



INSTITUTO POLITÉCNICO
DE VIANA DO CASTELO

ESTG

FLEX ICT – PLATAFORMA ROBÓTICA FLEXÍVEL E INTELIGENTE
PARA ICT LABORATORIAL

2025

Márcio Jorge Pereira Gama



INSTITUTO POLITÉCNICO
DE VIANA DO CASTELO

FLEX ICT – PLATAFORMA ROBÓTICA FLEXÍVEL E INTELIGENTE PARA ICT LABORATORIAL

Márcio Jorge pereira Gama

Escola Superior de Tecnologia e Gestão



INSTITUTO POLITÉCNICO
DE VIANA DO CASTELO

Márcio Jorge Pereira Gama

Flex ICT - Plataforma Robótica Flexível e Inteligente para ICT Laboratorial

Nome do Curso de Mestrado
Eletrónica e Eletrificação Automóvel

Trabalho efetuado sob a orientação do(s)
Professor Doutor Sérgio Ivan Lopes
Professor Emanuel António Carvalhido Lomba

Novembro de 2025

MEMBROS DO JÚRI

Presidente:

Professor Doutor Paulo Jorge Campos Costa

Professor Coordenador do Instituto Politécnico de Viana do Castelo

Vogal:

Doutor Daniel Filipe Albuquerque

Professor Adjunto da Escola Superior de Tecnologia e Gestão de Águeda,
Universidade de Aveiro

Vogal:

Doutor Sérgio Ivan Fernandes Lopes

Professor Coordenador do Instituto Politécnico de Viana do Castelo

AGRADECIMENTOS

A conclusão desta etapa formativa, materializada pelo presente trabalho de projeto de Mestrado, representa mais do que o cumprimento de um requisito académico. Foi uma jornada exigente que não seria possível sem o contributo inestimável de várias pessoas e instituições, a quem é justo dirigir o meu profundo agradecimento.

Este trabalho foi desenvolvido e materializado graças ao acolhimento e ao suporte técnico/científico do CiTin – Centro de Interface Tecnológico Industrial. A possibilidade de utilizar as suas infraestruturas e de integrar o projeto no contexto de investigação aplicada do seu ambiente de inovação foi decisiva para a validação prática da prova de conceito.

O projeto enquadra-se no WP3 da Agenda Drivolution - Transição para a Fábrica do Futuro (02/C05-i01.02/2022.PC644913740-00000022), tendo contribuído para o demonstrador “Flex ICT – Plataforma robótica flexível e inteligente para ICT laboratorial”. Este resultado emergiu de uma colaboração tripartida entre o Mestrado Profissional em Eletrónica e Eletrificação Automóvel do Instituto Politécnico de Viana do Castelo, o CiTin e o parceiro industrial BorgWarner Turbo & Thermal Technologies, evidenciando uma valiosa sinergia entre formação avançada, investigação aplicada e desenvolvimento industrial.

Direciono o meu reconhecimento aos meus Orientadores, Professor Doutor Sérgio Lopes e Professor Emanuel Lomba, pela orientação sábia, pela disponibilidade e pelo estímulo intelectual que foram fundamentais para a elaboração e desenvolvimento deste trabalho. A sua mestria foi um pilar incontornável neste percurso.

À equipa de *Test Warranty* da BorgWarner TTT, em especial ao Luís Amorim, pela disponibilização de recursos, partilha de conhecimento e apoio técnico essencial. Ao Nelson Pereira, pelo papel catalisador, tendo sido o obreiro do desafio inicial que motivou este desenvolvimento.

Por fim, e porque a base de todo o esforço repousa no seio pessoal, dirijo o meu agradecimento mais profundo. Aos meus Pais e Sogros, pelo apoio incondicional e por serem um porto de abrigo sempre presente. Um agradecimento singular à minha Esposa, cujo papel foi absolutamente decisivo. O seu apoio, assumindo

com total autonomia as responsabilidades da nossa família durante os meus longos períodos de dedicação, foi a base que me permitiu concentrar e perseverar. À nossa Filha, pela sua paciência e compreensão, esta conquista é, em grande medida, o reflexo do vosso carinho e contributo.

RESUMO

A indústria automóvel exige componentes eletrónicos de elevada fiabilidade, particularmente em sistemas críticos como os *High Voltage Coolant Heaters* (HVCH). Os processos tradicionais de teste *In-Circuit* (ICT) laboratorial enfrentam limitações de flexibilidade, custos elevados e longos prazos devido à necessidade de dispositivos de fixação personalizados para cada nova PCBA. Este projeto propõe e valida uma estação de teste automatizada e flexível, assente numa arquitetura modular que integra: um robô colaborativo para posicionamento de pontas de prova; um sistema de visão baseado em YOLOv8 para identificação automática das PCBAs; um conjunto de subsistemas e instrumentos de medição (microcontrolador ESP32, interface de comunicação Kvaser, módulo de relés, multímetro, fonte de alimentação) controlados via protocolos padrão: SCPI (para o multímetro), comunicação serial UART (para o ESP32) e o protocolo LIN (para a interface Kvaser), e uma aplicação central em Python. A rastreabilidade é garantida através de uma base de dados temporal InfluxDB e visualização em dashboards Grafana.

Os resultados demonstram a robustez da solução. O modelo YOLOv8 atingiu uma exatidão de 99,5% (mAP50), resolvendo as falsas identificações de algoritmos tradicionais como o SSIM. A validação da precisão das medições, comparando 20 medições automáticas com referência manual, apresentou diferenças relativas maioritariamente inferiores a 0,01%, com máximo de 0,03%. A análise de capacidade do processo (C_p/C_{pk}) confirmou a repetibilidade excecional, com valores de C_{pk} superiores a 1,67, classificando o processo como "Altamente Capaz" segundo referenciais industriais.

Este trabalho desenvolve e valida uma prova de conceito funcional para um paradigma de teste mais ágil e económico, eliminando a necessidade de dispositivos de fixação dedicados. A estação implementada reduz custos e tempos de *setup*, estabelecendo uma base sólida para a inspeção automática de múltiplas variantes de PCBAs na BorgWarner, contribuindo para a modernização dos processos de controlo de qualidade no contexto da Indústria 4.0.

PALAVRAS CHAVE: Printed Circuit Board Assemblies (PCBAs); flying probe test (FPT); Robótica colaborativa; Visão por computador; YOLOv8; Deep Learning; Análise de capacidade do processo (C_p/C_{pk}); Indústria 4.0; HVCH.

ABSTRACT

The automotive industry demands high-reliability electronic components, particularly in critical systems such as High Voltage Coolant Heaters (HVCH). Traditional laboratory In-Circuit Test (ICT) processes face limitations in flexibility, high costs, and long lead times due to the need for custom fixtures for each new PCBA. This project proposes and validates an automated and flexible test station based on a modular architecture that integrates: a collaborative robot for probe positioning; a vision system based on YOLOv8 for automatic PCBA identification; a set of measurement subsystems and instruments (ESP32 microcontroller, Kvaser communication interface, relay module, multimeter, power supply) controlled via standard protocols: SCPI (for the multimeter), UART serial communication (for the ESP32), and the LIN protocol (for the Kvaser interface); and a central Python application. Traceability is ensured through an InfluxDB time-series database and visualization in Grafana dashboards.

The results demonstrate the robustness of the solution. The YOLOv8 model achieved an accuracy of 99.5% (mAP50), overcoming the false identification issues of traditional algorithms such as SSIM. Validation of measurement accuracy, comparing 20 automatic measurements with a manual reference, showed relative differences mostly below 0.01%, with a maximum of 0.03%. Process capability analysis (Cp/Cpk) confirmed exceptional repeatability, with Cpk values exceeding 1.67, classifying the process as "Highly Capable" according to industry standards.

This work develops and validates a functional proof-of-concept for a more agile and cost-effective testing paradigm, eliminating the need for dedicated fixtures. The implemented station reduces costs and setup times, establishing a solid foundation for the automatic inspection of multiple PCBA variants at BorgWarner, contributing to the modernization of quality control processes in the context of Industry 4.0.

Keywords: Printed Circuit Board Assemblies (PCBAs); Flying Probe Test (FPT); Collaborative Robotics; Computer Vision; YOLOv8; Deep Learning; Process Capability Analysis (Cp/Cpk); Industry 4.0; HVCH.

LISTA DE ABREVIATURAS/SIGLAS/SÍMBOLOS

AC - Corrente Alternada

ADC - Analog-to-Digital Converter (Conversor Analógico-Digital)

CAD – Computer Aided Design (Desenho Assistido por Computador)

CiTIn - Centro de Interface Tecnológico Industrial

CNN - Convolutional Neural Network (Rede Neuronal Convolucional)

C_p - Índice de Capacidade do Processo

C_{pk} - Índice de Capacidade do Processo Ajustado

CSV - Comma-Separated Values (Valores Separados por Vírgulas)

CV - Computer Vision (Visão Computacional)

DC - Corrente Contínua

FCT - Functional Circuit Test (Teste Funcional de Circuito)

FFF - Fused Filament Fabrication (Fabrico por Fusão de Filamento)

FOV - Field of View (Campo de Visão)

FPT - Flying Probe Test (Teste de “Sonda” Móvel)

GUI - Graphical User Interface (Interface Gráfica do Utilizador)

HSS - High Side Switch

HVCH - High Voltage Coolant Heater

IGBT - Insulated-Gate Bipolar Transistor (Transístor Bipolar de Porta Isolada)

ICT - In-Circuit Test (Teste em Circuito)

ID - Identifier (Identificador)

IoU - Intersection over Union (Interseção sobre União)

IT - information technology (Tecnologia de Informação)

ISO/TS - International Organization for Standardization / Technical Specification
(Organização Internacional de Normalização / Especificação Técnica)

JSON - JavaScript Object Notation

LIN - Local Interconnect Network

LSS - Low Side Switch

LV - Low Voltage (Baixa Tensão)

mAP - mean Average Precision (Precisão Média)

MEEA - Mestrado em Engenharia Eletrotécnica e de Automação

ML - Machine Learning (Aprendizagem Automática)

MOPF - Medium Output Power Frame (Designação específica do produto em estudo)

NOK - Not OK (Não Conforme)

OK - OK (Conforme)

OT - Operation Technology (Tecnologia de Operação)

PCBA - Printed Circuit Board Assembly (Conjunto de Placa de Circuito Impresso)

PLA - Ácido Poliláctico

SCPI - Standard Commands for Programmable Instruments (Comandos Standard para Instrumentos Programáveis)

SSIM - Structural Similarity Index Measure (Medida de Índice de Similaridade Estrutural)

TCP/IP - Transmission Control Protocol/Internet Protocol (Protocolo de Controlo de Transmissão/Protocolo da Internet)

UI - User Interface (Interface do Utilizador)

YOLO - You Only Look Once (Arquitetura de deteção de objetos)

ÍNDICE

1	Introdução	1
1.1	Enquadramento e Descrição do Problema.....	2
1.2	Motivação	3
1.3	Contribuições.....	4
1.4	Objetivos.....	4
1.4.1	Objetivo Principal	4
1.4.2	Objetivos Específicos	5
1.5	Análise do Estado da Arte/Soluções Existentes	5
1.5.1	Testes In-Circuit (ICT) no Setor Automóvel	5
1.5.2	Robótica Colaborativa na Indústria	7
1.5.3	Automação de Medições Elétricas	9
1.5.4	Soluções Existentes e Limitações	10
1.5.5	Visão Computacional na Indústria.....	10
1.5.6	Machine Learning e o Paradigma das Redes Neurais	11
1.5.7	Algoritmos de Visão Artificial	12
1.5.7.1	O Algoritmo SSIM (Structural Similarity Index).....	12
1.5.7.2	YOLO	12
1.6	Conclusão.....	13
2	Desenvolvimento	15
2.1	Arquitetura conceptual	15
2.2	Decisões de Projeto	16
2.3	Hardware	19
2.3.1	Arquitetura Física	19
2.3.2	Sistema Eletrónico de Controlo e Aquisição	20
2.3.3	Interface de Comunicação Automóvel	23
2.3.4	Sistema de Comutação e Controlo de Baixo Nível	24
2.3.5	Estrutura Mecânica e Suportes	29
2.3.6	Dispositivos Sob Teste e Objetivos de Validação	38
2.4	Software	42
2.4.1	Firmware Esp32	43
2.4.1.1	Fluxo da Operação	44
2.4.2	Python	48

2.4.2.1	<i>Arquitetura Geral do Software</i>	49
2.4.2.2	<i>Organização e Sincronização de Dados</i>	55
2.4.2.3	<i>Resiliência Segurança Operacional</i>	57
2.4.3	Docker Desktop	59
2.4.3.1	<i>Docker Compose</i>	61
2.4.4	Grafana	63
2.4.4.1	<i>Arquitetura</i>	64
2.4.4.2	<i>Configuração e Personalização</i>	64
2.4.4.3	<i>Aplicação ao Caso de Estudo</i>	65
2.4.5	YOLOv8	67
2.4.5.1	<i>Limitações do SSIM e Transição para YOLOv8</i>	67
2.4.6	Bibliotecas e Ferramentas de Desenvolvimento	74
3	Resultados e Análise de Dados	76
3.1	Desempenho do Sistema de Visão	76
3.1.1	Desempenho do SSIM	76
3.1.2	Resultados do Modelo YOLOv8	77
3.1.2.1	<i>Resultados do Treino Inicial</i>	77
3.1.2.2	<i>Resultados do Treino com Dataset Expandido</i>	79
3.1.2.3	<i>Resultados por Classe</i>	79
3.1.2.4	<i>Comparação Numérica entre Modelos YOLOv8n e YOLOv8s</i>	80
3.1.2.5	<i>Resultados em Ambiente Operacional</i>	80
3.1.2.6	<i>Análise Estatística da identificação</i>	82
3.2	Precisão e Repetibilidade das Medições Elétricas	84
3.2.1	Validação do Sistema Automatizado vs. Método Manual	84
3.2.2	IGBTs PCBA 5.2KW	86
3.2.2.1	<i>Análise Estatística dos Resultados do IGBT1 (LSS)</i>	87
3.2.2.2	<i>Análise Estatística dos Resultados do IGBT2 (LSS)</i>	90
3.2.2.3	<i>Análise Estatística dos Resultados do IGBT3 (HSS)</i>	92
3.2.2.4	<i>Análise Estatística dos Resultados de valores de tensão</i>	94
3.2.3	IGBTs PCBA 8KW	96
3.2.3.1	<i>Análise Estatística dos Resultados do IGBT1 (HSS)</i>	97
3.2.3.2	<i>Análise Estatística dos Resultados do IGBT2 (HSS)</i>	98
3.2.3.3	<i>Análise Estatística dos Resultados do IGBT3 (HSS)</i>	100
3.2.3.4	<i>Análise Estatística dos Resultados do IGBT4 (LSS)</i>	101
3.2.3.5	<i>Análise Estatística dos Resultados do IGBT5 (LSS)</i>	102
3.2.3.6	<i>Análise Estatística dos Resultados do IGBT6 (LSS)</i>	104

3.2.3.7	<i>Análise Estatística dos Resultados de pontos de tensão bottom overlay..</i>	105
4	Discussão	108
4.1	Avaliação do Cumprimento dos Objetivos Propostos	108
4.2	Análise Comparativa com o Método Atual e Enquadramento no Estado da Arte.....	109
4.3	Limitações e Perspetivas de Trabalho Futuro	111
5	Conclusões.....	114

ÍNDICE DE FIGURAS

Figura 1 - Cama de agulhas ICT (SPEA).....	6
Figura 2 - Flying probe test (Matric. 2023).....	7
Figura 3 - Espaço de trabalho em ambiente colaborativo	8
Figura 4 - Robôs colaborativos Ingun em tarefas repetitivas e não ergonômicas. (Ingun).....	9
Figura 5 - Evolução do Yolo ao longo do tempo, (google Images)	13
Figura 6 - Arquitetura conceptual do projeto	15
Figura 7 - Layout físico do projeto.....	19
Figura 8 - Elite Robot EC-63, Controlador, Consola.....	20
Figura 9 - Multímetro Keithley DMM6500, (Keithley)	21
Figura 10 - Print recomendação retirado do documento de especificações da Borgwarner	21
Figura 11 - Características de medição do Keithley DMM6500, (Keithley)	21
Figura 12 - Fonte de alimentação Keithley 2231A-30-3, (Keithley)	22
Figura 13 - Interface Kvaser com conetores de alimentação e ligação ao PCBA	23
Figura 14 - Microcontrolador Esp32, (Google Images)	25
Figura 15 - Gráficos do comportamento do relé SRD 05VDC SL C, (Datsheet)	26
Figura 16 - Módulo 8 relés	28
Figura 17 - Esquema elétrico do módulo de relés. Esquema obtido do fabricante	28
Figura 18 - Bancada Covis-Cobot.....	29
Figura 19 - Base de posicionamento e fixação PCBAs em 3D	31
Figura 20 - Base de posicionamento e fixação PCBAs.....	31
Figura 21 - Base dedicada à fixação de PCBAs com duas referências.....	31
Figura 22 - Acopladores integradas no suporte e na base	33
Figura 23 – Suporte personalizado 3D	34
Figura 24 - Base desenvolvida pelo CiTin	34
Figura 25 - Camisa Ingun KS 100, (Ingun).....	34
Figura 26 - Agulha Ingun GKS 100 217, (Ingun).....	34
Figura 27 - Agulha Ingun GKS 100 288, (Ingun).....	35
Figura 28 – “Dual Gripper” completo.....	36
Figura 29 - Caixas de acoplamento Esp32 e Módulo de relés.....	38
Figura 30 - PCBA 8KW/PCBA 5.2KW da MOPF. (Borgwarner).....	38
Figura 31 - Exemplo HVCH, (Borgwarner)	39
Figura 32 - Tabela com alguns pontos de medição para verificar.....	40
Figura 33 - Fluxograma Firmware FlexICT	47
Figura 34 - Diagrama de blocos do firmware FlexICT.....	47
Figura 35 - Scripts em Python usados no projeto	49
Figura 36 - Arquitetura Geral do Software.....	49
Figura 37 - Robô em posição de identificação (Esq.), interface de identificação (Dir.).	50
Figura 38 – Informação no dashboard relacionado com a referência identificada	52
Figura 39 - Arquitetura geral para os programas de medição	52
Figura 40 - Pasta Histórico e PCBA_Capturas.....	53
Figura 41 - Informação das PCBAs identificadas	53
Figura 42 - Programas de medição.....	54
Figura 43 - Ficheiros CSV	57
Figura 44 - Exemplo Dashboard medição resistências.....	57
Figura 45 - Docker Desktop Containers.....	60
Figura 46 - Código do docker-compose.yml.....	61

Figura 47 - excerto do subprograma DockerDesktop.py	62
Figura 48 - Exemplo da querie e do Dashboard Gauge.....	65
Figura 49 - Caraterísticas de várias versões do YOLO, (Ultralytics).....	68
Figura 50 - Organização do dataset e distribuição dos ficheiros nas pastas train e Val	70
Figura 51 - Algumas imagens utilizadas no treino do modelo YOLOv8	70
Figura 52 - Pasta labels.....	71
Figura 53 - Código do ficheiro data.yaml	71
Figura 54 - Código utilizado no treino do modelo Yolo.....	72
Figura 55 - Resultado de um processo de treino, 15 épocas, modelo yolov8n.pt.....	72
Figura 57 - Classificação da PCBA 8KW com SSIM	76
Figura 56 - Classificação da PCBA 5.2KW com SSIM	76
Figura 58 - Fase de treino com 3 imagens e 30 épocas	78
Figura 59 - Resultado do treino com 3 imagens e 30 épocas	78
Figura 60 - PCBA de 5.2KW identificada como 8KW	79
Figura 61 - Resultado sem PCBA	81
Figura 62 - Resultado PCBA 5.2KW com taxa de precisão de 92.9%	81
Figura 63 - Resultado PCBA 8KW com taxa de precisão de 97.9%.....	81
Figura 64 - Resultado da análise feita ao sistema de visão deep learning (Google Colab).....	82
Figura 65 - IGBT RGS50TSX2DHR e RGS50TSX2DHR	86
Figura 66 - Resultado da análise ao IGBT1 5.2KW feita na plataforma Google Colab	89
Figura 67 – Exemplo dashboard medição aleatória IGBT1 no PCBA de 5.2KW	90
Figura 68 - Resultado da análise ao IGBT2 5.2KW (Google Colab).....	91
Figura 69 - Resultado da análise ao IGBT3 5.2KW (Google Colab).....	93
Figura 70 - Dashboard medição tensões em diversos pontos no PCBA de 5.2KW	94
Figura 71 - Resultado da análise às tensões PCBA de 5.2KW (Google Colab).....	95
Figura 72 - Test Points de serial debug (ficha técnica).....	96
Figura 73 - Resultado da análise ao IGBT1 8KW (Google Colab).....	97
Figura 74 - Resultado da análise ao IGBT2 8KW (Google Colab).....	99
Figura 75 - Resultado da análise ao IGBT3 8KW (Google Colab).....	100
Figura 76 - Resultado da análise ao IGBT4 8KW (Google Colab).....	101
Figura 77 - Resultado da análise ao IGBT5 8KW (Google Colab).....	103
Figura 78 - Resultado da análise ao IGBT6 8KW Google Colab	104
Figura 79 - Resultado da análise às medições de tensão na PCBA de 8KW (Google Colab)	106
Figura 80 - Dashboard com os valores medidos e com gráfico de histórico.....	107

ÍNDICE DE TABELAS

Tabela 1 - Arquitetura do Sistema Flex ICT: Camada OT.....	17
Tabela 2 - Arquitetura do Sistema Flex ICT: Camada IT	18
Tabela 3 - Arquitetura do Sistema Flex ICT: Flux.....	18
Tabela 4 – Principais Especificações Técnicas do Hardware do Sistema	22
Tabela 5 - Critérios de Seleção da Interface Kvaser LIN.....	24
Tabela 6 - Principais Especificações Técnicas do Sistema de Comutação e Controlo.....	29
Tabela 7 - Vantagens da Integração da Visão e Medição no End-Effector do Robô.....	33
Tabela 8 - Especificações Técnicas das Pontas de Prova (Tensões)	35
Tabela 9 - Especificações Técnicas das Pontas de Prova (Resistência/Díodo)	35

Tabela 10 - Critérios de Desenho das estruturas de alojamento	37
Tabela 11 - Vantagens da Fabricação Aditiva (Impressão 3D por FFF)	37
Tabela 12 - Características e Justificação da Seleção da Câmara	41
Tabela 13 - Fluxo Operacional do Script principal "Identificar_PCBA.py"	51
Tabela 14 - Especificação dos Módulos de Software da Camada de Aplicação	53
Tabela 15 - Resumo da Arquitetura e Configuração da Infraestrutura de Dados Contendorizada	66
Tabela 16 - Comparação técnica entre os modelos YOLOv8n e YOLOv8s*	73
Tabela 17 - Especificação das Principais Bibliotecas Python por Módulo Funcional	74
Tabela 18 - Especificação das Principais Bibliotecas Python por Módulo Funcional	75
Tabela 19 - Métricas de avaliação do modelo YOLOv8 no conjunto de validação.	79
Tabela 20 - Desempenho detalhado por classe do modelo YOLOv8.	80
Tabela 21 - Validação da Precisão do Sistema Automatizado MOPF 5.2KW	84
Tabela 22 - Validação da Precisão do Sistema Automatizado MOPF 8KW	85
Tabela 23 - 20 medições do IGBT1	88
Tabela 24 - Índices de Capacidade do Processo para o IGBT1	90
Tabela 25 - Índices de Capacidade do Processo para o IGBT2	92
Tabela 26 - Índices de Capacidade do Processo para o IGBT3	93
Tabela 27 - Índices de Capacidade do Processo para o IGBT1	98
Tabela 28 - Índices de Capacidade do Processo para o IGBT2	99
Tabela 29 - Índices de Capacidade do Processo para o IGBT3	101
Tabela 30 - Índices de Capacidade do Processo para o IGBT4	102
Tabela 31 - Índices de Capacidade do Processo para o IGBT5	103
Tabela 32 - Índices de Capacidade do Processo para o IGBT6	105
Tabela 33 - Tabela retirada da documentação técnica do MOPF 8KW	105
Tabela 34 - Síntese comparativa do cumprimento dos objetivos do projeto	108
Tabela 35 - Análise paradigmática: ICT tradicional vs. Flex ICT	109

ÍNDICE DE GRÁFICOS

Gráfico 1 - Yolov8n vs Yolov8s usando os valores reais de mAP50-95, Fonte: Ultralytics.....	80
Gráfico 2 - Gráficos estatísticos do sistema de visão deep learning, (Google Colab)	83
Gráfico 3 - Gráficos Cp e Cpk do IGBT1 5.2KW (Google Colab).....	89
Gráfico 4 - Gráficos Cp e Cpk do IGBT2 5.2KW (Google Colab).....	91
Gráfico 5 - Gráficos Cp e Cpk do IGBT2 5.2KW (Google Colab).....	92
Gráfico 6 - Gráficos das tensões em diversos pontos LV, 5.2KW (Google Colab)	94
Gráfico 7 - Gráficos Cp e Cpk do IGBT1 8KW (Google Colab)	98
Gráfico 8 - Gráficos Cp e Cpk do IGBT2 8KW (Google Colab).....	98
Gráfico 9 - Gráficos Cp e Cpk do IGBT3 8KW (Google Colab).....	100
Gráfico 10 - Gráficos Cp e Cpk do IGBT5 8KW (Google Colab).....	102
Gráfico 11 - Gráficos Cp e Cpk do IGBT5 8KW (Google Colab).....	102
Gráfico 12 - Gráficos Cp e Cpk do IGBT6 8KW (Google Colab).....	104
Gráfico 13 - Gráficos Cp e Cpk das medições de valores de tensão na PCBA de 8KW (Google Colab)	106

1 INTRODUÇÃO

Este relatório descreve o trabalho desenvolvido no âmbito da unidade curricular de Projeto/Estágio do Mestrado Profissional em Eletrónica e Eletrificação Automóvel do Instituto Politécnico de Viana do Castelo, inserido no contexto do *Work Package 3 da Agenda Drivolution* – Transição para a Fábrica do Futuro (Código de Operação 02/C05-i01.02/2022.PC644913740-00000022), financiada pelo Plano de Recuperação e Resiliência (PRR). A Agenda *Drivolution* tem como objetivo apoiar a transformação digital e a transição energética no setor automóvel, promovendo a criação de um modelo de Fábrica do Futuro capaz de integrar inovação tecnológica, eficiência produtiva e sustentabilidade industrial. Para tal, o projeto envolve múltiplas entidades académicas e industriais, fomentando a transferência de conhecimento, o desenvolvimento experimental e a aplicação prática de soluções tecnológicas avançadas em contexto industrial real.

