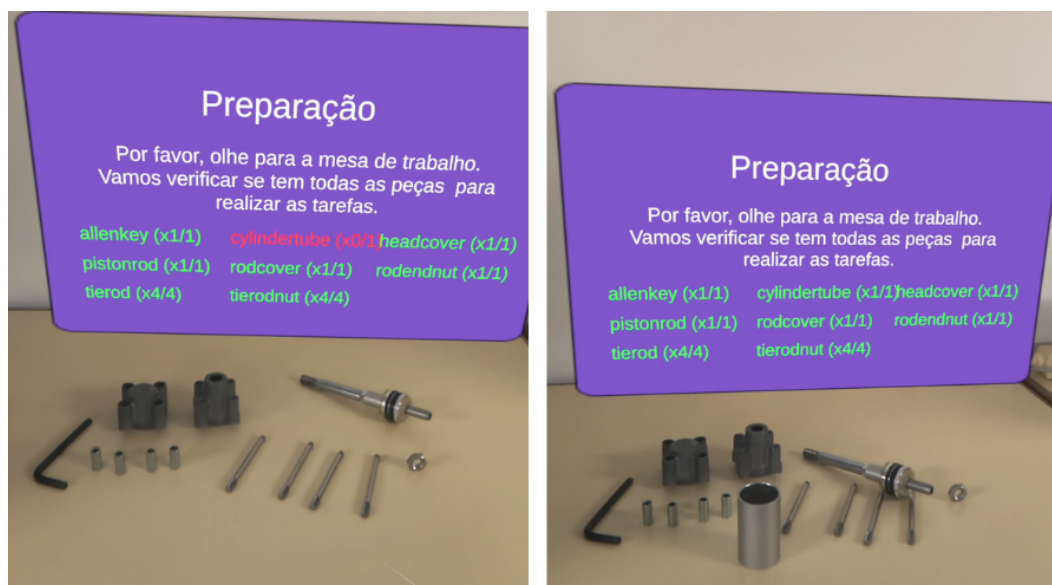


Figura 4.25: Fase de preparação na aplicação de instrução virtual

Concluída a fase de preparação e tendo por base o modelo de validação, inicia-se o processo de execução das tarefas. O envio de imagens segue o procedimento descrito anteriormente. A câmara do HMD, controlada através da API do Magic Leap, realiza a captura de imagens a uma frequência de trinta *frames* e armazena apenas o mais recente para evitar repetições desnecessárias e assegurar que o processo de análise utiliza sempre o dado mais atual. A imagem é convertida e enviada para a API. Contudo, neste contexto, é processada com um modelo de validação associado ao projeto, com o objetivo de verificar se a classe de validação definida na tarefa em execução está presente na imagem recebida. Se a validação não for detetada e o utilizador clicar no botão “Próxima”, o incumprimento da tarefa impede o avanço. O utilizador recebe uma mensagem de correção, conforme ilustrado na Figura 4.26. Assim que a tarefa é executada corretamente, o modelo deteta a classe e o utilizador pode, então, avançar para a próxima tarefa. Quando ocorre esta incongruência, regista-se no desempenho do utilizador como um erro, além dos outros parâmetros, como o tempo de execução da tarefa e se esta está completa.

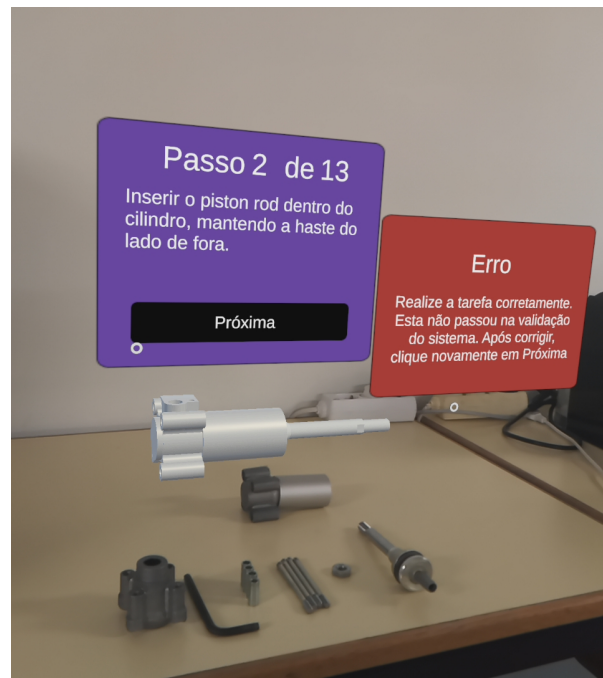


Figura 4.26: Formação no trabalho com a notificação de que a tarefa não foi corretamente cumprida

#### 4.2.5 Executar Tarefas - Monitorização do Controlo de Qualidade

Caso o operador escolha um projeto na categoria de controlo de qualidade, o *feedback* será fornecido apenas em situações de inconformidade. Esta abordagem pretende reduzir a carga cognitiva, limitando as notificações aos momentos realmente necessários. Após a seleção, o sistema inicia o envio de imagens em tempo real para a API, que são processadas pelo modelo de deteção de falhas previamente associado ao projeto. Se a classificação identificar a mesma classe definida como erro na tarefa, o sistema exibe um alerta por um período específico. A Figura 4.27 mostra a visão do utilizador, onde a mensagem de inconformidade reflete as instruções definidas na tarefa para corrigir a situação.

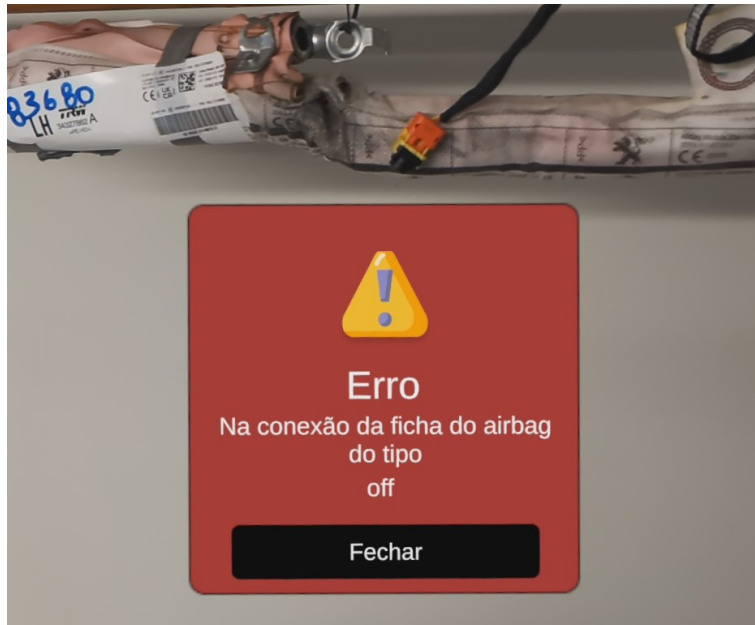


Figura 4.27: O operador é alertado para a não conformidade identificada no controlo

#### 4.2.6 API

A API criada tem como principal objetivo permitir a comunicação de dados entre a aplicação de instrução virtual e a aplicação de administração. Esta *interface* disponibiliza diversas funcionalidades essenciais, como a autenticação de utilizadores, a listagem de projetos associados, e respetivas tarefas. Além disso, suporta o carregamento de modelos 3D e a execução das validações visuais, em tempo real, inerentes ao controlo de qualidade e a formação no trabalho.

Durante a execução das tarefas, a *interface* gere informações críticas, como os tempos de execução, a conclusão ou não das tarefas e a identificação de erros. Esta abordagem assegura a sincronização e a integridade dos dados entre os componentes. Foi desenvolvida com a DRF, no padrão REST, e a sua estrutura segue o modelo CRUD para as operações principais, ao permitir criar, ler, atualizar e eliminar os utilizadores, as tarefas e os projetos, com este último representado na Figura 4.28. Adicionalmente, inclui *endpoints* específicos que, devido à sua particularidade, não seguem rigorosamente este padrão e estão documentados através de fluxogramas na Secção 7.4 dos Anexos.



Figura 4.28: Operações CRUD dos projetos

### 4.3 Sumário

Este capítulo abordou a implementação prática do sistema, detalhou a criação da aplicação de administração, da solução de RM e da API que conecta ambas. A primeira integra funcionalidades como autenticação, gestão de utilizadores, formação e controlo de qualidade, enquanto a segunda permite executar as tarefas e realizar a monitorização em tempo real.

O capítulo seguinte apresenta os testes efetuados às soluções desenvolvidas e os resultados das respetivas métricas de desempenho.



## Capítulo 5

# Validação e Avaliação

Neste capítulo apresentam-se os casos de uso aplicados na validação das funcionalidades de formação e controlo de qualidade do sistema desenvolvido. Seguidamente, procede-se à avaliação dos resultados.

### 5.1 Validação da Formação com Montagem de Cilindro Pneumático

Esta secção apresenta os procedimentos adotados para validar a solução desenvolvida na vertente de formação, tanto vocacional como no trabalho, clarifica a relevância do objeto de estudo selecionado, detalha os conjuntos de dados criados e justifica o processo de elaboração das animações.

#### 5.1.1 Formação Vocacional

O objeto escolhido para validar a solução proposta foi o CP. Consiste num atuador que converte a pressão de ar comprimido em movimento mecânico [111]. Isso é possível ao deslocar um *piston* dentro de um *cylinder*, onde o ar introduzido exerce tensão sobre ele, movendo-o numa direção linear. É especialmente útil em sistemas industriais onde sejam necessários deslocamentos precisos. Este componente é constituído por sete partes distintas, ilustradas na Figura 5.1. Além das duas já mencionadas, incluem-se o *rod cover*, *head cover*, *tie rod*, *rod end nut* e *tie rod nut*. As etapas de montagem, definidas com a ajuda do manual do modelo “C96S” [112], são descritas na Tabela 5.1.


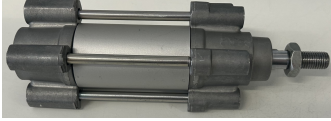



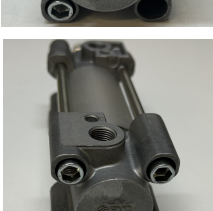



Figura 5.1: Peças envolvidas na montagem do CP

Tabela 5.1: Tabela com tarefas e imagens das etapas correspondentes

Tarefa	Descrição	Imagem
1	Encaixar o <i>cylinder tube</i> na <i>head cover</i> .	
2	Inserir o <i>piston rod</i> dentro do <i>cylinder</i> , mantendo a haste do lado de fora.	
3	Colocar a peça <i>head cover</i> na haste do <i>piston rod</i> .	
4	Apertar completamente a <i>rod end nut</i> , com movimentos de rotação, na extremidade da haste.	
5	Coloque o primeiro <i>tie rod</i> com a rosca menor na entrada superior do <i>rod cover</i> , localizada no canto superior do seu lado, e aperte firmemente até ao fim.	
6	Introduza o segundo <i>tie rod</i> com a rosca menor na entrada superior do <i>rod cover</i> , posicionada no canto superior oposto a si, e aperte até ficar totalmente ajustado.	
7	Insira o <i>tie rod</i> na entrada inferior do <i>rod cover</i> , situada no canto inferior mais afastado de si, e fixe-o até ao fim.	

Tarefa	Descrição	Imagem
8	Posicione o último <i>tie rod</i> na última abertura livre do <i>rod cover</i> e fixe-o até ao fim.	
9	Aplique a primeira <i>nut</i> no <i>tie rod</i> superior mais próxima, rodando-a ligeiramente sem apertar totalmente.	
10	Coloque a segunda <i>nut</i> na outra posição oposta, ajustando-a levemente.	
11	Proceda da mesma forma com a terceira <i>nut</i> , na parte superior mais distante, com um ajuste parcial.	
12	Finalize com a quarta <i>nut</i> no último ponto inferior, rodando-a também sem apertar na totalidade.	
13	Com a ajuda de uma chave <i>allen</i> , aperte definitivamente as <i>tie rod nuts</i> em cruz.	

Com a lista das instruções, optou-se ainda por elaborar as animações de cada uma das etapas. Estes conteúdos permitem criar um projeto de formação vocacional completo. Para criar as animações, assume-se a existência ou a prévia criação dos modelos 3D das peças envolvidas nas etapas de montagem do componente, descritas anteriormente na secção 5.1.1. Não foi necessário modelar as peças do CP, pois foram disponibilizados pelos autores em [38]. As animações 3D, desenvolvidas com o Blender, integram várias componentes do cilindro de acordo com a sequência de montagem. Ao todo, treze animações foram criadas, conforme representado na Figura 5.2, e apresentam de forma clara e precisa o movimento que o utilizador deve replicar ao executar a tarefa.

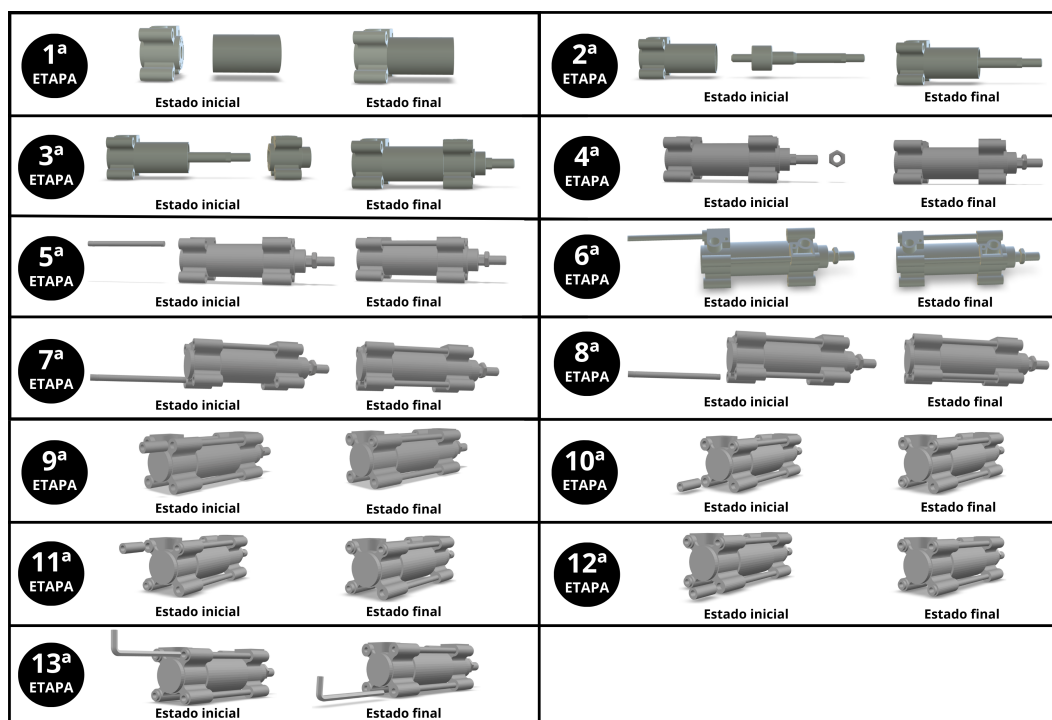


Figura 5.2: Representação das animações criadas

### 5.1.2 Formação no Trabalho

A formação no trabalho envolve a associação de até dois tipos de modelos: o Modelo para Identificação de Componentes Individuais e o Modelo para Validação das Tarefas, detalhados anteriormente na Secção 3.1.4. Cada um reflete um objetivo específico, pelo que o CP foi utilizado como base para desenvolver um modelo de identificação das suas peças e outro para validar as tarefas da sua montagem. O processo iniciou-se com a aquisição de imagens do objeto em diferentes condições, seguiu-se a anotação das características relevantes nas figuras e, por fim, o treino do modelo com os dados anotados.

A recolha das imagens teve em consideração aspetos como variações de fundos, utilização de bancadas de trabalho distintas, múltiplos ângulos e diferentes condições de iluminação. Este último fator foi atingido através da utilização de luz natural e artificial com intensidades diversificadas. Para garantir uma ampla gama de ângulos, as capturas foram realizadas com rotações em torno do objeto e, para obter diferentes perspetivas, procedeu-se à aproximação e afastamento da câmara em relação ao objeto. Estas escolhas tiveram como objetivo diversificar e robustecer o modelo, de maneira a evitar os problemas recorrentes na VC, como a confusão com o fundo e as distorções causadas pela iluminação. Com um telemóvel iPhone 14, foram captadas 2756 imagens individuais com resolução de 4032x3024 píxeis e em formato JPG.

A anotação dos dados visuais foi realizada com o *software* Roboflow. Foi criado um projeto para cada caso, com a definição do tipo de tarefa de visão pretendida, como a OD ou a segmentação de instâncias. Após o carregamento das imagens captadas, foram atribuídas categorias com designações apropriadas. A rotulagem foi efetuada através de polígonos, como

retângulos no caso da OD, para delimitar a área onde o elemento se encontra e associá-lo à respetiva categoria.

As Tabelas 5.2 e 5.3 contêm uma visão geral de cada *dataset*. Fazem parte as categorias, a quantidade de imagens, o número total de anotações e um resumo com os totais de imagens únicas e anotações por conjunto. As etiquetas com um número inferior de imagens face ao total de anotações referem-se a peças em numerosas quantidades, como os parafusos (*tierod*), que se repetem e resultam em múltiplas anotações numa única figura. Além disso, o total de registos por elemento nem sempre corresponde ao número de imagens únicas devido à presença de diferentes tipos de objetos numa única fotografia.

Tabela 5.2: Detalhes do *dataset* de componentes individuais do CP

<b>Dataset Detecção de Peças com o CP</b>				
<b>Nº</b>	<b>Classe</b>	<b>Descrição</b>	<b>Imagens por Classe</b>	<b>Anotações por Classe</b>
1	<i>allenkey</i>	Chave <i>allen</i> utilizada na montagem	150	150
2	<i>cylindertube</i>	Tubo principal do CP	150	150
3	<i>headcover</i>	Tampa superior do CP	150	150
4	<i>pistonrod</i>	Haste principal do <i>piston</i>	150	150
5	<i>rodcover</i>	Cobertura da haste do <i>piston</i>	150	150
6	<i>rodendnut</i>	Porca de fixação da extremidade da haste	150	150
7	<i>tierod</i>	Haste transversal de fixação	80	150
8	<i>tierodnut</i>	Porca de fixação da haste transversal	81	150
	<b>Totais do Dataset</b>		<b>Imagens Únicas: 807</b>	<b>Anotadas: 1200</b>

Tabela 5.3: Detalhes do *dataset* de tarefas do CP

<b>Dataset Execução de Tarefas com a Montagem do Cilindro Pneumático</b>				
<b>Nº</b>	<b>Classe</b>	<b>Descrição</b>	<b>Imagens por Classe</b>	<b>Anotações por Classe</b>
1	<i>pctask1</i>	Primeira tarefa do processo de montagem do CP (consultar a Tabela 5.1)	150	150
2	<i>pctask2</i>	Segunda tarefa do processo de montagem do CP	149	149
3	<i>pctask3</i>	Terceira tarefa do processo de montagem do CP	150	150
4	<i>pctask4</i>	Quarta tarefa do processo de montagem do CP	150	150

5	<i>pctask5</i>	Quinta tarefa do processo de montagem do CP	150	150
6	<i>pctask6</i>	Sexta tarefa do processo de montagem do CP	150	150
7	<i>pctask7</i>	Sétima tarefa do processo de montagem do CP	150	150
8	<i>pctask8</i>	Oitava tarefa do processo de montagem do CP	150	150
9	<i>pctask9</i>	Nona tarefa do processo de montagem do CP	150	150
10	<i>pctask10</i>	Décima tarefa do processo de montagem do CP	150	150
11	<i>pctask11</i>	Décima primeira tarefa do processo de montagem do CP	150	150
12	<i>pctask12</i>	Décima segunda tarefa do processo de montagem do CP	150	150
13	<i>pctask13</i>	Décima terceira tarefa do processo de montagem do CP	150	150
	<b>Totais do Dataset</b>		<b>Imagens Únicas: 1949</b>	<b>Anotações: 1949</b>

Após a rotulagem de todas as figuras, o *dataset* é exportado no formato “YOLOv8”, que já inclui toda a estrutura necessária para o treino. A escolha deste modelo e versão baseia-se nas vantagens apontadas por Silva et al. [44], como a elevada precisão, a capacidade de processamento em tempo quase real e a eficácia na deteção de detalhes subtis em imagens. Estas características tornam-no especialmente apropriado para aplicações industriais de controlo de qualidade. As imagens e respetivos rótulos são organizados em três pastas distintas, de acordo com as percentagens previamente definidas: validação, teste e treino.

A última etapa corresponde ao treino do YOLO, versão 8, no tamanho intermédio “m”, com os dois *datasets* descritos para a montagem do CP. O processo foi realizado com as mesmas normas para todos os conjuntos. Os testes iniciais com o primeiro conjunto de peças permitiram definir as condições ideais, demonstradas nas Secções 5.4.1, 5.4.2 e 5.4.3, e aplicadas aos restantes conjuntos. Esta abordagem definiu que cada *dataset* fosse composto apenas por imagens originais, sem recurso a técnicas de aumento, como rotações, espelhamentos ou ajustes de luminosidade. A distribuição das imagens seguiu uma divisão equilibrada: 70% para treino, 20% para validação e 10% para teste, em conformidade com as recomendações do Roboflow [113]. Por último, o treino de cada conjunto ocorreu ao longo de 100 *epochs* (épocas).

### 5.1.2.1 Modelo para Identificação de Componentes Individuais do Cilindro Pneumático

Para a construção do *dataset*, observado na Figura 5.3, foram obtidas 807 imagens das peças do CP, incluindo a chave de aperto necessária. A Figura 5.4 reúne algumas das imagens recolhidas do *piston rod*, onde se observa a variação do fundo e dos ângulos.