Neste enquadramento, foi desenvolvido o demonstrador “Flex ICT – Plataforma robótica flexível e inteligente para ICT laboratorial”, resultado da colaboração entre o CiTin – Centro de Interface Tecnológico Industrial e o parceiro industrial *BorgWarner Turbo and Thermal Technologies*. A plataforma Flex ICT foi projetada para integrar soluções de automação inteligente e digitalização de processos em laboratórios de inspeção, controlo e teste (ICT), permitindo otimizar a flexibilidade operacional, aumentar a eficiência dos fluxos de trabalho e reforçar a robustez e a fiabilidade dos processos de ICT. Este trabalho contribui simultaneamente para o desenvolvimento de competências avançadas em eletrónica, instrumentação e integração de sistemas ciber-físicos no contexto industrial e para a implementação prática de conceitos relacionados com a Fábrica do Futuro, ao promover o desenvolvimento de investigação aplicada, formação especializada e inovação tecnológica em ambiente industrial.

Neste capítulo são apresentados, de forma sucinta, os tópicos fundamentais que enquadram e justificam o desenvolvimento do projeto realizado no âmbito do Mestrado em Eletrónica e Eletrificação Automóvel, incluindo a descrição do problema, a motivação, os objetivos gerais e específicos, bem como o contexto tecnológico que sustenta a sua relevância.

1.1 ENQUADRAMENTO E DESCRIÇÃO DO PROBLEMA

O setor automóvel, particularmente na vertente dos componentes eletrónicos, enfrenta atualmente o desafio de conciliar a crescente complexidade dos produtos com ciclos de desenvolvimento cada vez mais curtos e com exigências de qualidade extremamente rigorosas. Segundo Hornacek e Tanuska [1], a evolução para ambientes industriais inteligentes e interligados requer “métodos de inspeção preditiva e adaptativos que permitam reduzir o tempo de desenvolvimento e melhorar a rastreabilidade”.

Na *BorgWarner Turbo and Thermal Technology*, este desafio manifesta-se no processo de testes de medição rápidos e validação de Placas de Circuito Impresso (PCBAs), onde os métodos convencionais revelam limitações significativas em termos de eficiência, precisão e escalabilidade. O processo atual baseia-se no desenvolvimento de moldes físicos dedicados e na execução manual das medições elétricas, o que acarreta diversas fragilidades operacionais e económicas:

- **Inflexibilidade Operacional:** a dependência de moldes físicos, cujo fabrico é moroso e geralmente dependente de terceiros, impede uma resposta ágil a novas variantes de produto ou alterações de design [2].
- **Baixa Eficiência:** a natureza manual do processo torna-o lento e suscetível a variações entre colaboradores, limitando a produtividade e a consistência das medições.
- **Risco de Erro Humano:** a execução manual de medições repetitivas aumenta a probabilidade de falsos contactos, leituras incorretas e inconsistências nos resultados [4].
- **Custos Elevados:** o fabrico de moldes personalizados para cada PCBA representa um investimento significativo, tornando o processo pouco viável para lotes pequenos ou protótipos.

De acordo com Villani, Pini, Leali e Secchi (2018) [5], a robótica colaborativa, não apenas melhora a eficiência e a repetibilidade das tarefas, mas também permite a reconfiguração flexível dos processos produtivos. Face a este cenário, torna-se evidente a necessidade de uma solução de teste automatizada, modular e reconfigurável, capaz de eliminar as limitações do método tradicional e potenciar a

eficiência global do laboratório. Soluções que integram visão computacional, sistemas de medição inteligentes e robôs colaborativos representam o caminho mais promissor para alcançar tais objetivos.

1.2 MOTIVAÇÃO

A motivação deste projeto assenta em três pilares fundamentais: a necessidade industrial, a aplicação prática do conhecimento académico e o alinhamento com os princípios da Indústria 4.0.

Em primeiro lugar, a BorgWarner procura superar as limitações do processo de teste atual através do desenvolvimento de uma solução interna, ágil e reconfigurável, que permita realizar medições elétricas e funcionais em diferentes PCBAs sem necessidade de *hardware* dedicado (moldes específicos). Esta abordagem tem como objetivo reduzir custos, aumentar a fiabilidade e encurtar o tempo de resposta (*time-to-market*) [1][3].

Em segundo lugar, este projeto representa uma oportunidade de aplicar e desenvolver, de forma prática, conhecimentos adquiridos ao longo do Mestrado em Eletrónica e Eletrificação Automóvel, nomeadamente nas áreas de Sistemas Ciber-Físicos e indústria 4.0, Eletrónica digital e microcontroladores, Eletrónica de potência, Circuitos e sistemas de aquisição de dados, Fundamentos da eletrónica e Dados industriais e *analytics*. A integração destas disciplinas constitui um dos pilares tecnológicos da transição para sistemas de teste inteligentes, permitindo desenvolver soluções com maior autonomia e precisão.

Por fim, o projeto encontra-se totalmente alinhado com os princípios da Indústria 4.0, promovendo a digitalização, interligação e autonomia dos processos industriais. De acordo com GermanEdge [3], a implementação de sistemas inteligentes em ambientes de teste automóvel “reforça a capacidade de análise em tempo real e a rastreabilidade, pilares fundamentais para a competitividade do setor”. Assim, a criação de uma estação de teste automatizada, flexível e interligada demonstra um passo evolutivo claro na direção da transformação digital dos laboratórios de validação.

1.3 CONTRIBUIÇÕES

As principais contribuições deste trabalho são as seguintes:

Publicação científica:

M. Gama, E. Lomba, S. I. Lopes, “*Flex ICT – Flexible and intelligent robotic platform for laboratory ICT*”, 5th Symposium of Applied Science for Young Researchers (SASYR 2025), julho de 2025, Instituto Politécnico de Viana do Castelo, Viana do Castelo, Portugal. [65]

Comunicação em poster:

M. Gama, E. Lomba, S. I. Lopes, “*Flex ICT – Flexible and intelligent robotic platform for laboratory ICT*”, 5th Symposium of Applied Science for Young Researchers (SASYR 2025), julho de 2025, Instituto Politécnico de Viana do Castelo, Viana do Castelo, Portugal (Anexo 1).

Protótipo funcional de uma plataforma robótica flexível para ICT laboratorial, atualmente em demonstração nas instalações do CiTin – Centro de Interface Tecnológico Industrial.

1.4 OBJETIVOS

Face ao problema e motivação expostos, o presente trabalho define um objetivo principal desdobrado em objetivos específicos mensuráveis.

1.4.1 Objetivo Principal

Desenvolver, implementar e validar um protótipo funcional de uma estação de teste ICT baseada na metodologia *Functional Circuit Test* (FCT), para as PCBAs MOPF 5.2 kW e 8 kW da BorgWarner. A estação deve integrar de forma coesa um sistema de visão artificial para identificação, um robô colaborativo para manipulação, um sistema de medição automatizado e um *software* central de controlo, promovendo a flexibilidade, digitalização e autonomia características da Indústria 4.0.

1.4.2 Objetivos Específicos

Para cumprir o objetivo principal, foram estabelecidos os seguintes objetivos específicos:

- Projetar e fabricar a infraestrutura mecânica e de interface (pontas de prova personalizadas, base ajustável, invólucros) utilizando CAD e impressão 3D.
- Implementar um sistema de medição de grandezas elétricas automatizado e preciso, com integração de instrumentos via TCP/IP, LIN e USB.
- Integrar protocolos de comunicação híbrida (LIN, TCP/IP, USB serial) para gestão dos subsistemas e ativação das PCBAs.
- Programar trajetórias dinâmicas e adaptativas para o robô colaborativo Elite Robot EC-63, sincronizadas com o resultado da identificação visual.
- Desenvolver, treinar e avaliar um algoritmo de visão computacional, baseado em YOLOv8 para identificação robusta e rápida das PCBAs.
- Desenvolver uma aplicação modular em *Python* com interface gráfica, *dashboards* de monitorização e registo automático de dados.
- Validar o sistema global através de testes quantitativos de precisão, repetibilidade, velocidade e robustez nas PCBAs MOPF.

1.5 ANÁLISE DO ESTADO DA ARTE/SOLUÇÕES EXISTENTES

O presente capítulo tem como objetivo analisar e contextualizar os principais conceitos, tecnologias e soluções existentes relacionados com a proposta deste projeto, nomeadamente no âmbito dos testes elétricos ICT, da robótica colaborativa, das medições elétricas automatizadas e da programação de microcontroladores em placas de circuito impresso (PCBA). Esta revisão visa identificar o estado atual da tecnologia, as limitações dos métodos tradicionais e as oportunidades de inovação que fundamentam a relevância da solução proposta.

1.5.1 Testes In-Circuit (ICT) no Setor Automóvel

Os testes *in-circuit* constituem uma etapa fundamental na cadeia de produção de dispositivos eletrónicos, em particular na indústria automóvel, onde os requisitos de fiabilidade e conformidade são especialmente rigorosos [8]. O ICT permite verificar

componentes individuais numa placa de circuito impresso, como resistências, condensadores e díodos, além de assegurar a continuidade dos caminhos condutores e a correta programação de dispositivos lógicos, incluindo microcontroladores [9].

Tradicionalmente, os testes ICT são realizados através de sistemas de “cama de agulhas” (*bed-of-nails*), cf. Figura 1, que recorrem a uma matriz de pinos de teste adaptada a cada tipo de placa [10]. Embora eficazes, estes sistemas apresentam várias limitações:

- Baixa flexibilidade para variantes de PCBA;
- Custos elevados com dispositivos de fixação personalizados;
- Dificuldade de adaptação a mudanças rápidas na produção;
- Risco de danos físicos na placa ou nos componentes [11].

De acordo com Villani, Pini, Leali e Secchi (2018), “a evolução das tecnologias de teste e inspeção tem procurado responder às exigências de flexibilidade e segurança, integrando soluções mais adaptáveis e menos invasivas” [5]. Neste contexto, os desafios identificados impulsionaram a procura por alternativas mais versáteis, como o uso de *flying probes* [8], cf. figura 2 da página 7, mais recentemente, a integração de robôs colaborativos [14], que oferecem maior adaptabilidade e reduzem os riscos associados aos métodos tradicionais.



Figura 1 - Cama de agulhas ICT (SPEA)




Figura 2 - Flying probe test (Matric. 2023)

1.5.2 Robótica Colaborativa na Indústria

A origem da robótica colaborativa remonta a 1996, quando os professores J. Edward Colgate e Michael Peshkin, da Northwestern University (EUA), desenvolveram o primeiro protótipo de robô colaborativo. Inicialmente designados como máquinas de restrição programáveis, estes sistemas distinguiam-se pela sua abordagem passiva e segura, permitindo ao computador gerar superfícies de restrição para interação direta com o utilizador humano [14]. O termo *cobot* foi posteriormente introduzido por Brent Gillespie, sendo reconhecido pelo *Wall Street Journal* como uma das “palavras do futuro” em 2000. A primeira patente relacionada com esta tecnologia foi submetida em fevereiro de 1996, e uma segunda, já com a designação *cobot*, em outubro de 1997 [14].

Atualmente, os robôs colaborativos representam uma nova geração de sistemas industriais, caracterizados por serem seguros, versáteis e acessíveis. São amplamente utilizados em tarefas repetitivas e manuais, realizadas em colaboração com operadores humanos, sem necessidade de competências cognitivas avançadas ou tomada de decisão em tempo real [15]. Como refere Matthias e Thomas (2016), “a colaboração entre humanos e robôs abre novas oportunidades para aumentar a produtividade e a flexibilidade, ao mesmo tempo que garante elevados padrões de segurança” [16].

Uma das principais vantagens dos cobots é o seu funcionamento sem grades de proteção, o que permite apoiar diretamente os trabalhadores humanos sem grandes alterações nos *layouts* produtivos. Aplicações simples podem ser

implementadas de forma rápida e económica, sem necessidade de investimentos elevados em sistemas de segurança adicionais ou garras robóticas complexas [16].




Figura 3 - Espaço de trabalho em ambiente colaborativo

O conceito de *Human-Robot Collaboration* (HRC) descreve qualquer situação em que humanos e robôs partilham o mesmo espaço de trabalho, realizando tarefas combinadas num ambiente comum, cf. Figura 3. Esta abordagem elimina a separação rígida entre trabalho manual e automatizado, criando um espaço colaborativo integrado [17].

Na Figura 4, da página seguinte, observa-se um robô colaborativo da Ingun equipado com *gripper*, capaz de movimentar PCBAs para o dispositivo de fixação, abrir/fechar tampas e realizar medições diretamente sobre pontos de teste, assegurando precisão e repetibilidade [18]. No contexto específico dos testes ICT, os cobots podem ser equipados com ferramentas especializadas (pontas de prova, câmaras, ou alguma ferramenta de programação), posicionando-se com elevada precisão sobre pontos de teste e permitindo medições elétricas ou programação sem contacto físico permanente.

Estudos recentes demonstram que a integração de cobots em processos de teste elétrico reduz o tempo de *setup*, melhora a repetibilidade e aumenta a segurança do operador [19]. Fabricantes de renome, como Universal Robots, FANUC e KUKA, têm desenvolvido soluções modulares e programáveis, fortemente integradas em ambientes industriais digitais [20].



Figura 4 - Robôs colaborativos Ingun em tarefas repetitivas e não ergonômicas. (Ingun)

1.5.3 Automação de Medições Elétricas

A automação de medições elétricas constitui um elemento essencial para assegurar precisão, repetibilidade e rastreabilidade nos processos industriais. Instrumentos como multímetros digitais, osciloscópios e analisadores de redes podem ser integrados em sistemas automatizados através de interfaces normalizadas, como Comandos Standard para Instrumentos Programáveis (SCPI), USB, GPIB ou Ethernet [21].

Adicionalmente, linguagens de programação como *Python* permitem o controlo remoto dos instrumentos, a aquisição de dados em tempo real e a geração automática de relatórios, potenciando a eficiência e a fiabilidade dos testes [22]. A integração destes sistemas com robôs colaborativos representa um salto qualitativo, ao permitir a execução de medições elétricas de forma totalmente automatizada e com elevada repetibilidade. Como referem Maurtua et al. (2017), “a colaboração entre humanos e robôs em ambientes industriais abre novas oportunidades para aumentar a produtividade e a flexibilidade, mantendo elevados padrões de segurança” [23].

1.5.4 Soluções Existentes e Limitações

Algumas soluções comerciais procuram responder a estas necessidades, como os sistemas de teste com *flying probes* (ex.: Takaya, SPEA) ou os sistemas robóticos que integram câmaras e visão computacional [24]. No entanto, estas soluções apresentam limitações relevantes: custos elevados, baixa acessibilidade para pequenas e médias empresas e dificuldade de reconfiguração em ambientes de produção dinâmicos.

As principais lacunas identificadas incluem:

- Ausência de sistemas modulares e reconfiguráveis para diferentes tipos de PCBAs;
- Integração limitada entre robótica colaborativa e *software* de teste;
- Escassez de soluções abertas e acessíveis para programação *in-line* de microcontroladores;
- Dificuldade em criar interfaces homem-máquina intuitivas para operadores com reduzida formação técnica.

1.5.5 Visão Computacional na Indústria

A visão computacional emergiu como uma das tecnologias mais transformadoras no contexto da automação industrial, desempenhando um papel central em tarefas como inspeção de qualidade, movimentação robótica e controlo de processos [25]. Os primeiros sistemas de visão industrial baseavam-se em algoritmos clássicos de processamento de imagem, como a deteção de bordos, a transformada de Hough e a segmentação por limiarização [25].

Embora eficazes em ambientes controlados, estas abordagens revelaram limitações significativas perante a variabilidade dos cenários reais. Alterações subtis na iluminação, pequenas rotações ou oclusões parciais dos objetos eram suficientes para comprometer a fiabilidade dos sistemas [25].

Segundo De Ketelaere et al. (2017), “a visão computacional industrial evoluiu rapidamente de sistemas baseados em regras fixas para abordagens orientadas por dados, capazes de lidar com maior diversidade de produtos e condições

ambientais” [28]. A introdução de câmaras digitais de alta resolução e técnicas tridimensionais contribuiu para mitigar algumas destas limitações, embora com maior complexidade e custo de implementação [29].

A integração da visão computacional com os paradigmas da Indústria 4.0 trouxe novos desafios e oportunidades, como sistemas de inspeção adaptativos, monitorização em tempo real e interoperabilidade entre robôs, sensores e algoritmos de análise visual [28][29].

1.5.6 Machine Learning e o Paradigma das Redes Neurais

A transição para abordagens baseadas em *Machine Learning* (ML) representou um marco na evolução da visão computacional industrial. Ao contrário dos métodos clássicos, baseados em regras explícitas, os algoritmos de ML aprendem padrões a partir de grandes volumes de dados, permitindo generalizar para novos contextos [26][27].

Entre as diferentes técnicas de ML, as Redes Neurais Convolucionais (CNNs) destacaram-se pela sua eficácia em tarefas de análise visual. Inspiradas no funcionamento do córtex visual humano, as CNNs aprendem hierarquicamente desde características de baixo nível (bordos, texturas) até representações de alto nível (formas complexas e objetos inteiros) [26].

Segundo Wu et al. (2019), as CNNs foram determinantes para o avanço de aplicações industriais em que a eficiência e a latência são críticas, possibilitando o reconhecimento visual em tempo real com elevada precisão [27]. Estas características tornaram as CNNs particularmente adequadas para inspeção visual, classificação de produtos e deteção de anomalias [27].

No contexto da Indústria 4.0, o *deep learning* integra-se em sistemas ciber-físicos, potenciando a ligação entre o mundo físico e o digital [28][29].

1.5.7 Algoritmos de visão artificial

1.5.7.1 O Algoritmo SSIM (Structural Similarity Index)

Desenvolvido por Wang et al. (2004), o SSIM é uma métrica amplamente utilizada para medir a similaridade perceptual entre duas imagens, indo além de simples diferenças de pixels ao incorporar informações sobre a estrutura luminositade, contraste e estrutura da imagem [6]. O índice produz um valor entre -1 e 1, onde 1 indica uma perfeita semelhança estrutural. A sua popularidade deve-se à sua maior correlação com a percepção humana de qualidade de imagem quando comparado com métricas tradicionais como o Erro Quadrático Médio (MSE) ou o Pico de Relação Sinal-Ruído (PSNR) [6]. A sua implementação é acessível através de bibliotecas modernas de processamento de imagem, como o *OpenCV*.

1.5.7.2 YOLO

No domínio da deteção de objetos, várias arquiteturas foram propostas ao longo da última década, como R-CNN e SSD. Contudo, a série YOLO (*You Only Look Once*) destacou-se pela sua combinação ímpar de precisão e velocidade, atributos fundamentais para aplicações em tempo real [30]. O YOLO é um dos algoritmos mais reconhecidos e utilizados em deteção de objetos em tempo real, sendo amplamente aplicado em contextos de visão computacional, automação industrial e robótica [29]. A sua principal inovação consiste na capacidade de realizar a deteção e a classificação de objetos numa única etapa, ao contrário de abordagens anteriores que dependiam de fases separadas de proposta de regiões e classificação [30].

O modelo YOLO trata o problema de deteção como uma tarefa de regressão, dividindo a imagem em grelhas e prevendo, para cada célula, as coordenadas das caixas delimitadoras (*bounding boxes*), a probabilidade de deteção e as classes correspondentes [30]. Esta abordagem permite uma execução extremamente rápida, o que torna o YOLO particularmente adequado para aplicações que exigem processamento em tempo real, como a inspeção automática de componentes eletrónicos, sistemas de vigilância e controlo robótico [1] [32].

Desde o seu lançamento inicial, o YOLO evoluiu significativamente, passando por diversas versões, cf. Figura 5, - YOLOv2, YOLOv3, YOLOv4, YOLOv5, YOLO X, YOLO R, YOLOv6, YOLOv7, YOLOv8, YOLO NAS, YOLOv9, YOLO v10 e YOLOv11 - cada uma introduzindo melhorias na precisão, velocidade e eficiência de inferência [7] [31]. O avanço contínuo do algoritmo reflete o interesse da comunidade científica e industrial em soluções de visão artificial que conciliem desempenho e aplicabilidade prática [28].




Figura 5 - Evolução do Yolo ao longo do tempo, (google Images)

1.6 CONCLUSÃO

A evolução da automação industrial tem sido marcada pela integração progressiva de tecnologias de teste elétrico automatizado, robótica colaborativa e visão computacional. Os métodos clássicos de inspeção, como ICT e *flying probe*, continuam relevantes, mas apresentam limitações em termos de custo, flexibilidade e acessibilidade para pequenas e médias empresas.

A introdução dos cobots trouxe uma nova dimensão, permitindo colaboração segura entre humanos e robôs, com aplicações crescentes em processos de teste e montagem. Paralelamente, a automação de medições elétricas com interfaces normalizadas (SCPI, GPIB, Ethernet) e linguagens como *Python* reforça a rastreabilidade e a repetibilidade dos processos.

No campo da visão computacional, a transição de algoritmos clássicos para abordagens baseadas em ML e CNNs aumentou a robustez e adaptabilidade dos

sistemas, tornando-os capazes de lidar com variabilidade ambiental e exigências de produção em tempo real. A integração destes métodos em paradigmas da Indústria 4.0 potencia sistemas ciber-físicos inteligentes e adaptativos.

Finalmente, arquiteturas modernas de detecção de objetos, como a família YOLO, consolidaram-se como soluções altamente competitivas, combinando velocidade e precisão. O YOLOv8, em particular, destaca-se pela capacidade de detecção, segmentação e rastreamento em tempo real, tornando-se uma ferramenta estratégica para inspeção visual de PCBAs e integração com robótica colaborativa.

2 DESENVOLVIMENTO

2.1 ARQUITETURA CONCEPTUAL

A arquitetura conceptual da plataforma FLEX ICT, cf. Figura 6, foi desenvolvida com o objetivo de materializar os requisitos funcionais identificados no capítulo anterior, garantindo uma separação clara entre os domínios da operação, *Operation Technology* (OT) e da informação, *Information Technology* (IT). Esta distinção, inspirada nos princípios da Indústria 4.0, estabelece um sistema ciber-físico baseado em modularidade de modo a facilitar a sua manutenção, escalabilidade e integração com outras soluções laboratoriais.




Figura 6 - Arquitetura conceptual do projeto

2.2 DECISÕES DE PROJETO

Centralização do Controlo em *Software* (IT) sobre uma Plataforma Única (*Python*): Desenvolver um *software* de controlo central em *Python* para coordenar todos os subsistemas. Esta abordagem elimina a dependência de hardware dedicado e permite a reconfiguração via *software* para diferentes PCBAs, atendendo ao requisito de flexibilidade.

Robótica Colaborativa: Optou-se por um robô colaborativo (cobot) em vez de sistemas de *flying probes* ou *bed-of-nails*. O cobot oferece a precisão necessária, segurança para operação sem barreiras, e, sobretudo, a reprogramabilidade que permite adaptar trajetórias e pontos de teste a novos produtos sem alterações de hardware [5].

Visão Computacional Baseada em *Deep Learning* (YOLOv8): Para superar as limitações de sensores físicos ou métodos de visão clássicos (ex: SSIM) perante variações, escolheu-se o algoritmo YOLOv8. A sua capacidade de generalização e velocidade de inferência em tempo real permite uma identificação robusta das PCBAs, que é o *trigger* para a seleção da sequência de testes correta [7, 32].