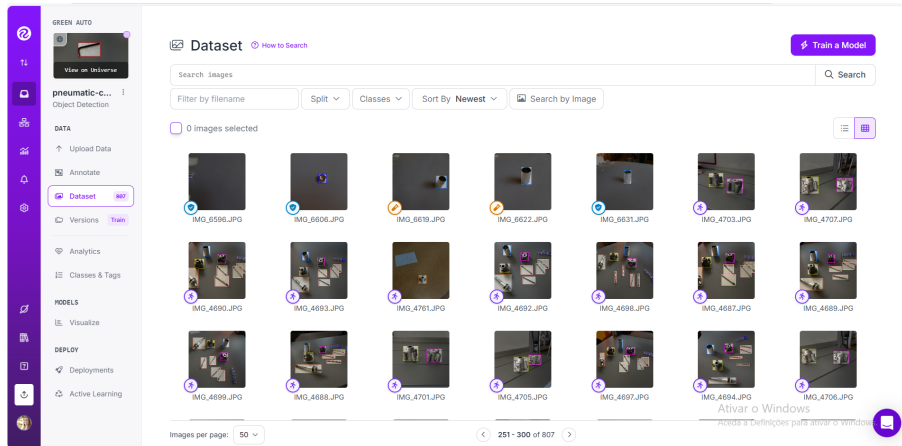


Figura 5.3: Visão geral do *dataset* para deteção das partes envolvidas na montagem do CP




Figura 5.4: *Piston rod* no conjunto de dados

Na fase de anotação, criaram-se oito classes com o nome de cada objeto. Optou-se por nomear as classes em língua inglesa, devido à sua universalidade e para assegurar a conformidade com os nomes presentes no manual. As classes são: *allenkey*, *cylindertube*, *headcover*, *pistonrod*, *rodcover*, *rodendnut*, *tierod* e *tierodnut*. A cada uma foi atribuída uma cor distinta para facilitar a identificação.

O processo de anotação é o mais exigente devido ao esforço mental necessário para garantir a consistência das anotações num grande conjunto de dados, tratando-se de uma tarefa exaustiva e repetitiva, como ilustrado na Figura 5.5 (a), onde dezenas de imagens da mesma classe são trabalhadas. Este esforço intensifica-se pela atenção minuciosa exigida para definir os limites dos objetos com precisão e pela tomada de decisões em situações de ambiguidade (b). Estes fatores, em conjunto, afetam diretamente os resultados do modelo e aumentam a pressão sobre a qualidade do trabalho realizado.

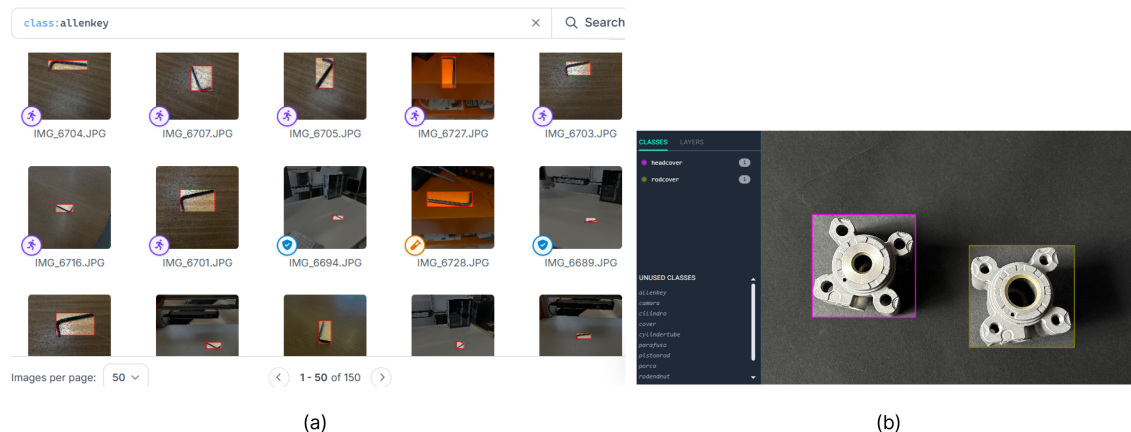


Figura 5.5: Complexidade da anotação pela repetitividade e ambiguidade.

Com o objetivo de agilizar e minimizar as dificuldades sentidas, recorreu-se à funcionalidade *label assist*, apresentada na Seção 2.6.5, com base no modelo desenvolvido em Silva et al. [44], que inclui algumas das peças do mesmo CP. Os passos para a sua aplicação encontram-se na Figura 5.6. Inicialmente, procede-se à seleção do modelo, ilustrado em (a), e, de seguida, das classes desejadas, conforme indicado em (b), aplicando o modelo de forma preditiva a novas imagens. Este procedimento mostrou-se útil, embora apresentasse algumas limitações, como a ausência de deteções para peças como *tierodnut* e *allenkey*.

Adicionalmente, o uso da mesma etiqueta para diferentes peças, como *rodcover* e *headcover*, resultou em rótulos incorretos. Verificaram-se também inconsistências na anotação do componente *piston rod*, conforme indicado em (c). Apesar disso, a disponibilização de uma referência prévia, com o desenho da caixa delimitadora, permitiu uma redução significativa do tempo necessário. Em (d), é apresentada a anotação corrigida da imagem, com as etiquetas ajustadas e as caixas delimitadoras posicionadas com maior rigor.

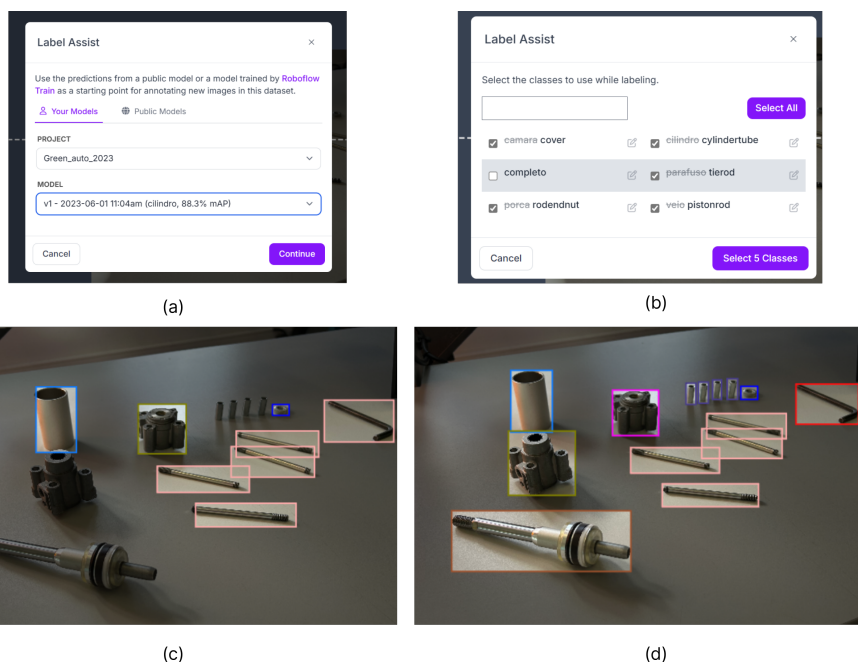


Figura 5.6: Roboflow *label assist*

### 5.1.2.2 Modelo para Validação das Tarefas com Montagem de Cilindro Pneumático

Face à crescente dificuldade em distinguir as diferentes tarefas, particularmente a partir da quinta etapa, momento em que se inicia a colocação dos *tie rods* e o nível de detalhe se torna progressivamente mais elevado e exigente, optou-se por uma abordagem assente na segmentação de instância. Este tipo de tarefa no domínio da VC possibilita a identificação precisa de cada etapa, mesmo daquelas com elevado grau de similaridade entre si. Deste modo, o conjunto de dados utilizado distingue-se dos restantes orientados para a OD, uma vez que está destinado à segmentação de instâncias.

O objetivo desta escolha é informar a CNN sobre os píxeis específicos dos quais deve extrair as características, tornando o modelo mais apto a lidar com os detalhes de cada tarefa. Este tipo de anotação, em comparação com os outros, requer mais atenção e tempo. No entanto, a ferramenta *Smart Polygon* do *Roboflow*, que utiliza o modelo *Segment Anything Model 2*, contribui para atenuar estas exigências. Esta funcionalidade permite selecionar automaticamente a área do objeto, ao traçar o seu contorno na imagem. Embora a precisão não seja total e exija alguns ajustes, a ferramenta reduz consideravelmente o tempo de anotação. A Figura 5.7 ilustra um dos dados visuais, demonstrando na prática o tipo de rotulagem descrito.



Figura 5.7: Anotação da décima terceira tarefa

A Figura 5.8 apresenta uma amostra do *dataset* final, que contém um total de 1949 imagens e 13 classes (*pctask1*, *pctask2*, *pctask3*, *pctask4*, *pctask5*, *pctask6*, *pctask7*, *pctask8*, *pctask9*, *pctask10*, *pctask11*, *pctask12* e *pctask13*), as quais representam o estado final corretamente executado de uma tarefa específica. A categoria *pctask1* corresponde à primeira tarefa, a *pctask2* à segunda, e assim sucessivamente. O prefixo “pc” refere-se a “*pneumatic cylinder*”, o que significa que a montagem está associada ao componente CP.

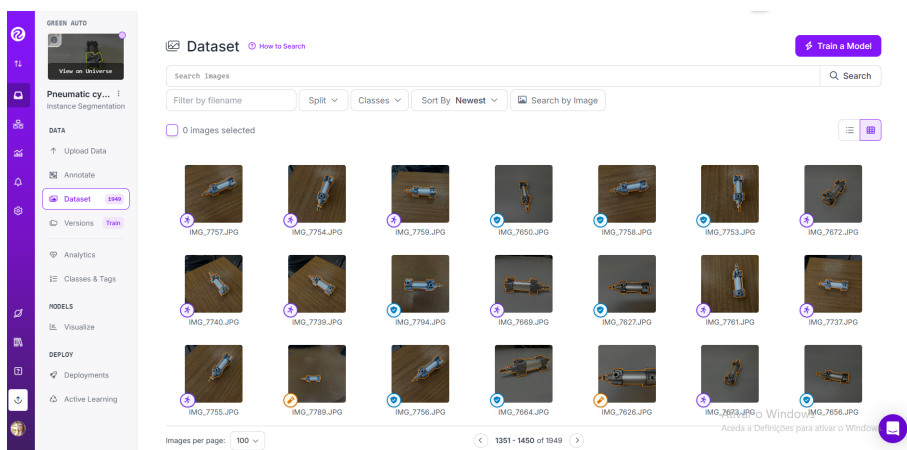


Figura 5.8: Conjunto de dados para a validação da correta execução das tarefas de montagem do CP

## 5.2 Validação do Controlo de Qualidade com Ligação de Cabo de *Airbag*

Esta secção detalha a abordagem utilizada para testar o controlo de qualidade. Abrange o componente seleccionado e o conjunto de dados desenvolvido para treinar o “Modelo para Reconhecer Erro(s)” requerido.

### 5.2.1 Cabo de *Airbag*

Como objeto de validação foi escolhido o cabo de *airbag* do automóvel. Este componente assegura a ligação correta entre os sensores de impacto e o mecanismo do *airbag*, garantindo a sua adequada ativação em caso de colisão. O sistema de monitorização implementado na linha de montagem do automóvel deve identificar quando a ficha se encontra desligada, conforme exemplificado na Figura 5.9 (a), e alertar o operador para que ele possa corrigir a situação detetada.




Figura 5.9: Ficha de *airbag* desligada (a) e ligada (b)

### 5.2.2 Modelo para Reconhecer Erro(s) da Ligação de Cabo de Airbag

A criação de um *dataset* para a deteção do cabo de *airbag* no seu estado de erro, ou seja, desligado, implica a captura do ambiente real, onde o cabo se encontra efetivamente conectado ou desligado do *socket* do *airbag*. Uma vez que as imagens foram captadas no interior de uma fábrica, durante o horário de trabalho e com a linha de montagem em operação, não foi possível ter um controlo total sobre os ângulos desejados ou a iluminação. Além disso, a luz artificial disponível revelou-se frequentemente insuficiente devido ao ambiente interno da carroçaria do automóvel. Para maximizar o tempo limitado disponível na recolha de dados das fichas do *airbag*, sete vídeos foram registados com o HMD Magic Leap enquanto os operadores trabalhavam no turno. As gravações têm uma taxa de 30 FPS, resolução de 1920x1080 píxeis e relação de aspeto de 9:10. Esses vídeos resultaram na extração de 577 imagens com dimensões finais de 976x1088 píxeis, armazenadas em formato PNG, escolhido por preservar a máxima qualidade possível. Ainda assim, a qualidade das imagens obtidas mostrou-se inferior à captada com um telemóvel iPhone 14. Por essa razão, o telemóvel foi também utilizado para garantir a máxima qualidade nos conjuntos de dados, tendo sido captados três vídeos adicionais nesse contexto, dos quais foram extraídas 224 imagens extras. Por motivos de privacidade, apenas é apresentada a Figura 5.10, que exemplifica a rotulagem do cabo. No total, foram anotadas 801 imagens com a técnica de OD, distribuídas por três classes: *off*, *on* e *emptySocket*.

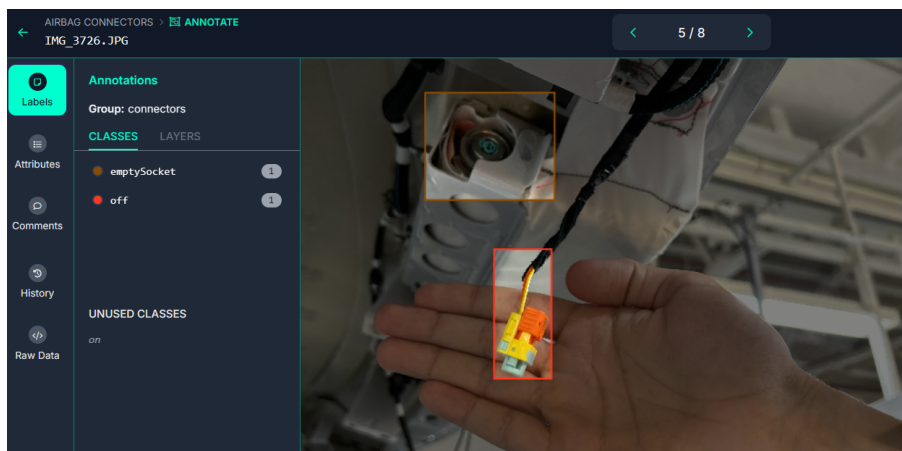


Figura 5.10: Rotulagem do cabo desligado

A Tabela 5.4 pormenoriza os detalhes do *dataset* final, onde se observa que o número total de anotações para *off* é 589.

Tabela 5.4: Detalhes do conjunto de dados para o controlo de qualidade

<i>Dataset</i> controlo de qualidade com a ligação de cabo de <i>airbag</i>				
Nº	Classe	Descrição	Imagens por Classe	Anotações por Classe
1	<i>off</i>	Ficha do <i>airbag</i> desconectada durante o processo de inspeção	509	589

2	<i>on</i>	Cabo do <i>airbag</i> ligada durante o processo de inspeção	344	344
3	<i>emptySocket</i>	<i>Socket</i> da ficha do <i>airbag</i> vazio, sem ficha inserida	174	174
	<b>Totais do <i>Dataset</i></b>		<b>Imagens Únicas: 801</b>	<b>Anotações: 1107</b>

### 5.3 Condições Laboratoriais

O ambiente laboratorial foi configurado de modo a maximizar a eficiência do treino, especificamente para o modelo YOLO. A sua capacidade de 64 GB de memória RAM torna-o apto para processar grandes volumes de dados sem interrupções. Já o SSD de alta velocidade viabiliza a redução do tempo de acesso a ficheiros e modelos. Adicionalmente, a GPU é essencial para acelerar o treino e, conseqüentemente, diminuir o tempo necessário para completar cada *epoch*. A Tabela 5.5 detalha todas as características técnicas.

Componente	Especificação
<b>Processador (CPU)</b>	12th Gen Intel(R) Core(TM) i9-13900KF a 3,2 GHz
<b>Memória RAM</b>	64 GB
<b>Placa Gráfica (GPU)</b>	Asus TUF Gaming GeForce RTX 4090 OC Edition 24GB GDDR6X
<b>Armazenamento</b>	SSD de 930,88 GB
<b>Sistema Operativo</b>	Windows 10 Pro de 64 bits
<b>Software e Bibliotecas</b>	Python 3.8.3, Torch 2.20+cu121, CUDA Toolkit 12.1, Ultralytics 8.2.68

Tabela 5.5: Especificações do ambiente utilizado para o treino dos modelos de visão

### 5.4 Avaliação do Modelo para Identificação de Componentes Individuais do Cilindro Pneumático

Esta secção aprofunda a avaliação do modelo para identificação de componentes individuais proposto, reúne diferentes resultados de teste e descreve a eficácia do processo de identificação dos componentes do CP. Inclui uma análise comparativa entre métodos de treino, apresentada nas Secções 5.4.1, 5.4.2 e 5.4.3. Nesta análise, são avaliadas as variações no número de épocas para compreender o seu efeito no desempenho do modelo, a influência da utilização de um *dataset* com ou sem aumento e o impacto da utilização de um conjunto de dados balanceado em comparação com um de divisão aleatória. São ainda detalhadas as métricas obtidas após o treino, com dados completamente novos, de forma a comprovar a sua competência na deteção de padrões em cenários desconhecidos.

### 5.4.1 Resultados do Teste: Treino com 50 Épocas *versus* 100 Épocas

Nesta secção apresentam-se as conclusões da comparação entre dois modelos treinados com 50 e 100 épocas. A análise centrou-se nos valores de `box_loss`, `cls_loss` e `dfi_loss` durante a fase de validação ao longo do treino, representados na Figura 5.11, os quais permitem avaliar se o modelo consegue generalizar e manter um bom desempenho quando exposto a novos dados. Além disso, observa-se na Figura 5.12 a mAP50, que avalia a AP de todas as classes.




Figura 5.11: Evolução dos componentes da função de perda nas 50 épocas (a) face às 100 (b)

Para uma melhor interpretação, foi calculada a média dos valores registados ao longo das épocas, cujos os resultados estão consolidados na Tabela 5.6.

Tabela 5.6: Análise comparativa da perda de validação em treinos de 50 épocas *versus* 100 épocas

Configuração	val/box_loss (média)	val/cls_loss (média)	val/dfi_loss (média)
50 <i>Epochs</i>	0.7070	1.1277	1.1523
100 <i>Epochs</i>	0.6678	0.8546	1.1036
Melhor	<b>100 <i>Epochs</i></b>	<b>100 <i>Epochs</i></b>	<b>100 <i>Epochs</i></b>

A análise revelou que a mAP50 apresentou melhor desempenho no treino de 100 épocas, com um valor de 0.966 registado em (b), em comparação com 0.964 observado para 50 épocas, indicado em (a).




Figura 5.12: Comparação dos valores de mAP50 para 50 épocas (a) e 100 épocas (b)

Os dados evidenciam uma melhoria consistente nos valores de Val Loss e mAP50, indicando que o modelo continuou a evoluir durante o treino. Por este motivo, decidiu-se adotar 100 épocas como configuração para maximizar a eficiência e a qualidade obtida.

#### 5.4.2 Resultados do Teste: *Dataset* com Aumentação *versus* Sem Aumentação

O presente teste teve como objetivo avaliar o desempenho do modelo em dois cenários distintos, um constituído por imagens exclusivamente originais e outro enriquecido com imagens adicionais obtidas através de técnicas de aumento. Em ambos os casos, o treino foi efetuado ao longo de 100 épocas.

No conjunto aumentado, aplicaram-se diversas técnicas, entre as quais o espelhamento horizontal, o recorte com zoom máximo de 20%, a inclinação horizontal e vertical de  $\pm 10^\circ$ , a variação de brilho entre -15% e +15%, as alterações na exposição até  $\pm 10\%$  e a desfocagem com um limite máximo de 1 píxel. Estas operações resultaram num total de 1935 imagens, o que corresponde a um acréscimo de 1128 relativamente ao conjunto original.

A Figura 5.13 apresenta as curvas da perda de validação. No cenário com aumento, ilustrado em (b), observa-se maior instabilidade, caracterizada por variações mais acentuadas, enquanto o cenário sem aumento, representado em (a), apresenta um comportamento mais regular.




Figura 5.13: Variação de `box_loss`, `cls_loss` e `dfl_loss` em dados não aumentados (a) e aumentados (b)

Na Tabela 5.7 são comparadas as médias das perdas para os dois conjuntos. O modelo sem aumento destacou-se em `box_loss` e `cls_loss`, com valores mais baixos, o que indica um melhor desempenho. Já na função `dfl_loss`, o modelo com dados aumentados mostrou uma vantagem mínima, com uma diferença de 0.0882.

Tabela 5.7: Efeitos da aumento de dados nos valores médios de `box_loss`, `cls_loss` e `dfl_loss`

Configuração	val/box_loss (média)	val/cls_loss (média)	val/dfl_loss (média)
Com Aumento	0.8566	1.3954	1.0154
Sem Aumento	0.6678	0.8546	1.1036
Melhor	<b>sem</b>	<b>sem</b>	<b>com</b>

Por outro lado, a análise da métrica mAP50, ilustrada na Figura 5.14 revelou uma clara superioridade no cenário sem aumento. O modelo treinado com dados originais alcançou um valor de 0.966, representado em (a), enquanto o conjunto com aumento não ultrapassou 0.784, conforme observado em (b).




Figura 5.14: Valores de mAP para dados sem (a) e com (b) técnicas de aumento

Com base nos resultados, verifica-se que o modelo sem aumento apresenta uma *performance* geral superior, com perdas mais reduzidas e maior AP. Assim, para o contexto analisado, recomenda-se a utilização do conjunto de dados original, assegurando maior estabilidade e eficácia.

### 5.4.3 Resultados do Teste: *Dataset* Balanceado 70/20/10 versus Aleatório

Este teste avaliou a influência do balanceamento do conjunto no desempenho do modelo. Foram considerados dois cenários: um sem balanceamento, onde a divisão foi realizada de forma irregular, e outro com balanceamento, através da funcionalidade *Rebalancing Split* do Roboflow. Na configuração sem balanceamento, as imagens foram adicionadas ao conjunto de dados em blocos, ou seja, carregadas e anotadas em grupos separados, sem considerar a distribuição das classes. Após a anotação de cada bloco, este era integrado no *dataset*, com uma percentagem fixa para treino, validação e teste. No entanto, como cada bloco continha um número variável de imagens e classes diferentes, a distribuição final não garantiu uma separação uniforme entre as classes dentro de cada conjunto. Assim, apesar de terminar com uma divisão 68% para treino, 21% para validação e 11% para teste, isso não significa que todas as classes estejam proporcionalmente representadas em cada uma dessas partes. Na configuração balanceada, o conjunto foi estruturado de forma equitativa: 70% para treino (565 exemplos), 20% para validação (162) e 10% para teste (80). Além disso, as classes foram ajustadas proporcionalmente em todas as fases, como demonstrado na Figura 5.15, garantindo uma representação equilibrada em cada segmento.



Figura 5.15: Distribuição equilibrada do conjunto de dados após a operação de rebalanceamento

As curvas de perda, apresentadas na Figura 5.16, evidenciam diferenças significativas entre os cenários. No caso balanceado, representado em (a), observa-se maior consistência ao longo do treino, enquanto no cenário sem balanceamento, ilustrado em (b), os valores mostram maior variabilidade.




Figura 5.16: Gráficos de perda relativos ao *dataset* balanceado (a) e à divisão aleatória (b)

A Tabela 5.8 apresenta as médias das métricas de perda em cada configuração. O conjunto balanceado revelou-se superior em todas as métricas analisadas, destacando-se pela redução dos valores de perda.

Tabela 5.8: Médias de val/box\_loss, val/cls\_loss e val/df\_loss para dados com e sem balanceamento

Configuração	val/box_loss (média)	val/cls_loss (média)	val/df_loss (média)
Não Balanceado	0.6678	0.8546	1.1036
Balanceado	0.5678	0.7090	0.9988
Melhor	<b>balanceado</b>	<b>balanceado</b>	<b>balanceado</b>

A análise da métrica mAP50, ilustrada na Figura 5.17, confirma os benefícios do balanceamento. O cenário balanceado registou um valor de 0.985, superior ao obtido na configuração sem balanceamento, que foi de 0.966. Este resultado aponta para uma maior AP para todas as classes no primeiro caso.




Figura 5.17: Comparação do mAP entre dados equilibrados (a) e desequilibrados (b)

Os resultados demonstram que o balanceamento melhora significativamente o desempenho do modelo. As métricas de perda mais reduzidas e a maior precisão alcançada com o conjunto balanceado sublinham a relevância desta abordagem para assegurar resultados mais robustos e fiáveis.

#### 5.4.4 Métricas de Desempenho Após o Treino

O teste foi efetuado com um nível de confiança mínimo de 0.75 e apresentou um desempenho global satisfatório. A Figura 5.18 (a) é uma amostra dessas classificações.

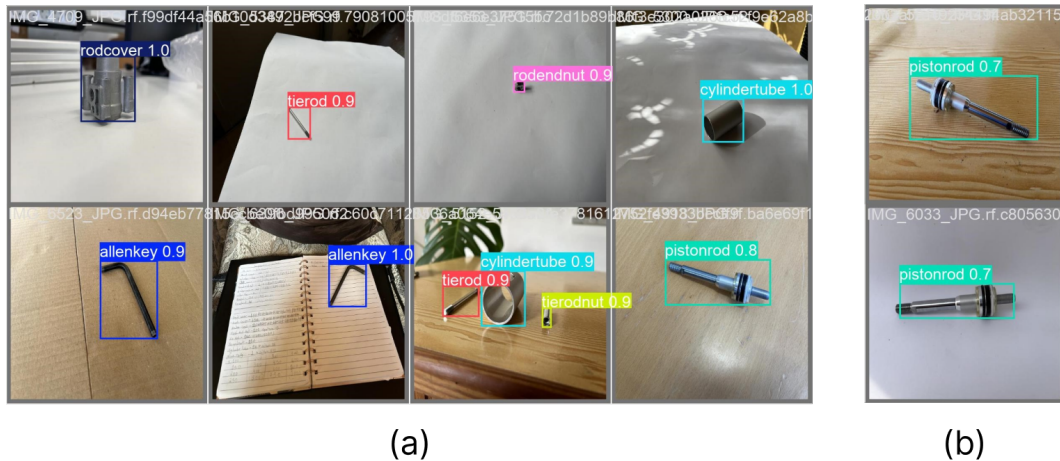


Figura 5.18: classificações dos testes com um mínimo de confiança de 0.75 (a) e um limite não definido (b)

A Tabela 5.9 reúne os resultados dos indicadores, com uma precisão média de 99.2% para todas as categorias, o que reflete a ocorrência de poucos FP. O *recall* registou 94.8%, o que comprova uma boa capacidade de detecção. O mAP50 alcançou 96.7% e o mAP50-95 atingiu 92.3%, o que reflete a correspondência rigorosa entre as classificações e os objetos reais, mesmo em cenários mais exigentes.

Classe	<i>Precision</i>	<i>Recall</i>	mAP50	mAP50-95
Todas	0.992	0.948	0.967	0.923
<i>allenkey</i>	0.933	0.933	0.933	0.909
<i>cylindertube</i>	1	1	0.995	0.978
<i>headcover</i>	1	1	0.995	0.982
<i>pistonroad</i>	1	0.812	0.906	0.836
<i>rodcover</i>	1	1	0.995	0.968
<i>rodendnut</i>	1	0.929	0.964	0.896
<i>tierod</i>	1	1	0.995	0.953
<i>tierodnut</i>	1	0.909	0.995	0.863

Tabela 5.9: Resumo dos resultados das métricas no conjunto de teste

Individualmente, a detecção da chave *allen* (*allenkey*) registou 93.3% de *precision* e *recall*, um resultado coeso que pode envolver algumas perdas pontuais. As classes *cylindertube*, *tierod*, *rodcover* e *headcover* têm valores excelentes, com 100% de *precision* e *recall*. Já o *pistonrod* obteve valores mais modestos, com um *recall* de 81.2%, justificado pelo alto grau de confiança selecionado, uma vez que, num novo teste, as mesmas amostras foram classificadas com um nível de 0.7, ou seja, o modelo é capaz de realizar a detecção com um critério ligeiramente menos exigente, como demonstrado na Figura 5.18 (b). As restantes classes, como *tierodnut*, mantiveram-se acima dos 90%, o que sustenta a sua solidez.

## 5.5 Avaliação do Modelo para Validação das Tarefas com Montagem de Cilindro Pneumático

Nesta secção procede-se à avaliação do modelo, cujo propósito consiste em confirmar as tarefas definidas. São descritas e comparadas as métricas de desempenho recolhidas durante e após o treino, o que permite uma análise completa do cumprimento do objetivo.

### 5.5.1 Métricas de Desempenho Durante o Treino

A Tabela 5.10 apresenta as métricas de avaliação, tanto de forma individual como para o conjunto global. A precisão global de 0.976 indica que o sistema é eficaz na minimização de FP, com cerca de 98% das predições corretas. O *recall* global de 0.982, por sua vez, confirma que a maioria dos objetos relevantes é identificada, com um número reduzido de FN. Este equilíbrio é fundamental para assegurar a fiabilidade da deteção em cenários reais.

Classe	<i>Precision</i>	<i>Recall</i>	mAP50	mAP50-95
Todas	0.976	0.982	0.988	0.988
<i>pctask1</i>	0.986	1	0.995	0.995
<i>pctask2</i>	0.983	0.947	0.955	0.955
<i>pctask3</i>	0.962	1	0.955	0.955
<i>pctask4</i>	1	0.954	0.988	0.984
<i>pctask5</i>	0.955	0.962	0.975	0.975
<i>pctask6</i>	0.965	0.984	0.986	0.986
<i>pctask7</i>	0.966	0.926	0.981	0.981
<i>pctask8</i>	0.933	0.988	0.992	0.992
<i>pctask9</i>	0.992	1	0.995	0.995
<i>pctask10</i>	0.99	1	0.995	0.995
<i>pctask11</i>	0.991	1	0.995	0.995
<i>pctask12</i>	0.969	1	0.995	0.995
<i>pctask13</i>	0.991	1	0.995	0.995

Tabela 5.10: Resultados do treino para todas as classes

A Figura 5.19 ilustra os gráficos de *precision* e *recall* em função da confiança. Em (a), observa-se um valor de 1 para classificações com confiança muito elevada (superior a 0.998), o que confirma a inexistência de FP quando o sistema apresenta total segurança nas suas deteções. A curva (b) revela um valor de 99% ao considerar todas as predições, mesmo aquelas com menor nível de confiança.

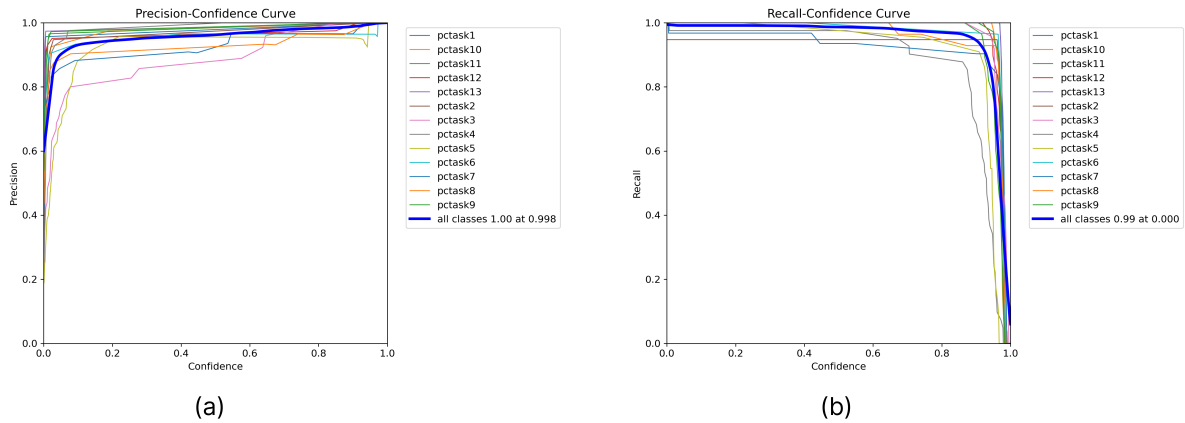


Figura 5.19: Representação das curvas de *precision* (a) e *recall* (b)

Os indicadores mAP50 e mAP50-95, ambos com o valor de 0.988, complementam a interpretação. Estes refletem a AP em diversos limiares IoU, desde 0.5 até 0.95, e revelam que o desempenho é elevado e consistente, independentemente das variações no grau de coincidência entre as classificações e as anotações verdadeiras.

### 5.5.2 Métricas de Desempenho Após o Treino

Conforme apresentado na Figura 5.20, a matriz de confusão demonstra um desempenho elevado do modelo nos novos dados de teste.




Figura 5.20: Matriz de confusão durante o treino (a) e nos novos dados de teste (b)

A Figura 5.21 mostra o aumento do F1-Score de 0.98 nos dados de validação para 0.99 nos dados de teste, o que demonstra que o modelo generaliza eficazmente para novos dados, com desempenho elevado e equilíbrio entre *precision* e *recall*. A confiança mais elevada nos dados de teste (0.813 face a 0.664) confirma uma melhoria significativa na fiabilidade das classificações. Estes resultados evidenciam que o modelo foi corretamente ajustado, com boa generalização e capacidade para lidar com cenários reais.

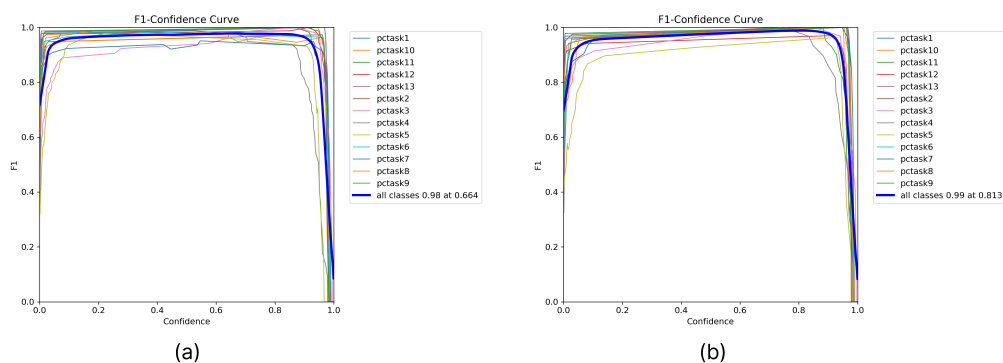


Figura 5.21: F1-Score no treino (a) e no teste (b)

## 5.6 Avaliação do Modelo para Reconhecer Erro(s) da Ligação de Cabo de *Airbag*

Aqui examina-se a *performance* do modelo orientado à identificação do cabo desligado. A comparação dos indicadores obtidas durante e após o treino permite aferir a consistência do método na detecção de falhas, o que viabiliza uma visão crítica da sua aplicação prática.

### 5.6.1 Métricas de Desempenho Durante o Treino

A Figura 5.22 apresenta a análise das classificações durante o treino do modelo através de uma matriz de confusão. Os valores dos TP (1, 0.98 e 0.95) indicam uma taxa de verdadeiros positivos muito elevada para as classes *emptySocket*, *off* e *on*, respetivamente. A proximidade destes valores ao 1 indica que o modelo tem um desempenho bom na classificação correta das instâncias nestas classes. Os valores próximos de zero nos FN reforçam a exaustividade das deteções. Estes valores baixos sugerem que o modelo deteta, com elevada fiabilidade, os objetos de interesse e evita omissões. A taxa de FP na classe *off* (0.68) pode ser explicada pela complexidade do fundo, que contém cabos e outros elementos visuais semelhantes. Este fundo, rico em detalhes, pode confundir o modelo, que reconhece padrões visuais similares e os interpreta incorretamente como *off*.




Figura 5.22: Matriz de confusão normalizada durante o treino do modelo para a identificação do cabo do *airbag* desligado

A Figura 5.23 mostra que, ao ajustar a confiança para o valor de 0.524, o modelo atinge um equilíbrio ideal entre *precision* e *recall*, com um F1-Score de 0.95. Para valores superiores a 0.8, observa-se uma queda acentuada da métrica, que desce até 0 à medida que o limiar se aproxima de 1, o que indica a rejeição da maioria das detecções e um aumento nos FN. Portanto, este gráfico é essencial para determinar o ponto ideal para obter os melhores resultados, de forma a evitar tanto FP quanto FN.




Figura 5.23: Gráfico *F1-Confidence Curve* referente à avaliação do modelo de detecção nos dados de validação

O desempenho do detetor proposto é quantificado pelos indicadores apresentados em 2.4. Os resultados de treino para todas as classes encontram-se na Tabela 5.11 e fornecem informações essenciais sobre a capacidade de OD, tanto em classes específicas como no contexto geral. Para todas as etiquetas combinadas, o valor de *recall* de 0.968 evidencia uma elevada capacidade de identificação, superior a 90%, o que indica que o treino poderá ser concluído.

A pontuação mAP50 de 0.975 reforça, ainda, o equilíbrio entre *precision* e *recall* num limite IoU de 0.5. Embora mais baixa, a pontuação mAP50-95 de 0.681 reflete um bom desempenho em diversos intervalos de IoU, o que evidencia a adaptabilidade do modelo a diferentes condições de teste e à variabilidade nos dados de entrada.

Classe	<i>Precision</i>	<i>Recall</i>	mAP50	mAP50-95
Todas	0.933	0.968	0.975	0.681
<i>off</i>	0.959	0.949	0.971	0.612
<i>on</i>	0.964	0.955	0.991	0.73
<i>emptySocket</i>	0.876	1	0.963	0.702

Tabela 5.11: Resultados do treino para as classes *on*, *off* e *emptySocket*, assim como a média geral

### 5.6.2 Métricas de Desempenho Após o Treino

Na Figura 5.24, observa-se a diminuição do valor de confiança necessário para alcançar uma *precision* de 1, que passa de 0.910 nos dados de validação (a) para 0.893 nos dados de teste (b), o que evidencia que o modelo mantém uma elevada precisão ao processar dados novos, com um valor de confiança ligeiramente inferior. Esta redução revela-se vantajosa, pois sugere um comportamento consistente e fiável, com capacidade robusta de evitar FP, mesmo com uma leve flexibilização no nível de confiança.




Figura 5.24: (a) *Precision-Confidence Curve* nos dados de validação durante o treino e (b) no conjunto de teste após a conclusão

Relativamente ao *recall*, a variação de 0.99 no treino para 0.98 no teste indica uma ligeira redução na capacidade de deteção em dados novos, como ilustrado na Figura 5.25. Contudo, esta diferença é marginal e sem impacto prático relevante, uma vez que o modelo continua a evidenciar um *recall* elevado. Em resumo, estes resultados demonstram um modelo bem treinado, que preserva robustez e consistência entre os conjuntos de treino e teste, com apenas uma leve perda de deteção em dados não vistos, dentro das expectativas normais.




Figura 5.25: *Recall* nos dados de treino (a) e teste (b)

A Figura 5.26 exibe algumas das classificações obtidas ao aplicar o modelo ao conjunto de teste.



Figura 5.26: Resultados das classificações do modelo no conjunto de teste

## 5.7 Discussão

A matriz de confusão contida na Secção 5.5.2 registou uma redução de FN e FP, acompanhada por um aumento nas identificações corretas de TP, que atingiu um valor de 1. Estes resultados confirmam a melhoria do modelo na identificação dos objetos e sugerem uma maior estabilidade na classificação. No entanto, apesar deste progresso, a análise revelou a persistência de alguns erros que exigem uma avaliação mais aprofundada. A maioria dos FP identificados resultou de previsões incorretas de objetos atribuídos a uma categoria distinta da real. Este padrão ocorreu maioritariamente entre tarefas consecutivas no processo de montagem, onde a proximidade das etapas e a semelhança entre as ações, como a colocação de parafusos, favoreceram classificações incorretas. Este comportamento era expectável, dado que a distinção entre tarefas visualmente semelhantes constitui um desafio. No entanto, verificou-se uma exceção ao padrão descrito. Um grupo identificado como *pctask5* (tarefa 5)

foi previsto como *pctask12* (tarefa 12), o que representou um erro atípico, uma vez que estas duas classes não são consecutivas no fluxo de montagem.

Após investigação, concluiu-se que a origem deste erro não se encontrava no modelo, mas sim no *dataset*. Foram detetadas cinco imagens incorretamente rotuladas, distribuídas entre treino, validação e teste. Estas imagens pertenciam originalmente à tarefa 5, mas foram associadas à tarefa 12 devido a um erro na anotação. Este problema, ilustrado na Figura 5.27, resultou do cansaço durante a anotação, um fator que comprometeu a qualidade dos dados.

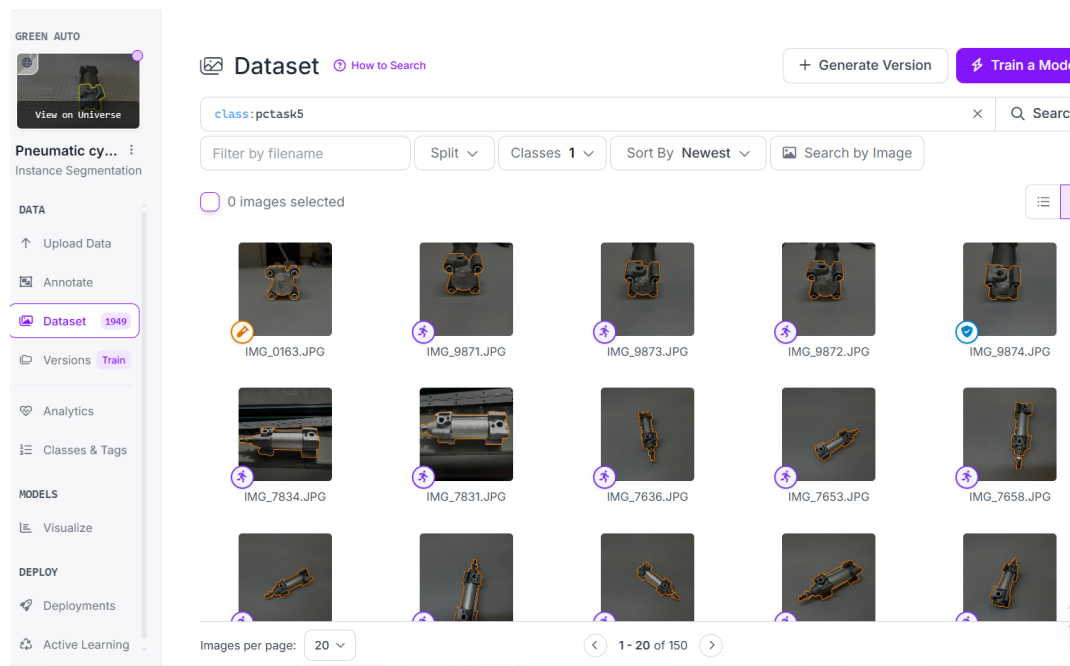


Figura 5.27: Representação do erro de anotação com imagens incorretamente rotuladas como pertencentes à tarefa 12

O processo de anotação exigiu atenção minuciosa e consistência, sobretudo em conjuntos de dados extensos. A repetibilidade da tarefa, aliada à necessidade de distinguir pequenas variações visuais, tornou a anotação particularmente suscetível a erros induzidos pela fadiga. Além disso, a utilização de tons de laranja semelhantes para diferentes etiquetas contribuiu para a confusão, o que aumentou a probabilidade de erros humanos. Embora o modelo tenha identificado corretamente os objetos como pertencentes à tarefa 12, a anotação incorreta associada à tarefa 5 comprometeu a avaliação final da classe. A análise da matriz de confusão revelou-se essencial para identificar esta falha, pois permitiu a deteção de incoerências no *dataset*, que poderiam comprometer a avaliação do modelo. Sem esta verificação, o erro poderia ter passado despercebido e influenciado a perceção do desempenho real do sistema. Estes fatores demonstram a necessidade de estratégias que reduzam o impacto da fadiga na anotação, garantindo maior rigor na criação do *dataset*.