Comunicação Baseada em Protocolos Padronizados e Abertos: A arquitetura de comunicação foi definida com base em protocolos padrão da indústria (TCP/IP para comando, SCPI para instrumentos [64], LIN para o dispositivo sob teste). Esta escolha garante interoperabilidade, facilidade de manutenção e a substituição futura de componentes [19, 21].

Separação Clara entre Camadas OT e IT com Integração Definida: Delineou-se uma separação arquitetural onde a camada OT (robô, instrumentos, ESP32) executa as ações físicas, e a camada IT (aplicação *Python*, base de dados) gere a lógica, os dados e a tomada de decisão. A integração é feita através de APIs bem definidas (sockets, HTTP), promovendo modularidade.

Gestão de Dados Orientada à Indústria 4.0: Decidiu-se implementar um pipeline de dados completo, desde a aquisição até à visualização, utilizando tecnologias específicas para séries temporais (InfluxDB) e dashboards (Grafana), contentorizados via *Docker Desktop*. Isto assegura rastreabilidade, análise em tempo real e suporte a decisões baseadas em dados.

As Tabelas 1, 2 e 3, apresentam detalhadamente cada componente, a sua função principal, os protocolos de comunicação utilizados e a sua localização no sistema, fornecendo uma visão completa e estruturada da solução desenvolvida.

Tabela 1 - Arquitetura do Sistema Flex ICT: Camada OT

Camada	Componente / Subsistema	Função Principal no Sistema	Protocolo / Interface de Comunicação	Localização / Execução
CAMADA OT	Robô Colaborativo (Cobot)	Atuador de precisão; posiciona as pontas de prova (ICT Needles) acopladas ao acoplador nos pontos de teste do PCBA	TCP/IP (Ethernet)	Estação Física
	Sistema de Visão (Câmara)	Sensor de imagem; captura a imagem do PCBA para identificação	USB	Montada no robô/Ligada ao computador central
	ICT Measurement Equipment (ex: Multímetro)	Instrumento de medição; executa as medições elétricas (tensão, resistência) nos pontos de teste	SCPI (via TCP/IP) [64]	Bancada de Instrumentos
	Módulo de Relés	Comutador de baixo nível; direciona os sinais de medição entre o instrumento e as pontas de prova corretas	GPIO (controlado pelo ESP32)	Caixa de Interface
	MCU ESP32	Controlador de campo inteligente; gere o módulo de relés, controlando as sequências de medição	TCP/IP (Ethernet, operação) / USB (manutenção)	Caixa de Interface
	Interface Kvaser LIN	Ponte de comunicação; estabelece ligação com o barramento LIN do PCBA para manter o MCU em modo ativo	LIN (para PCBA) / USB (para PC)	Ligada ao computador central

Tabela 2 - Arquitetura do Sistema Flex ICT: Camada IT

Camada	Componente / Subsistema	Função Principal no Sistema	Protocolo / Interface de Comunicação	Localização / Execução
CAMADA IT	Software de controlo (Phyton)	Cérebro do sistema, gere toda a sequência de testes, processa dados de visão e comanda todos os subsistemas	(Aplicação Central)	Computador Central
	YOLOv8	Algoritmo de <i>deep learning</i> ; identifica automaticamente o modelo da PCBA a partir da imagem capturada	(Biblioteca Python)	Computador Central
	Infraestrutura de Dados (Docker Desktop)	Ambiente de virtualização; gere e executa os serviços de dados em <i>containers</i>	<i>Docker Engine</i>	Computador Central
	Container: InfluxDB	Base de dados de séries temporal; armazena todas as medições, eventos e <i>timestamps</i> do sistema	API HTTP / Browser Web	Docker (Computador Central)
	Container: Grafana	Plataforma de visualização; fornece os Dashboards FLEX ICT para monitorização em tempo real e análise	API HTTP / Browser Web	Docker (Computador Central)
	Interface com o Utilizador	Permite o controlo, visualização de dados e tomada de decisão	GUI <i>Python</i> e <i>Web Interface</i> (Grafana)	Computador Central

Tabela 3 - Arquitetura do Sistema Flex ICT: Flux

Fluxo	Componente / Subsistema	Função Principal no Sistema	Protocolo / Interface de Comunicação	Localização / Execução
FLUXOS DO SISTEMA	Fluxo de Sinal (Setas Vermelhas)	Representa o caminho físico do sinal de medição, desde o instrumento, através das pontas de prova, até ao PCBA sob teste.		Caminho Elétrico / Físico
	Fluxo de Dados (Setas Azuis)	Representa a trajetória da informação digital, desde os equipamentos de medição (OT) até ao processamento, armazenamento e visualização (IT).	Vários (TCP/IP, HTTP, etc.)	Rede e <i>Software</i>

2.3 HARDWARE

Este capítulo descreve detalhadamente o desenvolvimento da componente física do sistema, desde a concepção mecânica até à integração final de todos os componentes eletrónicos. Serão apresentadas as escolhas de componentes, critérios de seleção, desenhos mecânicos e esquemas de ligação elétrica que materializam a arquitetura proposta.

2.3.1 Arquitetura física

A estação de teste foi criada como um sistema integrado onde a precisão mecânica e a robustez eletrónica são fundamentais. A figura 7, ilustra o espaço físico, organizado para otimizar o fluxo de trabalho:



Figura 7 - Layout físico do projeto

Zona de Entrada:

Onde o colaborador coloca as PCBAs na base.

Zona de Teste:

Área de interação do cobot com os equipamentos de medição.

Zona de Controlo:

Computador central e equipamentos de medição.

2.3.2 Sistema Eletrônico de Controle e Aquisição

O sistema de medição elétrica, controle e aquisição foi projetado para desempenhar o papel central de coordenação no projeto, funcionando de forma análoga a um “sistema nervoso”, ao gerir de modo autónoma e segura a sequência de medições elétricas em PCBAs. A arquitetura de *hardware*, cf. Figura 7, é constituída por um conjunto de módulos interligados, responsáveis por funções específicas de controlo, alimentação, medição e comutação. A seleção dos respetivos componentes foi realizada com base em critérios de precisão, fiabilidade, integrabilidade e custo-benefício e disponibilidade de uso no CiTin.

- **Computador Central**

O computador central constitui o núcleo do sistema, executando o *software* de gestão desenvolvido em *Python*. Este programa coordena todas as operações de alto nível, incluindo a comunicação TCP/IP com o robô colaborativo, a configuração remota dos instrumentos de medição via rede e o controlo da sequência de testes automatizados através do ESP32.

- **Robô colaborativo (Elite Robot EC-63)**

O robô colaborativo EC-63, constitui o principal atuador do sistema, responsável pelo posicionamento preciso do *efetor final* - composto por “Dual Gripper” com o suporte de acoplamentos das pontas de prova - sobre diferentes pontos do PCBA em teste, e da câmara de visão que nos permite garantir, com elevada fiabilidade, a identificação correta do PCBA a testar.



Figura 8 - Elite Robot EC-63, Controlador, Consola

- **Multímetro Digital (Keithley DMM6500)**

O multímetro digital é o principal instrumento de medição do sistema, responsável pela aquisição de parâmetros elétricos de elevada precisão. O modelo Keithley DMM6500 é o equipamento referenciado no documento de instruções e especificações de testes ICT e FCT pela BorgWarner, ver figura 10. É um equipamento caracterizado pela elevada resolução (até 6,5 dígitos), pela rapidez de amostragem e pela ligação Ethernet nativa, que permite o controlo remoto e a integração direta na rede de instrumentos. Estas características garantem a fiabilidade metrológica dos dados adquiridos, assegurando medições consistentes e rastreáveis, fundamentais em processos de validação de PCBAs.



Figura 9 - Multímetro Keithley DMM6500, (Keithley)

- **FCT-2 Equipment:**

- **HV voltage measurement.** Recommended equipment: **Keithley DMM6500** or Keysight 34465a
 - Range: more than: 1000 V.
 - Sampling Rate > 50Ksps.
 - Accuracy: less than $\pm (0.009\% \text{ of Measurement} + 0.08 \text{ V})$.

Figura 10 - Print recomendação retirado do documento de especificações da Borgwarner




Figura 11 - Características de medição do Keithley DMM6500, (Keithley)

- **Fonte de Alimentação de Bancada (Keithley 2231A-30-3)**

A fonte de alimentação fornece energia regulada e estável ao PCBA sob teste, reproduzindo as condições reais de funcionamento do circuito durante as medições. O modelo Keithley 2231A-30-3, disponibiliza três canais independentes, permitindo alimentar simultaneamente diferentes pontos de tensão (por exemplo, 3.3 V, 5 V e 12 V), no entanto para o nosso objetivo apenas usamos um canal com 13V DC.



Figura 12 - Fonte de alimentação Keithley 2231A-30-3, (Keithley)

A Tabela 4 apresenta, de forma sintetizada, as principais especificações técnicas dos componentes de hardware que integram a estação de teste.

Tabela 4 – Principais Especificações Técnicas do Hardware do Sistema

Componente	Modelo	Caraterísticas técnicas	Interface de comunicação
Computador Central	Lenovo Ideapad 3	CPU: Intel Core i7-1165G7 (2.8 GHz) RAM: 8 GB Armazenamento: 512 GB SSD NVMe)	Ethernet, USB
Robô Colaborativo	Elite Robot EC-63	Nº de Eixos: 6 Carga útil: 6 kg Alcance: 917 mm Precisão de repetibilidade: ± 0.03 mm Faixa de movimento (por eixo): J1: $\pm 360^\circ$ / J2: $\pm 360^\circ$ / J3: $\pm 160^\circ$ / J4: $\pm 360^\circ$ / J5: $\pm 360^\circ$ / J6: $\pm 360^\circ$ Certificações: CE, ISO 10218-1	Ethernet TCP/IP (API PYTHON)
Multímetro	Keithley DMM6500	Resolução: resistência $1\mu\Omega$ Dígitos: $6\frac{1}{2}$ Funções de medida: Período, Resistência, Frequência, Capacitância, Continuidade, Tensão DC, Temperatura, Tensão AC, Díodo, Corrente AC, Corrente DC Tensão DC máx: 1010V Frequência Máx: 300KHZ	Ethernet (SCPI via Sockets / VISA)
Fonte de Alimentação	Keithley 2231A-30-3	Canais: 3 (2x 30V/3A, 1x 6V/5A) Resolução programação: 1 mV / 0.1 mA Precisão DC: 0.03% + 3 mV	N/A

2.3.3 Interface de Comunicação Automóvel

A interface **Kvaser**, Leaf V3, cf. Figura 13, foi integrada no sistema, mediante critérios de seleção, cf. Tabela 5, com uma função dupla: atuar como nó mestre na rede LIN e servir como mecanismo *keep-alive* para o microcontrolador da PCBA em teste. A sua principal tarefa é enviar uma mensagem "*wake-up*" repetidamente e gerir o tráfego LIN. Este estímulo contínuo mantém o microcontrolador no estado operacional "acordado" durante toda a sequência de testes automatizada. Sem ele, o microcontrolador entraria num modo de *standby* de baixo consumo, o que impediria as medições de tensão na secção LV e invalidaria os testes funcionais (FCT),

Durante o ciclo de teste, o computador central, através de um *script Python*, comanda a interface Kvaser. Esta configura-se como Mestre LIN a 19200 bps, gera uma *frame* de "*wake-up*" e mantém a comunicação periódica. Desta forma, impede-se que o microcontrolador entre em modo de baixo consumo. De acordo com a documentação [34], o protocolo LIN é amplamente utilizado em aplicações da indústria automóvel para funções secundárias. O conector D-SUB de 9 pinos padrão permite uma ligação robusta. Assim, o Kvaser não é um mero instrumento de teste passivo, mas um componente ativo e indispensável para a validação funcional do PCBA sob teste.



Figura 13 - Interface Kvaser com conetores de alimentação e ligação ao PCBA

Tabela 5 - Critérios de Seleção da Interface Kvaser LIN

Critério de Seleção	Caraterística Técnica	Justificação
Conformidade com Standards Automóveis	Cumprimento das especificações elétricas e de <i>timing</i> do protocolo LIN [34]	Garante comunicação determinística e fiável, essencial para sistemas da indústria automóvel [34]
Compatibilidade de Sistema Operativo	Suporte nativo e drivers estáveis para Windows 11 (x64) [34]	Assegura uma instalação e operação estáveis no computador central do sistema
Desempenho de Comunicação	Operação entre 1 a 20 kbit/s (gama LIN) e capacidade de 20.000 mensagens/s [33] [34]	Cobre a faixa típica do protocolo, sendo mais do que suficiente para a função de <i>keep-alive</i> sem criar estrangulamentos
Robustez para Ambiente Industrial	Temperatura de operação: -40 °C a 85 °C [33]	Confere ampla margem de segurança para operação fiável em ambiente de laboratório ou produção
Isolamento Galvânico	Isolamento elétrico integrado entre a interface e o sistema anfitrião [33]	Protege o computador central e o hardware de teste de picos de tensão da PCBA, aumentando a robustez e segurança do sistema [33]

2.3.4 Sistema de Comutação e Controlo de Baixo Nível

- **Microcontrolador (ESP32)**

O microcontrolador ESP32, cf. Figura 14, atua como interface de controlo periférico, responsável por executar as instruções recebidas do computador central e comandar o módulo de relés. Através deste controlo, efetua-se a comutação automática dos caminhos de sinal entre os instrumentos de medida e os diferentes pontos do PCBA. Neste microcontrolador é carregado o *firmware* que incorpora todas a lógicas de medição necessárias para automação de todo o processo de medição.

A escolha do ESP32 foi motivada pela sua combinação de baixo custo, a ligação Wi-Fi integrada - que reduz a cablagem e simplifica a instalação - e desempenho suficiente para as tarefas de controlo requeridas, e por ser o microcontrolador sobre o qual lecionamos em várias cadeiras do mestrado. A ampla comunidade de suporte e a disponibilidade de bibliotecas de desenvolvimento robustas contribuíram para acelerar a implementação do *firmware* de controlo, garantindo fiabilidade e facilidade de manutenção.




Figura 14 - Microcontrolador Esp32, (Google Images)

• Módulo de Relés

O módulo de relés, cf. Figura 16 na página 28, atua como matriz de comutação elétrica. O seu propósito é isolar o circuito de controlo (ESP32) dos circuitos de potência e sinal. Permite selecionar, de forma segura e automatizada, as ligações entre as pontas de prova, os pontos de teste do PCBA e o multímetro. Isto garante flexibilidade e proteção durante os testes. O módulo de 8 canais (JQC-3FF-S-Z / SRD-05VDC-SL-C) foi selecionado pela sua compatibilidade com os requisitos do sistema, medições de resistência entre 7kΩ e 20MΩ (sem alimentação), tensões até 13V DC e correntes de comutação até 0,08A. Cada relé do módulo tem uma capacidade nominal de 30V DC / 10A e 250V AC / 10^a, cf. Tabela 9 na página 29. Estes limites estão muito acima dos requisitos operacionais, fornecendo uma margem de segurança substancial contra picos, tornando o relé eletricamente adequado [35].

Adicionalmente, o módulo integra transístores driver e opto-acopladores, cf. Figura 17 na página 28. Inclui também a opção de separar logicamente a alimentação das bobinas (JD-VCC) da lógica de controlo (VCC), removendo um *jumper*, tendo sido esta a configuração adotada. Com o *jumper* retirado, obtém-se um isolamento galvânico entre o ESP32 e as bobinas, reduzindo as interferências e protege o

microcontrolador durante a comutação. Tal prática é recomendada em sistemas embebidos para aumentar a robustez e reduzir o ruído elétrico [36].




Figura 15 - Gráficos do comportamento do relé SRD 05VDC SL C, (Datasheet)

Avaliação com base nos gráficos do datasheet

A análise dos gráficos, cf. Figura 15, caraterísticos do relé SRD-05VDC-SL-C, fornecidos pelo fabricante, revela-se indispensável para uma compreensão aprofundada do seu comportamento sob diferentes condições operacionais. O sistema, que executa sequências de medição de resistência e queda de tensão em díodos com o circuito sob teste sem alimentação, operando com tensões até 13V DC e correntes máximas de 0,08A, impõe boas condições operacionais ao relé.

O gráfico de **Expectativa de Vida Útil (Life Expectancy)** em função da **Corrente de Carga** demonstra que a durabilidade do relé é maximizada quando operado

significativamente abaixo da sua capacidade nominal de 10A [38]. Na presente aplicação, a corrente de comutação de 0,08A situa-se numa região do gráfico associada a uma degradação negligível dos contactos, assegurando uma vida operacional extremamente longa. Adicionalmente, a natureza puramente resistiva e de baixa energia dos circuitos de medição elimina praticamente os fenómenos de erosão por arco eléctrico, tipicamente associados a cargas indutivas ou com correntes iniciais significativas.

O gráfico de **Elevação de Temperatura da Bobine (*Coil Temperature Rise*)** indica que, para a potência nominal da bobine (aproximadamente 0.36W a 5V DC), o aumento de temperatura em regime estacionário é mínimo. Este facto, conjugado com a natureza intermitente das sequências de medição (que não implicam uma operação contínua e sustentada do relé), garante que a bobine não sofrerá sobreaquecimento, preservando a integridade do seu isolamento e a estabilidade dos parâmetros eléctricos ao longo do tempo.

Os diagramas de **Tempo de Operação e de Repouso**, da ordem dos milissegundos, são amplamente compatíveis com a velocidade de comutação exigida pelas sequências de medição [37]. Uma vez que o sistema não requer comutações de alta velocidade ou sincronismos temporais críticos, os atrasos inerentes ao relé não constituem um fator limitante para a precisão ou funcionalidade do equipamento de teste.

Em síntese, a análise cruzada dos parâmetros gráficos do relé — vida útil, elevação térmica e tempos de comutação - com as condições específicas da aplicação (baixa corrente, carga resistiva, operação intermitente) valida inequivocamente a sua seleção. O componente trabalha dentro de uma margem de segurança substancial, garantindo não só o correto funcionamento imediato, mas também uma fiabilidade robusta a longo prazo para o sistema de medição automática [39].

Riscos identificados e medidas de mitigação (implementadas)

- **Corrente de fuga / *leakage (off-state)***: medições na faixa dos 655KΩ dependem do nível de fuga dos contactos. Para minimizar erros:
 - Realizou-se o isolamento galvânico entre lógica e bobines (*jumper* retirado).

- Ruído e transientes na comutação: após cada comutação aguarda-se cerca de 0.5s, dependendo se a alteração for para medição da mesma grandeza elétrica




Figura 16 - Módulo 8 relés




Figura 17 - Esquema elétrico do módulo de relés. Esquema obtido do fabricante

Tabela 6 - Principais Especificações Técnicas do Sistema de Comutação e Controle

Componente	Modelo	Características técnicas
Microcontrolador	ESP32 (DevKit / ESP-WROOM-32)	Arquitetura: Dual-core Xtensa LX6 (até 240 MHz) Memória: 520 KB SRAM, 4 MB Flash (tip.) Conectividade: Wi-Fi 802.11 b/g/n, Bluetooth 4.2, Ethernet (via SPI) I/Os: 34 GPIOs, ADC de 12 bits, DAC, SPI, I ² C, UART Alimentação: 3.3V DC
Módulo de Relés	JQC-3FF-S-Z / SRD-05VDC-SL-C (8 Canais)	Canais: 8 relés independentes Tensão da Bobine: 5V DC Capacidade de Contacto (Rating): 30V DC / 10A, 250V AC / 10A Isolamento: Optoacoplador por canal Interface de Controle: Nível lógico TTL (3.3V/5V) Recurso de Isolamento: <i>Jumper</i> para separar alimentação da lógica (VCC) e das bobines (JD-VCC)

2.3.5 Estrutura Mecânica e Suportes

Bancada Principal

Foi utilizada a bancada demonstradora “Covis-Cobot”, cf. Figura 18, bancada que pode ser ajustável em altura, e disponibilizada pelo Citin para desenvolvimento de projetos com o robot colaborativo.

- **Material:** Perfis de alumínio 20x20 mm
- **Dimensões:** 800x1400x700 mm (LxAxP)
- **Caraterísticas:** Estrutura
- **Superfície de Trabalho:** Placa de madeira



Figura 18 - Bancada Covis-Cobot

Base de Fixação de PCBAs

A operação robusta e repetível do sistema exigiu o desenvolvimento de uma base de fixação dedicada, cf. Figura 19 na página 31. O seu objetivo principal é acomodar

com precisão PCBAs de diferentes geometrias e dimensões, garantindo flexibilidade. Esta abordagem está alinhada com as boas práticas de design de dispositivos de fixação, que destacam a importância da repetibilidade e modularidade [40][42].

Esta base atua como o interface físico crítico entre o PCBA e o sistema robótico, sendo responsável por suportar fisicamente a placa durante todo o ciclo de teste, posicionar e imobilizar de forma precisa e repetível a PCBA em relação ao robô, facilitar o acesso consistente do *efetor final* do robô, tanto a parte de visão para identificação fiável, como das pontas de prova aos pontos de teste específicos na placa.

A necessidade de uma solução ajustável, em oposição a moldes fixos e dedicadas a um único produto, prende-se com a natureza versátil do projeto, onde a agilidade na transição entre diferentes PCBAs é um valor acrescentado [41].

- **Desenho e Metodologia de Fabrico**

A base foi integralmente desenvolvida num ambiente de desenho assistido por computador (CAD) 3D, cf. Figura 20 na página 31. Esta metodologia permitiu otimizar a geometria, simular restrições mecânicas e assegurar compatibilidade com a gama de PCBAs prevista. O uso de CAD é reconhecido como essencial para garantir precisão e repetibilidade em dispositivos de fixação [45]. A fabricação, para prova de conceito, foi realizada através de fabricação aditiva (impressão 3D). A escolha desta metodologia justifica-se em três pontos: rapidez e baixo custo de prototipagem, liberdade geométrica para formas complexas e canais internos, e propriedades mecânicas adequadas. O plástico PLA (ácido poliático), material utilizado, apresenta rigidez suficiente para a aplicação, garantindo estabilidade dimensional necessária para medições precisas [44].

- **Arquitetura da base de fixação**

O sistema é composto por uma placa base, impressa em 3D, que serve de suporte principal. Foi concebida para ser rígida, minimizando flexões durante o contacto do robô.

Um ponto de referência fixo em duas extremidades da placa base com ângulo de 90º graus funciona como batente para os PCBAs. Este elemento define a origem do sistema de coordenadas para o posicionamento. Todas as PCBAs são

encostadas a este ponto, garantindo uma referência comum e repetibilidade entre ciclos de teste [40][42].

Para completar o objetivo de ser uma base flexível foi criado um mecanismo de ajuste, contribuindo para a flexibilidade do sistema. Consiste num varão roscado M8 que atravessa uma extremidade e um suporte lateral sendo fixo a uma porca M8 alojada no interior do suporte permitindo que a rotação do varão proporcione o movimento linear do suporte. Estes suportes incorporam faces de contacto em "L" que aplicam uma pressão uniforme e não destrutiva, imobilizando a PCBA de forma segura cf. Figura 19, 20 e 21.

Esta base de fixação é o elemento passivo fundamental na cadeia de metrologia do sistema. Mecanismos ajustáveis em dispositivos de fixação impressos em 3D são reconhecidos por aumentar a versatilidade e reduzir custos em ambientes de teste eletrónico [43].




Figura 20 - Base de posicionamento e fixação PCBAs




Figura 19 - Base de posicionamento e fixação PCBAs em 3D




Figura 21 - Base dedicada à fixação de PCBAs com duas referências

Acopladores de pontas de prova

O desenvolvimento do sistema de contacto com o PCBA foi uma fase crítica do projeto, pois constitui a interface física entre o robô e o ambiente de trabalho. Para garantir a versatilidade, robustez e fácil integração, adotou-se uma arquitetura modular. Esta é composta por três componentes principais: Acopladores de pontas de prova personalizados, um suporte de fixação e uma base de fixação ao "*dual gripper*" pré-existente.

Foram concebidos e desenhados três acopladores individuais, cf. Figuras 22 e 23 nas páginas 33 e 34, cada um otimizado para acoplar pontas de prova específicas dentro do cenário de teste, esta abordagem de múltiplos acopladores permite uma adaptabilidade eficiente a diferentes geometrias. Como referem Chen et al. (2021), a modularidade dos *end-effectors* é essencial para reduzir tempos de reconfiguração e aumentar a flexibilidade em ambientes colaborativos [46].

Um aspeto fundamental foi a facilidade de acoplamento. Para tal, foi desenvolvido um suporte de fixação dedicado, que atua como interface padrão entre a base, cf. Figura 24 na página 34, o "*dual gripper*" e o cobot. Este suporte de fixação foi projetado para permitir a montagem e desmontagem rápida dos acopladores. Esta solução minimiza o tempo de reconfiguração e favorece a manutenibilidade.