Para minimizar ambiguidades na classificação, adotou-se uma estratégia de três etiquetas para a deteção do erro de ligação de cabo de *airbag*. A distinção entre *socket* vazio, cabo ligado e desligado permitiu ao modelo interpretar corretamente as diferentes condições, o que evitou confusões entre um cabo solto e devidamente inserido. Embora, na monitorização

prática, apenas a primeira categoria seja utilizada, a decisão de manter as três etiquetas proporcionou ao modelo uma melhor compreensão dos cenários possíveis. Além disso, esta abordagem poderá facilitar futuras melhorias na detecção de anomalias.

Outro aspeto fundamental para a aplicação do modelo em contextos industriais é o tempo de resposta. Nos processos de controlo industrial, cada classificação desencadeia uma ação de validação ou correção, o que realça a importância de atingir uma latência baixa. O tempo médio registado, de 80 milissegundos, conforme ilustrado na Figura 5.28, revelou-se adequado para o caso de uso analisado. A capacidade de tomar decisões em tempo real evita interrupções no fluxo produtivo e reforça a precisão do processo.

```


0: 384x640 1 off, 77.1ms
Speed: 1.0ms preprocess, 77.1ms inference, 1.0ms postprocess per image at shape (1, 3, 384, 640)
[10/Oct/2024 18:38:41] "POST /api/v1/process-quality/ HTTP/1.1" 200 75

0: 384x640 1 off, 78.0ms
Speed: 1.0ms preprocess, 78.0ms inference, 1.0ms postprocess per image at shape (1, 3, 384, 640)
[10/Oct/2024 18:38:42] "POST /api/v1/process-quality/ HTTP/1.1" 200 75

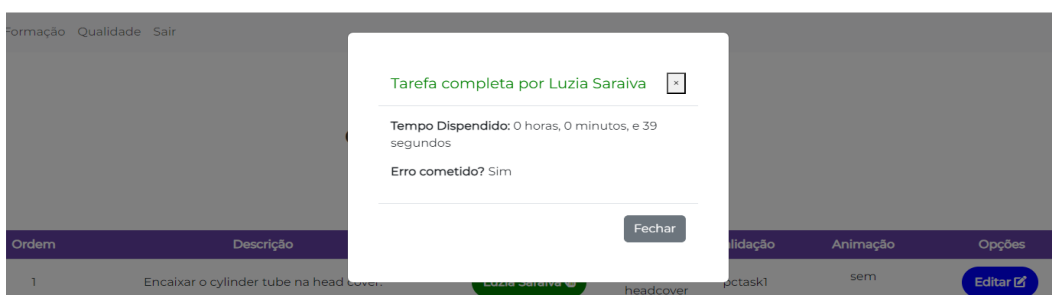
```

Figura 5.28: Saída da linha de comandos com as deteções realizadas pelo modelo em tempo real

O sistema, ao acompanhar com detalhe as tarefas realizadas, desempenha um papel elementar na formação de funcionários inexperientes e alunos em contexto vocacional. A recolha de dados, como o tempo total de execução e o registo de erros, ilustrados na Figura 5.29, permite monitorizar o progresso da aprendizagem e identificar dificuldades no desempenho dos utilizadores.

Ordem	Descrição	Atribuída	Peça	Validação	Animação	Opções
1	Encaixar o cylinder tube na head cover.	Luzia Saraiva	cylindertube, headcover	pctask1	sem	Editar
2	Inserir o piston rod dentro do cilindro, mantendo a haste do lado de fora.	Luzia Saraiva	pistonrod	pctask2		Editar

(a)



(b)

Figura 5.29: Dados de desempenho do aprendiz

No entanto, outro desafio é garantir que a recolha de informação é verdadeiramente útil para a aprendizagem. Neste sentido, o sistema não se limita a armazenar os dados essenciais, mas também os disponibiliza para que o supervisor possa analisar as dificuldades e ajustar a sua intervenção. Além disso, as mensagens de *feedback* são instantâneas, o que permite aos

aprendizes corrigirem os erros imediatamente e ajustarem a sua execução antes de avançarem para a etapa seguinte.

Deste modo, os resultados discutidos demonstraram que a qualidade da anotação, o tempo de execução e a forma como os dados são utilizados na supervisão e no apoio ao utilizador são fatores determinantes para a aplicação bem-sucedida do sistema.

## Capítulo 6

# Conclusões

Este capítulo conclui o projeto com um resumo final e a verificação do cumprimento dos objetivos estabelecidos. Por último, indica as direções dos trabalhos futuros.

### 6.1 Síntese

Este projeto materializa-se numa prova de conceito com o objetivo de desenvolver uma ferramenta de apoio aos operadores que aumente a produtividade, reduza as falhas e fomente a aprendizagem contínua em contextos vocacionais ou chão de fábrica. Para atingir estes fins, realizou-se uma revisão do estado de arte com o propósito de identificar as dificuldades enfrentadas no meio, as técnicas existentes e as oportunidades.

Desenvolveu-se um sistema que integra uma aplicação de administração, uma API e uma aplicação de instrução virtual para Magic Leap. A solução proporciona aos assistentes experientes os instrumentos necessários para construir as sequências de montagem e atribuí-las aos aprendizes. Por meio do HMD, os operadores dispõem dos recursos essenciais para realizar as tarefas de forma prática e segura. A solução contempla duas vertentes de formação. A formação vocacional, destinada a ambientes de sala de aula ou centros de formação, facilita a difusão do conhecimento através da interatividade e praticidade do sistema. A formação no trabalho incorpora a validação visual de cada tarefa, garantindo a correta execução de cada etapa antes da passagem à seguinte. O controlo de qualidade alerta os funcionários sempre que se identifica um erro, para que seja corrigido imediatamente e previna qualquer consequência negativa.

Para testar a proposta, selecionaram-se dois objetos de estudo: o CP e o cabo de *airbag*. Para as formações, escolheu-se o CP. Na inspeção de qualidade na linha de montagem, utilizou-se o cabo de *airbag* do automóvel. Essa decisão enquadra-se nos objetivos do projeto

GreenAuto como resposta direta ao incidente manifestado pelos operadores da Stellantis Mangualde. Esse problema só era percebido no teste elétrico do veículo, o que destacava a sua criticidade e obrigava à reabertura da carroçaria para corrigir a ligação.

A validação indica que a abordagem vocacional é facilmente aplicável a outros casos, por não depender da OD. A formação no trabalho e o controlo de qualidade, ao utilizarem a VC, enfrentam limitações devido ao processo de anotação de dados, que exige tempo e recursos humanos significativos. Técnicas emergentes, como o *meta-learning* e o *few-shot learning*, apresentam-se como perspectivas para mitigar esses desafios.

Os resultados práticos revelam que os modelos treinados são capazes de atingir valores de *precision* e *recall* superiores a 90%. Adicionalmente, as imagens registadas pelo Magic Leap e processadas em tempo real pela API apresentaram tempos de deteção estáveis na ordem dos 80 ms, ou seja, aproximadamente 15 FPS.

Relativamente aos trabalhos futuros, propõe-se o desenvolvimento de um módulo de comunicação para dispositivos móveis, como *tablets* e ecrãs interativos, de forma a oferecer uma alternativa à utilização exclusiva do HMD. Esta abordagem possibilitará a monitorização através de ecrãs, agilizará a adaptação dos utilizadores e trará vantagens no controlo de qualidade, sobretudo com a utilização de uma câmara fixa, de forma a evitar desvios da zona de interesse e a emitir alertas por aviso sonoro. A arquitetura desenvolvida favorece a integração de múltiplos equipamentos e métodos de aquisição de imagem, constituindo uma linha de investigação promissora. Adicionalmente, recomenda-se a aplicação de questionários para validar a qualidade da experiência dos utilizadores, em aspetos como a clareza e legibilidade das instruções, a facilidade de interação com a *interface* e a rapidez dessas ações, para que sejam identificadas oportunidades de melhoria.

## 6.2 Objetivos

O primeiro objetivo relacionou-se com a centralização das instruções operacionais e dos dados dos utilizadores num único sistema. Este surge da necessidade de superar a dispersão da informação e a falta de atualização dos processos de montagem, os quais se revelam demasiado extensos e complexos. Esta abordagem visa promover a uniformização e a padronização dos procedimentos no contexto fabril, ao assegurar que todos os operadores tenham acesso à mesma sequência, definida com base no método de montagem mais produtivo. Tal mecanismo facilita a integração de novos funcionários, que poderão adquirir, de forma célere, os conhecimentos necessários à execução das tarefas. Adicionalmente, a disponibilização digital permite reduzir os custos associados à impressão em papel.

A implementação da solução baseia-se em instruções claras, que são apresentadas com recurso à RM e complementadas por animações 3D, que, por sua vez, clarificam a fisionomia das peças e o movimento a replicar. Estes aspetos representam um avanço face aos métodos tradicionais, pois favorecem a compreensão e a adaptação dos procedimentos pelos alunos. A monitorização dos dados de desempenho oferece, adicionalmente, uma ferramenta para reconhecer áreas de melhoria e orientar o apoio aos colaboradores, impulsionando, desta forma, a melhoria contínua.

Não obstante os benefícios evidenciados, a análise crítica levanta questões acerca de determinadas limitações da abordagem proposta. A centralização da informação poderá enfrentar desafios de integração com os sistemas de gestão existentes. Além disso, a recolha de dados de desempenho suscita implicações éticas, uma vez que esses poderão ser interpretados como instrumento de pressão sobre os colaboradores. Apesar da sua disponibilidade ser exclusiva para os administradores, há dúvidas sobre a sua capacidade de prevenir um uso pejorativo.

Em relação ao segundo objetivo, “Apoiar o operador na sequência de montagem”, este revela-se indispensável face às limitações inerentes aos métodos atualmente utilizados. Verificou-se que a assistência especializada nem sempre está disponível, dado que os operadores mais experientes assumem, por vezes, o apoio aos colegas. Adicionalmente, as instruções em papel demonstram ser imprecisas, o que compromete a compreensão dos movimentos necessários à montagem e dificulta a sua interpretação. A solução proposta, materializada num sistema digital interativo, apresenta como principal vantagem a capacidade de proporcionar formação vocacional e formação no trabalho. Esta abordagem permite que o colaborador pratique a montagem de componentes, quer num contexto pré-laboral, quer no ambiente de fábrica, sobretudo quando surgem atividades novas ou processos de elevada complexidade. No entanto, o novo sistema poderá enfrentar desafios na adaptação dos operadores às novas competências digitais. A fim de mitigar estes riscos, recomenda-se a adoção de protocolos híbridos que assegurem a complementaridade entre o apoio digital e a supervisão humana.

Conforme referido no Enquadramento (1.1), a deteção de erros apenas após a produção acarreta consequências negativas. Tais impactos refletem-se no descontentamento dos funcionários, obrigados a refazer o trabalho e a acumular horas extraordinárias, no aumento dos custos e, conseqüentemente, na deterioração da reputação do fabricante. Com base nisso, estabeleceu-se o terceiro objetivo do projeto, “Identificação autónoma de falhas”. Com recurso a mecanismos baseados em VC, nomeadamente o YOLO, é possível identificar falhas em tempo real, desde que previamente treinado com um *dataset* específico. Foram criados dois conjuntos de dados para validar a abordagem: um destinado à confirmação das tarefas e outro configurado para identificar um erro concreto, como a verificação do correto encaixe de uma ficha do *airbag* do automóvel. No âmbito da formação no trabalho, a confirmação automática de cada tarefa garante que o operador não avança para a realização da tarefa seguinte sem que a mesma se encontre concluída. Por outro lado, no controlo de qualidade, a deteção antecipada permite corrigir os erros de imediato e garantir a integridade do produto final. Porém, a sua implementação apresenta desafios a nível tecnológico. Assim, impõe-se dispor de infraestruturas robustas, com elevada capacidade computacional para o treino dos modelos. Comparativamente, a solução de deteção distingue-se dos métodos tradicionais pela sua capacidade de oferecer, num único sistema, suporte à formação e ao controlo de qualidade, valendo-se da RM.

O quarto e último objetivo consiste na melhoria da gestão de utilizadores, projetos e tarefas. Entre as principais funcionalidades que promovem uma administração organizada encontram-se o registo de utilizadores, a criação de formações e controlos de qualidade, a definição de tarefas e a sua atribuição. Também contém a informação acerca do estado de

cada tarefa e os tempos de execução dos operadores. A implementação de uma UI intuitiva apresenta desafios a nível de conceção, uma vez que é necessário chegar a um *layout* que consiga harmonizar a apresentação de conteúdos sem sobrecarregar o utilizador. Este desafio é ultrapassado com a aplicação de métodos de *design* centrados no utilizador.

Em comparação com a solução de Zheng et al. [77], que se concentra na montagem de cabos em aeronaves, o presente trabalho aborda objetos de estudo distintos, apresenta um *design* mais amigável, com animações tridimensionais e instruções virtuais, e conta com monitorização contínua do desempenho.

No que diz respeito à captação dos dados por meio da análise de vídeo, a metodologia empregada envia as imagens mais recentes para a API, aguarda a resposta do processamento e dispensa a intervenção do aprendiz nesse processo. Tal método supera as limitações do processo manual descrito por Raj et al. [81], que exige que o utilizador se mantenha imóvel. Embora exista o risco de o operador desviar o olhar da zona de interesse, este é minimizado pela elevada velocidade do processamento e pela natureza sequencial da montagem.

Este projeto estabelece uma base sólida para investigações futuras e para a sua implementação em ambientes industriais modernos ou em contextos de formação técnica.

### 6.3 Trabalhos Futuros

Apesar dos avanços alcançados, este estudo abre caminho para desenvolvimentos futuros, tanto no que diz respeito ao aperfeiçoamento do produto final como à sua adoção no ambiente industrial. A RM define-se como uma tecnologia moderna, e os seus equipamentos ainda representam uma novidade, sobretudo face ao seu elevado custo e à forma de utilização pouco difundida. Deste modo, oportunidades de investigação poderão incluir a criação de estratégias para facilitar a sua adoção, seja através do desenvolvimento de programas de formação adaptados aos operadores, seja por meio de UI mais intuitivas que minimizem a necessidade de instrução inicial e acelerem a adaptação dos utilizadores.

O Magic Leap apresenta limitações quanto à autonomia e à ergonomia, aspetos esses que impõem restrições ao uso prolongado. Assim, trabalhos futuros poderão explorar melhorias na gestão da autonomia do dispositivo, bem como analisar o impacto do peso e do conforto do equipamento na experiência do aprendiz. Dado que a aplicação desenvolvida serve como ferramenta de apoio para situações como o ensino de novas aprendizagens, atividades complexas que exijam assistência e para inspeções minuciosas, é essencial garantir que o seu uso esteja ajustado às necessidades. Para tal, poderá ser estudada a aplicação do conceito Just-in-Time, para que o HMD seja utilizado de forma estratégica e apenas quando necessário, reduzindo a fadiga e maximizando o impacto formativo. Complementarmente, propõe-se o desenvolvimento de um componente de comunicação para dispositivos móveis, de forma a oferecer uma alternativa à utilização exclusiva do HMD e, assim, uma maior flexibilidade ao aluno.

A integração de novos casos práticos, tanto na formação no trabalho como no controlo de qualidade, exige a criação de novos modelos. Na eventualidade de não existirem conjuntos de dados ajustados aos requisitos pretendidos, será necessário proceder à elaboração de *datasets* específicos para treinar a CNN. Este processo envolve a anotação demorada e exaustiva

---

de uma grande quantidade de dados, mas poderá vir a beneficiar de novas técnicas mais ágeis. A par disso, a evolução dos próprios algoritmos, com abordagens inovadoras de *meta-learning* e *few-shot learning*, apresenta perspectivas promissoras para melhorar a capacidade dos modelos na aprendizagem de novas tarefas com poucos dados. Contudo, a implementação destas técnicas continua a representar um desafio, pelo que se justificam pesquisas adicionais para avaliar a sua aplicabilidade neste contexto.



## Capítulo 7

# Anexos

### 7.1 Descrição de Casos de Uso - Aplicação de Instrução Virtual

As tabelas 7.1, 7.2, 7.3 e 7.4 descrevem respetivamente os casos de uso autenticação, escolher projeto, iniciar tarefas e terminar tarefas.

Tabela 7.1: Descrição do Caso de Uso: Autenticação

<b>Nome do Caso de Uso</b>	Autenticação
<b>Descrição</b>	Permite ao utilizador autenticar-se no sistema utilizando credenciais válidas.
<b>Ator</b>	Utilizador Aprendiz/Operador
<b>Pré-condições</b>	O utilizador deve estar registado no sistema e possuir credenciais válidas (nome de utilizador e palavra-passe).

<b>Fluxo Principal de Eventos</b>	<ol style="list-style-type: none"> <li>1. O utilizador abre a aplicação, e o formulário de autenticação é exibido.</li> <li>2. O utilizador preenche os campos do formulário (nome de utilizador e palavra-passe) e clica no botão “Entrar”.</li> <li>3. O sistema valida as credenciais.</li> <li>4. Se as credenciais forem válidas, o utilizador é autenticado e redirecionado para a UI dos projetos.</li> </ol>
<b>Pós-condições</b>	O utilizador é autenticado no sistema e obtém acesso às funcionalidades conforme o seu perfil.

Tabela 7.2: Descrição do Caso de Uso: Escolher Projeto

<b>Nome do Caso de Uso</b>	Escolher Projeto
<b>Descrição</b>	Permite ao utilizador selecionar um projeto que contenha tarefas que lhe foram atribuídas e que ainda não tenham sido completadas.
<b>Ator</b>	Utilizador Aprendiz/Operador
<b>Pré-condições</b>	O utilizador deve estar autenticado no sistema e ter tarefas incompletas atribuídas.
<b>Fluxo Principal de Eventos</b>	<ol style="list-style-type: none"> <li>1. O utilizador, após a autenticação, acede à área de seleção de projeto.</li> <li>2. O sistema apresenta uma lista de até dois projetos nos quais o utilizador tem tarefas atribuídas, que ainda não foram concluídas, ordenados por prioridade e data de fim.</li> <li>3. O utilizador seleciona o projeto desejado, clicando no botão correspondente.</li> <li>4. O sistema confirma a ação e apresenta o botão “Começar”. Quando o utilizador o seleciona, é redirecionado para o ecrã de tarefas correspondente ao projeto escolhido.</li> </ol>
<b>Pós-condições</b>	O projeto selecionado encontra-se ativo e pronto para a execução das tarefas pendentes.

Tabela 7.3: Descrição do Caso de Uso: Iniciar Tarefas

<b>Nome do Caso de Uso</b>	Iniciar Tarefas
<b>Descrição</b>	Permite ao utilizador começar a executar as tarefas de um projeto selecionado, seguindo as etapas definidas para cada tipo de projeto (formação vocacional, formação no trabalho ou controlo de qualidade).
<b>Ator</b>	Utilizador Aprendiz/Operador
<b>Pré-condições</b>	O utilizador deverá já ter selecionado um projeto e estar autenticado no sistema.

<b>Fluxo Principal de Eventos</b>	<ol style="list-style-type: none"> <li>1. O utilizador, já com o projeto selecionado e após optar por “Começar”, é redirecionado para a interface de tarefas.</li> <li>2. O sistema apresenta a primeira tarefa a ser realizada, com as instruções e os recursos necessários.</li> <li>3. Dependendo do tipo de projeto, o fluxo varia: <ul style="list-style-type: none"> <li>• Para um projeto de “Formação Vocacional”, o utilizador inicia a tarefa, visualiza as instruções e animações correspondentes (se disponibilizadas), e, depois de concluí-la, clica em “Próxima”. O sistema regista o tempo de conclusão da tarefa e avança para a tarefa seguinte.</li> <li>• Para um projeto de “Formação no Trabalho”, se existir o “Modelo para Detecção de Peças”, o sistema realiza uma etapa de preparação antes de iniciar as tarefas, verificando se todo o material necessário está presente e nas quantidades corretas. Caso seja apenas fornecido o “Modelo para Validação de Tarefas”, o sistema passa diretamente para as tarefas, permitindo o avanço somente se a tarefa for corretamente cumprida. Caso contrário, o utilizador é alertado de que não acertadamente a tarefa e será contabilizado como um erro no seu desempenho.</li> <li>• Para um projeto de “Controlo de Qualidade”, o utilizador receberá alertas apenas se um erro predefinido na tarefa for detetado durante a execução.</li> </ul> </li> <li>4. O aprendiz repete o processo até que todas as tarefas estejam concluídas no caso de projetos de formação. Para o controlo de qualidade, o utilizador abandona a aplicação quando o controlo já não é necessário.</li> </ol>
<b>Pós-condições</b>	Para as formações, as tarefas de um projeto estão concluídas e o seu desempenho é salvo. Para o controlo de qualidade, apenas a presença de erros é contabilizada.

Tabela 7.4: Descrição do Caso de Uso: Terminar Tarefas

<b>Nome do Caso de Uso</b>	Terminar Tarefas
----------------------------	------------------

<b>Descrição</b>	Permite ao utilizador concluir a execução de todas as tarefas associadas a um projeto e finalizar o ciclo de trabalho, assegurando a validação correta de acordo com o tipo de projeto.
<b>Ator</b>	Utilizador Aprendiz/Operador
<b>Pré-condições</b>	O utilizador deverá ter concretizado todas as tarefas do projeto a ele atribuídas.
<b>Fluxo Principal de Eventos</b>	<ol style="list-style-type: none"> <li>1. O utilizador acede à última tarefa do projeto e conclui a sua execução.</li> <li>2. O sistema verifica se todas as tarefas foram completadas com sucesso, sem erros pendentes.</li> <li>3. Conforme o tipo de projeto (Formação Vocacional, Formação no Trabalho, Controlo de Qualidade) a ação de conclusão varia. <ul style="list-style-type: none"> <li>• Para a “Formação Vocacional”, ao chegar à última tarefa, o utilizador opta por “Concluir”. Após finalizar a tarefa, clica no botão, sinalizando ao sistema que completou a última tarefa e, conseqüentemente, o projeto.</li> <li>• Na “Formação no Trabalho”, ao clicar em “Concluir”, o sistema valida se a tarefa foi corretamente realizada. Se houver alguma inconformidade, não é possível finalizar até que a tarefa seja executada corretamente, sendo apresentada uma mensagem de erro ao utilizador. Após a correta execução, a conclusão da última tarefa e, conseqüentemente, do projeto, é registada com sucesso no sistema.</li> <li>• Para “Controlo de Qualidade”, o utilizador decide quando a funcionalidade já não é necessária, permitindo encerrar o processo.</li> </ul> </li> <li>4. O utilizador confirma a conclusão do projeto clicando em “Terminar”, e o sistema regista o tempo total de execução do projeto.</li> </ol>
<b>Pós-condições</b>	Os dados de desempenho do utilizador na concretização das tarefas dos projetos ficam disponíveis na aplicação de administração.

## 7.2 Descrição de Casos de Uso - Aplicação de Administração

Nas tabelas 7.5, 7.6, 7.7 e 7.8 encontram-se descritos, respetivamente, os casos de gestão de utilizadores, gestão de formação vocacional, gestão de formação no trabalho e gestão do controlo de qualidade.

Tabela 7.5: Descrição do Caso de Uso: Gestão de Utilizadores

<b>Nome do Caso de Uso</b>	Gestão de Utilizadores
<b>Descrição</b>	Cobre todas as operações associadas à gestão de contas de utilizador, incluindo o registo de novos utilizadores, autenticação, e ações administrativas como visualizar, editar ou eliminar perfis.
<b>Atores</b>	Utilizador Administrador e Novo utilizador (sem conta registada)
<b>Pré-condições</b>	<ul style="list-style-type: none"><li>• Para registar, o utilizador não pode ter uma conta existente.</li><li>• Para aceder à gestão de utilizadores, o utilizador deve estar autenticado e possuir permissões administrativas.</li></ul>

<b>Fluxo Principal de Eventos</b>	<ol style="list-style-type: none"><li>1. Registo de novo utilizador:<ul style="list-style-type: none"><li>• Caso o utilizador não tenha uma conta, deve seleccionar a opção “Registar” na UI inicial, sendo redirecionado para a UI de registo.</li><li>• Na UI de registo, são solicitados os seus dados pessoais. Que incluem o nome completo, o nome de utilizador, o e-mail, a palavra-passe, o género, a data de nascimento, o número de telemóvel, a morada, o código postal, o país e a cidade.</li><li>• Quando se opta por registar, a conformidade dos dados é verificada. Abrangendo como critérios o preenchimento dos campos obrigatórios, o e-mail não estar já registado, nome de utilizador único e igualdade entre a palavra-passe e a sua confirmação.</li><li>• Se tudo estiver nos conformes a conta do utilizador é criada com sucesso.</li><li>• O novo utilizador fica pendente até que um administrador lhe atribua as permissões de acesso. Estas têm em conta o perfil de utilizador (administrador ou aprendiz/operador).</li></ul></li><li>2. Autenticação:<ul style="list-style-type: none"><li>• O administrador acede à UI de autenticação.</li><li>• Introduce o nome de utilizador e a palavra-passe registados.</li><li>• O sistema valida as credenciais e autentica o utilizador, permitindo-lhe o acesso à aplicação.</li></ul></li><li>3. Gestão de utilizadores (após autenticação):<ul style="list-style-type: none"><li>• O utilizador, com permissões administrativas e autenticado acede à secção de Utilizadores.</li></ul></li></ol>
-----------------------------------	---

<b>Fluxo Principal de Eventos (continuação)</b>	<ul style="list-style-type: none"> <li>• O sistema apresenta uma lista de todos os utilizadores registados. É possível filtrar os utilizadores por “Administradores”, “Aprendizes/Operadores” e “Utilizadores Pendentes”.</li> <li>• Ao seleccionar a opção “Detalhes”, o administrador pode visualizar as informações de qualquer pessoa.</li> <li>• Para que um utilizador deixe de estar pendente, é necessário clicar em “Editar” na pessoa em questão e, no formulário, atribuir-lhe o tipo de perfil.</li> <li>• Quando o ator deseja remover alguém do sistema recorre ao botão “Eliminar”.</li> </ul>
<b>Pós-condições</b>	<ul style="list-style-type: none"> <li>• Novo utilizador registado.</li> <li>• O utilizador autenticado pode realizar as operações no sistema de acordo com os seus privilégios.</li> <li>• As alterações de perfil ou eliminações de utilizadores são aplicadas conforme solicitado.</li> </ul>

Tabela 7.6: Descrição do Caso de Uso: Gestão de Formação Vocacional

<b>Nome do Caso de Uso</b>	Gestão de Formação Vocacional
<b>Descrição</b>	Este caso de uso abrange a gestão de formações vocacionais, permitindo a criação de novas formações, a adição de tarefas, a visualização da lista de tarefas e, após a conclusão, a consulta do desempenho dos executantes.
<b>Atores</b>	Administrador
<b>Pré-condições</b>	<ul style="list-style-type: none"> <li>• O utilizador deve ser administrador.</li> <li>• Devem existir aprendizes/operadores registados para atribuição das tarefas.</li> </ul>

<b>Fluxo Principal de Eventos</b>	<ol style="list-style-type: none"><li>1. Criação de uma nova formação vocacional:<ul style="list-style-type: none"><li>• O administrador acede à secção “Formação” e seleciona a opção “Formação Vocacional”.</li><li>• Seleciona o botão “Criar Nova”.</li><li>• Introduce os dados da formação, como nome, prioridade, descrição, utilizador responsável, data de início e data de fim.</li><li>• O sistema regista a nova formação e confirma a sua criação.</li></ul></li><li>2. Adição de tarefas à formação vocacional:<ul style="list-style-type: none"><li>• O administrador seleciona a formação criada ou uma formação existente.</li><li>• Opta por ver as tarefas e, em seguida, por adicionar novas.</li><li>• Define as tarefas da formação, incluindo descrição, animação e utilizadores responsáveis pela execução.</li><li>• O sistema associa as tarefas à formação.</li></ul></li><li>3. Visualização da lista de tarefas:<ul style="list-style-type: none"><li>• O administrador pode visualizar a lista completa de tarefas associadas a cada formação.</li></ul></li></ol>
<b>Fluxo Principal de Eventos (continuação)</b>	<ul style="list-style-type: none"><li>• O sistema apresenta o estado de cada tarefa (pendente ou concluída).</li></ul> <ol style="list-style-type: none"><li>4. Visualização do desempenho do executante:<ul style="list-style-type: none"><li>• Após a conclusão da tarefa, o administrador pode consultar o desempenho dos aprendizes clicando no botão que indica a conclusão da tarefa, associado ao nome do aprendiz.</li><li>• O sistema apresenta o tempo despendido na execução de cada tarefa.</li></ul></li></ol>

<b>Pós-condições</b>	<ul style="list-style-type: none"> <li>• A nova formação fica disponível.</li> <li>• As tarefas são registadas e associadas à formação.</li> <li>• O desempenho dos executantes é registado e pode ser consultado pelo administrador após a conclusão das tarefas.</li> </ul>
----------------------	---

Tabela 7.7: Descrição do Caso de Uso: Gestão de Formação no Trabalho

<b>Nome do Caso de Uso</b>	Gestão de Formação no Trabalho
<b>Descrição</b>	Facilita a gestão de formações no local de trabalho. Através da criação de formações específicas, a adição de tarefas práticas, a monitorização do progresso e a consulta do desempenho dos trabalhadores após a conclusão das tarefas.
<b>Atores</b>	Administrador
<b>Pré-condições</b>	<ul style="list-style-type: none"> <li>• O acesso é restrito a utilizadores com perfil de administrador.</li> <li>• A atribuição de tarefas requer a existência de aprendizes/operadores registados.</li> </ul>

<p><b>Fluxo Principal de Eventos</b></p>	<p>1. Criação de uma nova formação no trabalho:</p> <ul style="list-style-type: none"> <li>• O administrador acede à secção “Formação” e seleciona a opção “Formação no Trabalho”.</li> <li>• Seleciona o botão “Criar Nova”.</li> <li>• Insere as especificidades da formação, como o nome, prioridade, descrição, utilizador responsável, data de início e data de fim. Adicionalmente, são solicitados o “Modelo para Identificação de Componentes Individuais” e o “Modelo para Validação de Tarefas” no formato .pt, acompanhados do respetivo ficheiro Data.yaml.</li> <li>• O sistema regista a nova formação e confirma a sua criação.</li> </ul> <p>2. Adição de tarefas práticas:</p> <ul style="list-style-type: none"> <li>• O administrador seleciona a formação criada ou uma formação existente.</li> <li>• Clica em “Ver Tarefas” e, em seguida, em “Adicionar Tarefas”.</li> <li>• Especifica as tarefas da formação em contexto laboral, indicando as instruções para a execução da tarefa, a animação, os utilizadores que irão executá-la e ainda as classes “Peça” e “Validação” que devem ser identificadas pelo sistema.</li> <li>• As tarefas são vinculadas à formação pelo sistema.</li> </ul> <p>3. Visualização da lista de tarefas:</p> <ul style="list-style-type: none"> <li>• O administrador pode consultar a lista integral de tarefas relacionadas a cada formação.</li> </ul>
<p><b>Fluxo Principal de Eventos (continuação)</b></p>	<p>4. Visualização do desempenho:</p> <ul style="list-style-type: none"> <li>• Após a finalização de cada tarefa, o administrador pode verificar o desempenho dos colaboradores.</li> <li>• O sistema mostra o tempo gasto em cada tarefa, bem como a existência ou não de erros.</li> </ul>

<b>Pós-condições</b>	<ul style="list-style-type: none"> <li>• A nova formação no trabalho está pronta para ser utilizada.</li> <li>• As tarefas práticas são registadas e integradas na formação.</li> <li>• O desempenho dos trabalhadores é registado e pode ser verificado pelo administrador após a finalização das tarefas.</li> </ul>
----------------------	--

Tabela 7.8: Descrição do Caso de Uso: Gestão do Controlo de Qualidade

<b>Nome do Caso de Uso</b>	Gestão do Controlo de Qualidade
<b>Descrição</b>	O caso de uso em questão permite a gestão das atividades relacionadas com o controlo de qualidade. Estas englobam a criação de novos controlos de qualidade, a adição de tarefas de inspeção e a consulta dos resultados após a conclusão das verificações.
<b>Atores</b>	Administrador
<b>Pré-condições</b>	<ul style="list-style-type: none"> <li>• Ser administrador.</li> <li>• É necessária a existência de aprendizes/operadores registados para atribuir as tarefas de controlo de qualidade.</li> </ul>

<p><b>Fluxo Principal de Eventos</b></p>	<p>1. Criação de um novo controlo de qualidade:</p> <ul style="list-style-type: none"> <li>• O administrador entra na secção “Qualidade” e seleciona o botão “Criar Novo”.</li> <li>• Insere os pormenores como nome, prioridade, descrição, pessoa responsável, data de início e data de fim. Adicionalmente, é requisitado a adicionar o “Modelo para Identificação de Erros” e o ficheiro com as classes correspondentes.</li> <li>• O novo controlo de qualidade é sucessivamente guardado.</li> </ul> <p>2. Adição de tarefas de inspeção:</p> <ul style="list-style-type: none"> <li>• O administrador seleciona o controlo de qualidade criado ou um existente.</li> <li>• Acede a “Ver Tarefas” e escolhe a opção “Adicionar Tarefas”.</li> <li>• Define as tarefas de inspeção, especificando as diretrizes para a execução de cada verificação, os utilizadores designados, as classes que o sistema deve identificar visualmente para sinalizar falhas, e ainda a descrição de como corrigir os erros detetados.</li> <li>• As tarefas são automaticamente associadas ao controlo de qualidade pelo sistema.</li> </ul> <p>3. Visualização da lista de tarefas:</p> <ul style="list-style-type: none"> <li>• O administrador pode consultar a lista de tarefas atribuídas e monitorizar o estado de cada verificação.</li> </ul>
<p><b>Fluxo Principal de Eventos (continuação)</b></p>	<p>4. Avaliação e consulta dos resultados:</p> <ul style="list-style-type: none"> <li>• Após a conclusão das inspeções, o administrador pode verificar os resultados das tarefas.</li> <li>• O sistema indica se o erro predefinido foi identificado.</li> </ul>

<b>Pós-condições</b>	<ul style="list-style-type: none"> <li>• O novo controlo de qualidade fica operacional.</li> <li>• As tarefas de inspeção são registadas e integradas no controlo de qualidade.</li> <li>• Os resultados das verificações são guardados e podem ser consultados pelo administrador assim que as tarefas forem concluídas.</li> </ul>
----------------------	--

### 7.3 Tabelas de Entidades

Esta secção descreve as entidades que integram o modelo conceptual, organizadas sob a forma de dicionários de dados. Para cada uma, são especificados os respetivos atributos, tipos de dados e descrições.

#### Entidade: User

Tabela 7.9: Tabela de entidades - user

Nome do Atributo	Tipo de Dado	Descrição
user_id	INT	Identificador único do utilizador.
password	VARCHAR(128)	Palavra-passe encriptada utilizada para a autenticação do utilizador no sistema.
last_login	DATETIME(6)	Data e hora do último acesso do utilizador ao sistema.
is_superuser	TINYINT(1)	Campo padrão do Django que indica permissões administrativas completas. Este campo não é utilizado no sistema atual, uma vez que as permissões são personalizadas.
first_name	VARCHAR(150)	Primeiro nome do utilizador.
last_name	VARCHAR(150)	Apelido do utilizador.
is_staff	TINYINT(1)	Campo padrão do Django que define acesso ao painel administrativo. Este campo não é relevante no sistema atual, pois o painel administrativo do Django não é utilizado.
is_active	TINYINT(1)	Indica se o utilizador está ativo no sistema. Embora não seja utilizado no momento, poderá ser implementado futuramente para gerir a suspensão ou desativação de contas sem eliminação permanente.

Nome do Atributo	Tipo de Dado	Descrição
date_joined	DATETIME(6)	Regista a data de criação do utilizador no sistema. Este campo não é utilizado atualmente, mas poderá ser relevante para auditorias ou relatórios no futuro.
is_admin	TINYINT(1)	Define se o utilizador possui permissões administrativas no sistema, o que substitui o campo padrão <code>is_superuser</code> .
is_employee	TINYINT(1)	Indica se o utilizador é um operador/aprendiz da empresa, de forma a diferenciá-lo dos administradores.
is_female	TINYINT(1)	Indica se o utilizador se identifica como do género feminino.
is_male	TINYINT(1)	Indica se o utilizador se identifica como do género masculino.
name	VARCHAR(255)	Nome completo do utilizador.
mobile_number	VARCHAR(50)	Número de telemóvel associado ao utilizador.
birth_date	DATE	Data de nascimento do utilizador.
address	VARCHAR(100)	Endereço completo do utilizador.
username	VARCHAR(100)	Nome de utilizador único, destinado para a autenticação.
email	VARCHAR(50)	Endereço de e-mail do utilizador.
zipcode	VARCHAR(10)	Código postal associado ao endereço do utilizador.
profile_photo	VARCHAR(100)	Caminho do ficheiro da fotografia de perfil do utilizador.
city_id	INT	Identificador da cidade associada ao utilizador, relacionado com a tabela de cidades.
country_id	INT	Identificador do país associado ao utilizador, relacionado com a tabela de países.

### Entidade: Project

Tabela 7.10: Tabela de entidades - Project

Nome do Atributo	Tipo de Dado	Descrição
project_id	INT	Identificador único associado ao projeto.
name	VARCHAR(255)	Nome do projeto.
description	LONGTEXT	Detalhamento completo do projeto, como os seus objetivos e requisitos principais.
start_date	DATE	Data prevista ou efetiva para o início do projeto.

Nome do Atributo	Tipo de Dado	Descrição
end_date	DATE	Data prevista ou efetiva para o fim do projeto.
piece_model_id_id	INT	Identificador que estabelece a ligação com o modelo de deteção de peças associado ao projeto.
priority_id_id	INT	Identificador que indica a prioridade atribuída ao projeto, com base na sua relevância e urgência.
responsible_user_id	INT	Identificador único do utilizador responsável pela gestão ou supervisão do projeto.
validation_model_id_id	INT	Identificador que relaciona o projeto com o modelo de validação aplicável.
project_type_id_id	INT	Identificador que especifica o tipo de projeto, categorizando-o para fins operacionais.
error_model_id_id	INT	Identificador que vincula o projeto a um modelo de erros.

### Entidade: Validation Model

Tabela 7.11: Tabela de entidades - validation model

Nome do Atributo	Tipo de Dado	Descrição
validation_model_id	INT	Identificador único do modelo de validação.
model_file	VARCHAR(100)	Caminho onde está armazenado o ficheiro do modelo de validação.
data_yaml	VARCHAR(100)	Caminho para ficheiro “data” que contém todas as classes do modelo de validação

### Entidade: Error Model

Tabela 7.12: Tabela de entidades - error model

Nome do Atributo	Tipo de Dado	Descrição
error_model_id	INT	Identificador exclusivo associado ao modelo de deteção de erros.
model_file	VARCHAR(100)	Caminho completo para o ficheiro do modelo de deteção de erros.
data_yaml	VARCHAR(100)	Caminho para o ficheiro que inclui a lista das classes associadas ao modelo de deteção de erros.

**Entidade: Piece Model**

Tabela 7.13: Tabela de entidades - piece model

Nome do Atributo	Tipo de Dado	Descrição
piece_model_id	INT	Identificador único do modelo de detecção de peças.
model_file	VARCHAR(100)	Caminho completo onde está armazenado, na aplicação de administração, o ficheiro do modelo de detecção de peças.
data_yaml	VARCHAR(100)	Caminho do ficheiro em formato YAML que contém informações estruturadas sobre as classes do modelo de detecção de peças.

**Entidade: Project Type**

Nome do Atributo	Tipo de Dado	Descrição
project_type_id	INT	Identificador único que distingue cada tipo de projeto.
name	VARCHAR(50)	Nome representativo do tipo de projeto, utilizado categorizar os projetos.
description	LONGTEXT	Texto descritivo que detalha as especificidades do tipo de projeto.

**Entidade: Priority**

Tabela 7.15: Tabela de entidades - Priority

Nome do Atributo	Tipo de Dado	Descrição
priority_id	INT	Identificador único que permite distinguir cada prioridade armazenada no sistema.
name	VARCHAR(50)	Nome da prioridade, utilizado para facilitar a sua identificação.
description	LONGTEXT	Texto detalhado que descreve o contexto e os critérios associados à prioridade.
color	VARCHAR(7)	Código hexadecimal que representa a cor associada à prioridade, utilizada para diferenciação visual.
urgency_level	SMALLINT	Nível de urgência atribuído à prioridade, expresso através de um valor numérico onde valores mais elevados indicam maior urgência.

**Entidade: Task**

Tabela 7.16: Tabela de entidades - Task

Nome do Atributo	Tipo de Dado	Descrição
task_id	INT	Identificador único da tarefa, utilizado para diferenciar as entradas na base de dados.
animation_file	VARCHAR(100)	Caminho do ficheiro de animação associado à tarefa.
sequence_number	INT	Número sequencial que indica a ordem de execução das tarefas.
description	LONGTEXT	Texto descritivo com os detalhes da tarefa.
error_description	LONGTEXT	Informação detalhada sobre o erro ocorrido durante a execução da tarefa.

**Entidade: Error Class**

Tabela 7.17: Tabela de entidades - error class

Nome do Atributo	Tipo de Dado	Descrição
error_class_id	INT	Identificador único que distingue cada classe de erro registada.
name_class	VARCHAR(100)	Nome atribuído à classe de erro, proveniente do ficheiro YAML.
error_model_id_id	INT	Identificador que estabelece a relação com o modelo de erro ao qual esta classe pertence.

**Entidade: Task Error Classes**

Tabela 7.18: Tabela de entidades - task error classes

Nome do Atributo	Tipo de Dado	Descrição
id	BIGINT	Identificador exclusivo da relação, utilizado para distinguir cada associação entre tarefas e classes de erro.
task_id	INT	Identificador da tarefa associada, que referencia a entidade <b>task</b> .
error_class_id	INT	Identificador da classe de erro associada, que estabelece ligação à entidade <b>error_class</b> .

**Entidade: Piece Class**

Tabela 7.19: Tabela de entidades - piece class

Nome do Atributo	Tipo de Dado	Descrição
piece_class_id	INT	Identificador exclusivo que caracteriza cada classe do modelo de deteção de peças.
name_class	VARCHAR(100)	Denominação atribuída à classe da peça, proveniente do ficheiro YAML do modelo correspondente.
piece_model_id_id	INT	Identificador que relaciona esta classe com o modelo de deteção de peças a que pertence.

**Entidade: Task Piece Classes**

Tabela 7.20: Tabela de entidades - task piece classes

Nome do Atributo	Tipo de Dado	Descrição
id	BIGINT	Identificador único da relação, responsável por diferenciar cada associação entre tarefas e classes de peças.
task_id	INT	Identificador da tarefa associada, ligado à entidade <code>task</code> .
piececlass_id	INT	Identificador da classe de peças associada, que estabelece uma conexão com a entidade <code>piece_class</code> .