A estratégia de integração privilegiou a reutilização de componentes já validados. Isto reduziu o tempo de desenvolvimento e aumentou a fiabilidade do sistema. O suporte de fixação dos acopladores das pontas de prova foi desenhado para ser acoplado de forma rápida e segura a uma base do "*dual Gripper*" já desenvolvida pelo CiTin, cf. Figura 24 da página 34. Esta base, por sua vez, é fixada a um sistema "*dual gripper*", cf. Figura 28 da página 36, também pré-existente e disponibilizado pelo CiTin.

A opção por aproveitar esta infraestrutura preexistente permitiu concentrar esforços nas inovações específicas deste projeto: o desenho dos suportes das pontas de prova.

Uma decisão de projeto crucial foi adaptar e localizar o sistema de medição e o sistema de visão artificial diretamente no "*dual gripper*". Esta opção contrasta com a localização mais comum destes equipamentos em posições fixas no ambiente de

trabalho. Segundo Krug et al. (2020), a integração de sistemas de visão diretamente no *end-effector* elimina erros de calibração entre coordenadas independentes e aumenta a precisão relacional [47].

Esta adaptação na montagem dos dois sistemas no *end-effector* do robô foi motivada por várias vantagens operacionais:

Tabela 7 - Vantagens da Integração da Visão e Medição no End-Effector do Robô

Vantagem Operacional	Descrição Técnica	Benefício Prático
Flexibilidade Maximizada	O sistema de visão e medição move-se com o robô, permitindo a inspeção dos PCBAs a partir de múltiplos ângulos e posições	Elimina a necessidade de um posicionamento rígido e fixo das peças, adaptando-se a diferentes geometrias e layouts de teste
Precisão Relacional	A aquisição da imagem e a medição são realizadas a partir do próprio <i>end-effector</i> , utilizando o mesmo sistema de coordenadas	Elimina o erro de calibração acumulado entre sistemas de coordenadas independentes (robô vs. câmara fixa), garantindo maior precisão no posicionamento
Melhor Exploração das Capacidades do Robô	Aproveita integralmente a mobilidade e os graus de liberdade do robô colaborativo	Transforma o robô num sistema de inspeção móvel e altamente adaptável, além das suas funções padrão de manipulação

Em suma, a solução implementada e baseada nas vantagens apresentadas na tabela 7, não é mais que um sistema de trabalho modular e intercambiável, integrado numa base robusta pré-existente, proporciona uma plataforma versátil e eficiente. Esta arquitetura não só atende aos requisitos imediatos do projeto, como também estabelece uma base sólida para a investigação e desenvolvimento futuros em aplicações de robótica colaborativa com reconfiguração rápida e inspeção integrada.



Figura 22 - Acopladores integradas no suporte e na base




Figura 23 – Suporte personalizado 3D



Figura 24 - Base desenvolvida pelo CiTin

Para efeitos de medição e baseado em contexto de trabalho na BorgWarner, foram escolhidas as seguintes pontas de prova, cf. Figuras 25, 26 e 27 com as características técnicas identificadas na tabela 8 e 9 da página 35:

- **Medição de Tensões:**




Figura 26 - Agulha Ingun GKS 100 217, (Ingun)




Figura 25 - Camisa Ingun KS 100, (Ingun)

Tabela 8 - Especificações Técnicas das Pontas de Prova (Tensões)

Componente	Modelo	Caraterísticas técnicas principais
Ponta de prova	Ingun KS-100 217 170	Flexão de trabalho: 4.3 mm Flexão máxima: 6.35 mm Corrente nominal: 5 A Material de contacto: Aço Cobertura de contacto: Dourado Resistência de contacto (máx.): 20 mΩ Temperatura de trabalho: -40 a 80 °C Força de deflexão da mola: 3 N
Camisa	Ingun KS-100	*Compatível com a agulha KS-100 217 170, serve de alojamento

- **Medição Resistência/Díodo:**




Figura 27 - Agulha Ingún GKS 100 288, (Ingún)

Tabela 9 - Especificações Técnicas das Pontas de Prova (Resistência/Díodo)

Componente	Modelo	Caraterísticas técnicas principais
Ponta de prova	Ingun GKS-100 288 150 A	Flexão de trabalho: 4.3 mm Flexão máxima: 6.35 mm Corrente nominal: 5 A Material de contacto: Aço Cobertura de contacto: Dourado Resistência de contacto (máx.): 20 mΩ Temperatura de trabalho: -40 a 80 °C Força de deflexão da mola: 3 N
Camisas	Ingun KS-100	*Compatível com a agulha KS-100 288 150 A, serve de alojamento





Figura 28 – “Dual Gripper” completo

Desenho e fabrico das estruturas de alojamento

Para garantir a robustez, organização e segurança do sistema eletrónico, foi imperativo o desenvolvimento de alojamentos personalizados para os seus principais componentes. Estas caixas de proteção têm como funções primárias a proteção física dos componentes/circuitos, a gestão do cabeamento, a dissipação de calor e a facilitação da montagem e manutenção. O microcontrolador Esp32 e o módulo de relés foram identificados como componentes críticos a alojar.

As caixas de proteção foram integralmente desenvolvidas em *software* de Desenho Assistido por Computador, cf. Figura 29 da página 38. A metodologia de desenho seguiu uma abordagem "de dentro para fora", onde a geometria e as dimensões dos componentes eletrónicos (Esp32, módulo de relés, terminais de ligação) definiram o volume interno primário, cf. Tabela 10 na página 37. De acordo com Thompson et al. (2020), a abordagem de design 'de dentro para fora' em invólucros eletrónicos garante uma otimização do espaço e uma integração mecânica perfeita com os componentes internos [48].

Tabela 10 - Critérios de Desenho das estruturas de alojamento

Critério de Desenho	Solução Implementada	Objetivo / Função
Ajuste e Fixação	Desenvolvimento de suportes e calços internos com furos para parafusos	Garantir uma fixação segura das placas (ESP32, módulo de relés), prevenindo vibrações e evitando curtos-circuitos
Gestão de Cabeamento	Incorporação de zonas de passagem dedicadas na estrutura da caixa	Assegurar que as ligações elétricas (cabos) estão organizadas e livres de colisões com a carcaça, prevenindo danos
Ventilação e Dissipação Térmica	Inclusão de aberturas estratégicas na carcaça	Permitir a convecção natural de ar para dissipar o calor gerado pelos componentes durante o funcionamento
Acessibilidade e Montagem	Divisão do modelo em base e tampa, com furos para parafusos de fixação	Facilitar o acesso aos componentes para montagem, inspeção e manutenção, assegurando uma montagem sólida e desmontável

A fabricação dos protótipos das caixas foi realizada através de Fabricação Aditiva (Impressão 3D), utilizando a tecnologia Fusão de Filamento (FFF), cf. Tabela 11.

Tabela 11 - Vantagens da Fabricação Aditiva (Impressão 3D por FFF)

Vantagem	Descrição / Impacto no Projeto	Fundamentação / Referência
Rapidez e Baixo Custo de Prototipagem	Permite iterações rápidas do desenho com base em testes físicos, a um custo muito reduzido	
Liberdade Geométrica	Possibilita a criação de formas complexas e características personalizadas (suportes integrados, entradas de cabos) inviáveis ou dispendiosas com métodos tradicionais (ex.: maquinação)	
Propriedades do Material Adequadas	O PLA oferece rigidez suficiente, é um isolante elétrico natural e de fácil impressão	Segundo Gibson et al. (2021), a fabricação aditiva por FFF oferece uma combinação única de liberdade de design, rapidez e propriedades isolantes adequadas [49]

Os alojamentos finais foram otimizados para facilitar a montagem na bancada de teste, minimizando o comprimento dos cabos de sinal e protegendo os componentes de interferências e danos no ambiente colaborativo. A sua conceção e fabrico por impressão 3D não só cumpriram o requisito funcional de proteção, como também elevaram a profissionalização, fiabilidade e integração coesa de todo o sistema de automação.



Figura 29 - Caixas de acoplamento Esp32 e Módulo de relés

2.3.6 Dispositivos Sob Teste e Objetivos de Validação

O presente trabalho foca-se na validação automática de duas PCBAs diferentes, ou seja, duas referências específicas, designadas por MOPF 5.2KW e MOPF 8KW, cf. Figura 30. Estas placas são componentes críticos no contexto dos sistemas HVCH, cf. Figura 31 da página 39, para veículos elétricos. A sua função primordial é a gestão e conversão de energia, tornando a sua fiabilidade e correto funcionamento absolutamente essenciais para a segurança e desempenho global do sistema, uma vez que os HVCH são componentes de missão crítica para a gestão térmica das baterias e do grupo motopropulsor em veículos elétricos [50].




Figura 30 - PCBA 8KW/PCBA 5.2KW da MOPF. (Borgwarner)




Figura 31 - Exemplo HVCH, (Borgwarner)

- **Caraterização das PCBAs MOPF**

As PCBAs em questão, MOPF, são placas complexas que integram tanto a secção de HV como a de LV num único *hardware*. A sua arquitetura é composta por uma secção de potência (alta tensão/corrente) que inclui componentes como IGBTs e díodos de potência, que são responsáveis pela comutação e controlo da elevada corrente necessária para o elemento aquecedor e por uma secção de controlo (baixa tensão), que inclui o microcontrolador, circuitos driver para os IGBTs, sensores e circuitos de interface que operam a tensões típicas, por exemplo 3.3V, 5V ou 12V.

- **Estratégia de Teste e Objetivos**

A estratégia de teste implementada visa validar as PCBAs em dois níveis fundamentais, combinando elementos de teste em circuito ICT e de teste funcional FCT.

Testes em Circuito não alimentado (Abordagem de ICT)

Nesta fase, o sistema realiza medições sem alimentar a placa, com o objetivo de verificar a integridade dos componentes e a correta montagem. Os testes planeados incluem:

- **Medição de Valores de Resistência:**
 - Verificação de valores de resistência em IGBTs.

- Estes testes permitem detetar componentes em aberto, em curto-circuito ou com valores fora da tolerância especificada.
- **Teste de queda de tensão em díodos:**
 - Este teste valida a polarização correta e a integridade das junções semicondutoras, permitindo identificar componentes danificados ou inseridos incorretamente.
 - Este teste é feito entre os terminais Emissor/Coletor dos IGBTs.

Testes em Circuito Alimentado (Leve abordagem ao FCT)

Nesta fase, a placa é energizada de forma controlada, permitindo uma validação funcional básica. Os testes focam-se na secção de LV e na tabela 32, retirada da documentação técnica da Borgwarner, estão identificados alguns dos valores possíveis de medição:

- **Medição de Valores de Tensão em Pontos definidos (LV):**
 - Com a placa alimentada a 13V DC, o sistema mede tensões em pontos estratégicos da secção de controlo.
 - A fonte de alimentação programável Keithley 2231A-30-3 é utilizada para fornecer a alimentação de forma segura, assegurando a integridade da placa sob teste durante a validação funcional inicial [51]

	Description	Measure Testpoint (TP)	TP PCBA Layer	Reference	TP PCBA Layer	Measurement			
						Min	Nom	Max	Unit
1	Measure AnClamp30_1	TP1111	BOT	TP1108 / TP1242	BOT / TOP	2.459	-	2.721	V
2	Measure AnClamp30_2	TP1114	BOT	TP1108 / TP1242	BOT / TOP	1.912	-	2,18	V
3	Measure 15V_HV	TP1305 / TP1304	BOT	TP1322 / Tprg704	BOT / TOP	14.853	-	15,910	V
4	Measure 15V_HV_HSS	TP1326 / TP1325	BOT	TP1328 / TP427	BOT / BOT	14.765	-	15.892	V
5	Measure HV Current_Offset	TP101	BOT	TP118 / Tprg704	BOT / TOP	0.370	-	0.403	V
6	Measure OvrCurr1 Signal Reference	TP113	BOT	TP120 / Tprg704	BOT / TOP	3.706	-	3.783	V
7	Measure Lacht Inputs signal	TP300	BOT	TP120 / Tprg704	BOT / TOP	4,946	-	5,038	V
8	Measure Lacht Reference signal	TP304	BOT	TP120 / Tprg704	BOT / TOP	2,449	-	2,541	V
9	Measure Flyback Enable	TP1314	BOT	TP1319 / Tprg1103	BOT / TOP	11,946	-	12,592	V
10	Measure 5V_LV	TP1211 / Tprg1104	BOT / TOP	TP1204 / TP1242	BOT / TOP	4,95	-	5,05	V
11	Measure 5V_HV_HSS	TP415	BOT	TP427	BOT	4.986	-	5,311	V
12	Measure 5V_HV	TP1321 / Tprg703	BOT / TOP	TP1322 / Tprg704	BOT / TOP	4,949	-	5,041	V
13	Measure the input voltage of U1301	TP1320	BOT	TP1322 / Tprg704	BOT / TOP	6,800	-	7,176	V
14	Measure the Vref of LSS1 IGBT driver	TP504_LSS1	BOT	TP509_LSS1 / Tprg704	BOT / TOP	4,880	-	5,099	V
15	Measure the Vref of LSS2 IGBT driver	TP504_LSS2	BOT	TP509_LSS2 / Tprg704	BOT / TOP	4,880	-	5,099	V

Figura 32 - Tabela com alguns pontos de medição para verificar

A automação deste processo através do sistema robótico desenvolvido assegura não só a repetibilidade e precisão dos testes, mas também uma validação significativamente mais rápida face aos métodos manuais tradicionais, posicionando esta solução como um ativo valioso para laboratórios de testes.

Câmara de Visão Artificial

O sistema de visão artificial, baseado numa câmara ELP-USBFHD01M-SFV, que pode ser vista montada no “*dual Gripper*”, cf. figura 28, da página 36, disponível no laboratório do CiTin, foi implementado para conferir capacidades de inspeção e posicionamento de alta precisão ao robô colaborativo. A sua função principal é a localização e identificação da referência da PCBA que está inserida na base de identificação.

- **Caraterísticas e Justificação:**

Tabela 12 - Caraterísticas e Justificação da Seleção da Câmara

Caraterística Técnica	Especificação / Descrição	Justificação para a Seleção
Resolução e Sensor	Full HD (1920x1080 px), Sensor 2.0 MP	Proporciona o detalhe espacial necessário para identificar caraterísticas de pequena dimensão em PCBAs. Oferece um equilíbrio ideal entre qualidade de imagem e eficiência de processamento, evitando a carga computacional desproporcional de resoluções superiores [26]
Lente	Distância focal variável (2.8-12 mm)	Permite ajustar dinamicamente o campo de visão (FOV) e a magnificação consoante a área a identificar e a distância de trabalho. Aumenta a versatilidade do sistema ao adaptar-se a diferentes requisitos sem alterações mecânicas no <i>setup</i>
Interface de Ligação	USB 2.0	Assegura uma integração simples do tipo <i>plug-and-play</i> com o computador central. É amplamente suportado por bibliotecas de visão artificial (ex.: OpenCV), facilitando o desenvolvimento

A seleção do modelo, além da disponibilidade, foi baseada num equilíbrio entre desempenho, flexibilidade ótica e custo, sendo as suas características técnicas decisivas para a aplicação:

- **Integração com o *software* e Algoritmo de Detecção**

A operação da câmara é gerida através de um script em *Python*, aproveitando o vasto ecossistema de bibliotecas disponíveis para visão computacional, nomeadamente o *OpenCV* para aquisição e pré-processamento de imagem. A interface de programação padrão USB garante uma comunicação fiável e de baixa latência, adequada para aplicações de controlo em tempo real.

O núcleo do processamento de imagem assenta no algoritmo de deteção de objetos YOLOv8 (*You Only Look Once*, versão 8), selecionado pela sua excelente relação entre velocidade de inferência e precisão. Como salientaram Redmon et al. no trabalho seminal que introduziu a arquitetura YOLO, a sua principal vantagem reside na reformulação da deteção como um problema de regressão única, permitindo uma velocidade de processamento radicalmente superior aos métodos da época [30]. O YOLOv8, enquanto evolução direta desse conceito, mantém estas vantagens fundamentais, sendo particularmente adequado para aplicações robóticas onde a latência é um fator crítico.

2.4 SOFTWARE

A implementação do *software* para o sistema de teste automático seguiu uma arquitetura em camadas, desenvolvida maioritariamente em *Python* no ambiente de desenvolvimento integrado *Visual Studio Code*. Esta escolha potenciou a produtividade, aproveitando o vasto ecossistema de bibliotecas para aplicações científicas e de automação [22].

O núcleo da aplicação, responsável pela gestão de testes, comunicação instrumental (via SCPI) e controlo do robô, foi implementado em *Python*. Para as funcionalidades de visão artificial, a mesma base de código integra a biblioteca *OpenCV* e o modelo pré-treinado YOLOv8, assegurando a deteção e localização precisa da PCBA [7, 30]. A lógica de controlo de baixo nível do hardware de

aquisição e comutação é gerida por um *firmware* personalizado, programado em C/C++ para o microcontrolador Esp32.

Para monitorização e análise de dados em tempo real, o sistema emprega uma *stack* tecnológica contentorizada com *Docker*, utilizando a base de dados de séries temporais *InfluxDB* para armazenamento e a plataforma *Grafana* para visualização. Esta arquitetura assegura a escalabilidade e uma análise temporal robusta dos resultados de teste [1].

2.4.1 Firmware Esp32

O *firmware* `FlexICT`, baseado num diagrama de blocos, cf. Figura 34 da página 47, foi desenvolvido para o microcontrolador Esp32 e constitui uma camada de inteligência embebida responsável por todas as operações de medição elétrica e controlo de relés, desempenhando um papel central na automação dos testes funcionais. Nas fases iniciais do seu desenvolvimento, foi adotada uma abordagem segmentada, em que cada tipo de medição elétrica era suportado por um *firmware* específico. Este processo implicava a seleção da medição pretendida, a verificação da versão de *firmware* instalada no Esp32 e, caso esta não correspondesse à versão requerida, a substituição do *firmware* por aquele adequado ao objetivo. Embora funcional, esta estratégia revelou-se ineficiente em termos de tempo de ciclo, introduzindo atrasos significativos na operação global do sistema.

Para superar esta limitação, foi implementada uma solução unificada sob a designação `FlexICT`, que integra toda a lógica necessária num único *firmware* e que está representada no fluxograma da figura 33 na página 47. Esta transição de uma arquitetura monolítica para uma modular e unificada é uma prática recomendada para reduzir a complexidade e melhorar a manutenibilidade em sistemas embebidos [22]. Esta abordagem permitiu consolidar as funcionalidades, reduzindo substancialmente o tempo de reconfiguração e aumentando a eficiência do sistema, sem comprometer a flexibilidade e escalabilidade exigidas. Entre as principais vantagens desta solução destacam-se a simplicidade de gestão, uma vez que apenas um *firmware* necessita de manutenção e atualização; a robustez, com o Esp32 a funcionar como um dispositivo de estado sólido, dispensando

reprogramações entre testes; e a eficiência, ao simplificar a comunicação para comandos de texto, tornando o sistema mais rápido e fiável. Além disso, o `FlexICT` permite a aquisição e validação local das medições, assegurando rapidez e verificação de integridade, e suporta comunicação bidirecional via TCP/IP, possibilitando uma troca de dados estruturada com o *software* principal.

2.4.1.1 *Fluxo da operação*

O fluxo de operação do *firmware* `FlexICT` segue uma sequência lógica e robusta, concebida para garantir uma comunicação fiável entre o sistema de controlo principal, desenvolvido em *Python*, e o hardware de comutação baseado no Esp32. O processo inicia-se com a fase de iniciação do sistema, onde o *firmware* configura todos os componentes de hardware, incluindo a definição dos pinos dos relés no estado desligado, estabelece a ligação à rede Wi-Fi previamente configurada e inicia o servidor TCP na porta 3333, permanecendo num estado de espera ativa por ligações externas.

Quando é detetada uma ligação - normalmente proveniente do *script* de medição - o sistema, valida a ligação e prepara-se para receber comandos. Segue-se a fase de processamento de comandos, em que o *firmware* aguarda a receção de instruções em texto, terminadas com *newline*, através da ligação TCP. Cada comando recebido é analisado sequencialmente através de uma árvore de decisão bem definida. Os comandos globais, como *STOP*, *GET_VERSION* e *GET_STATUS*, são processados independentemente do programa ativo, enquanto os comandos de seleção de programa, como *SET_PROGRAM:XXX*, alteram o contexto de operação para um dos programas disponíveis. Os comandos específicos de medição são direcionados para o processador correspondente ao programa atualmente selecionado.

Na execução das rotinas de medição, o sistema adota uma abordagem cautelosa, preparando sempre o hardware antes de qualquer operação. É executada a função `desligarTodosReles()` para garantir um estado conhecido e evitar conflitos de comutação, seguindo-se a ativação de combinações específicas de relés conforme a rotina de medição solicitada. Após cada operação bem-sucedida, o sistema envia

uma mensagem de confirmação para o *Python*, mantendo um diálogo constante sobre o estado das operações.

A gestão dos estados e transições constitui um aspeto crítico do fluxo operacional. O *firmware* mantém permanentemente o estado do programa ativo e o estado de medição, gerindo as transições entre programas e estados de forma controlada, de modo a garantir a integridade do sistema. Quando recebe o comando `QUIT` ou ocorre um encerramento da ligação inesperado, o sistema executa automaticamente a sequência de limpeza antes de terminar a ligação, assegurando que nenhum relé permanece ativo indevidamente.

O tratamento de exceções e erros está integrado em todo o fluxo operacional. Os comandos inválidos ou incompatíveis com o programa ativo resultam em mensagens de erro específicas, que permitem o diagnóstico preciso de problemas. Perante *timeouts* ou encerramentos inesperados, o sistema desencadeia automaticamente a sequência de recuperação, de forma a garantir a segurança do *hardware*, demonstrando uma conceção tolerante a falhas. Todas as operações geram *feedback* textual claro e compreensível, facilitando a monitorização e manutenção do sistema por parte dos colaboradores.

O fluxo caracteriza-se por ser síncrono e bloqueante, assegurando que apenas uma operação é executada de cada vez, eliminando condições não controlo e garantindo consistência operacional. A natureza baseada no estado do sistema permite um comportamento determinístico e previsível, com respostas consistentes para os mesmos comandos em condições idênticas. Esta abordagem assegura que o sistema de comutação responde de forma fiável e previsível aos comandos recebidos, mantendo a flexibilidade necessária para suportar múltiplos programas de teste com requisitos de comutação distintos - desde a simples ativação de um único relé para medições de tensão até combinações complexas para a caracterização de IGBTs em diferentes configurações de placa.

A arquitetura modular do *firmware FlexICT* organiza-se em componentes especializados que colaboram para executar as funções do sistema. O módulo de gestão de comunicação da rede é responsável por toda a comunicação TCP/IP, incluindo a ligação Wi-Fi e o servidor de *sockets*. O módulo de gestão de *hardware*

controla o sistema de relés, fornecendo interfaces para ativação individual e em combinação. O módulo de gestão de programas mantém o estado operacional do sistema, gerindo as transições entre diferentes modos de teste. O processador de comandos interpreta e valida as instruções recebidas, direcionando-as para os respetivos manipuladores. Por fim, o módulo de rotinas de medição encapsula a lógica específica de cada programa de teste, implementando as combinações exatas de relés necessárias para cada medição.

Esta organização modular confere ao sistema vantagens notáveis em termos de manutenção, permitindo que cada componente seja atualizado de forma independente; testabilidade, pela possibilidade de testar módulos individualmente; extensibilidade, facilitando a adição de novos programas de teste; e reutilização, possibilitando o reaproveitamento de módulos noutros projetos. A robustez do sistema é reforçada pelo tratamento centralizado de erros e exceções, assegurando que falhas num módulo não comprometem o funcionamento global, uma característica fundamental para a fiabilidade de sistemas de missão crítica em ambientes de produção [39]

A implementação do *firmware* demonstra uma conceção cuidadosamente equilibrada entre flexibilidade operacional, segurança e fiabilidade, essenciais num ambiente industrial. A capacidade de suportar múltiplos programas de teste com um único *firmware*, mantendo simultaneamente a simplicidade de operação e a robustez na execução, posiciona o FlexICT como uma solução eficiente e adaptável para sistemas automatizados de teste de PCBAs. Este design para um comportamento determinístico e previsível é crucial para a fiabilidade em sistemas de automação industrial [1].




Figura 33 - Fluxograma Firmware FlexICT



Figura 34 - Diagrama de blocos do firmware FlexICT

2.4.2 Python

A linguagem *Python* foi selecionada como base de desenvolvimento, não apenas pela sua sintaxe acessível, mas fundamentalmente devido ao seu vasto ecossistema de bibliotecas científicas e de prototipagem rápida, que a tornam uma ferramenta de eleição para a integração de sistemas de instrumentação e automação [22].

O objetivo arquitetural central do *software* é garantir uma execução sequencial, autónoma e segura das tarefas de teste, assegurando simultaneamente a rastreabilidade e visualização em tempo real dos parâmetros medidos. A sua conceção segue um paradigma modular e escalável, centrado num script principal `Identificar_PCBA.py`, cf. Figura 35 da página 49, que funciona como núcleo de controlo. Esta abordagem modular é uma prática estabelecida para assegurar a manutenibilidade e a escalabilidade de sistemas de automação industrial complexos [1].