**Entidade: Validation Class**

Tabela 7.21: Tabela de entidades - validation class

Nome do Atributo	Tipo de Dado	Descrição
validation_class_id	INT	Identificador único que diferencia cada classe de validação registada no sistema.
name_class	VARCHAR(100)	Nome atribuído à classe de validação, derivado do ficheiro de configuração YAML do modelo.
validation_model_id_id	INT	Identificador que associa esta classe ao modelo de validação a que pertence.

**Entidade: Task Validation Classes**

Tabela 7.22: Tabela de entidades - task validation classes

Nome do Atributo	Tipo de Dado	Descrição
id	BIGINT	Identificador único da relação, utilizado para distinguir cada ligação entre tarefas e classes de validação.
task_id	INT	Identificador da tarefa vinculada, relacionado com a entidade <code>task</code> .
validationclass_id	INT	Identificador da classe de validação associada, que cria uma ligação à entidade <code>validation_class</code> .

### Entidade: Task Assigne Users

Tabela 7.23: Tabela de entidades - task assigne users

Nome do Atributo	Tipo de Dado	Descrição
id	BIGINT	Chave primária que identifica de forma única a associação entre uma tarefa e o utilizador atribuído.
task_id	INT	Referência à tarefa associada, que vincula este registo à tabela <code>task</code> .
user_id	INT	Identificador do utilizador designado para a tarefa, relacionado com a tabela <code>user</code> .

### Entidade: Performance Task

Tabela 7.24: Tabela de entidades - performance task

Nome do Atributo	Tipo de Dado	Descrição
performance_task_id	INT	Identificador único do desempenho do utilizador ao realizar uma tarefa específica.
start_date_registered	DATETIME(6)	Data e hora em que o operador iniciou a execução da tarefa.
end_date_registered	DATETIME(6)	Data e hora em que o operador terminou a execução da tarefa.
found_error	TINYINT(1)	Indica se o utilizador cometeu algum erro durante a realização da tarefa.
need_assistance	TINYINT(1)	Este campo não é utilizado atualmente, mas poderá ser implementado no futuro para indicar se o utilizador necessitou de assistência remota durante a tarefa.

Nome do Atributo	Tipo de Dado	Descrição
<code>completed</code>	TINYINT(1)	Indica se o utilizador concluiu a tarefa com sucesso.
<code>task_id</code>	INT	Identificador da tarefa associada, com o objetivo de estabelecer a ligação entre o desempenho do utilizador e a tarefa na entidade <code>task</code> .
<code>user_id</code>	INT	Identificador do utilizador que realizou a tarefa, que referencia a entidade <code>user</code> .

## 7.4 Fluxogramas das Principais Interações com a API

Nesta secção, apresentam-se os fluxogramas que descrevem os pedidos enviados à API durante as principais interações da aplicação de instrução virtual.

### 7.4.1 Autenticação

A Figura 7.1 descreve a comunicação entre a aplicação de instrução virtual e a aplicação de administração durante o processo de autenticação. Os pedidos enviados à API incluem a validação das credenciais e a emissão do *token* de acesso, com respostas distintas para sucesso ou falha.

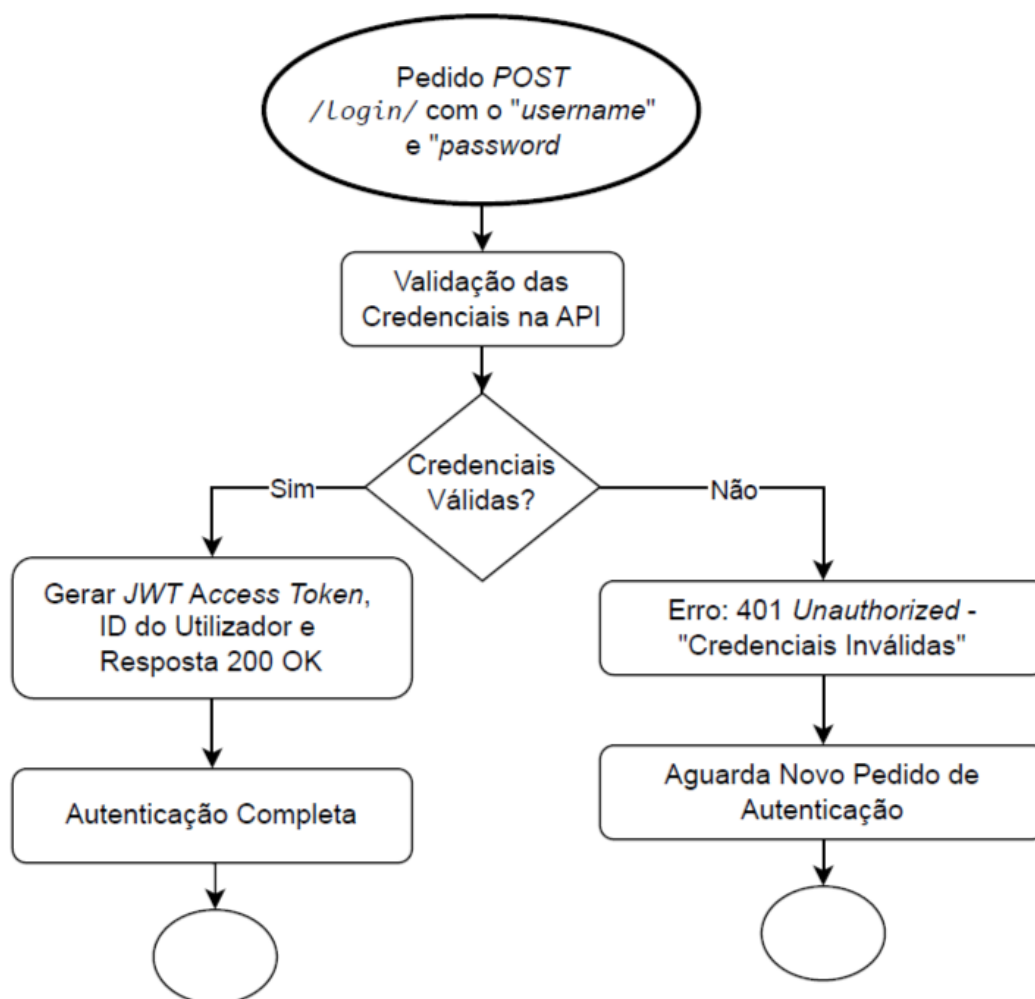


Figura 7.1: Fluxograma da API para a autenticação

#### 7.4.2 Escolher Projeto

A Figura 7.2 apresenta as requisições recebidas para obtenção e apresentação dos projetos atribuídos ao utilizador. São expostas as interações necessárias para listar as opções disponíveis e permitir a seleção de uma opção.

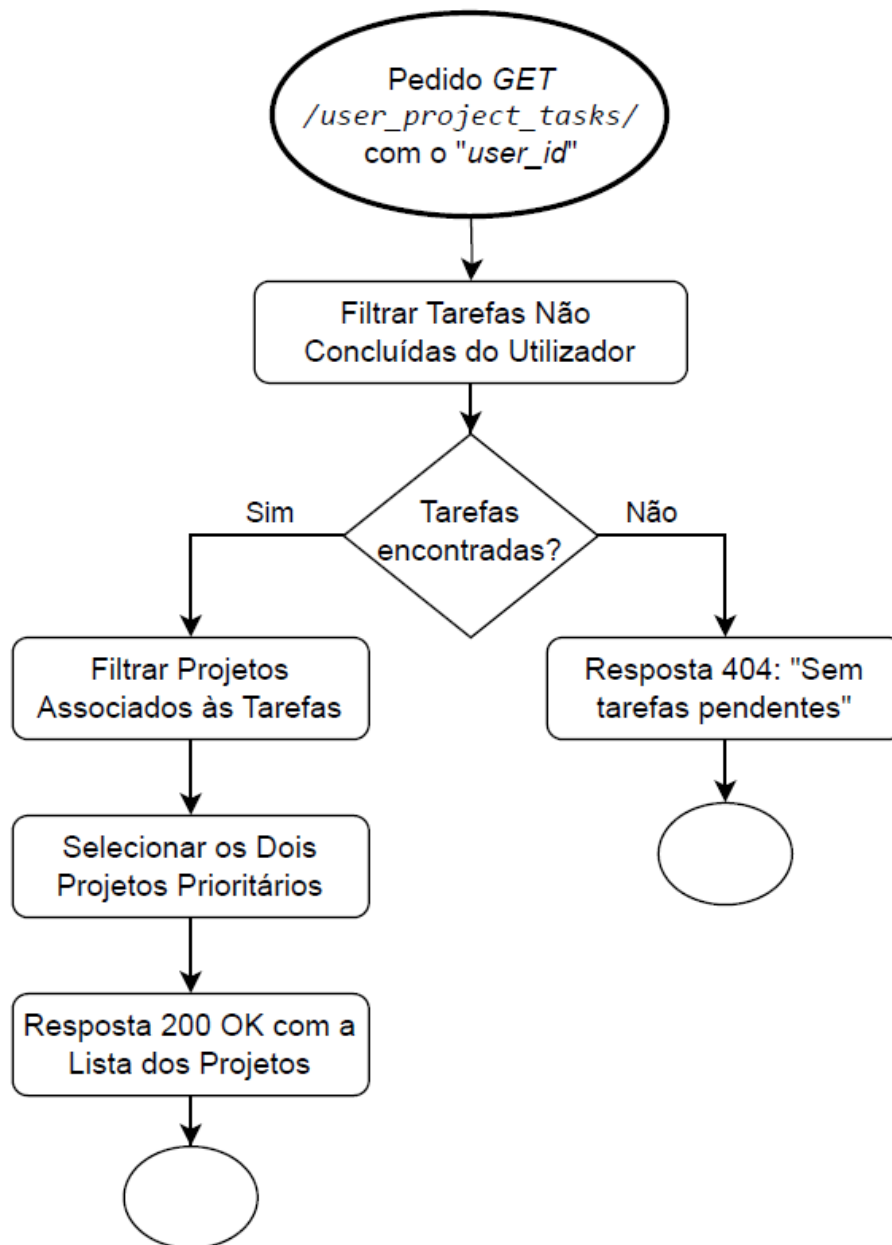


Figura 7.2: Fluxograma de todos os pedidos à API durante a ação selecionar projeto

### 7.4.3 Executar Tarefas - Formação Vocacional

O fluxograma da Figura 7.3 ilustra a sequência de comunicações necessárias para realizar as tarefas de uma formação vocacional.

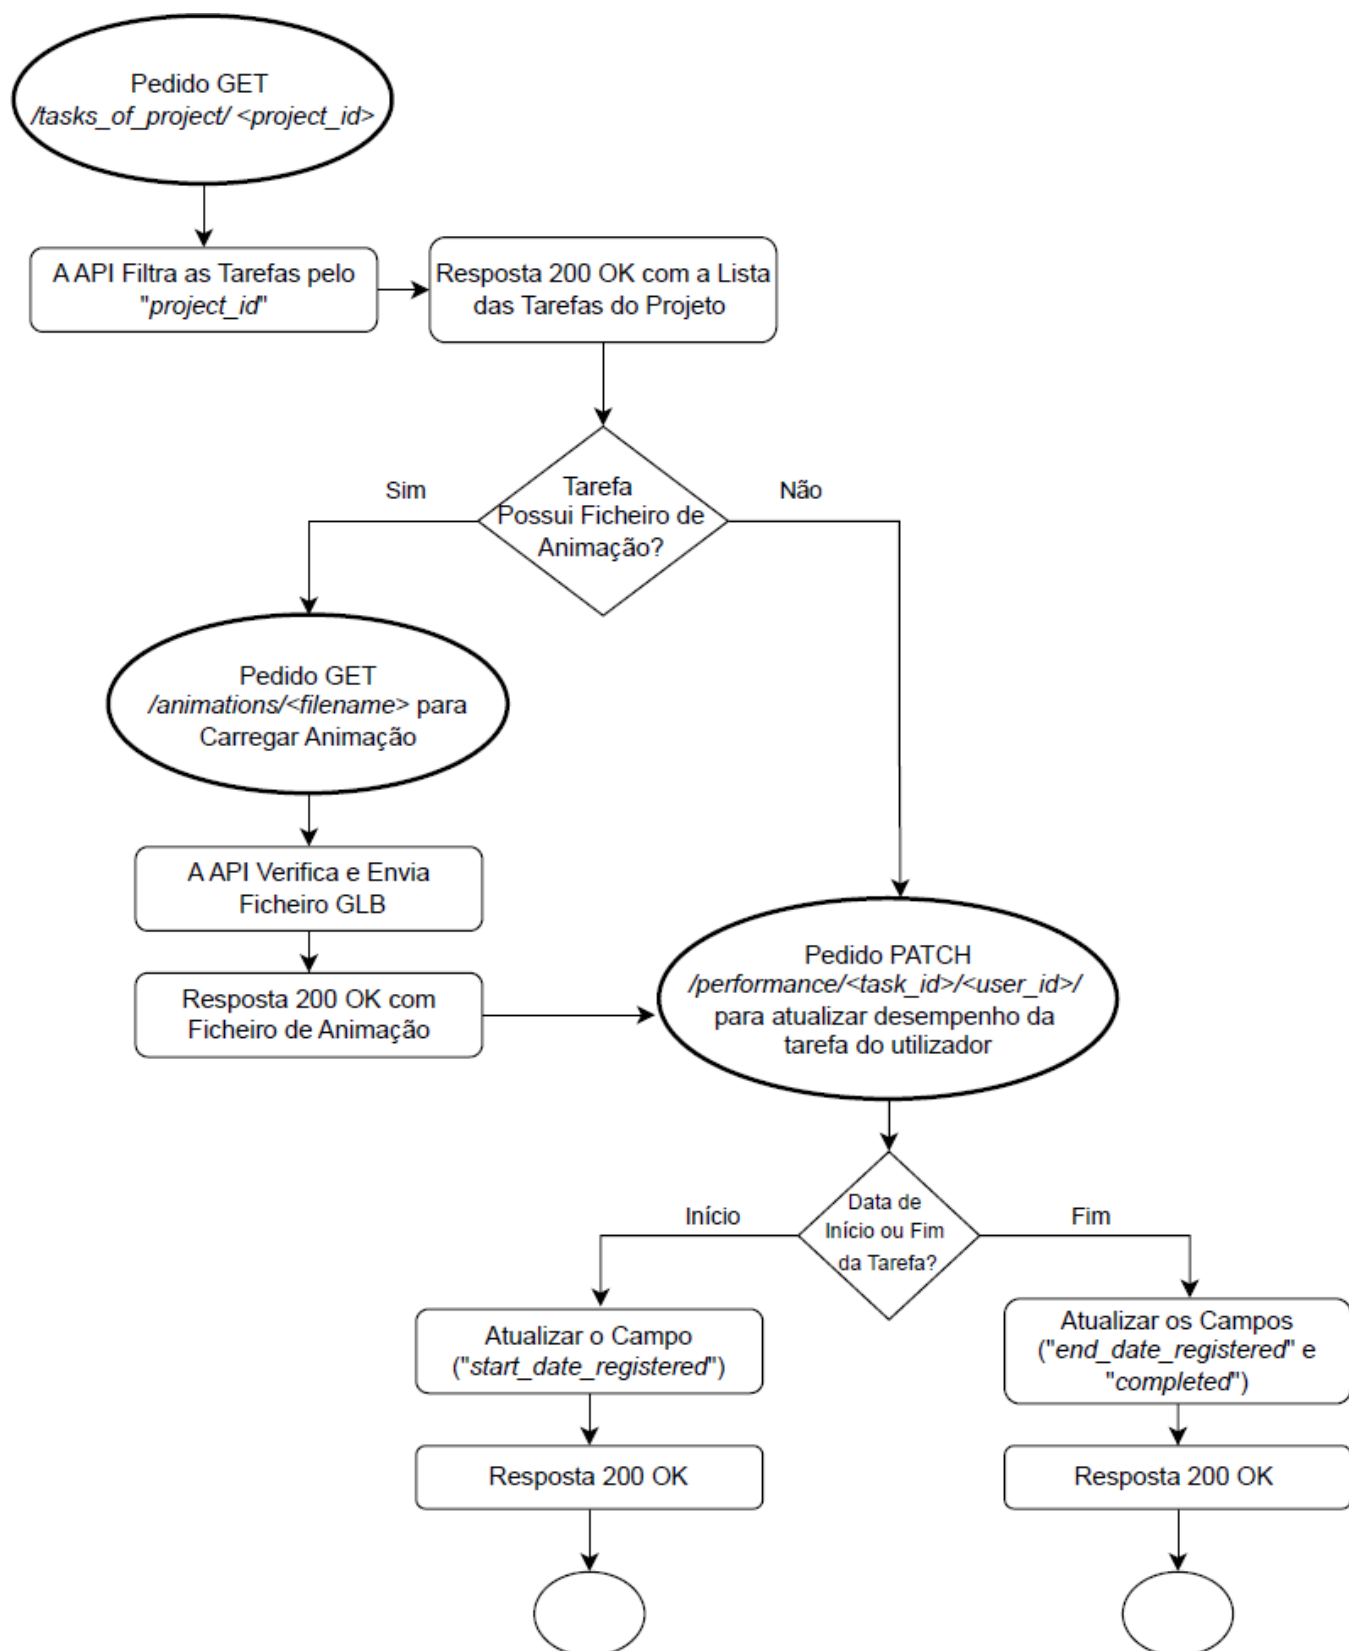


Figura 7.3: Fluxograma de todos os pedidos à API no decorrer da execução das tarefas

#### 7.4.4 Executar Tarefas - Formação no Trabalho

Esta secção detalha os pedidos enviados à API durante a execução das tarefas de formação no trabalho. Dependendo de o projeto incluir um modelo de identificação de deteção de peças, poderá existir uma fase inicial de preparação, descrita na Figura 7.4, com a verificação das peças e componentes necessários antes do início das tarefas. Caso contrário, ou seja, se existir apenas o modelo de validação de tarefas, realiza-se apenas a execução das mesmas, apresentada no fluxograma da Figura 7.5. Este processo abrange o envio de imagens para validação, a verificação das classes detetadas e o registo dos resultados de cada etapa.