A partir deste núcleo, são geridas todas as operações de alto nível do sistema, incluindo:

- A identificação automática da PCBA através do sistema de visão computacional.
- A seleção dinâmica do programa de medição adequado com base na PCBA identificada.
- A comunicação e sincronização com os diversos módulos de *hardware* (robô colaborativo, Esp32, multímetro, interface LIN, etc.).
- O registo e monitorização de dados em tempo real.

O sistema está concebido para suportar diferentes tipos de medições e variantes de PCBAs, mantendo uma base de *firmware* e uma lógica de controlo unificadas. Esta estratégia confere uma elevada flexibilidade e promove a reutilização de código, permitindo a adaptação a novos requisitos de teste sem alterações profundas na arquitetura, um princípio fundamental para o desenvolvimento de sistemas de teste versáteis e económicos [39].

Camara_APP	21/10/2025 17:56	Arquivo Fonte Pyt...	16 KB
Config	29/10/2025 15:52	Arquivo Fonte Pyt...	5 KB
Dashboard	12/10/2025 16:23	Arquivo Fonte Pyt...	6 KB
DockerDesktop	03/10/2025 17:37	Arquivo Fonte Pyt...	3 KB
EliteRobot	03/10/2025 15:44	Arquivo Fonte Pyt...	3 KB
Esp32	24/10/2025 16:03	Arquivo Fonte Pyt...	8 KB
Identificar_PCBA	24/10/2025 18:05	Arquivo Fonte Pyt...	6 KB
InfluxDB	16/10/2025 17:37	Arquivo Fonte Pyt...	2 KB
InterfaceGrafica	22/10/2025 21:13	Arquivo Fonte Pyt...	7 KB
InterfaceGrafica_Tensoes	22/10/2025 21:18	Arquivo Fonte Pyt...	6 KB
Kvaser_Lin	07/10/2025 17:02	Arquivo Fonte Pyt...	1 KB
Medir_IGBTS_5.2KW	28/10/2025 15:16	Arquivo Fonte Pyt...	10 KB
Medir_IGBTS_8KW	28/10/2025 15:21	Arquivo Fonte Pyt...	11 KB
Medir_Tensao_Bottom_5.2KW	20/10/2025 21:09	Arquivo Fonte Pyt...	8 KB
Medir_Tensao_Bottom_8KW	29/10/2025 15:34	Arquivo Fonte Pyt...	10 KB
Medir_Tensao_Top_5.2KW	28/10/2025 15:23	Arquivo Fonte Pyt...	10 KB
Medir_Tensao_Top_8KW	28/10/2025 15:24	Arquivo Fonte Pyt...	10 KB
Multimetro_keithleyDMM6500	22/10/2025 20:49	Arquivo Fonte Pyt...	3 KB
Startup_Warning	28/10/2025 15:15	Arquivo Fonte Pyt...	7 KB
Yolo	14/10/2025 21:22	Arquivo Fonte Pyt...	2 KB

Figura 35 - Scripts em Python usados no projeto

2.4.2.1 Arquitetura Geral do Software

A aplicação segue um modelo de controlo hierárquico modular, cf. Figura 36. O script principal `Identificar_PCBA.py` atua como camada de estruturação e comunicação entre os módulos funcionais e os scripts específicos de medição. A estrutura é composta por três camadas principais:




Figura 36 - Arquitetura Geral do Software

2.4.2.1.1 Camada de Coordenação (Master Controller)

Identificar_PCBA.py, este script é o ponto de entrada do sistema e o principal responsável pela lógica de alto nível. A figura 37 mostra o robô em posição de identificação e a interface gráfica principal do software, a sua operação pode ser resumida no fluxo identificado na tabela 13 da página seguinte.




Figura 37 - Robô em posição de identificação (Esq.), interface de identificação (Dir.).

Tabela 13 - Fluxo Operacional do Script principal "Identificar_PCBA.py"

Fase	Módulos / Ações Principais	Descrição da Operação	Resultado / Saída
1. Iniciação e Configuração	Config.py EliteRobot.py	1. Carrega os parâmetros de configuração do sistema 2. Inicia a comunicação com os subsistemas 3. Comanda o robô para posicionar-se no ponto de identificação da PCBA	Sistema inicializado, robô posicionado e pronto para início do ciclo
2. Identificação da PCBA	Camara_APP.py Yolo.py Dashboard.py	1. Ativa a câmara e captura uma imagem. 2. Executa o algoritmo YOLOv8 para classificar a PCBA (MOPF 5.2KW ou 8KW) 3. Abre automaticamente um <i>Dashboard</i> específico com a informação da PCBA identificada, cf. Figura 38 da página 52	PCBA classificada, <i>Dashboard</i> em execução com dados contextuais
3. Seleção Dinâmica da Rotina de Teste	Interface Gráfica (GUI)	1. Apresenta ao operador apenas os programas de medição disponíveis para a PCBA identificada. 2. Aguarda a seleção manual do programa desejado (ex: Medir_IGBTs_8KW.py)	Programa de teste específico selecionado e pronto para execução
4. Execução da Sequência de Teste	Script de medição específico (ex: Medir_IGBTs_8KW.py) Módulos especializados (ex: Multimetrol_keithleyDMM6500.py, InfluxDB.py)	1. O script de medição executa a sequência de testes. 2. Faz chamadas sequenciais aos módulos correspondentes para realizar operações (ex: leitura do multímetro, envio de dados), cf. Figura 39 da página 52 3. Coordena o robô, instrumentos e sistemas de dados	Medições elétricas realizadas e resultados gerados
5. Consolidação e Relatório	Sistema de ficheiros Geração de CSV	1. Armazena a imagem capturada na pasta PCBA_Capturas, cf. Figura 40 da página 53 2. Gera um ficheiro CSV na pasta Histórico com metadados da identificação (data, hora, classe, precisão, localização), cf. Figura 41 da página 53 3. Guarda e regista todos os resultados do ciclo de testes	Evidências (imagens) e relatório estruturado (CSV) criados para rastreabilidade e análise



Figura 38 – Informação no dashboard relacionado com a referência identificada




Figura 39 - Arquitetura geral para os programas de medição

Nome	Data de modificação	Tipo	Tamanho
BaseDados	26/10/2025 15:17	Pasta de ficheiros	
Documentação	17/10/2025 16:46	Pasta de ficheiros	
Esp32_Comentado	18/10/2025 12:10	Pasta de ficheiros	
Esp32_Firmware	22/10/2025 16:54	Pasta de ficheiros	
Histórico	04/11/2025 17:34	Pasta de ficheiros	
Imagens	30/10/2025 16:52	Pasta de ficheiros	
PCBA_Capturas	29/10/2025 17:40	Pasta de ficheiros	
Scripts	04/11/2025 16:24	Pasta de ficheiros	
YOLO	28/10/2025 15:05	Pasta de ficheiros	

Figura 40 - Pasta Histórico e PCBA_Capturas

	DataHora	Classe	Precisão	Localização
15	2025-10-24 17:34:44	5.2KW	95.9%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\5.2KW_20251024_173444.jpg
16	2025-10-24 17:36:15	5.2KW	95.5%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\5.2KW_20251024_173615.jpg
17	2025-10-24 17:36:47	8KW	92.3%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\8KW_20251024_173647.jpg
18	2025-10-24 17:37:19	5.2KW	96.8%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\5.2KW_20251024_173719.jpg
19	2025-10-24 17:41:48	5.2KW	96.4%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\5.2KW_20251024_174148.jpg
10	2025-10-24 17:49:49	5.2KW	96.3%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\5.2KW_20251024_174949.jpg
11	2025-10-24 17:55:37	5.2KW	96.2%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\5.2KW_20251024_175537.jpg
12	2025-10-24 17:56:37	5.2KW	96.6%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\5.2KW_20251024_175637.jpg
13	2025-10-24 18:04:03	8KW	96.4%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\8KW_20251024_180403.jpg
14	2025-10-29 15:21:06	8KW	94.9%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\8KW_20251029_152106.jpg
15	2025-10-29 15:35:19	8KW	98.0%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\8KW_20251029_153519.jpg
16	2025-10-29 15:41:12	8KW	98.1%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\8KW_20251029_154112.jpg
17	2025-10-29 15:43:50	8KW	97.9%	C:\Users\marci\Desktop\FlexICT\PCBA_Capturas\8KW_20251029_154350.jpg

Figura 41 - Informação das PCBAs identificadas

2.4.2.1.2 Camada de Funcionalidades e Comunicação

Conjunto de módulos/subprogramas *Python* que encapsulam a lógica de comunicação e controlo de cada subsistema. Estes módulos funcionam como *drivers* de alto nível, sendo carregados conforme a necessidade do ciclo de teste. Na tabela 14 são apresentadas as principais funcionalidades assim como os protocolos de comunicação.

Tabela 14 - Especificação dos Módulos de Software da Camada de Aplicação

Módulos/Subprogramas	Descrição da Funcionalidade	Protocolo / Interface de Comunicação
Config.py	Parâmetros de configuração e <i>paths</i> do sistema.	
Camara_APP.py	Interface gráfica do sistema de visão.	
Dashboard.py	Interface gráfica com <i>dashboards</i> da PCBA identificada.	

DockerDesktop.py	Aplicação para gerenciar os <i>containers</i> InfluxDB e Grafana.	API HTTP
EliteRobot.py	Controlo do robô colaborativo.	TCP/IP
InterfaceGrafica.py	Interface gráfica do feedback entre <i>Python</i> /robô/InfluxDB vs ESP32.	
InterfaceGrafica_Tensoes.py	Interface gráfica do feedback entre Python/robô/InfluxDB vs ESP32/LIN.	
Kvaser_Lin.py	Interface com o barramento LIN.	LIN
Multimetro_keithleyDMM6500.py	Comunicação com o instrumento de medição.	TCP/IP
Esp32.py	Comunicação com o microcontrolador ESP32.	TCP/IP
InfluxDB.py	Envio e armazenamento de dados em base de dados temporal.	API HTTP
Startup_Warning.py	Interface informativa antes de iniciar as medições.	
Yolo.py	Algoritmo para identificação de PCBA.	

2.4.2.1.3 Camada de Execução de Testes

Esta camada é composta por seis *scripts* de medição:

1. Medir_IGBTS_5.2KW
2. Medir_Tensao_Bottom_5.2KW
3. Medir_Tensao_Top_5.2KW
4. Medir_IGBTS_8KW
5. Medir_Tensao_Bottom_8KW
6. Medir_Tensao_Top_8KW.

Cada *script*, cf. Figura 42 contém a lógica específica do tipo de teste, mas é chamada e controlado pelo programa principal. A escolha do script é feita com base no modelo de PCBA identificado e nas necessidades de teste.

Medir_IGBTS_5.2KW	28/10/2025 15:16	Arquivo Fonte Pyt...	10 KB
Medir_IGBTS_8KW	28/10/2025 15:21	Arquivo Fonte Pyt...	11 KB
Medir_Tensao_Bottom_5.2KW	20/10/2025 21:09	Arquivo Fonte Pyt...	8 KB
Medir_Tensao_Bottom_8KW	29/10/2025 15:34	Arquivo Fonte Pyt...	10 KB
Medir_Tensao_Top_5.2KW	28/10/2025 15:23	Arquivo Fonte Pyt...	10 KB
Medir_Tensao_Top_8KW	28/10/2025 15:24	Arquivo Fonte Pyt...	10 KB

Figura 42 - Programas de medição

2.4.2.2 *Organização e sincronização de dados*

A fiabilidade de um sistema de teste automatizado depende não apenas da precisão das medições, mas também da robustez com que os dados são organizados, correlacionados e persistidos. Nesta prova de conceito, a arquitetura de dados foi cuidadosamente concebida para transformar leituras analógicas brutas em informação contextualizada e com rastreabilidade completa, assegurando que cada valor pode ser inequivocamente associado ao estado físico do sistema no momento da sua aquisição, um requisito fundamental para sistemas de diagnóstico e controlo de qualidade na Indústria 4.0 [1].

A base desta organização assenta numa estratégia que recorre a dois sistemas de armazenamento em paralelo, cada um com vantagens complementares. Para garantir acesso imediato e portabilidade, todos os dados são guardados localmente em ficheiros CSV, cf. Figura 43 da página 57. A geração e gestão inteligente destes ficheiros é assegurada pela função `get_csv_path()` do módulo `Config.py`, que cria dinamicamente uma estrutura de diretórios e uma nomenclatura baseada na data e hora de início do teste. Esta abordagem assegura uma organização cronológica automática, facilitando a localização e o arquivo de sessões de teste sem intervenção manual. Paralelamente, para suportar análise temporal avançada e monitorização em tempo real, os dados são estruturados e enviados para uma base de dados *InfluxDB*. Neste modelo, cada ponto de dados é armazenado como uma entrada numa *measurement* (como 'resistência'), enriquecida com *tags* que fornecem o contexto dimensional (ex.: *igbt*="IGBT1", *modo*="M1") e *fields* que contêm os valores medidos. Esta estrutura permite consultas complexas e agregações eficientes, transformando dados brutos em informação operacional acionável.

A sincronização entre os subsistemas físicos e este fluxo de dados é fundamental e é gerida pelo *script* principal `Identificar_PCBA.py` em conjunto com os *scripts* de medição específicos (ex: `Medir_IGBTS_5.2KW.py`). O processo inicia-se com a identificação automática da placa através do módulo de visão artificial baseado em YOLOv8 [30]. Com base na placa detetada, o sistema, através do colaborador, seleciona e executa dinamicamente um dos seis programas de

medição específicos. Durante a execução de cada rotina, é desencadeada uma sequência de eventos para cada ponto de teste. Primeiro, o *firmware* FlexICT no Esp32 é instruído para configurar os relés de acordo com o tipo de teste (IGBT, tensões, etc.). Em seguida, o robô é posicionado automaticamente nos pontos de medição definidos no *script* correspondente. Simultaneamente, o multímetro é configurado dinamicamente conforme o modo de medição solicitado (resistência, díodo, etc.). A leitura resultante é então capturada e imediatamente carimbada com um *timestamp* de alta precisão. Este carimbo temporal é o elemento de ligação crítico, permitindo correlacionar de forma inequívoca um valor elétrico medido com uma determinada configuração de relés, uma posição do robô e um tipo de placa específica, assegurando a integridade dos dados ao longo de toda a cadeia de aquisição [39].

A monitorização em tempo real é disponibilizada através de *dashboards* específicos desenvolvidos na plataforma *Grafana*, cf. Figura 44 da página 57, que permitem a visualização imediata do estado do sistema, a evolução temporal dos parâmetros medidos e a deteção visual de tendências ou anomalias. A dupla persistência em CSV local e *InfluxDB* proporciona benefícios complementares: o formato CSV oferece portabilidade e simplicidade de acesso para análise com ferramentas externas, enquanto o *InfluxDB* fornece desempenho otimizado para consultas temporais complexas. Esta arquitetura de dados integrada, desde a gestão de alto nível até à persistência de dados, assegura que o sistema executa provas de teste completas de forma autónoma, fiável e com rastreabilidade total, constituindo o núcleo inteligente da prova de conceito desenvolvida.

medicoes_IGBTS_5.2KW_16-04-17	29/10/2025 16:06	Documento de Te...	1 KB
medicoes_IGBTS_5.2KW_16-13-02	29/10/2025 16:15	Documento de Te...	1 KB
medicoes_IGBTS_5.2KW_16-48-22	29/10/2025 16:50	Documento de Te...	1 KB
medicoes_IGBTS_5.2KW_16-57-36	29/10/2025 16:59	Documento de Te...	1 KB
medicoes_IGBTS_8KW_15-36-10	29/10/2025 15:40	Documento de Te...	1 KB
medicoes_IGBTS_8KW_16-09-08	29/10/2025 16:09	Documento de Te...	0 KB
medicoes_IGBTS_8KW_17-41-22	29/10/2025 17:45	Documento de Te...	1 KB
medicoes_Tensao_Bottom_8kW_15-23-17	29/10/2025 15:24	Documento de Te...	1 KB
medicoes_Tensao_Top_5.2kW_15-54-36	29/10/2025 15:55	Documento de Te...	1 KB
medicoes_Tensao_Top_5.2kW_15-57-47	29/10/2025 15:58	Documento de Te...	1 KB
medicoes_Tensao_Top_5.2kW_16-00-32	29/10/2025 16:01	Documento de Te...	1 KB
medicoes_Tensao_Top_5.2kW_16-51-39	29/10/2025 16:52	Documento de Te...	1 KB
medicoes_Tensao_Top_5.2kW_16-53-36	29/10/2025 16:54	Documento de Te...	1 KB
medicoes_Tensao_Top_5.2kW_16-55-49	29/10/2025 16:56	Documento de Te...	1 KB
medicoes_Tensao_Top_5.2kW_17-10-05	29/10/2025 17:11	Documento de Te...	1 KB
medicoes_Tensao_Top_8kW_15-42-05	29/10/2025 15:43	Documento de Te...	1 KB
medicoes_Tensao_Top_8kW_15-44-27	29/10/2025 15:45	Documento de Te...	1 KB

Figura 43 - Ficheiros CSV



Figura 44 - Exemplo Dashboard medição resistências

2.4.2.3 Resiliência e segurança operacional

A operação autónoma de um sistema que integra múltiplos componentes de *hardware* e *software* exige uma conceção robusta, capaz de antecipar e gerir eventos adversos sem comprometer a segurança do equipamento ou a integridade

dos dados. A resiliência operacional foi, por isso, um princípio orientador desde a fase de desenvolvimento, alinhando-se com as melhores práticas de fiabilidade de sistemas para aplicações críticas [39].

Um dos pilares desta resiliência é a verificação proativa do estado do sistema antes da execução de qualquer teste. Como já foi mencionado anteriormente uma rotina automática confirma a presença e a versão do *firmware* `FlexICT` no Esp32. Caso seja detetada uma versão incorreta ou uma falha de comunicação, o sistema pode iniciar automaticamente um procedimento de reprogramação do microcontrolador via porta série, assegurando que o dicionário de comandos partilhado entre o *Python* e o Esp32 está perfeitamente sincronizado. Esta medida previne erros de comutação que poderiam resultar em curtos-circuitos ou medições incorretas, protegendo tanto a PCBA sob teste como o próprio equipamento de medição.

A arquitetura de processos concorrentes constitui outro mecanismo de defesa crítico. As operações de medição, que envolvem comunicações de rede potencialmente bloqueantes, são executadas em *threads* dedicadas. Este isolamento garante que a GUI permanece responsiva, permitindo a monitorização em tempo real e a intervenção do colaborador, mesmo que uma rotina de teste fique bloqueada à espera de uma resposta de um dos instrumentos. Adicionalmente, todos os módulos de comunicação – com o Esp32, o robô, o multímetro e o Kvaser – implementam gestão de exceções e *timeouts*. Se um dispositivo não responder dentro de uma janela temporal expectável, a operação é cancelada, um erro é registado em *logs* dedicados (como `main_queue` e `esp32_queue`) e o sistema avança para um estado de segurança, impedindo que uma falha pontual se propague e comprometa a operação global, uma estratégia essencial para a tolerância a faltas [39].

Os procedimentos de paragem segura (*safe stop*) estão profundamente embutidos na lógica do sistema. Funções como `stop_measurement()` e `close_connection()` são concebidas para serem invocadas tanto em condições normais de terminação como perante a deteção de uma exceção. A sua principal responsabilidade é garantir que todos os atuadores, em particular os relés do Esp32, são desligados, interrompendo imediatamente qualquer fluxo de corrente

elétrica para a PCBA. Esta funcionalidade é crucial para prevenir danos em componentes sensíveis durante situações de erro, assegurando a segurança física dos ativos [5].

Finalmente, a estratégia de redundância de dados assegura a preservação da informação mesmo em cenários de falha de infraestrutura. O armazenamento local em CSV atua como um *buffer* de resiliência. Em caso de uma indisponibilidade inesperada da rede que torne o servidor *InfluxDB* inacessível, o sistema continua a operar e a guardar todas as medições localmente. Os dados podem ser posteriormente recuperados e, se necessário, carregados manualmente para a base de dados, garantindo que nenhum resultado de teste é perdido. Em conjunto, estes mecanismos conferem ao sistema uma capacidade robusta de lidar com imprevistos, assegurando a continuidade operacional e a proteção dos ativos físicos e de informação. Esta abordagem assegura que nenhum resultado de teste é perdido, mantendo a integridade e rastreabilidade dos dados, um aspeto crítico para a fiabilidade do sistema de teste no seu conjunto [1, 39].

2.4.3 Docker Desktop

O *Docker Desktop* é uma ferramenta amplamente utilizada para o desenvolvimento e execução de aplicações em ambientes contentorizados, permitindo que os programadores criem, testem e implementem sistemas de forma reprodutível e independente da infraestrutura física [52]. A tecnologia de *containers* baseia-se no princípio do isolamento de processos, em que cada aplicação é executada num ambiente próprio, partilhando o mesmo *kernel* do sistema operativo, mas mantendo as suas dependências e bibliotecas de forma independente [53].

Ao contrário das máquinas virtuais, que necessitam de um sistema operativo completo em cada instância, os *containers* são significativamente mais leves e rápidos, apresentando tempos de inicialização reduzidos e melhor aproveitamento dos recursos de *hardware* [54]. Esta característica torna o *Docker Desktop* particularmente adequado para cenários de desenvolvimento científico e industrial, onde a consistência e a portabilidade do ambiente são essenciais, como na

execução de serviços interligados de bases de dados, aplicações *Python* e plataformas de visualização [55].

No contexto deste trabalho, o *Docker Desktop* foi utilizado para alojar e gerir *containers* que executam o *InfluxDB* e o *Grafana*, cf. Figura 45, ferramentas responsáveis, respetivamente, pelo armazenamento e pela visualização de dados de medições elétricas. Através do uso do *Docker Compose*, cf, figura 46 da página 61, foi possível definir e gerir múltiplos serviços dentro de uma mesma infraestrutura, simplificando o processo de implementação e garantindo que o ambiente pudesse ser facilmente replicado em diferentes máquinas [56] [57].

Para além da portabilidade, a contentorização com o *Docker* assegura o controlo e o isolamento das dependências de *software*. Esta estabilidade do ambiente elimina conflitos de bibliotecas e problemas de compatibilidade, contribuindo diretamente para a robustez, manutenibilidade e reprodutibilidade a longo prazo do sistema de aquisição e análise de dados [54].




Figura 45 - Docker Desktop Containers

2.4.3.1 Docker Compose

```
version: "3.9"

services:
  influxdb:
    image: influxdb:2.7
    container_name: influxdb
    restart: always
    ports:
      - "8086:8086"
    volumes:
      - ./influxdb_data:/var/lib/influxdb2
    environment:
      - DOCKER_INFLUXDB_INIT_MODE=setup
      - DOCKER_INFLUXDB_INIT_USERNAME=admin
      - DOCKER_INFLUXDB_INIT_PASSWORD=admin123
      - DOCKER_INFLUXDB_INIT_ORG=MEEA
      - DOCKER_INFLUXDB_INIT_BUCKET=MEDIÇÕES_IGBT
      - DOCKER_INFLUXDB_INIT_ADMIN_TOKEN=marcio_token

  grafana:
    image: grafana/grafana:latest
    container_name: grafana
    restart: always
    ports:
      - "3000:3000"
    volumes:
      - ./grafana_data:/var/lib/grafana
    environment:
      - GF_SECURITY_ADMIN_USER=admin
      - GF_SECURITY_ADMIN_PASSWORD=admin123
    depends_on:
      - influxdb
```

Figura 46 - Código do docker-compose.yml

A figura 46 mostra o código de configuração de um ambiente contentorizado utilizando o *Docker Compose*, com o objetivo de disponibilizar dois serviços essenciais para um sistema de aquisição e visualização de dados: o *InfluxDB* e o *Grafana*, como mencionado no tópico 3.2.3. A versão especificada para o ficheiro é a 3.9, que determina a sintaxe e funcionalidades disponíveis no *Docker Compose*. Esta abordagem de contentorização garante consistência entre ambientes de desenvolvimento e produção, seguindo as melhores práticas para investigação reprodutível [54].

O primeiro serviço configurado é o *InfluxDB*, a base de dados utilizada para armazenar as medições. Este serviço é baseado na imagem oficial *influxdb:2.7* e é configurado para reiniciar automaticamente em caso de falha. A porta 8086 é exposta para permitir o acesso à API HTTP do *InfluxDB*. Os dados persistentes são guardados localmente na pasta `./influxdb_data`, que é montada no volume interno do *container*. A configuração inicial do *InfluxDB* é feita através de variáveis de ambiente, que definem o modo de iniciação, o nome de utilizador e palavra-passe do administrador (admin / admin123), a organização (MEEA), o *bucket* de dados (MEDIÇÕES_IGBT) e o *token* de autenticação (marcio_token). Esta

configuração garante que o *InfluxDB* está pronto a receber dados assim que o *container* é iniciado [56].

O segundo serviço é o *Grafana*, este serviço utiliza a imagem *grafana/grafana:latest*, garantindo que utilizamos a versão mais recente. Tal como o *InfluxDB*, o *Grafana* está configurado para reiniciar automaticamente e expõe a porta 3000, que corresponde à interface web. Os dados e configurações do *Grafana* são perseverados na pasta local *./grafana_data*. As credenciais de acesso são definidas através das variáveis de ambiente *GF_SECURITY_ADMIN_USER* e *GF_SECURITY_ADMIN_PASSWORD*, com os valores *admin* e *admin123*, respetivamente. O *Grafana* depende do *InfluxDB*, o que significa que só é iniciado após o *InfluxDB* estar operacional [57].

Em conjunto, esta configuração permite levantar automaticamente um ambiente completo de aquisição e visualização de dados com apenas um comando (*docker-compose up -d*). O *InfluxDB* recebe os dados enviados pela aplicação *Python*, enquanto o *Grafana* consulta estes mesmo dados periodicamente para apresentar visualizações em tempo real [55].

```
# 2. INICIAR CONTAINERS (docker compose)
compose_file = DOCKER_COMPOSE_PATH / "docker-compose.yml"
try:
    subprocess.run(
        ["docker", "compose", "-f", str(compose_file), "up", "-d"],
        check=True,
        capture_output=True,
        text=True
    )
    print("[Docker] Containers iniciados")
except subprocess.CalledProcessError as e:
    print(f"[Docker] ERRO ao executar 'docker compose'. Detalhes: {e.stderr}")
    return False
```

Figura 47 - excerto do subprograma *DockerDesktop.py*

A figura 47, mostra a parte do código do subprograma *DockerDesktop.py* que inicia automaticamente os *containers* definidos no *Docker-compose.yml*. Para isto acontecer, o *script* define o caminho completo até ao ficheiro de configuração, combinando a variável *DOCKER_COMPOSE_PATH* com o nome do ficheiro. Em seguida, recorre à função *subprocess.run* para executar o comando no sistema operativo, garantindo que os serviços definidos no *Docker Compose* são lançados em modo "*detached*", ou seja, em segundo plano.

A função `subprocess.run` é configurada para verificar se o comando foi executado com sucesso (`check=True`), capturar a saída do processo (`capture_output=True`) e tratar essa saída como texto (`text=True`). Caso o comando seja executado corretamente, o sistema imprime uma mensagem de confirmação indicando que os *containers* foram iniciados. No entanto, se ocorrer algum erro, como a ausência do *Docker*, problemas de configuração no ficheiro YAML ou conflitos de porta, o *script* está preparado para lidar com situações em que a execução do comando falha, interceptando o erro gerado e tratando-o de forma controlada `CalledProcessError`, e imprime uma mensagem de erro detalhada com base na saída de erro (`e.stderr`) e devolve `False`, indicando que a operação falhou.

Este mecanismo permite que o sistema *Python* controle o ambiente *Docker* de forma automatizada, integrando a iniciação dos serviços *InfluxDB* e *Grafana* no fluxo de execução da aplicação principal. Esta integração assegura que a infraestrutura de suporte está operacional antes do início das medições, contribuindo para a fiabilidade global do sistema de teste [39]. A gestão de exceções implementada permite lidar de forma elegante com potenciais erros, como a ausência do *Docker* ou conflitos de portas, mantendo a estabilidade do sistema mesmo perante condições adversas.

2.4.4 Grafana

A monitorização em tempo real das medições, particularmente no contexto de medição de grandezas elétricas nas PCBAs nomeadamente valores de resistência, diodo em IGBTs e valores de tensão em vários *test points* da placa, requer ferramentas robustas e fiáveis para visualização e análise de dados. Neste contexto, foi selecionado o *Grafana* como plataforma principal de visualização, implementado num ambiente contentorizado através do *Docker Desktop*. Esta escolha fundamenta-se na capacidade do *Grafana* para processar e visualizar dados temporais em tempo real, combinada com as vantagens de isolamento e portabilidade oferecidas pela contentorização [54] [57].

A integração do *Grafana* com o *InfluxDB*, igualmente contentorizado, permite criar um sistema coeso de aquisição, armazenamento e visualização de dados. Segundo a documentação oficial do Grafana Labs [57], esta combinação de tecnologias tem demonstrado excelentes resultados em aplicações industriais, particularmente em cenários que exigem alta disponibilidade e baixa latência na visualização de métricas [1] [57].

2.4.4.1 Arquitetura

O sistema de monitorização implementado segue uma arquitetura modular baseada em *containers Docker*, composta por dois serviços principais: o *InfluxDB* para armazenamento temporal de dados e o *Grafana* para visualização e análise. Esta abordagem assegura uma clara separação de responsabilidades entre a camada de armazenamento e a camada de apresentação, um princípio arquitetural que promove a manutenibilidade e a escalabilidade [55]. O *container* do *Grafana* foi configurado com a imagem oficial *grafana/grafana*, registando a porta 3000 para acesso à *interface web*. Paralelamente, o *container* do *InfluxDB* utiliza a imagem *influxdb:2.7*, com a porta 8086 exposta para comunicação com a aplicação de aquisição de dados, figura 45 na página 63. Como já foi mencionado no capítulo anterior a comunicação entre os dois *containers* é estabelecida através de uma rede Docker personalizada, garantindo o isolamento do tráfego e melhorando a segurança do sistema [52].

A implementação em *container* oferece várias vantagens operacionais, incluindo a consistência entre ambientes de desenvolvimento e produção, facilidade de implementação e a capacidade de escalar serviços individualmente conforme as necessidades do projeto.

2.4.4.2 Configuração e personalização

A configuração do *Grafana* foi adaptada especificamente para as necessidades de monitorização dos parâmetros elétricos dos IGBTs e valores de tensão em circuito LV. Foram desenvolvidos *dashboards* personalizados que permitem a visualização em tempo real. Cada *dashboard* incorpora múltiplos painéis que apresentam os

dados de forma clara e intuitiva, facilitando a interpretação por parte dos colaboradores.

A ligação entre o *Grafana* e o *InfluxDB* foi configurada utilizando o conector nativo, permitindo consultas eficientes aos dados temporais através da linguagem *InfluxQL*. Esta integração permite não apenas a visualização de dados em tempo real, mas também a análise histórica e a identificação de tendências nos parâmetros monitorizados [57].

2.4.4.3 Aplicação ao Caso de Estudo

No contexto específico da monitorização da placa de 5.2KW e 8 KW, o *Grafana* tem demonstrado excelentes capacidades para visualizar os parâmetros críticos dos IGBTs. O sistema permite correlacionar diferentes métricas e identificar padrões que poderiam passar despercebidos numa análise convencional.

A capacidade de criar *queries*, cf. Figura 48, combinada com a flexibilidade de visualização do *Grafana*, tem sido fundamental para a análise do comportamento dos componentes em diferentes condições operacionais. Por exemplo, é possível correlacionar variações nas resistências G-E com mudanças nas tensões de diodo, permitindo uma compreensão mais profunda na validação dos componentes [39].

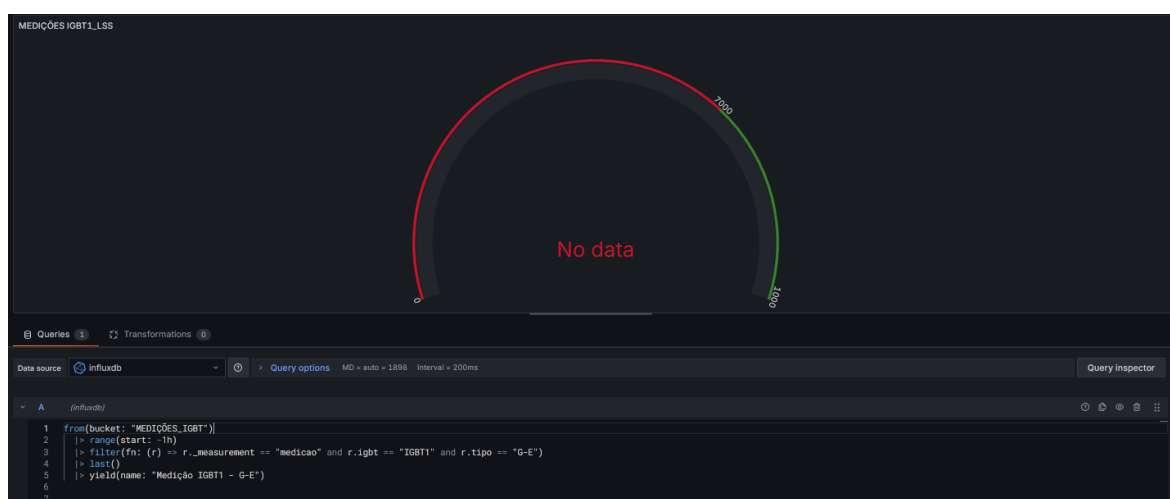


Figura 48 - Exemplo da query e do Dashboard Gauge

Como síntese, a tabela 15, da página seguinte, mostra um resumo da arquitetura da infraestrutura de dados

Tabela 15 - Resumo da Arquitetura e Configuração da Infraestrutura de Dados Contentorizada

Componente / Conceito	Tecnologia / Ferramenta	Papel no Sistema Flex ICT	Benefícios/Justificação
Plataforma de Contentorização	<i>Docker Desktop</i>	Ambiente de execução para os serviços de dados (<i>InfluxDB</i> , <i>Grafana</i>)	Portabilidade, reprodutibilidade e isolamento. Elimina conflitos de dependências e garante ambiente consistente entre desenvolvimento e produção
Gestão de Serviços	<i>Docker Compose</i> (ficheiro docker-compose.yml)	Define, configura e inicia automaticamente os <i>containers</i> do <i>InfluxDB</i> e <i>Grafana</i> como serviços interligados	Automação e consistência. Permite iniciar toda a infraestrutura com um comando (docker-compose up -d). Define dependências (<i>Grafana</i> só inicia após o <i>InfluxDB</i>)
Automação da Iniciação	<i>Script Python</i> DockerDesktop.py	Integra a inicialização dos <i>containers</i> no fluxo principal da aplicação <i>Python</i> , usando subprocess.run.	Fiabilidade e controlo. Garante que os serviços estão operacionais antes das medições, com tratamento de exceções para falhas (ex: <i>Docker</i> não instalado)
Armazenamento de Dados Temporais	<i>InfluxDB</i>	Base de dados de séries temporais que armazena todas as medições elétricas	Otimizado para dados temporais. API HTTP eficiente, configuração inicial via variáveis de ambiente (utilizador, organização, <i>bucket</i>). Dados persistentes em volume local (./influxdb_data)
Visualização e Dashboards	<i>Grafana</i>	Plataforma de visualização que consulta o <i>InfluxDB</i> para criar <i>dashboards</i> interativos em tempo real	Visualização poderosa e flexível. <i>Dashboards</i> personalizados para parâmetros elétricos (ex: resistências G-E, tensões). Ligação nativa ao <i>InfluxDB</i> usando <i>InfluxQL</i>
Arquitetura de Integração	Rede <i>Docker</i> personalizada	Liga os <i>containers</i> <i>InfluxDB</i> e <i>Grafana</i> , separando o tráfego	Segurança e desempenho. Comunicação direta e isolada entre serviços. Separação clara de responsabilidades (armazenamento vs apresentação)
Benefício Global da Abordagem	Contentorização com <i>Docker</i>	Enquadramento tecnológico unificador para os serviços de dados	Manutenibilidade, escalabilidade e imutabilidade. Versão do ambiente, fácil replicação noutras máquinas, e atualizações independentes de cada serviço

2.4.5 YOLOv8

2.4.5.1 *Limitações do SSIM e Transição para YOLOv8*

Apesar das suas vantagens em contextos de controlo de qualidade onde se compara uma imagem de referência com uma versão degradada, o SSIM revelou-se inadequado para o cenário específico de classificação de diferentes modelos de PCBAs. A principal limitação deve-se com a sua natureza fundamental de comparação direta par-a-par. Para identificar uma placa, o sistema teria de comparar a imagem capturada da placa desconhecida contra uma imagem de referência de cada modelo possível. Dado que as PCBAs MOPF 5.2KW e 8KW partilham uma arquitetura visual e componentes semelhantes, as suas diferenças subtis eram insuficientes para produzir um valor SSIM decisivamente mais baixo para o modelo incorreto. O algoritmo falhava em capturar e ponderar as características discriminativas específicas, tratando diferenças críticas (como a presença ou ausência de um componente) com a mesma importância que variações menores de iluminação.

Um problema ainda mais crítico ocorria quando não existia qualquer placa no campo de visão, ou seja, colocada na base. Neste cenário, a imagem capturada (da base de fixação vazia) era comparada com as imagens de referência das PCBAs, e o algoritmo invariavelmente atribuía um score de similaridade ligeiramente mais elevado a uma das placas, detetando sempre a placa de 8KW com uma precisão ainda mais elevada do que quando a placa estava colocada na base. resultando numa falsa identificação positiva. A incapacidade do SSIM de determinar a presença de um objeto, em oposição à sua mera semelhança estrutural, tornou-o impraticável para uma aplicação que requer uma deteção e classificação robustas. Estas limitações, inerentes a métodos de comparação de imagem tradicionais, motivaram a transição para uma abordagem baseada em *deep learning* com o algoritmo YOLOv8, que é intrinsecamente capaz de detetar objetos e classificá-los com base em características hierárquicas complexas aprendidas durante o treino [27], resolvendo assim os problemas de baixa discriminação e falsos positivos.

Esta versão introduz melhorias significativas na arquitetura, destacando-se pela transição para uma abordagem de detecção sem âncoras, que simplifica o pipeline e melhora a generalização [7][31]. A arquitetura incorpora mecanismos de atenção, como o *Convolutional Block Attention Module* (CBAM), e técnicas avançadas de *data augmentation* para maior robustez em condições variáveis [7][29]. Estruturalmente modular e baseado em PyTorch, o modelo facilita a personalização e o treino para aplicações específicas, como inspeção visual automatizada e detecção de defeitos [1][32]. Através da interface simplificada do pacote *ultralytics*, o YOLOv8 consolida-se como uma solução escalável e adaptável, adequada tanto para a indústria 4.0 como para investigação em visão computacional [25].




Figura 49 - Características de várias versões do YOLO, (Ultralytics)

Com base nos gráficos comparativos da figura 49, o YOLOv8 demonstra superioridade técnica tanto em eficácia como em eficiência. Em termos de precisão (mAP), ele supera consistentemente as versões anteriores para qualquer tamanho de modelo, atingindo, por exemplo, 52.0 mAP com cerca de 50M de parâmetros, contra os 48.0 do YOLOv5-7.0, o que evidencia os ganhos da sua arquitetura *anchor-free* e dos mecanismos de atenção [1, 29]. Além de uma maior precisão, o YOLOv8 também oferece o melhor equilíbrio entre velocidade e precisão, posicionando-se no gráfico de latência com uma curva mais alta e à esquerda, o que significa que, para um mesmo tempo de inferência, proporciona uma detecção mais precisa. Consequentemente, a escolha do YOLOv8 para o sistema de visão do projeto justifica-se pela sua capacidade única de fornecer alta precisão (>90%

na tarefa específica) com baixa latência, um requisito fundamental para inspeção industrial automatizada que exige fiabilidade e rapidez de resposta.

Estrutura do dataset

A preparação e organização do *dataset* são etapas fundamentais no desenvolvimento de modelos de deteção de objetos baseados em redes neuronais convolucionais, como o YOLOv8. A estrutura adotada, cf. Figura 50, 51 e 52 das páginas seguintes, segue uma divisão clássica entre os conjuntos de treino (*train*) e validação (*val*), cada um contém subpastas *images* e *labels* [25]. Esta organização é compatível com os requisitos da *framework Ultralytics* e facilita a gestão dos dados ao longo do ciclo de treino e avaliação.

Na pasta *images* contém as imagens originais que serão usadas para treino e validação em um dos seguintes formatos *.jpg*, onde cada imagem representa uma amostra visual que pode conter uma ou mais instâncias de objetos a detetar tendo obrigatoriamente de o nome dos ficheiros ser único e consistente com os ficheiros da pasta *labels*.

Na pasta *labels* contém os ficheiros de anotação correspondentes às imagens com formato *.txt*, com o mesmo nome da imagem, onde cada linha representa uma instância de objeto com o seguinte formato: `<class_id> <x_center> <y_center> <width> <height>`, todos os valores são normalizados entre 0 e 1, em relação à largura e altura da imagem, e *class_id* corresponde à classe definida no ficheiro *data.yaml*.

A escolha da proporção 80% para treino e 20% para validação baseia-se em práticas consolidadas na literatura científica, que apontam para este equilíbrio como ideal para garantir simultaneamente uma aprendizagem robusta e uma avaliação fiável da capacidade de generalização do modelo [27][39]. O conjunto de treino fornece ao modelo exemplos variados para aprender os padrões visuais relevantes, enquanto o conjunto de validação é utilizado para medir o desempenho em dados não vistos, permitindo identificar fenómenos como o sobre ajustamento (*overfitting*) [7][30].

Durante o processo de treino, o modelo YOLOv8 ajusta os seus parâmetros internos com base nas imagens e respetivas anotações presentes no conjunto de treino. A cada época, o desempenho é avaliado sobre o conjunto de validação, através de métricas como a precisão, o *recall* e a média da precisão (mAP), sendo esta última particularmente relevante em tarefas de deteção de objetos. Esta abordagem permite monitorizar a evolução do modelo e tomar decisões informadas sobre a sua maturidade e prontidão para integração em ambiente produtivo.

A separação 80/20 revela-se especialmente eficaz quando o número total de imagens é limitado, garantindo que o modelo dispõe de dados suficientes para aprender sem comprometer a fiabilidade da avaliação. Em contextos industriais, esta metodologia contribui para a construção de sistemas de inspeção automática mais robustos, escaláveis e adaptáveis a variações visuais subtis entre classes [1][28].

train	28/10/2025 15:05		
val	28/10/2025 15:05		
data	18/09/2025 17:31	images	28/10/2025 15:05
TreinoPCBA_YOLO	15/09/2025 17:19	labels	28/10/2025 15:05

Figura 50 - Organização do dataset e distribuição dos ficheiros nas pastas train e Val




Figura 51 - Algumas imagens utilizadas no treino do modelo YOLOv8

MOPF5.2KW_1_aug_0	MOPF5.2KW_2_aug_3	MOPF5.2KW_3_aug_5	MOPF5.2KW_4_aug_5	MOPF5.2KW_5_aug_9
MOPF5.2KW_1_aug_2	MOPF5.2KW_2_aug_4	MOPF5.2KW_3_aug_6	MOPF5.2KW_4_aug_7	MOPF5.2KW_5_aug_11
MOPF5.2KW_1_aug_3	MOPF5.2KW_2_aug_5	MOPF5.2KW_3_aug_7	MOPF5.2KW_4_aug_8	MOPF5.2KW_5_aug_12
MOPF5.2KW_1_aug_4	MOPF5.2KW_2_aug_6	MOPF5.2KW_3_aug_8	MOPF5.2KW_4_aug_9	MOPF5.2KW_5_aug_13
MOPF5.2KW_1_aug_5	MOPF5.2KW_2_aug_7	MOPF5.2KW_3_aug_9	MOPF5.2KW_4_aug_10	MOPF5.2KW_5_aug_14
MOPF5.2KW_1_aug_6	MOPF5.2KW_2_aug_8	MOPF5.2KW_3_aug_10	MOPF5.2KW_4_aug_11	MOPF5.2KW_5_aug_15
MOPF5.2KW_1_aug_7	MOPF5.2KW_2_aug_9	MOPF5.2KW_3_aug_11	MOPF5.2KW_4_aug_12	MOPF5.2KW_5_aug_18
MOPF5.2KW_1_aug_8	MOPF5.2KW_2_aug_10	MOPF5.2KW_3_aug_12	MOPF5.2KW_4_aug_13	MOPF5.2KW_5_aug_19
MOPF5.2KW_1_aug_11	MOPF5.2KW_2_aug_11	MOPF5.2KW_3_aug_13	MOPF5.2KW_4_aug_14	MOPF5.2KW_6_aug_0
MOPF5.2KW_1_aug_12	MOPF5.2KW_2_aug_13	MOPF5.2KW_3_aug_14	MOPF5.2KW_4_aug_15	MOPF5.2KW_6_aug_1
MOPF5.2KW_1_aug_13	MOPF5.2KW_2_aug_14	MOPF5.2KW_3_aug_15	MOPF5.2KW_4_aug_16	MOPF5.2KW_6_aug_2
MOPF5.2KW_1_aug_14	MOPF5.2KW_2_aug_15	MOPF5.2KW_3_aug_16	MOPF5.2KW_4_aug_17	MOPF5.2KW_6_aug_3
MOPF5.2KW_1_aug_15	MOPF5.2KW_2_aug_16	MOPF5.2KW_3_aug_17	MOPF5.2KW_4_aug_18	MOPF5.2KW_6_aug_4
MOPF5.2KW_1_aug_16	MOPF5.2KW_2_aug_17	MOPF5.2KW_3_aug_18	MOPF5.2KW_4_aug_19	MOPF5.2KW_6_aug_5

Figura 52 - Pasta labels

Na figura 54, da página seguinte, é demonstrado o código em *Python* utilizado para treinar o modelo de deteção das PCBAs. Importa a classe YOLO da biblioteca oficial da *Ultralytics*, que fornece uma interface simplificada para treinar, validar e usar modelos YOLOv8. Carrega o modelo pré-treinado YOLOv8s, que serve como ponto de partida para o treino. caminho para o ficheiro `data.yaml`, que define o *dataset* (classes, caminhos para imagens de treino/validação).

`epochs=50`: número de épocas (ciclos completos de treino).

`imgsz=640`: dimensão das imagens usadas durante o treino (640x640 pixels).

O modelo é treinado com base nas imagens e classes definidas no ficheiro *YAML*, cf. Figura 53. Mostra os resultados do treino, incluindo métricas como perda, precisão (mAP), e tempo por época. Por fim guarda o modelo ajustado com os novos pesos para um ficheiro chamado `modelo_PCBA.pt`

```

1  names:
2    0: 5.2KW
3    1: 8KW
4  path: C:\Users\marci\Desktop\MEEA\PF - Projecto final\Implementar\5.2KW\YOLO 17_09\Augmented_Dataset
5  train: train/images
6  val: val/images
7  |

```

Figura 53 - Código do ficheiro `data.yaml`

O código do ficheiro `data.yaml` informa o modelo YOLO sobre:

- Quais são as classes a detetar
- Onde estão localizados os dados de treino e validação
- Como estruturar o processo de aprendizagem

```
1 from ultralytics import YOLO
2
3 # Carregar modelo
4 model = YOLO('yolov8s.pt')
5
6 # Treinar modelo
7 results = model.train(
8     data=r"C:\Users\marci\Desktop\MEEA\PF - Projecto final\Implementar\5.2KW\Testes 12_09\DatasetPCBA\data.yaml",
9     epochs=50,
10    imgsiz=640
11 )
12 print(results)
13 model.save(["modelo_PCBA.pt"])
```

Figura 54 - Código utilizado no treino do modelo Yolo

O processo de treino, cf. Figura 55, foi conduzido através do *framework* *PyTorch*, utilizando o pacote *ultralytics*, que simplifica a configuração e execução de modelos YOLOv8. Foram definidos parâmetros como o número de épocas e a dimensão das imagens, com o objetivo de otimizar a precisão do modelo sem comprometer o tempo de inferência. Após o treino, o modelo foi guardado no formato *.pt* (*PyTorch*), permitindo a sua integração direta com o sistema principal desenvolvido em *Python*, responsável pela coordenação do robô de inspeção e restante hardware.

```
Epoch  GPU_mem  box_loss  cls_loss  dfl_loss  Instances  Size
14/15   0G        0.2014    0.8888    0.8469    1          640: 100% 2/2 0.0it/s 1:22
      Class  Images  Instances  Box(P)    R    mAP50  mAP50-95): 100% 1/1 0.8it/s 1.2s
      all    3        3        0.633    1    0.995    0.945

Epoch  GPU_mem  box_loss  cls_loss  dfl_loss  Instances  Size
15/15   0G        0.1722    0.8414    0.9701    1          640: 100% 2/2 0.0it/s 1:46
      Class  Images  Instances  Box(P)    R    mAP50  mAP50-95): 100% 1/1 1.4it/s 0.7s
      all    3        3        0.639    1    0.995    0.945

15 epochs completed in 0.411 hours.
Optimizer stripped from C:\Users\marci\runs\detect\train6\weights\last.pt, 22.5MB
Optimizer stripped from C:\Users\marci\runs\detect\train6\weights\best.pt, 22.5MB

Validating C:\Users\marci\runs\detect\train6\weights\best.pt...
ultralytics 8.3.198 Python-3.12.0 torch-2.8.0+cpu CPU (11th Gen Intel Core i7-1165G7 @ 2.80GHz)
Model summary (fused): 72 layers, 11,126,358 parameters, 0 gradients, 28.4 GFLOPs
      Class  Images  Instances  Box(P)    R    mAP50  mAP50-95): 100% 1/1 0.9it/s 1.2s
      all    3        3        0.639    1    0.995    0.945
      5.2KW    2        2        0.984    1    0.995    0.895
      8KW     1        1        0.293    1    0.995    0.995

Speed: 1.4ms preprocess, 362.2ms inference, 0.0ms loss, 7.0ms postprocess per image
Results saved to C:\Users\marci\runs\detect\train6
```

Figura 55 - Resultado de um processo de treino, 15 épocas, modelo yolov8n.pt

yolov8s.pt vs yolov8n.pt

Os modelos da família YOLOv8 seguem uma filosofia de escalonamento baseada no tamanho do modelo (nano, small, medium, large, etc.), oferecendo diferentes equilíbrios entre velocidade de inferência, complexidade computacional e precisão. O modelo yolov8n.pt (nano) é a versão mais leve, otimizada para ambientes com recursos limitados, apresentando um menor número de parâmetros, menor tamanho do ficheiro e maior velocidade de inferência, à custa de uma precisão ligeiramente inferior. Em contrapartida, o yolov8s.pt (small) apresenta um número superior de parâmetros e maior complexidade computacional, resultando num aumento de desempenho em métricas como o mAP, embora com alguma perda na velocidade [7][25].