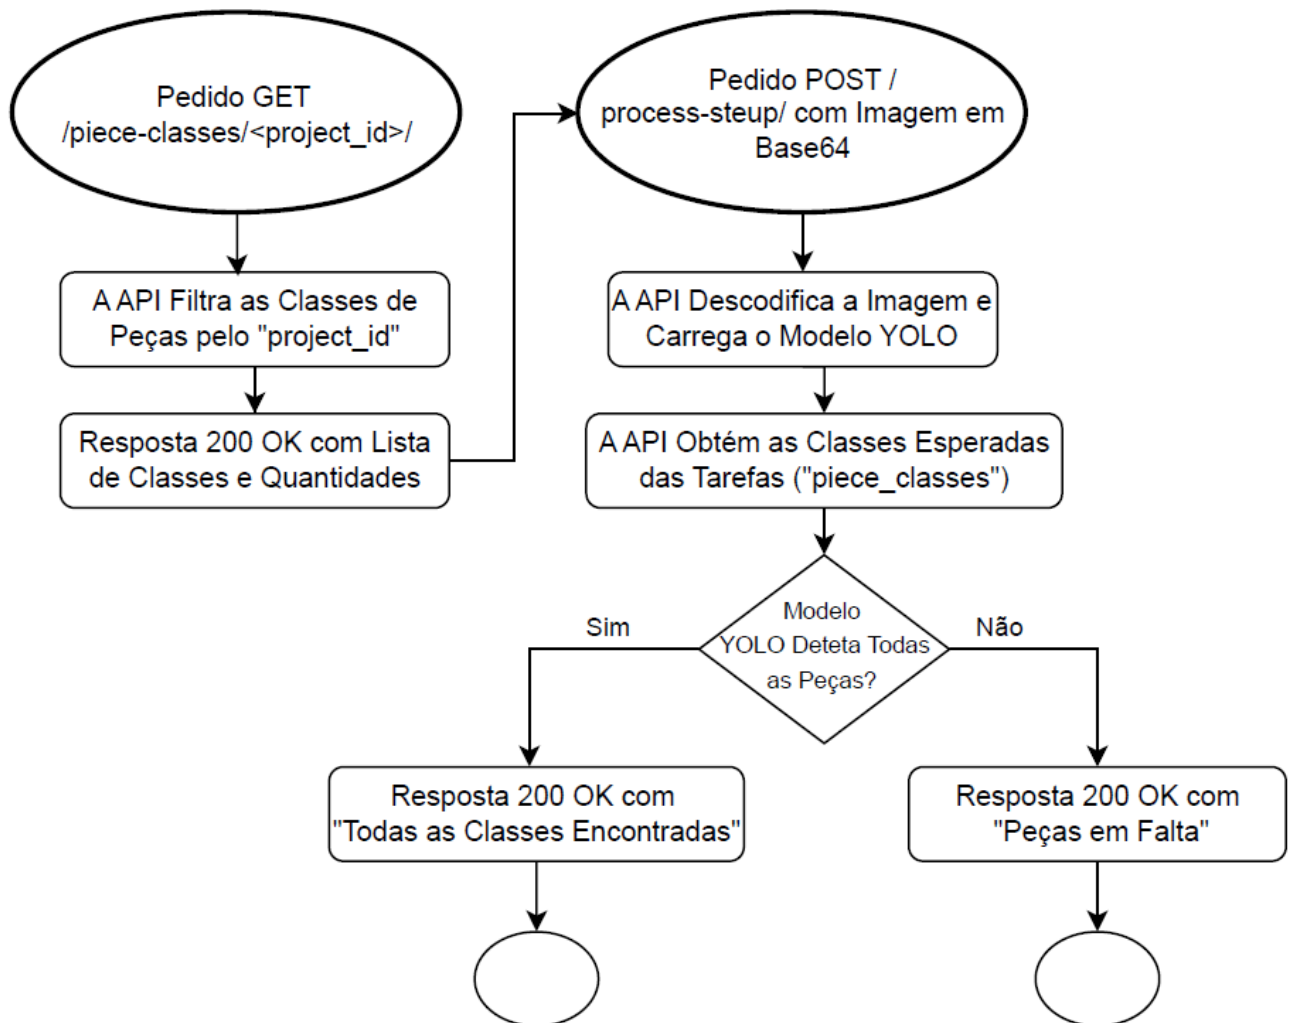


Figura 7.4: Fluxograma de todos os pedidos à API na fase de preparação

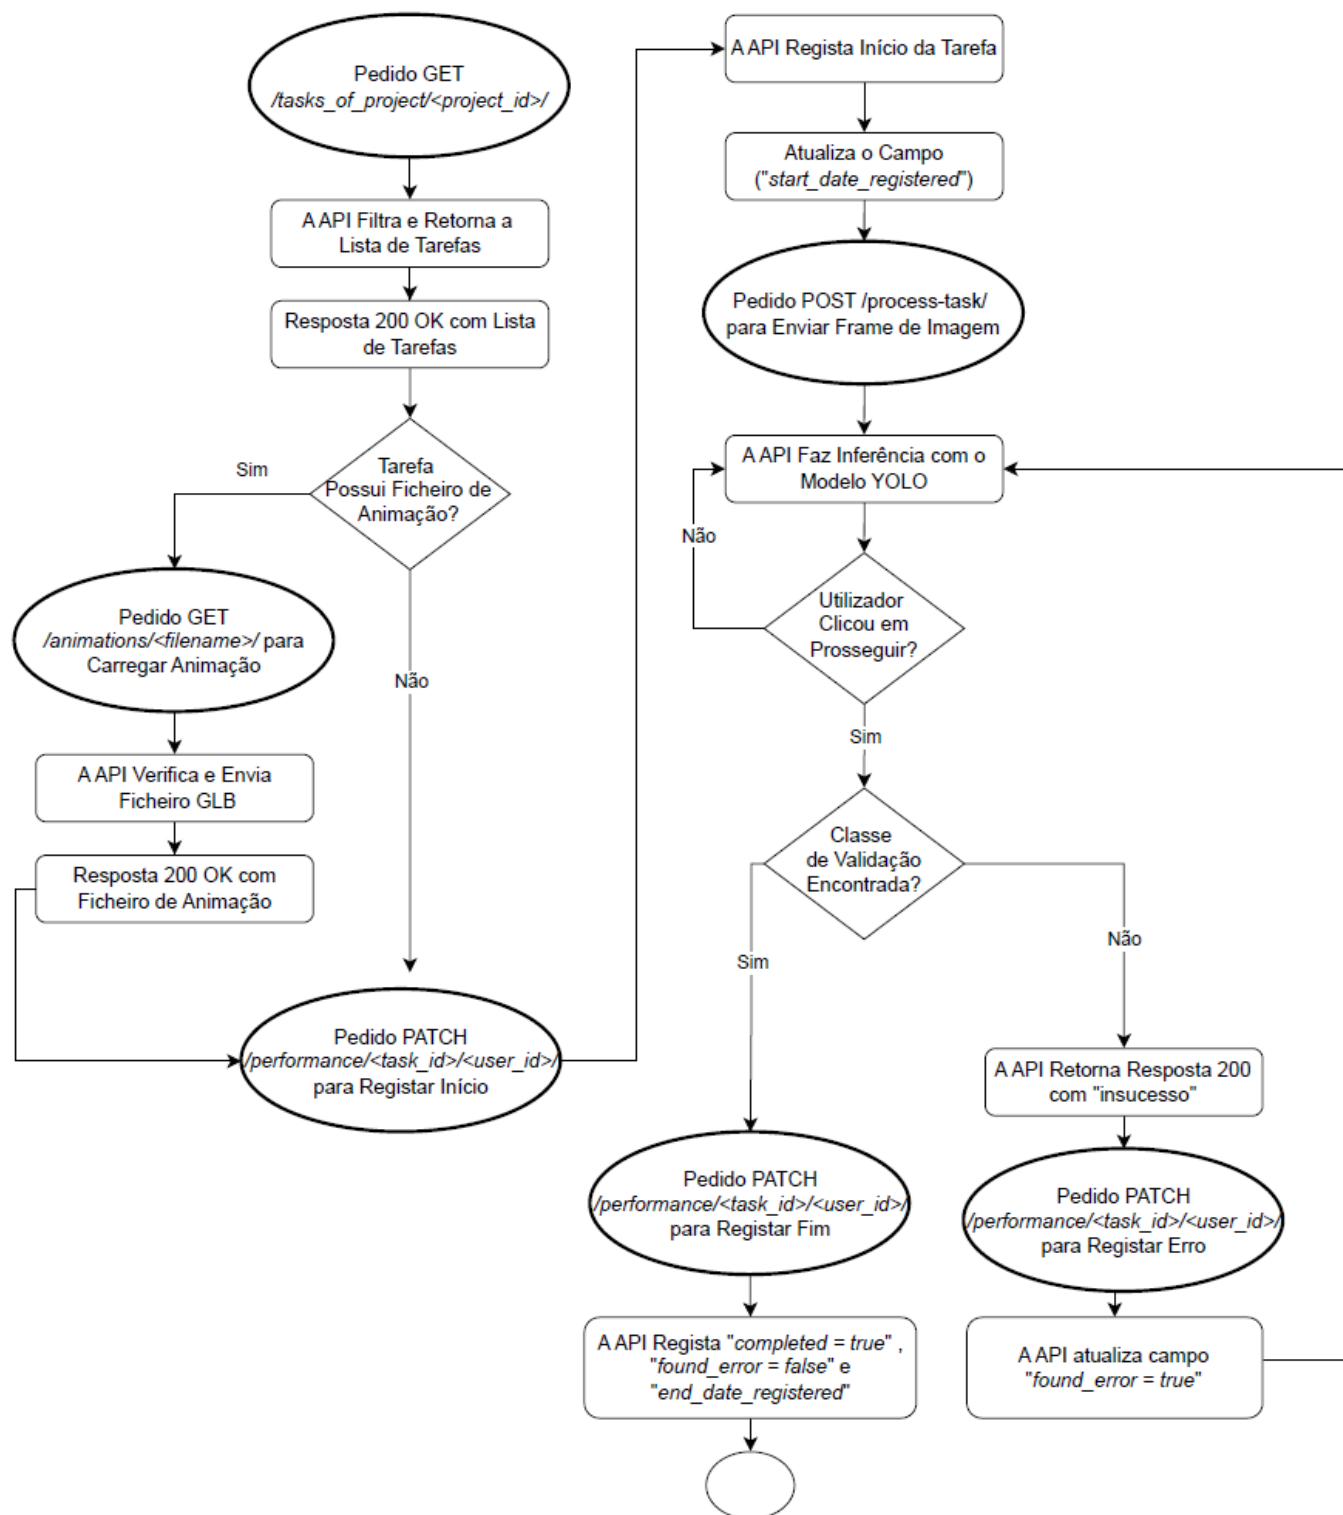


Figura 7.5: Fluxograma de todos os pedidos à API no decorrer da execução das tarefas

#### 7.4.5 Executar Tarefas - Monitorização do Controlo de Qualidade

A Figura 7.6 mostra todos os pedidos enviados à API pela aplicação de instrução virtual para a realização do controlo de qualidade. Inclui a análise das imagens capturadas, a

identificação de erros com base nas classes definidas e o retorno das respostas que influenciam os alertas apresentados quando são encontrados problemas.

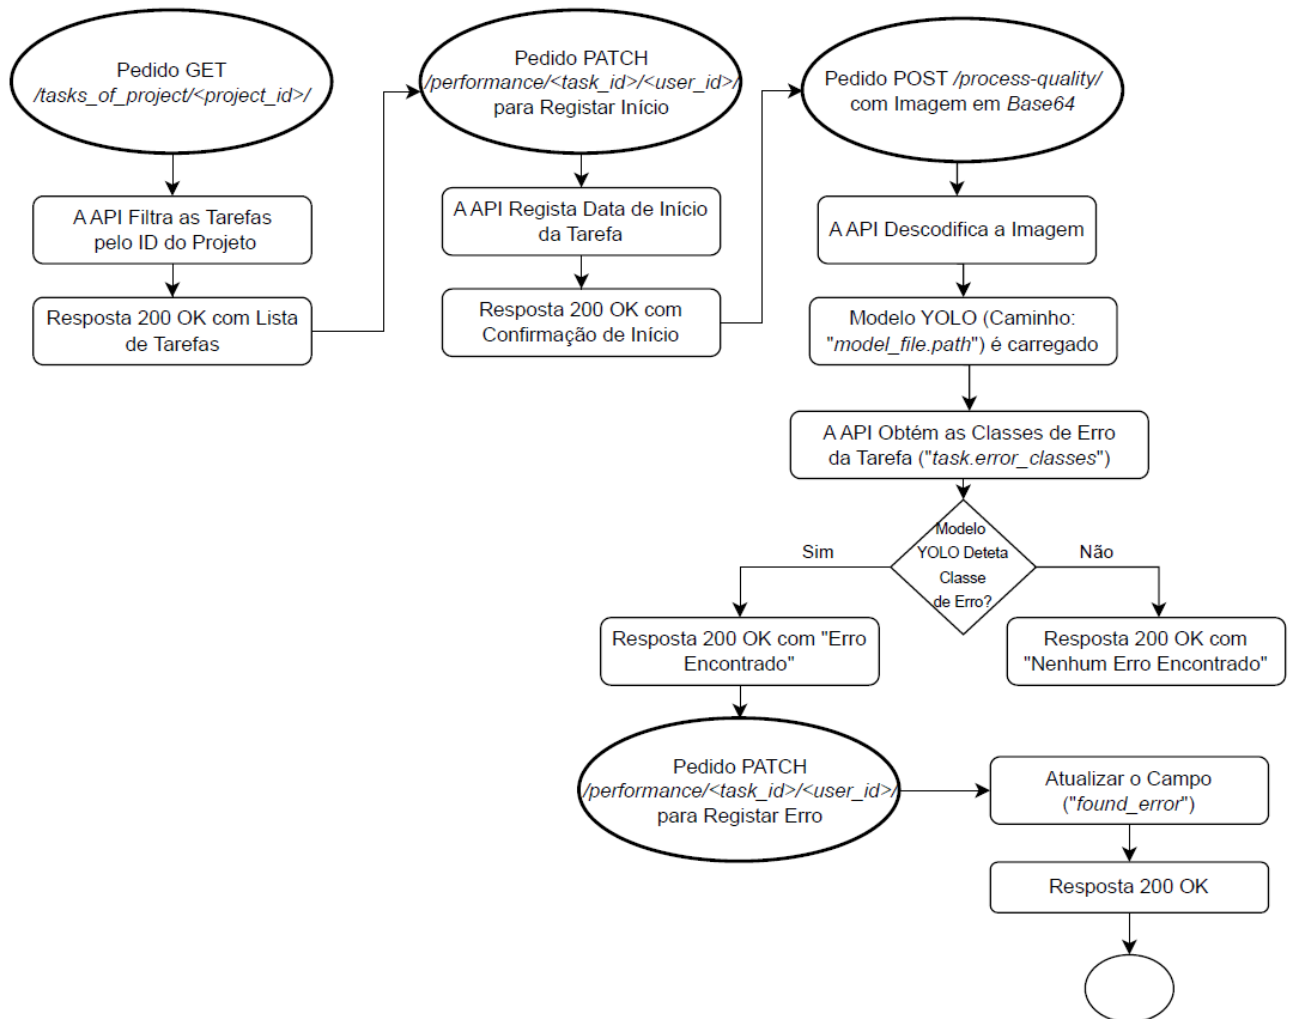


Figura 7.6: Fluxograma de todos os pedidos à API ao longo do controlo de qualidade



# Referências

- [1] S. Ehsan Hashemi-Petroodi, Alexandre Dolgui, Sergey Kovalev, Mikhail Y. Kovalyov, and Simon Thevenin. Workforce reconfiguration strategies in manufacturing systems: a state of the art. *International Journal of Production Research*, 59(22):6721 – 6744, 2021. ISSN 00207543. URL <https://search.ebscohost.com/login.aspx?direct=true&AuthType=ip,shib&db=bth&AN=153311431&lang=pt-pt&site=eds-live&scope=site>. [Citado na página 1]
- [2] Uwe Dombrowski, Thomas Richter, and Philipp Krenkel. Interdependencies of industrie 4.0 & lean production systems: A use cases analysis. *Procedia Manufacturing*, 11: 1061–1068, 2017. [Citado na página 1]
- [3] Amr Adel. Future of industry 5.0 in society: Human-centric solutions, challenges and prospective research areas. *Journal of Cloud Computing*, 11(1):1–15, 2022. [Citado na página 1]
- [4] Adrian Miqueo, Marta Torralba, and José A. Yagüe-Fabra. Lean manual assembly 4.0: A systematic review. *Applied Sciences*, 10(23), 2020. ISSN 2076-3417. doi: 10.3390/app10238555. URL <https://www.mdpi.com/2076-3417/10/23/8555>. [Citado nas páginas 2 e 3]
- [5] Matilda Wollter Bergman, Cecilia Berlin, Maral Babapour Chafi, Ann-Christine Falck, and Roland Örtengren. Cognitive ergonomics of assembly work from a job demands–resources perspective: Three qualitative case studies. *International Journal of Environmental Research and Public Health*, 18(23), 2021. ISSN 1660-4601. doi: 10.3390/ijerph182312282. URL <https://www.mdpi.com/1660-4601/18/23/12282>. [Citado nas páginas 2 e 3]
- [6] Feng-Kuang Chiang, Xiaojing Shang, and Lu Qiao. Augmented reality in vocational training: A systematic review of research and applications. *Computers in Human Behavior*, 129:107125, 2022. ISSN 0747-5632. doi: <https://doi.org/10.1016/j.chb.2021.107125>. URL <https://www.sciencedirect.com/science/article/pii/S0747563221004489>. [Citado nas páginas 2 e 3]
- [7] B. John, J.c. Kurian, R. Fitzgerald, and D.h.l. Goh. Students’ Learning Experience in a Mixed Reality Environment: Drivers and Barriers. *Communications of the Association for Information Systems*, 50(1):510–535, January 2022. ISSN 15293181. doi: 10.17705/1CAIS.05024. URL <https://search.ebscohost.com/login.aspx?direct=true&AuthType=ip,shib&db=edselc&AN=edselc.2-52.0-85134366479&lang=pt-pt&si>

- te=eds-live&scope=site. Num Pages: 535 Publisher: Association for Information Systems 510. [Citado na página 2]
- [8] Agenda Green Auto. Agenda Green Auto - Inovação Verde para a Indústria Automóvel. URL <https://www.agendagreenauto.pt/>. Visitado em 2025-02-11. [Citado na página 3]
- [9] IPV. Investigar&Inovar - IPV, October 2021. URL <https://ipv.pt/investigarinovar/>. Visitado em 2025-02-11. [Citado na página 3]
- [10] Alexandre Dolgui, Fabio Sgarbossa, and Marco Simonetto. Design and management of assembly systems 4.0: systematic literature review and research agenda. *International Journal of Production Research*, 60(1):184 – 210, 2022. ISSN 00207543. URL <https://search.ebscohost.com/login.aspx?direct=true&AuthType=ip,shib&db=bth&AN=155345739&lang=pt-pt&site=eds-live&scope=site>. [Citado na página 3]
- [11] Pieter Vanneste, Yi Huang, Jung Yeon Park, Frederik Cornillie, Bart Decloedt, and Wim Van den Noortgate. Cognitive support for assembly operations by means of augmented reality: an exploratory study. *International Journal of Human-Computer Studies*, 143:102480, 2020. ISSN 1071-5819. doi: <https://doi.org/10.1016/j.ijhcs.2020.102480>. URL <https://www.sciencedirect.com/science/article/pii/S1071581920300823>. [Citado na página 3]
- [12] Faisal M. Alessa, Mohammed H. Alhaag, Ibrahim M. Al-harkan, Mohamed Z. Ramadan, and Fahad M. Alqahtani. A neurophysiological evaluation of cognitive load during augmented reality interactions in various industrial maintenance and assembly tasks. *Sensors (14248220)*, 23(18):7698, 2023. ISSN 14248220. URL <https://search.ebscohost.com/login.aspx?direct=true&AuthType=ip,shib&db=a9h&AN=172417562&lang=pt-pt&site=eds-live&scope=site>. [Citado na página 3]
- [13] Darko Hercog, Primož Bencak, Uroš Vincetič, and Tone Lerher. Product assembly assistance system based on pick-to-light and computer vision technology. *Sensors (14248220)*, 22(24):9769, 2022. ISSN 14248220. URL <https://search.ebscohost.com/login.aspx?direct=true&AuthType=ip,shib&db=a9h&AN=161002635&lang=pt-pt&site=eds-live&scope=site>. [Citado na página 4]
- [14] Sebastian Pimminger, Werner Kurschl, and Johannes Schönböck. Mixed reality workplace training systems for smart factories: Challenges and future directions. In *2022 IEEE 3rd International Conference on Human-Machine Systems (ICHMS)*, pages 1–6. IEEE, 2022. [Citado na página 4]
- [15] Andrzej Pacana. Analysis of quality control efficiency in the automotive industry. *Transportation Research Procedia*, January 2021. URL <https://www.academia.edu>

- /94131803/Analysis\_of\_quality\_control\_efficiency\_in\_the\_automotive\_industry. [Citado na página 4]
- [16] b on. b-on, 2024. URL <https://www.b-on.pt/>. Visitado em 2024-01-15. [Citado na página 5]
- [17] MDPI. MDPI | About, 2024. URL <https://www.mdpi.com/about>. Visitado em 2024-01-15. [Citado na página 5]
- [18] IEEE. IEEE Xplore, 2024. URL <https://ieeexplore.ieee.org/Xplore/home.jsp>. Visitado em 2024-01-15. [Citado na página 5]
- [19] Elsevier B.V. ScienceDirect.com | Science, health and medical journals, full text articles and books., 2024. URL <https://www.sciencedirect.com/>. Visitado em 2024-01-15. [Citado na página 5]
- [20] Mohammed S Nassr and Samy S Abu-Naser. Its for enhancing training methodology for students majoring in electricity. *International Journal of Academic Pedagogical Research (IJAPR)*, 3(3):16–30, 2019. [Citado na página 7]
- [21] Le Bo, Xiaoxiao Ding, and Sihan Wang. A comparative analysis of traditional teaching and pbl model. In *Proceedings of the 2022 8th International Conference on Humanities and Social Science Research (ICHSSR 2022)*, pages 1686–1690. Atlantis Press, 2022. ISBN 978-94-6239-580-0. doi: 10.2991/assehr.k.220504.306. URL <https://doi.org/10.2991/assehr.k.220504.306>. [Citado na página 7]
- [22] GE Digital. Education Services | GE Digital, 2023. URL <https://www.ge.com/digital/services/education-services>. [Citado na página 7]
- [23] Satnam Singh Saini, Simarjit Singh Malhi, Bhupinder Kaur Saro, Mohammad Shuaib Khan, and Amanpreet Kaur. Virtual reality: A survey of enabling technologies and its applications in iot. In *2022 International Conference on Electronics and Renewable Systems (ICEARS)*, pages 597–603. IEEE, 2022. [Citado na página 7]
- [24] Dennis L. Kappen and Lennart E. Nacke. The kaleidoscope of effective gamification: Deconstructing gamification in business applications. In *Proceedings of the First International Conference on Gameful Design, Research, and Applications, Gamification '13*, page 119–122, New York, NY, USA, 2013. Association for Computing Machinery. ISBN 9781450328159. doi: 10.1145/2583008.2583029. URL <https://doi.org/10.1145/2583008.2583029>. [Citado na página 7]
- [25] Bosch Rexroth AG. Trainings, 2023. URL <https://www.boschrexroth.com/en/id/academy/training/>. [Citado na página 8]
- [26] Microsoft Corporation. Toyota manufacturing group uses Dynamics 365 mixed reality to boost operational efficiency and scalability, 2021. URL <https://customers.microsoft.com/en-us/story/849867-toyota-motor-north-america-dynamics-365>. [Citado na página 8]

- [27] Ken Taylor and Michelle Eggleston Schwartz. Trends 2024: L&D as a Key Business Driver, November 2023. URL <https://trainingindustry.com/articles/strategy-alignment-and-planning/trends-2024-ld-as-a-key-business-driver/>. Visitado em 2024-02-13. [Citado na página 8]
- [28] Atul Palange and Pankaj Dhatrak. Lean manufacturing a vital tool to enhance productivity in manufacturing. *Materials Today: Proceedings*, 46:729–736, 2021. ISSN 2214-7853. doi: <https://doi.org/10.1016/j.matpr.2020.12.193>. URL <https://www.sciencedirect.com/science/article/pii/S2214785320398783>. 2nd International Conference on Manufacturing Material Science and Engineering. [Citado na página 8]
- [29] Harald Bauer, Felix Brandl, Christopher Lock, and Gunther Reinhart. Integration of industrie 4.0 in lean manufacturing learning factories. *Procedia manufacturing*, 23: 147–152, 2018. doi: <https://doi.org/10.1016/j.promfg.2018.04.008>. URL <https://www.sciencedirect.com/science/article/pii/S2351978918304803>. [Citado na página 8]
- [30] Paul Milgram and Fumio Kishino. A taxonomy of mixed reality visual displays. *IEICE TRANSACTIONS on Information and Systems*, 77(12):1321–1329, 1994. [Citado nas páginas ix e 8]
- [31] Matthias Eder, Maria Hulla, Felizian Mast, and Christian Ramsauer. On the application of augmented reality in a learning factory working environment. *Procedia Manufacturing*, 45:7–12, 2020. [Citado na página 9]
- [32] Yuk-Ming Tang, Kin Man Au, Henry CW Lau, George TS Ho, and Chun-Ho Wu. Evaluating the effectiveness of learning design with mixed reality (mr) in higher education. *Virtual Reality*, 24(4):797–807, 2020. [Citado na página 9]
- [33] Kavya Chivukula. RAAF uses HoloLens mixed-reality device for C-17A maintenance, September 2020. URL <https://www.airforce-technology.com/news/raaf-uses-hololens-mixed-reality-device-for-c-17a-maintenance/>. [Citado na página 9]
- [34] Microsoft Corporation. Microsoft HoloLens | Tecnologia de Realidade Mista para Empresas, 2023. URL <https://www.microsoft.com/pt-pt/hololens>. Visitado em 2023-11-06. [Citado na página 9]
- [35] Microsoft Devices Blog and Lorraine Bardeen. Ford brings Microsoft HoloLens to Design Studio; Drives speed, creativity and collaboration, September 2017. URL <https://blogs.windows.com/devices/2017/09/20/ford-brings-microsoft-hololens-to-design-studio-drives-speed-creativity-and-collaboration/>. Visitado em 2023-11-03. [Citado na página 9]
- [36] Manuel Rebol, Colton Hood, Claudia Ranniger, Adam Rutenberg, Neal Sikka, Erin Maria Horan, Christian Gütl, and Krzysztof Pietroszek. Remote assistance