Inicialmente, optou-se pela versão yolov8n.pt por ser a mais leve e rápida, aspetos relevantes para uma potencial integração futura em sistemas com recursos mais limitados. No entanto, durante os primeiros ensaios de treino com o meu dataset, observou-se que a precisão das deteções ficava aquém do desejado, especialmente na distinção entre os dois modelos, que apresentam diferenças subtis.

A transição para yolov8s.pt, corrigiu os problemas anteriores e os resultados obtidos revelaram-se significativamente mais robustos, com melhorias expressivas na precisão da identificação. Este ganho de desempenho justificou plenamente a adoção desta versão no sistema final, uma vez que a fiabilidade da identificação é prioritária num contexto laboratorial, onde o custo de uma troca de placa ou teste incorreto supera largamente o ligeiro acréscimo no tempo de processamento, a comparação técnica dos dois modelos estudados pode ser vista na tabela 16.

*Tabela 16 - Comparação técnica entre os modelos YOLOv8n e YOLOv8s**

Modelo	Tamanho do ficheiro (MB)	Parâmetros (M)	FLOPs (G)	mAP ₅₀₋₉₅ (%)	Velocidade de inferência (ms/img, GPU)
YOLOv8n	≈ 6.2	3.2	8.7	37.3	≈ 1.2
YOLOv8s	≈ 22.0	11.2	28.6	44.9	≈ 1.9

**Fonte: Dados adaptados da documentação oficial Ultralytics YOLOv8.*

2.4.6 Bibliotecas e ferramentas de desenvolvimento

O desenvolvimento do *software* para esta prova de conceito recorreu a um conjunto abrangente de bibliotecas externas para apoiar o processamento de imagem, a comunicação com o *hardware*, a gestão de dados e a criação de interfaces gráficas, cf. Tabelas 17 e 18. A integração destas ferramentas permitiu garantir modularidade, desempenho e escalabilidade em todas as etapas do sistema, desde a aquisição e tratamento dos dados até à sua apresentação visual.

Tabela 17 - Especificação das Principais Bibliotecas Python por Módulo Funcional

Aplicação	Bibliotecas	Finalidade Específica no Sistema	Scripts / Módulos de Exemplo no Projeto	Referência
Interface Gráfica (GUI)	Tkinter	Criação da estrutura base da GUI (janelas, botões, menus).	InterfaceGrafica.py Camara_APP.py	[22] [58]
	ttkbootstrap	Aspeto visual e experiência do utilizador	InterfaceGrafica.py Dashboard.py	[59]
	Pillow (PIL)	Tratamento e exibição de imagens na GUI	Camara_APP.py	[60]
Visão Computacional (Machine Learning)	ultralytics	API de alto nível para treino e inferência com o modelo YOLOv8	TreinoPCBA_YOLO.py, YOLO.py	[25]
	OpenCV (cv2)	Aquisição e processamento básico do fluxo de vídeo	YOLO.py, Camara_APP.py	[58]
	os, shutil, random	Gestão de ficheiros, divisão de <i>datasets</i> e aumento de dados (<i>data augmentation</i>)	Split_dataset.py, data_augmentation.py	

Tabela 18 - Especificação das Principais Bibliotecas Python por Módulo Funcional

Aplicação	Bibliotecas	Finalidade Específica no Sistema	Scripts / Módulos de Exemplo no Projeto	Referência
Comunicação com Hardware	pyserial	Comunicação série (UART) com o microcontrolador ESP32	Esp32.py	[58]
	socket, json	Comunicação TCP/IP para controlo do robô colaborativo	EliteRobot.py	
	canlib.linlib	Comunicação com o barramento LIN (interface Kvaser)	Kvaser_Lin.py	[34]
	pyvisa	Controlo remoto do multímetro Keithley DMM6500 via comandos SCPI [64]	Multimetro_KeithleyDMM6500.py	[58]
Gestão de Dados e Integração	pandas	Manipulação de dados e exportação para CSV	Scripts de medição	[58]
	influxdb-client	Comunicação via API HTTP para armazenamento na base de dados temporal InfluxDB	InfluxDB.py	[56]
	Grafana	Plataforma para criação de <i>dashboards</i> interativos de visualização de dados	Dashboard.py	[57]
	csv, datetime, pathlib	Leitura/escrita de ficheiros CSV, geração de <i>timestamps</i> e gestão de localizações	Vários scripts	
Utilitários	threading	Garantir a responsividade da interface durante operações bloqueantes	Programas de medição	[58]
	subprocess	Execução e gestão de processos externos (ex: <i>containers Docker</i>)	DockerDesktop.py	[58]
	queue, logging	Gestão de filas para comunicação entre <i>threads</i> e registo de eventos do sistema	Vários scripts	
	pathlib	Manipulação robusta de localizações de ficheiros e pastas	Vários scripts	

3 RESULTADOS E ANÁLISE DE DADOS

O presente capítulo tem como objetivo a apresentação e análise crítica dos resultados obtidos com a aplicação desenvolvida para a medição automatizada de grandezas elétricas em PCBAs, focando-se na fase de integração e validação do sistema completo. A avaliação efetuada é multidimensional, visando aferir o cumprimento dos objetivos inicialmente definidos para o projeto, designadamente: a precisão e robustez na identificação automática de diferentes PCBAs, a exatidão e fiabilidade dos valores obtidos nas medições elétricas realizadas, e a eficácia da integração dos diversos subsistemas de *hardware* que constituem a solução final.

Para além da análise puramente técnica, é avaliada a adequação da solução proposta face aos processos e metodologias atualmente em vigor na organização, analisando-se o seu grau de compatibilidade, a facilidade de adoção e o impacto potencial na rotina operacional. Esta avaliação é sustentada por dados empíricos recolhidos durante um período de testes em ambiente controlado de laboratório, o que permitiu observar o comportamento do sistema em condições próximas das reais, incluindo a sua interação com o robô colaborativo e os instrumentos de medição.

3.1 DESEMPENHO DO SISTEMA DE VISÃO

3.1.1 Desempenho do SSIM



Figura 57 - Classificação da PCBA 5.2KW com SSIM




Figura 56 - Classificação da PCBA 8KW com SSIM

As imagens da figura 56 e 57 correspondem ao processo de classificação automática utilizando o algoritmo SSIM. O sistema atribuiu à imagem a classe 5.2KW, com um valor de confiança de 33.2% e um valor médio de SSIM de 0.432. O algoritmo SSIM foi aplicado através da comparação entre a imagem captada e uma imagem de referência associada a cada classe, considerando componentes de estrutura, luminosidade e contraste.

No ensaio correspondente à PCBA 8KW, o sistema atribuiu um valor de confiança de 51.8%, com um valor médio de SSIM de 0.430. Em ambos os casos, os valores de SSIM obtidos situaram-se abaixo de 0.5.

3.1.2 Resultados do Modelo YOLOv8

Após os testes realizados com o algoritmo SSIM, foi implementada uma abordagem baseada na arquitetura YOLOv8. O modelo foi treinado com um conjunto de dados personalizado constituído por 320 imagens de PCBAs dos modelos 5.2KW e 8KW.

3.1.2.1 Resultados do Treino Inicial

Os primeiros testes utilizaram o modelo YOLOv8n, treinado com um conjunto de três imagens, composto por uma imagem sem PCBA e uma imagem representativa de cada classe. O treino foi realizado ao longo de 15 épocas. Os valores obtidos para as métricas de precisão e mAP foram registados como insuficientes, cf. Figura 59 e 60 da página seguinte.

O treino foi posteriormente prolongado para 30 épocas, cf. Figura 58, mantendo-se o mesmo conjunto de imagens. Os valores obtidos para as métricas mantiveram-se próximos dos registados no treino inicial, conforme apresentado na Figura 58.

```

all      3      3      0.00331      1      0.663      0.638

Epoch  GPU_mem box_loss cls_loss dfl_loss Instances      Size
19/30   0G      0.5401  1.352   1.123   2          640: 100%
Class   Images Instances Box(P)      R      mAP50  mAP50-95): 100% 2/2 0.4it/s 5.1s
all      3      3      0.0033      1      0.663      0.663

Epoch  GPU_mem box_loss cls_loss dfl_loss Instances      Size
20/30   0G      0.5005  1.69    1.027   2          640: 100%
Class   Images Instances Box(P)      R      mAP50  mAP50-95): 100% 2/2 0.4it/s 5.3s
all      3      3      0.441     1      0.663      0.663

closing dataloader mosaic

Epoch  GPU_mem box_loss cls_loss dfl_loss Instances      Size
21/30   0G      0.3664  1.868   1.036   1          640: 100%
Class   Images Instances Box(P)      R      mAP50  mAP50-95): 100% 2/2 0.4it/s 5.1s
all      3      3      0.511     1      0.663      0.663

Epoch  GPU_mem box_loss cls_loss dfl_loss Instances      Size
22/30   0G      0.2799  1.519   0.8619  1          640: 100%
Class   Images Instances Box(P)      R      mAP50  mAP50-95): 100% 2/2 0.4it/s 5.4s
all      3      3      0.00331   1      0.663      0.663

Epoch  GPU_mem box_loss cls_loss dfl_loss Instances      Size
23/30   0G      0.3208  1.532   0.9674  1          640: 100%
Class   Images Instances Box(P)      R      mAP50  mAP50-95): 100% 2/2 0.4it/s 5.4s
all      3      3      0.00333   1      0.663      0.547

Epoch  GPU_mem box_loss cls_loss dfl_loss Instances      Size

```

Figura 58 - Fase de treino com 3 imagens e 30 épocas




Figura 59 - Resultado do treino com 3 imagens e 30 épocas



Figura 60 - PCBA de 5.2KW identificada como 8KW

3.1.2.2 Resultados do Treino com Dataset Expandido

O número de imagens utilizadas no treino foi progressivamente aumentado, sendo utilizado o modelo YOLOv8s. O conjunto de validação foi constituído por 58 imagens, contendo um total de 53 instâncias.

As métricas globais obtidas no conjunto de validação são apresentadas na Tabela 19.

Tabela 19 - Métricas de avaliação do modelo YOLOv8 no conjunto de validação.

Métrica	Precision	Recall	mAP50	mAP50-95
Valor	98.3%	99.8%	99.5%	98.5%

3.1.2.3 Resultados por Classe

A Tabela 20 apresenta os resultados obtidos por classe no conjunto de validação. Para a classe 5.2KW, foram utilizadas 39 imagens, correspondentes a 39 instâncias. Para a classe 8KW, foram utilizadas 14 imagens, correspondentes a 14 instâncias.

Tabela 20 - Desempenho detalhado por classe do modelo YOLOv8.

Classe	Imagens	Instâncias	Precison	Recall	mAP50	mAP50-95
5.2KW	39	39	96.7%	100%	99.5%	98.7%
8KW	14	14	100%	99.6%	99.5%	98.3%

3.1.2.4 Comparação Numérica entre Modelos YOLOv8n e YOLOv8s

Foi realizada uma comparação entre os modelos **YOLOv8n** e **YOLOv8s**, utilizando o mesmo conjunto de imagens e o mesmo número de épocas de treino. A comparação baseou-se nos valores de **mAP50-95** obtidos para as três classes avaliadas. Os valores correspondentes são apresentados no Gráfico 1.




Gráfico 1 - YOLOv8n vs YOLOv8s usando os valores reais de mAP50-95, Fonte: Ultralytics

3.1.2.5 Resultados em Ambiente Operacional

O modelo YOLOv8 foi integrado no sistema de visão artificial e testado em ambiente operacional. Durante esta fase, foram realizadas várias execuções do sistema em tempo real, envolvendo a identificação e classificação de PCBAs.

Nos ensaios em que a base de fixação se encontrava vazia, o modelo não produziu qualquer deteção. Quando uma PCBA estava presente, o sistema produziu deteções associadas às classes correspondentes. As Figuras 61, 62 e 63

apresentam exemplos da saída do sistema, incluindo os *bounding boxes* e as classes atribuídas às PCBA's detetadas.




Figura 61 - Resultado sem PCBA



Figura 62 - Resultado PCBA 5.2KW com taxa de precisão de 92.9%



Figura 63 - Resultado PCBA 8KW com taxa de precisão de 97.9%

3.1.2.6 *Análise Estatística da identificação*

Foi realizada uma análise estatística ao desempenho do sistema de visão computacional baseado no modelo YOLOv8, com o objetivo de caracterizar quantitativamente os resultados obtidos no processo de identificação automática de PCBAs dos tipos 5.2KW e 8KW.

A análise baseou-se num conjunto de 120 *snapshots* sequenciais, recolhidos durante a operação do sistema. Para cada *snapshot* foi registado o valor de precisão associado à classe identificada. O tratamento e análise dos dados foram efetuados recorrendo ao Google Colab, utilizando técnicas de estatística descritiva. O critério de aceitação considerado para a análise foi um limite mínimo de precisão de 90.0%, definido com base nos requisitos operacionais do sistema [7].

```
✓ ANÁLISE - SISTEMA DE VISÃO
=====
🔗 DESEMPENHO DO SISTEMA DE VISÃO:
=====
📊 8KW:
  Snapshots: 69
  Precisão: 96.0% (média)
  Variação: 92.0% a 98.4%
  Consistência: ±1.6%
  ✓ Todos acima de 90.0%

📊 5.2KW:
  Snapshots: 51
  Precisão: 94.8% (média)
  Variação: 92.2% a 97.7%
  Consistência: ±1.6%
  ✓ Todos acima de 90.0%

📊 COMPARAÇÃO ENTRE CLASSES:
=====
Diferença: 1.2%
8KW é 1.2% mais preciso que 5.2KW
```

Figura 64 - Resultado da análise feita ao sistema de visão deep learning (Google Colab)




Gráfico 2 - Gráficos estatísticos do sistema de visão deep learning, (Google Colab)

Os dados agregados da avaliação são apresentados na Figura 64 da página anterior e no Gráfico 2. Para a classe 8KW, a precisão média observada foi de 96.0%, com uma variação entre 92.0% e 98.4%. Para a classe 5.2KW, a precisão média foi de 94.8%, com uma variação entre 92.2% e 97.7%. A diferença entre as precisões médias das duas classes foi de 1.2%.

No gráfico de "Precisão Média por Classe", os valores para ambas as classes situam-se acima da linha de referência de 90.0%. Os gráficos de "Distribuição das Precisoões" e "Comparação de Precisão" mostram a dispersão dos valores para cada classe. O gráfico de "Evolução ao Longo do Tempo" apresenta a sequência das precisões obtidas em cada *snapshot* para ambas as classes.

3.2 PRECISÃO E REPETIBILIDADE DAS MEDIÇÕES ELÉTRICAS

3.2.1 Validação do Sistema Automatizado vs. Método Manual

Para validar a precisão fundamental do sistema automatizado, os seus valores medidos foram comparados com valores de referência obtidos através do método manual. A metodologia consistiu em comparar a média de 20 medições consecutivas realizadas pelo sistema automatizado em cada ponto de teste com uma única medição de referência, executada manualmente com o mesmo multímetro de alta precisão, nas mesmas condições e pontos de teste de ambas as PCBAs.

A concordância entre os dois métodos foi quantificada através do cálculo da diferença relativa percentual, utilizando a seguinte fórmula [68]:

$$\text{Diferença Relativa (\%)} = | (\text{Média Automática} - \text{Valor Manual}) / \text{Valor Manual} | \times 100\%$$

Os resultados desta análise crítica são apresentados na Tabela 21 e na Tabela 22.

Tabela 21 - Validação da Precisão do Sistema Automatizado MOPF 5.2KW

Parâmetro Medido	Valor de referência (Manual)	Média de 20 medições em automático	Diferença Relativa (%)
Resistência E-C (IGBT1) (Ω)	120432	120977,79	-0,0038
Resistência G-E (IGBT1) (Ω)	7319,39	7286,52	-0,0045
Tensão Díodo E-C (IGBT1) (V)	0,81	0,81	0,0000
Resistência E-C (IGBT2) (Ω)	117105,69	118358	0,0077
Resistência G-E (IGBT2) (Ω)	3325,84	3310,32	0,0020
Tensão Díodo E-C (IGBT2) (V)	0,77	0,77	0,0000
Resistência G-E (IGBT3) (Ω)	100299,70	100395,92	0,0010
Resistência G-E (IGBT3) (Ω)	73370,60	73161,78	-0,0028
Resistência G-E (IGBT3) (Ω)	1051529	1051110,75	-0,0004
VCC Digital Isolator (V)	4,9955	4,996	0,0001
TP1137 TprgL1104 (V)	4,9953	4,996	0,0001
TP1135 TprgL1102 XresLV (V)	4,9805	4,981	0,0001
TP1133 TprgL1100 SWDIOLV (V)	4,9564	4,963	0,0013
Conetor LV (V)	12,988	12,987	-0,0001

Com base nos resultados apresentados na Tabela 21, foram calculadas as diferenças relativas percentuais entre o valor de referência manual e a média de 20 medições automáticas.

A totalidade das 14 medições apresentou diferenças relativas inferiores a 0,008%, com a maioria abaixo dos 0,005%.

Das 14 medições analisadas, 13 apresentaram diferenças relativas inferiores a 0,005%. Apenas uma medição (Resistência E-C IGBT2) apresentou diferença relativa de 0,0077%, ligeiramente acima dos 0,005%.

As medições de tensão (VCC Digital Isolator, TP1137, TP1135, TP1133 e Conetor LV) apresentaram diferenças inferiores a 0,0014%.

Tabela 22 - Validação da Precisão do Sistema Automatizado MOPF 8KW

Parâmetro Medido	Valor de referência (Manual)	Média de 20 medições em automático	Diferença Relativa (%)
Resistência E-C (IGBT1) (Ω)	31922,50	32923,31	0,0314
Resistência G-E (IGBT1) (Ω)	8855,20	8862,85	0,0008
Resistência C-E (IGBT1) (Ω)	648658,00	649091,32	0,0007
Resistência E-C (IGBT2) (Ω)	32316,00	32095,98	-0,0068
Resistência G-E (IGBT2) (Ω)	14988,80	14978,45	-0,0007
Resistência C-E (IGBT2) (Ω)	647826,00	647176,26	-0,0010
Resistência E-C (IGBT3) (Ω)	32708,70	32545,00	-0,0050
Resistência G-E (IGBT3) (Ω)	14968,60	14960,93	-0,0005
Resistência C-E (IGBT3) (Ω)	647729,00	647394,88	-0,0005
Resistência E-C (IGBT4) (Ω)	116759,00	116968,49	0,0018
Resistência G-E (IGBT4) (Ω)	7354,52	7343,56	-0,0015
Tensão Díodo E-C (IGBT4) (V)	0,81	0,81	0
Resistência E-C (IGBT5) (Ω)	113842,00	114216,49	0,0033
Resistência G-E (IGBT5) (Ω)	7351,22	7341,83	-0,0013
Tensão Díodo E-C (IGBT5) (V)	0,81	0,81	0
Resistência E-C (IGBT6) (Ω)	116367,00	116168,68	-0,0017
Resistência G-E (IGBT6) (Ω)	7330,72	7344,15	0,0018
Tensão Díodo E-C (IGBT6) (V)	0,81	0,81	0
INPUT U1200 V (V)	12,33	12,31	-0,0015
INPUT VOLTAGE T1300 (V)	12,22	12,20	-0,0015
5V_LV (V)	4,99	5,00	0,0002
AnClamp30_1 TP1114 (V)	2,60	2,60	-0,0007
AnClamp30_2 TP1114 (V)	2,03	2,03	-0,0010

Com base nos resultados apresentados na Tabela 22, foram calculadas as diferenças relativas percentuais entre o valor de referência manual e a média de 20 medições automáticas para a PCBA MOPF 8KW.

As diferenças relativas em valores absolutos situam-se entre 0% e 0,0314%.

Das 23 medições analisadas, a diferença relativa entre medição automática e medição manual a que apresentou o valor mais significativo foi a medição de resistência entre emissor e coletor no IGBT1 com 0,0314%

Em 12 medições, as diferenças relativas foram inferiores a 0,0015%, incluindo três medições com diferença nula (0,0000%) nos díodos dos IGBTs 4, 5 e 6.

As medições de tensão (INPUT U1200, INPUT VOLTAGE T1300, 5V_LV, AnClamp30_1 e AnClamp30_2) apresentaram diferenças inferiores a 0,0015%.

3.2.2 IGBTs PCBA 5.2KW

A análise de precisão e repetibilidade foi realizada na PCBA de 5.2KW, que compreende dois IGBTs em configuração LSS com o modelo RGS50TSX2DHR e um IGBT em HSS com o modelo RGS50TSX2HR, cf. Figura 65. O sistema de teste operou com o circuito sem energia. A ligação entre as pontas de teste, movimentadas pelo robô, e os relés de medição foi estabelecida através de fios elétricos de 0,50 mm² com cobre flexível, em distâncias de aproximadamente 1,5 m, medindo resistências acima de 7 k Ω [35].




Figura 65 - IGBT RGS50TSX2DHR e RGS50TSX2DHR

Nos dois IGBTs LSS, o protocolo de medição inclui três parâmetros fundamentais:

- Queda de Tensão no Díodo entre Emissor/Coletor: Valor esperado: entre 0,3V e 3V
- Resistência entre Emissor/Coletor Valor esperado: > 115 k Ω

- Resistência entre Gate/Emissor: Valor esperado: $> 7 \text{ k}\Omega$

No IGBT HSS, as medições realizadas compreendem:

- Resistência entre Coletor/Emissor: Valor esperado: $> 95 \text{ k}\Omega$
- Resistência entre Emissor/Coletor: Valor esperado: $> 1 \text{ M}\Omega$
- Resistência entre Gate/Emissor: Valor esperado: $> 70 \text{ k}\Omega$

3.2.2.1 *Análise Estatística dos Resultados do IGBT1 (LSS)*

Para validar o sistema de medição de parâmetros elétricos em IGBTs, foi implementada uma análise de capacidade do processo utilizando os índices estatísticos Cp e Cpk [39, 71]. Foram recolhidas 20 medições sequenciais, cf. Tabela 23, para cada um dos três parâmetros críticos dos IGBTs e foram estabelecidos limites de especificação (LSL - Limite inferior de especificação, USL - Limite superior de especificação) baseados nas características técnicas dos componentes. Todas as tabelas de valores de medição, à exceção do IGBT1, de 5.2KW podem ser verificadas no apêndice III.

- Resistência Emissor-Coletor (R_{EC})
- Resistência Gate-Emissor (R_{GE})
- Tensão do díodo Gate-Emissor (V_{GE})

Os índices de capacidade calculados foram:

- **Cp (Capacidade Potencial):** Avalia a capacidade potencial do processo face à variabilidade natural, e **Cpk (Capacidade Real):** Considera a centragem do processo, avaliando a capacidade real face à localização da média

$$C_p = \frac{USL - LSL}{6 \times \text{desvio padrão}}$$

$$C_{pk} = \text{mínimo} \left(\frac{USL - \text{médio}}{3 \times \text{desvio padrão}} , \frac{\text{médio} - LSL}{3 \times \text{desvio padrão}} \right)$$

A interpretação seguiu os referenciais da indústria [61]:

- $C_p/C_{pk} \geq 1,67$: Processo excelente
- $1,33 \leq C_p/C_{pk} < 1,67$: Processo capaz
- $1,00 \leq C_p/C_{pk} < 1,33$: Processo no limite
- $C_p/C_{pk} < 1,00$: Processo não capaz

A análise foi executada na plataforma *Google Colab* (Google Colaboratory), um ambiente de programação baseado em *cloud* que permite a execução de código *Python* diretamente no *browser* [62].