- with mixed reality for procedural tasks. In *2021 IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW)*, pages 653–654, 2021. doi: 10.1109/VRW52623.2021.00209. [Citado na página 9]
- [37] Porsche. Designed by Innovation, August 2019. URL <https://newsroom.porsche.com/en/2019/digital/porsche-design-mixed-reality-technology-meyle-mueller-medialesson-hololens-interview-18189.html>. Visitado em 2023-11-04. [Citado na página 9]
- [38] Pedro Alexandre Loureiro Nogueira. Aplicação da realidade mista na aprendizagem em unidades industriais - learning factory. Master's thesis, Polytechnic Institute of Viseu, March 2023. URL <https://repositorio.ipv.pt/handle/10400.19/7790>. Accepted: 2023-05-23T11:06:24Z. [Citado nas páginas 9 e 63]
- [39] Unity Technologies. Plataforma de desenvolvimento em tempo real do Unity | Engine para 3D, 2D, VR e AR, 2024. URL <https://unity.com>. Visitado em 2024-10-25. [Citado nas páginas 9 e 18]
- [40] Epic Games Inc. Unreal Engine | A mais poderosa ferramenta de 3D em tempo real, 2023. URL <https://www.unrealengine.com/pt-BR>. Visitado em 2023-10-30. [Citado na página 9]
- [41] Team Viewer. TeamViewer Customer Success story: Audi, 2022. URL <https://www.teamviewer.com/en/success-stories/audi/>. Visitado em 2023-11-04. [Citado na página 10]
- [42] Honeywell. Honeywell Introduces Virtual Reality-Based Simulator To Optimize Training For Industrial Workers, October 2020. URL <https://www.honeywell.com/us/en/press/2020/10/honeywell-introduces-virtual-reality-based-simulator-to-optimize-training-for-industrial-workers>. [Citado na página 10]
- [43] Riccardo Palmarini, Iñigo Fernández Del Amo, Dedy Ariansyah, Samir Khan, John Ahmet Erkoyuncu, and Rajkumar Roy. Fast augmented reality authoring: Fast creation of ar step-by-step procedures for maintenance operations. *IEEE Access*, 11:8407–8421, 2023. doi: 10.1109/ACCESS.2023.3235871. [Citado na página 10]
- [44] José Silva, Pedro Coelho, Luzia Saraiva, Paulo Vaz, Pedro Martins, and Alfonso López-Rivero. Validating the Use of Smart Glasses in Industrial Quality Control: A Case Study. *Applied Sciences*, 14(5):1850, January 2024. ISSN 2076-3417. doi: 10.3390/app14051850. URL <https://www.mdpi.com/2076-3417/14/5/1850>. Number: 5 Publisher: Multidisciplinary Digital Publishing Institute. [Citado nas páginas 10, 66 e 68]
- [45] Ying Bi, Bing Xue, Pablo Mesejo, Stefano Cagnoni, and Mengjie Zhang. A survey on evolutionary computation for computer vision and image analysis: Past, present, and future trends. *IEEE Transactions on Evolutionary Computation*, 27(1):5–25, 2023. doi: 10.1109/TEVC.2022.3220747. [Citado nas páginas 10 e 12]

- [46] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324, 1998. doi: 10.1109/5.726791. [Citado na página 11]
- [47] Mahsa Valizadeh and Sarah Jeannette Wolff. Convolutional neural network applications in additive manufacturing: A review. *Advances in Industrial and Manufacturing Engineering*, 4:100072, 2022. ISSN 2666-9129. doi: <https://doi.org/10.1016/j.aime.2022.100072>. URL <https://www.sciencedirect.com/science/article/pii/S2666912922000046>. [Citado na página 11]
- [48] Junyi Chai, Hao Zeng, Anming Li, and Eric W. T. Ngai. Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*, 6:100134, 2021. ISSN 2666-8270. doi: <https://doi.org/10.1016/j.mlwa.2021.100134>. URL <https://www.sciencedirect.com/science/article/pii/S2666827021000670>. [Citado nas páginas ix, 11 e 12]
- [49] Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. Imagenet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pages 248–255, June 2009. doi: 10.1109/CVPR.2009.5206848. [Citado na página 11]
- [50] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. ImageNet Classification with Deep Convolutional Neural Networks. In F. Pereira, C. J. Burges, L. Bottou, and K. Q. Weinberger, editors, *Advances in Neural Information Processing Systems*, volume 25. Curran Associates, Inc., 2012. URL [https://proceedings.neurips.cc/paper\\_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf). [Citado na página 11]
- [51] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew Rabinovich. Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1–9, 2015. [Citado na página 11]
- [52] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition, 2015. [Citado na página 11]
- [53] Jifeng Dai, Yi Li, Kaiming He, and Jian Sun. R-FCN: Object Detection via Region-based Fully Convolutional Networks. In D. Lee, M. Sugiyama, U. Luxburg, I. Guyon, and R. Garnett, editors, *Advances in Neural Information Processing Systems*, volume 29. Curran Associates, Inc., 2016. URL [https://proceedings.neurips.cc/paper\\_files/paper/2016/file/577ef1154f3240ad5b9b413aa7346a1e-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2016/file/577ef1154f3240ad5b9b413aa7346a1e-Paper.pdf). [Citado na página 11]
- [54] Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, and Alexander C Berg. Ssd: Single shot multibox detector. In *Computer*

- Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I 14*, pages 21–37. Springer, 2016. [Citado na página 12]
- [55] Joseph Redmon, Santosh Divvala, Ross Girshick, and Ali Farhadi. You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2016. [Citado nas páginas 12 e 19]
- [56] Joseph Redmon and Ali Farhadi. Yolo9000: Better, faster, stronger. In *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 6517–6525, 2017. doi: 10.1109/CVPR.2017.690. [Citado na página 12]
- [57] Joseph Redmon and Ali Farhadi. Yolo3: An incremental improvement, 2018. [Citado na página 12]
- [58] Tsung-Yi Lin, Priya Goyal, Ross Girshick, Kaiming He, and Piotr Dollar. Focal loss for dense object detection. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, Oct 2017. [Citado na página 12]
- [59] Demetris Demetriou, Pavlos Mavromatidis, Ponsian M. Robert, Harris Papadopoulos, Michael F. Petrou, and Demetris Nicolaides. Real-time construction demolition waste detection using state-of-the-art deep learning methods; single-stage vs two-stage detectors. *Waste Management*, 167:194–203, 2023. ISSN 0956-053X. doi: <https://doi.org/10.1016/j.wasman.2023.05.039>. URL <https://www.sciencedirect.com/science/article/pii/S0956053X23003872>. [Citado na página 12]
- [60] Kaiming He, Georgia Gkioxari, Piotr Dollár, and Ross Girshick. Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision*, pages 2961–2969, 2017. [Citado na página 12]
- [61] Liang-Chieh Chen, Yukun Zhu, George Papandreou, Florian Schroff, and Hartwig Adam. Encoder-decoder with atrous separable convolution for semantic image segmentation. In *Proceedings of the European conference on computer vision (ECCV)*, pages 801–818, 2018. [Citado na página 12]
- [62] Jacob Solawetz. What is Instance Segmentation? A Guide with Roboflow., April 2022. URL <https://blog.roboflow.com/instance-segmentation-roboflow/>. Visitado em 2024-11-25. [Citado na página 12]
- [63] Ultralytics. Função de perda, 2024. URL <https://www.ultralytics.com/pt/glossary/loss-function>. Visitado em 2025-01-14. [Citado na página 13]
- [64] Chenxukun Lou, Lawrence Tinsley, Fabian Duarte Martinez, Simon Gray, and Barmak Honarvar Shakibaei Asli. Optimized ai methods for rapid crack detection in microscopy images. *Electronics*, 13(23), 2024. ISSN 2079-9292. doi: 10.3390/electronics13234824. URL <https://www.mdpi.com/2079-9292/13/23/4824>. [Citado na página 14]

- [65] Yanzhi Qi, Zhi Ding, Yaozhi Luo, and Zhi Ma. A three-step computer vision-based framework for concrete crack detection and dimensions identification. *Buildings*, 14(8), 2024. ISSN 2075-5309. doi: 10.3390/buildings14082360. URL <https://www.mdpi.com/2075-5309/14/8/2360>. [Citado na página 14]
- [66] Madallah Alruwaili, Muhammad Nouman Atta, Muhammad Hameed Siddiqi, Abdullah Khan, Asfandyar Khan, Yousef Alhwaiti, and Saad Alanazi. Deep learning-based yolo models for the detection of people with disabilities. *IEEE Access*, 12:2543–2566, 2024. doi: 10.1109/ACCESS.2023.3347169. [Citado na página 15]
- [67] Ultralytics. Matriz de confusão, 2024. URL <https://www.ultralytics.com/pt/globalssary/confusion-matrix>. [Citado na página 15]
- [68] Ravpreet Kaur and Sarbjeet Singh. A comprehensive review of object detection with deep learning. *Digital Signal Processing*, 132:103812, 2023. ISSN 1051-2004. doi: <https://doi.org/10.1016/j.dsp.2022.103812>. URL <https://www.sciencedirect.com/science/article/pii/S1051200422004298>. [Citado na página 15]
- [69] Simon Wenkel, Khaled Alhazmi, Tanel Liiv, Saud Alrshoud, and Martin Simon. Confidence score: The forgotten dimension of object detection performance evaluation. *Sensors*, 21(13), 2021. ISSN 1424-8220. doi: 10.3390/s21134350. URL <https://www.mdpi.com/1424-8220/21/13/4350>. [Citado na página 15]
- [70] Rafael Padilla, Wesley L. Passos, Thadeu L. B. Dias, Sergio L. Netto, and Eduardo A. B. da Silva. A comparative analysis of object detection metrics with a companion open-source toolkit. *Electronics*, 10(3), 2021. ISSN 2079-9292. doi: 10.3390/electronics10030279. URL <https://www.mdpi.com/2079-9292/10/3/279>. [Citado na página 15]
- [71] Ahmed Gad. Evaluating Deep Learning Models: The Confusion Matrix, Accuracy, Precision, and Recall, 2021. URL <https://www.kdnuggets.com/evaluating-deep-learning-models-the-confusion-matrix-accuracy-precision-and-recall>. Section: 2021 Feb Tutorials, Overviews. [Citado na página 16]
- [72] Rafael Padilla, Sergio L. Netto, and Eduardo A. B. da Silva. A survey on performance metrics for object-detection algorithms. In *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*, pages 237–242, 2020. doi: 10.1109/IWSSIP48289.2020.9145130. [Citado na página 16]
- [73] Abdur Rahman, Yuzhen Lu, and Haifeng Wang. Performance evaluation of deep learning object detectors for weed detection for cotton. *Smart Agricultural Technology*, 3: 100126, 2023. ISSN 2772-3755. doi: <https://doi.org/10.1016/j.atech.2022.100126>. URL <https://www.sciencedirect.com/science/article/pii/S2772375522000910>. [Citado na página 16]
- [74] Syed Sahil Abbas Zaidi, Mohammad Samar Ansari, Asra Aslam, Nadia Kanwal, Mamoona Asghar, and Brian Lee. A survey of modern deep learning based object detection models. *Digital Signal Processing*, 126:103514, 2022. ISSN 1051-2004. doi:

- <https://doi.org/10.1016/j.dsp.2022.103514>. URL <https://www.sciencedirect.com/science/article/pii/S1051200422001312>. [Citado na página 16]
- [75] M.C. Hinojosa Lee, J. Braet, and J. Springael. Performance metrics for multilabel emotion classification: Comparing micro, macro, and weighted f1-scores. *Applied Sciences (Switzerland)*, 14(21), 2024. ISSN 20763417. URL <https://search.ebscohost.com/login.aspx?direct=true&AuthType=ip,shib&db=edselc&AN=edse1c.2-52.0-85208596727&lang=pt-pt&site=eds-live&scope=site>. [Citado na página 16]
- [76] Ultralytics. Pontuação F1, 2024. URL <https://www.ultralytics.com/pt/glossary/f1-score>. Visitado em 2024-11-23. [Citado na página 16]
- [77] Lianyu Zheng, Xinyu Liu, Zewu An, Shufei Li, and Renjie Zhang. A smart assistance system for cable assembly by combining wearable augmented reality with portable visual inspection. *Virtual Reality & Intelligent Hardware*, 2(1):12–27, 2020. ISSN 2096-5796. doi: <https://doi.org/10.1016/j.vrih.2019.12.002>. URL <https://www.sciencedirect.com/science/article/pii/S2096579620300036>. [Citado nas páginas 17 e 92]
- [78] George Apostolopoulos, Dionisis Andronas, Nikos Fourtakas, and Sotiris Makris. Operator training framework for hybrid environments: An augmented reality module using machine learning object recognition. *Procedia CIRP*, 106:102–107, 2022. ISSN 2212-8271. doi: <https://doi.org/10.1016/j.procir.2022.02.162>. URL <https://www.sciencedirect.com/science/article/pii/S2212827122001639>. 9th CIRP Conference on Assembly Technology and Systems. [Citado na página 17]
- [79] OpenCV team. About, 2024. URL <https://opencv.org/about/>. Visitado em 2024-01-18. [Citado na página 17]
- [80] Mauricio-Andrés Zamora-Hernández, John Alejandro Castro-Vargas, Jorge Azorin-Lopez, and Jose Garcia-Rodriguez. Deep learning-based visual control assistant for assembly in Industry 4.0. *Computers in Industry*, 131:103485, 2021. ISSN 0166-3615. doi: <https://doi.org/10.1016/j.compind.2021.103485>. URL <https://www.sciencedirect.com/science/article/pii/S0166361521000920>. [Citado na página 17]
- [81] Subin Raj, L. R. D. Murthy, Thanikai Adhithiyam Shanmugam, Gyanig Kumar, Amresh Chakrabarti, and Pradipta Biswas. Augmented reality and deep learning based system for assisting assembly process. *Journal on Multimodal User Interfaces*, 18(1): 119–133, March 2024. ISSN 1783-8738. doi: 10.1007/s12193-023-00428-3. URL <https://doi.org/10.1007/s12193-023-00428-3>. [Citado nas páginas 17 e 92]
- [82] Unity Technologies. Soluções de Realidade Aumentada e Virtual para Manufatura, 2024. URL <https://unity.com/solutions/manufacturing>. Visitado em 2024-10-25. [Citado na página 18]

- [83] Unity Technologies. Scripts em Unity para programadores experientes em C# e C++, 2024. URL <https://unity.com/how-to/programming-unity>. Visitado em 2024-10-25. [Citado na página 18]
- [84] Joseph Redmon and Ali Farhadi. Yolo9000: Better, faster, stronger. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, July 2017. Visitado em 2025-01-06. [Citado na página 19]
- [85] Joseph Redmon and Ali Farhadi. YoloV3: An incremental improvement, 2018. URL <https://arxiv.org/abs/1804.02767>. Visitado em 2025-01-06. [Citado na página 19]
- [86] Ultralytics. YOLOv4, 2023. URL <https://docs.ultralytics.com/pt/models/yolov4>. Visitado em 2025-01-06. [Citado na página 19]
- [87] Ultralytics. YOLOv7, 2024. URL <https://docs.ultralytics.com/pt/models/yolov7>. [Citado na página 19]
- [88] Ultralytics. YOLOv8, 2023. URL <https://docs.ultralytics.com/models/yolov8>. [Citado na página 19]
- [89] Momina Liaqat Ali and Zhou Zhang. The yolo framework: A comprehensive review of evolution, applications, and benchmarks in object detection. *Computers*, 13(12), 2024. ISSN 2073-431X. doi: 10.3390/computers13120336. URL <https://www.mdpi.com/2073-431X/13/12/336>. [Citado na página 19]
- [90] Ultralytics. Ultralytics | Revolucionando o mundo da IA de visão, 2025. URL <https://www.ultralytics.com/pt>. [Citado na página 20]
- [91] Ultralytics. YOLOv3, 2023. URL <https://docs.ultralytics.com/models/yolov3>. [Citado na página 20]
- [92] Ultralytics. Predict, 2024. URL <https://docs.ultralytics.com/modes/predict>. Visitado em 2024-11-01. [Citado na página 20]
- [93] PyTorch Foundation. PyTorch documentation — PyTorch 2.5 documentation, 2024. URL <https://pytorch.org/docs/stable/index.html>. Visitado em 2025-01-07. [Citado na página 20]
- [94] NVIDIA Corporation. NVIDIA CUDA, 2024. URL <https://docs.nvidia.com/cuda/doc/index.html>. Visitado em 2025-01-07. [Citado na página 20]
- [95] Sparsh Mittal and Shraysh Vaishay. A survey of techniques for optimizing deep learning on gpus. *Journal of Systems Architecture*, 99:101635, 2019. ISSN 1383-7621. doi: <https://doi.org/10.1016/j.sysarc.2019.101635>. URL <https://www.sciencedirect.com/science/article/pii/S1383762119302656>. [Citado na página 20]
- [96] Python. General Python FAQ, 2024. URL <https://docs.python.org/3/faq/general.html>. Visitado em 2024-11-01. [Citado na página 20]

- 
- [97] Django. Django, 2024. URL <https://www.djangoproject.com/>. Visitado em 2024-11-01. [Citado na página 20]
- [98] Tom Christie. Home - Django REST framework, 2024. URL <https://www.django-rest-framework.org/>. Visitado em 2025-01-10. [Citado na página 20]
- [99] Ahmad Hayat Maki A. Create REST API using Django REST Framework | Django REST Framework Tutorial, November 2023. URL <https://medium.com/@ahmalope rs703/getting-started-with-django-rest-api-for-beginners-9c121a2ce0d3>. [Citado na página 20]
- [100] Use Roboflow Annotate | Roboflow Docs, October 2024. URL <https://docs.roboflow.com/annotate/use-roboflow-annotate>. [Citado na página 21]
- [101] Roboflow. Roboflow Annotate: Label Images Faster Than Ever, 2024. URL <https://roboflow.com/annotate>. Visitado em 2024-11-01. [Citado na página 21]
- [102] Joseph Nelson. What is Image Preprocessing and Augmentation?, January 2020. URL <https://blog.roboflow.com/why-preprocess-augment/>. [Citado na página 21]
- [103] Roboflow. Roboflow Pricing and Plans, 2024. URL <https://roboflow.com/pricing>. Visitado em 2024-11-01. [Citado na página 21]
- [104] Kinsta. O Que é MySQL? Uma Explicação Simples para Quem Está Começando, 2022. URL <https://kinsta.com/pt/base-de-conhecimento/o-que-e-mysql/>. Visitado em 2024-11-02. [Citado na página 21]
- [105] Oracle. What is MySQL?, 2024. URL <https://www.oracle.com/pt/mysql/what-is-mysql/>. Visitado em 2024-11-02. [Citado na página 21]
- [106] Foundation Blender. blender.org - Home of the Blender project - Free and Open 3D Creation Software, 2024. URL <https://www.blender.org/>. Visitado em 2024-11-05. [Citado na página 22]
- [107] Khronos Group. glTF - Runtime 3D Asset Delivery, December 2020. URL <https://www.khronos.org/glTF/>. Visitado em 2025-01-04. [Citado na página 22]
- [108] Thor Brigsted. Siccity/GLTFUtility, November 2024. URL <https://github.com/Siccity/GLTFUtility>. Data de publicação original: 2018-10-10. [Citado na página 22]
- [109] Newtonsoft. Json.NET - Newtonsoft, 2024. URL <https://www.newtonsoft.com/json>. Visitado em 2024-11-05. [Citado na página 22]
- [110] Magic Leap. Product Specifications, April 2024. URL <https://www.magicleap.com/hc/en-us/articles/7813913215373-Product-Specifications>. Visitado em 2025-01-09. [Citado na página 22]
- [111] D. Saravanakumar, B. Mohan, and T. Muthuramalingam. A review on recent research trends in servo pneumatic positioning systems. *Precision Engineering*, 49:481–492,

- July 2017. ISSN 0141-6359. doi: 10.1016/j.precisioneng.2017.01.014. URL <https://www.sciencedirect.com/science/article/pii/S0141635916302574>. [Citado na página 61]
- [112] SMC. WEB Catalog SMC CORPORATION, 2024. URL <https://www.smcworld.com/webcatalog/en-jp/air-cylinders/air-cylinders-square-cover/C96-C96SD-2-E/#detail>. Visitado em 2024-11-03. [Citado na página 61]
- [113] Jacob Solawetz. Train, Validation, Test Split for Machine Learning, September 2020. URL <https://blog.roboflow.com/train-test-split/>. [Citado na página 66]