Tabela 23 - 20 medições do IGBT1

Nº Medição	Resistência E-C (Ω)	Resistência G-E (Ω)	Díodo E-C (V)
1	120136.1	7255,05	0.807
2	120149.7	7285.01	0.807
3	120068.8	7285.01	0.807
4	120049.7	7234.25	0.805
5	120320.8	7269.91	0.807
6	120268.2	7277.04	0.806
7	120068.3	7276.76	0.807
8	120363.0	7278.07	0.807
9	120103.7	7277.81	0.807
10	119431.8	7237.8	0.807
11	119372.6	7302.83	0.810
12	119673.8	7312.88	0.812
13	119745.2	7316.82	0.812
14	119898.1	7319.18	0.812
15	119914.8	7321.50	0.813
16	120091.4	7323.79	0.813
17	120166.9	7330.03	0.814
18	120328.0	7307.37	0.813
19	121068.9	7234.25	0.805
20	120336.1	7285.01	0.807

```

✓ ANÁLISE Cp/Cpk - IGBT1 5.2KW
=====
INTERVALOS DE VALIDAÇÃO:
R_EC: LSL = 113000Ω, USL = 123000Ω
R_GE: LSL = 7000Ω, USL = 10000Ω
Diodo: LSL = 0.3V, USL = 3.0V

RESISTÊNCIA E-C (Ω)
Média: 119977.79
Desvio Padrão: 313.83
Coeficiente de Variação: 0.26%
Cp: 5.311
Cpk: 3.210
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

RESISTÊNCIA G-E (Ω)
Média: 7286.52
Desvio Padrão: 30.20
Coeficiente de Variação: 0.41%
Cp: 16.556
Cpk: 3.162
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

DIODO E-C (V)
Média: 0.81
Desvio Padrão: 0.00
Coeficiente de Variação: 0.38%
Cp: 147.104
Cpk: 55.453
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

RESUMO DOS RESULTADOS Cp/Cpk
=====
R_EC: Cp = 5.311, Cpk = 3.210
R_GE: Cp = 16.556, Cpk = 3.162
Diodo: Cp = 147.104, Cpk = 55.453

ANÁLISE DA CAPACIDADE DO PROCESSO:
=====
✓ PROCESSO GERAL: CAPAZ

```

Figura 66 - Resultado da análise ao IGBT1 5.2KW feita na plataforma Google Colab




Gráfico 3 - Gráficos Cp e Cpk do IGBT1 5.2KW (Google Colab)

A análise de capacidade do processo, está demonstrada na figura 66 e no gráfico 3 da página anterior, baseada em 20 medições experimentais para o IGBT1 (LSS) da PCBA 5.2KW, resultou índices, indicados na tabela 24, para os três parâmetros avaliados.

Tabela 24 - Índices de Capacidade do Processo para o IGBT1

Parâmetro	Cp	Cpk
Resistência Emissor-Coletor (E-C)	5,31	3,21
Resistência Gate-Emissor (G-E)	16,56	3,16
Tensão do Díodo E-C	147,10	55,45

A diferença entre os valores de Cp e Cpk para a resistência E-C foi de 2,10. Para a resistência G-E, a diferença foi de 13,40. Para a tensão do díodo E-C, os valores de Cp e Cpk excederam 147 e 55, respectivamente. Na figura 67 pode ser visto um exemplo de dashboard após a medição referente ao IGBT1 da PCBA de 5.2KW.



Figura 67 – Exemplo dashboard medição aleatória IGBT1 no PCBA de 5.2KW

3.2.2.2 Análise Estatística dos Resultados do IGBT2 (LSS)

No IGBT2 e de forma a provar que esta prova de conceito realiza medições coerentes, soldou-se uma resistência de $\approx 5000 \Omega$ em paralelo com os terminais Gate/Emissor, devendo a nossa medição resultar num valor a rondar os 3000 Ω .

- Resistência Emissor-Coletor (R_{EC})

- Resistência Gate-Emissor (R_GE)
- Tensão do díodo Gate-Emissor (V_GE)

```

✓ ANÁLISE Cp/Cpk - IGBT2 5.2KW (COMPONENTE NOK)
=====
📊 INTERVALOS DE VALIDAÇÃO PARA COMPONENTE NOK:
R_EC: LSL = 113000Ω, USL = 123000Ω
R_GE: LSL = 7000Ω, USL = 10000Ω
Diodo: LSL = 0.3V, USL = 3V

🔧 RESISTÊNCIA E-C (Ω)
Média: 116208.44
Desvio Padrão: 335.13
Coeficiente de Variação: 0.29%
Cp: 4.973
Cpk: 3.191
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔧 RESISTÊNCIA G-E (Ω)
Média: 3319.32
Desvio Padrão: 6.60
Coeficiente de Variação: 0.20%
Cp: 75.805
Cpk: -186.010
✓ PROCESSO EXCELENTE | FORA DE ESPECIFICAÇÃO

🔧 DIODO E-C (V)
Média: 0.77
Desvio Padrão: 0.00
Coeficiente de Variação: 0.45%
Cp: 129.394
Cpk: 45.135
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

📋 RESUMO DOS RESULTADOS Cp/Cpk - IGBT2
=====
R_EC: Cp = 4.973, Cpk = 3.191
R_GE: Cp = 75.805, Cpk = -186.010
Diodo: Cp = 129.394, Cpk = 45.135

🔧 ANÁLISE DA CAPACIDADE DO PROCESSO - IGBT2:
=====
✓ PROCESSO GERAL: CAPAZ

```

Figura 68 - Resultado da análise ao IGBT2 5.2KW (Google Colab)




Gráfico 4 - Gráficos Cp e Cpk do IGBT2 5.2KW (Google Colab)

A análise de capacidade do processo para o IGBT2 da PCBA 5.2KW, demonstrada na figura 68 e no gráfico 4 da página anterior, baseada em 20 medições, resultou nos índices, indicados na tabela 25, para os três parâmetros avaliados.

Tabela 25 - Índices de Capacidade do Processo para o IGBT2

Parâmetro	Cp	Cpk
Resistência Emissor-Coletor (E-C)	4,97	3,19
Resistência Gate-Emissor (G-E)	75,81	-186,01
Tensão do Díodo E-C	129,39	45,13

A diferença entre os valores de Cp e Cpk para a resistência G-E foi de 261,82. O valor de Cpk para este parâmetro foi negativo. Para a tensão do díodo E-C a diferença entre Cp e Cpk foi de 84,26.

3.2.2.3 Análise Estatística dos Resultados do IGBT3 (HSS)

No IGBT3 não temos o díodo interno entre o emissor e o coletor, neste IGBT medimos apenas valores de resistência, mas agora em três sequências:

- Resistência Coletor-Emissor (R_CE)
- Resistência Emissor-Coletor (R_EC)
- Resistência Gate-Emissor (R_GE)




Gráfico 5 - Gráficos Cp e Cpk do IGBT2 5.2KW (Google Colab)

```

✓ ANÁLISE Cp/Cpk - IGBT3 5.2KW
=====
INTERVALOS DE VALIDAÇÃO PARA IGBT3:
R_EC: LSL = 950000, USL = 1100000
R_GE: LSL = 700000, USL = 750000
R_CE: LSL = 1000000, USL = 1100000

RESISTÊNCIA E-C (Ω)
Média: 100395.92
Desvio Padrão: 179.36
Coeficiente de Variação: 0.18%
Cp: 13.939
Cpk: 10.028
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

RESISTÊNCIA G-E (Ω)
Média: 73161.78
Desvio Padrão: 268.59
Coeficiente de Variação: 0.37%
Cp: 3.103
Cpk: 2.281
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

RESISTÊNCIA C-E (Ω)
Média: 105110.75
Desvio Padrão: 2736.59
Coeficiente de Variação: 0.26%
Cp: 6.090
Cpk: 5.955
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

RESUMO DOS RESULTADOS Cp/Cpk - IGBT3
=====
R_EC: Cp = 13.939, Cpk = 10.028
R_GE: Cp = 3.103, Cpk = 2.281
R_CE: Cp = 6.090, Cpk = 5.955

ANÁLISE DA CAPACIDADE DO PROCESSO - IGBT3:
=====
✓ PROCESSO GERAL: CAPAZ

```

Figura 69 - Resultado da análise ao IGBT3 5.2KW (Google Colab)

A análise de capacidade do processo para o IGBT3 da PCBA 5.2KW, demonstrados na figura 69 e no gráfico 5 da página anterior, baseada em 20 medições, resultou nos índices, da tabela 26, para os três parâmetros avaliados.

Tabela 26 - Índices de Capacidade do Processo para o IGBT3

Parâmetro	Cp	Cpk
Resistência Emissor-Coletor (E-C)	13,94	10,03
Resistência Gate-Emissor (G-E)	3,10	2,28
Resistência Coletor-Emissor (C-E)	6,09	5,96

A diferença entre os valores de Cp e Cpk para a resistência G-E foi de 0,82. O valor mais baixo de Cpk, nesta análise, foi precisamente nesta sequência de medição.

3.2.2.4 *Análise Estatística dos Resultados de valores de tensão*




Gráfico 6 - Gráficos das tensões em diversos pontos LV, 5.2KW (Google Colab)



Figura 70 - Dashboard medição tensões em diversos pontos no PCBA de 5.2KW




Figura 71 - Resultado da análise às tensões PCBA de 5.2KW (Google Colab)

A estabilidade dos níveis de tensão do sistema LV foi verificada através de 20 amostras sequenciais em diferentes pontos de medição, abrangendo linhas de 5V DC e a alimentação principal de 13V DC.

Os resultados para os pontos de 5V DC, também demonstrados no gráfico 6 da página anterior e na figura 71, foram os seguintes:

- **VCC Digital Isolator:** média de 4,996V, com variação entre 4,996V e 4,997V.
- **TP1137 TprgL1104:** média de 4,996V, com variação entre 4,995V e 4,997V.
- **TP1135 TprgL1102 XresLV:** média de 4,981V, com variação entre 4,981V e 4,982V.
- **TP1133 TprgL1100 SWDIOLV:** média de 4,963 V, com variação entre 4,820V e 4,992V.

Para a linha de alimentação principal de 13V DC (**Conector LV**), a média foi de 12,987V,

com variação entre 12,975V e 12,989V, correspondendo a um desvio padrão de aproximadamente $\pm 0,003V$.

Na figura 70 da página anterior está demonstrado um exemplo de um dashboard com os pontos de medição em análise. A figura 72, da página seguinte, mostra o desenho esquemático de alguns test points analisados.




Figura 72 - Test Points de serial debug (ficha técnica)

3.2.3 IGBTs PCBA 8KW

A análise de precisão e repetibilidade em relação à medição da funcionalidade da PCBA de 8 KW, segue as mesmas características da PCBA de 5.2KW, no entanto esta placa tem 6 IGBTs, compreendendo três IGBTs em configuração LSS com o modelo RGS50TSX2DHR e três IGBTs em HSS com o modelo RGS50TSX2HR. Todas as tabelas de valores de medição, 8KW, estão identificadas no apêndice III.

Nos IGBTs LSS, o protocolo de medição inclui três parâmetros fundamentais:

- Queda de Tensão no Díodo entre Emissor/Coletor: Valor esperado: entre 0,3V e 3V
- Resistência entre Emissor/Coletor Valor esperado: > 100 kΩ
- Resistência entre Gate/Emissor: Valor esperado: > 7 kΩ

No IGBT1 HSS, as medições realizadas compreendem:

- Resistência entre Coletor/Emissor: Valor esperado: > 645 KΩ
- Resistência entre Emissor/Coletor: Valor esperado: > 30 kΩ
- Resistência entre Gate/Emissor: Valor esperado: > 7 kΩ

No IGBT2 e 3 HSS, as medições realizadas compreendem:

- Resistência entre Coletor/Emissor: Valor esperado: > 645 K Ω
- Resistência entre Emissor/Coletor: Valor esperado: > 30 k Ω
- Resistência entre Gate/Emissor: Valor esperado: > 13 k Ω

3.2.3.1 *Análise Estatística dos Resultados do IGBT1 (HSS)*

```
✓ ANÁLISE Cp/Cpk - IGBT1 8KW
=====
📄 INTERVALOS DE VALIDAÇÃO PARA IGBT1:
R_CE: LSL = 645000 $\Omega$ , USL = 655000 $\Omega$ 
R_EC: LSL = 30000 $\Omega$ , USL = 35000 $\Omega$ 
R_GE: LSL = 7000 $\Omega$ , USL = 10000 $\Omega$ 

🔧 RESISTÊNCIA C-E ( $\Omega$ )
Média: 649091.87
Desvio Padrão: 376.76
Coeficiente de Variação: 0.06%
Cp: 4.424
Cpk: 3.620
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔧 RESISTÊNCIA E-C ( $\Omega$ )
Média: 32923.31
Desvio Padrão: 170.76
Coeficiente de Variação: 0.52%
Cp: 4.880
Cpk: 4.054
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔧 RESISTÊNCIA G-E ( $\Omega$ )
Média: 8862.85
Desvio Padrão: 24.06
Coeficiente de Variação: 0.27%
Cp: 20.779
Cpk: 15.752
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

📄 RESUMO DOS RESULTADOS Cp/Cpk - IGBT1
=====
R_CE: Cp = 4.424, Cpk = 3.620
R_EC: Cp = 4.880, Cpk = 4.054
R_GE: Cp = 20.779, Cpk = 15.752

🔧 ANÁLISE DA CAPACIDADE DO PROCESSO - IGBT1:
=====
✓ PROCESSO GERAL: CAPAZ
```

Figura 73 - Resultado da análise ao IGBT1 8KW (Google Colab)




Gráfico 7 - Gráficos Cp e Cpk do IGBT1 8KW (Google Colab)

A análise de capacidade do processo para o IGBT1 da PCBA 8KW, está demonstrada na figura 73 da página anterior e no gráfico 7, baseada em 20 medições, resultou nos índices, apresentados na tabela 27, para os três parâmetros avaliados.

Tabela 27 - Índices de Capacidade do Processo para o IGBT1

Parâmetro	Cp	Cpk	Coefficiente de Variação
Resistência Coletor-Emissor (C-E)	4,42	3,62	0,06%
Resistência Emissor-Coletor (E-C)	4,88	4,05	0,52%
Resistência Gate-Emissor (G-E)	20,78	15,75	0,27%

O desvio padrão para a resistência C-E foi de 376,76 Ω , com uma média de 649.091,87 Ω . Para a resistência E-C, o desvio padrão foi de 170,76 Ω [61].

3.2.3.2 Análise Estatística dos Resultados do IGBT2 (HSS)




Gráfico 8 - Gráficos Cp e Cpk do IGBT2 8KW (Google Colab)

```

✓ ANÁLISE Cp/Cpk - IGBT2 8KW
=====
📊 INTERVALOS DE VALIDAÇÃO PARA IGBT2 8KW:
R_CE: LSL = 645000Ω, USL = 655000Ω
R_EC: LSL = 30000Ω, USL = 35000Ω
R_GE: LSL = 13000Ω, USL = 18000Ω

🔧 RESISTÊNCIA C-E (Ω)
Média: 647176.26
Desvio Padrão: 339.74
Coeficiente de Variação: 0.05%
Cp: 4.906
Cpk: 2.135
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔧 RESISTÊNCIA E-C (Ω)
Média: 32095.98
Desvio Padrão: 252.36
Coeficiente de Variação: 0.79%
Cp: 3.302
Cpk: 2.769
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔧 RESISTÊNCIA G-E (Ω)
Média: 14978.45
Desvio Padrão: 12.12
Coeficiente de Variação: 0.08%
Cp: 68.774
Cpk: 54.426
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

📄 RESUMO DOS RESULTADOS Cp/Cpk - IGBT2 8KW
=====
R_CE: Cp = 4.906, Cpk = 2.135
R_EC: Cp = 3.302, Cpk = 2.769
R_GE: Cp = 68.774, Cpk = 54.426

🔍 ANÁLISE DA CAPACIDADE DO PROCESSO - IGBT2 8KW:
=====
✓ PROCESSO GERAL: CAPAZ

```

Figura 74 - Resultado da análise ao IGBT2 8KW
(Google Colab)

A análise de capacidade do processo para o IGBT2 da PCBA 8KW, está demonstrada na figura 74 e no gráfico 8 da página anterior, baseada em 20 medições, resultou nos índices, apresentados na tabela 28, para os três parâmetros avaliados.

Tabela 28 - Índices de Capacidade do Processo para o IGBT2

Parâmetro	Cp	Cpk
Resistência Coletor-Emissor (C-E)	4,91	2,14
Resistência Emissor-Coletor (E-C)	3,30	2,77
Resistência Gate-Emissor (G-E)	68,77	54,43

3.2.3.3 Análise Estatística dos Resultados do IGBT3 (HSS)

```
✓ ANÁLISE Cp/Cpk - IGBT3 8KW
=====
📊 INTERVALOS DE VALIDAÇÃO PARA IGBT3 8KW:
R_CE: LSL = 645000Ω, USL = 645000Ω
R_EC: LSL = 300000Ω, USL = 350000Ω
R_GE: LSL = 140000Ω, USL = 180000Ω

🔍 RESISTÊNCIA C-E (Ω)
Média: 647394.88
Desvio Padrão: 466.75
Coeficiente de Variação: 0.07%
Cp: 3.571
Cpk: 1.710
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔍 RESISTÊNCIA E-C (Ω)
Média: 32545.00
Desvio Padrão: 282.68
Coeficiente de Variação: 0.87%
Cp: 2.948
Cpk: 2.895
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔍 RESISTÊNCIA G-E (Ω)
Média: 14960.93
Desvio Padrão: 7.53
Coeficiente de Variação: 0.05%
Cp: 88.538
Cpk: 42.539
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

📋 RESUMO DOS RESULTADOS Cp/Cpk - IGBT3 8KW
=====
R_CE: Cp = 3.571, Cpk = 1.710
R_EC: Cp = 2.948, Cpk = 2.895
R_GE: Cp = 88.538, Cpk = 42.539

🔍 ANÁLISE DA CAPACIDADE DO PROCESSO - IGBT3 8KW:
=====
✓ PROCESSO GERAL: CAPAZ
```

Figura 75 - Resultado da análise ao IGBT3 8KW (Google Colab)




Gráfico 9 - Gráficos Cp e Cpk do IGBT3 8KW (Google Colab)

A análise de capacidade do processo para o IGBT3 da PCBA 8KW, está demonstrada na figura 75 e no gráfico 9, baseada em 20 medições, resultou nos

índices, apresentados na tabela 29, da página seguinte, para os três parâmetros avaliados.

Tabela 29 - Índices de Capacidade do Processo para o IGBT3

Parâmetro	Cp	Cpk
Resistência Coletor-Emissor (C-E)	3,57	1,71
Resistência Emissor-Coletor (E-C)	2,95	2,89
Resistência Gate-Emissor (G-E)	88,54	42,54

3.2.3.4 Análise Estatística dos Resultados do IGBT4 (LSS)

```

✓ ANÁLISE Cp/Cpk - IGBT4 8KW
=====
📊 INTERVALOS DE VALIDAÇÃO PARA IGBT4 8KW:
R_EC: LSL = 100000Ω, USL = 120000Ω
R_GE: LSL = 7000Ω, USL = 10000Ω
Diodo: LSL = 0.3V, USL = 3

🔍 RESISTÊNCIA E-C (Ω)
Média: 116968.49
Desvio Padrão: 281.05
Coeficiente de Variação: 0.24%
Cp: 11.860
Cpk: 3.595
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔍 RESISTÊNCIA G-E (Ω)
Média: 7343.56
Desvio Padrão: 13.03
Coeficiente de Variação: 0.18%
Cp: 38.361
Cpk: 8.786
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔍 DIODO E-C (V)
Média: 0.81
Desvio Padrão: 0.00
Coeficiente de Variação: 0.18%
Cp: 299.301
Cpk: 113.723
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

📄 RESUMO DOS RESULTADOS Cp/Cpk - IGBT4 8KW
=====
R_EC: Cp = 11.860, Cpk = 3.595
R_GE: Cp = 38.361, Cpk = 8.786
Diodo: Cp = 299.301, Cpk = 113.723

🔍 ANÁLISE DA CAPACIDADE DO PROCESSO - IGBT4 8KW:
=====
✓ PROCESSO GERAL: CAPAZ

```

Figura 76 - Resultado da análise ao IGBT4 8KW (Google Colab)




Gráfico 10 - Gráficos Cp e Cpk do IGBT5 8KW (Google Colab)

A análise de capacidade do processo para o IGBT4 da PCBA 8KW, está demonstrada na figura 76 da página anterior e no gráfico 9, baseada em 20 medições, resultou nos índices, apresentados na tabela 30, para os três parâmetros avaliados.

Tabela 30 - Índices de Capacidade do Processo para o IGBT4

Parâmetro	Cp	Cpk
Resistência Emissor-Coletor (E-C)	11,87	3,60
Resistência Gate-Emissor (G-E)	38,36	8,79
Tensão do Díodo E-C	299,38	113,72

3.2.3.5 Análise Estatística dos Resultados do IGBT5 (LSS)




Gráfico 11 - Gráficos Cp e Cpk do IGBT5 8KW (Google Colab)

```

✓ ANÁLISE Cp/Cpk - IGBT5 8KW
=====
📊 INTERVALOS DE VALIDAÇÃO PARA IGBT5 8KW:
R_EC: LSL = 100000Ω, USL = 120000Ω
R_GE: LSL = 7000Ω, USL = 10000Ω
Diodo: LSL = 0.3V, USL = 3V

🔍 RESISTÊNCIA E-C (Ω)
Média: 114216.49
Desvio Padrão: 438.91
Coeficiente de Variação: 0.38%
Cp: 7.595
Cpk: 4.392
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔍 RESISTÊNCIA G-E (Ω)
Média: 7341.83
Desvio Padrão: 13.52
Coeficiente de Variação: 0.18%
Cp: 36.977
Cpk: 8.427
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔍 DIODO E-C (V)
Média: 0.81
Desvio Padrão: 0.00
Coeficiente de Variação: 0.13%
Cp: 413.063
Cpk: 157.163
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

📄 RESUMO DOS RESULTADOS Cp/Cpk - IGBT5 8KW
=====
R_EC: Cp = 7.595, Cpk = 4.392
R_GE: Cp = 36.977, Cpk = 8.427
Diodo: Cp = 413.063, Cpk = 157.163

🔍 ANÁLISE DA CAPACIDADE DO PROCESSO - IGBT5 8KW:
=====
✓ PROCESSO GERAL: CAPAZ

```

Figura 77 - Resultado da análise ao IGBT5 8KW (Google Colab)

A análise de capacidade do processo para o IGBT5 da PCBA 8KW, está demonstrada na figura 77 e no gráfico 9 da página anterior, baseada em 20 medições, resultou nos índices, apresentados na tabela 31, para os três parâmetros avaliados.

Tabela 31 - Índices de Capacidade do Processo para o IGBT5

Parâmetro	Cp	Cpk
Resistência Emissor-Coletor (E-C)	7,59	4,39
Resistência Gate-Emissor (G-E)	36,98	8,43
Tensão do Díodo E-C	413,06	157,16

3.2.3.6 Análise Estatística dos Resultados do IGBT6 (LSS)




Gráfico 12 - Gráficos Cp e Cpk do IGBT6 8KW (Google Colab)

```

✓ ANÁLISE Cp/Cpk - IGBT6 8KW
=====
📊 INTERVALOS DE VALIDAÇÃO PARA IGBT6 8KW:
R_EC: LSL = 100000Ω, USL = 120000Ω
R_GE: LSL = 7000Ω, USL = 10000Ω
Diodo: LSL = 0.3V, USL = 3V

🔍 RESISTÊNCIA E-C (Ω)
Média: 116168.68
Desvio Padrão: 568.08
Coeficiente de Variação: 0.49%
Cp: 5.868
Cpk: 2.248
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔍 RESISTÊNCIA G-E (Ω)
Média: 7344.15
Desvio Padrão: 14.32
Coeficiente de Variação: 0.19%
Cp: 34.924
Cpk: 8.013
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

🔍 DIODO E-C (V)
Média: 0.81
Desvio Padrão: 0.00
Coeficiente de Variação: 0.12%
Cp: 472.961
Cpk: 180.145
✓ PROCESSO EXCELENTE | ✓ PROCESSO CENTRADO

📋 RESUMO DOS RESULTADOS Cp/Cpk - IGBT6 8KW
=====
R_EC: Cp = 5.868, Cpk = 2.248
R_GE: Cp = 34.924, Cpk = 8.013
Diodo: Cp = 472.961, Cpk = 180.145

🔍 ANÁLISE DA CAPACIDADE DO PROCESSO - IGBT6 8KW:
=====
✓ PROCESSO GERAL: CAPAZ

```

Figura 78 - Resultado da análise ao IGBT6 8KW Google Colab

A análise de capacidade do processo para o IGBT6 da PCBA 8KW, está demonstrada na figura 78 e no gráfico 10 baseada em 20 medições, resultou nos

índices, apresentados na tabela 32 da página seguinte, para os três parâmetros avaliados.

Tabela 32 - Índices de Capacidade do Processo para o IGBT6

Parâmetro	Cp	Cpk
Resistência Emissor-Coletor (E-C)	5,868	3,248
Resistência Gate-Emissor (G-E)	34,924	8,013
Tensão do Díodo E-C	472,961	180,145

3.2.3.7 Análise Estatística dos Resultados de pontos de tensão bottom overlay

Para valores de tensão escolhi cinco pontos de medição na parte LV do lado inferior da placa. Esta análise estatística tem como objetivo continuar a avaliar a qualidade e estabilidade das medições, neste caso tensões medidas em pontos críticos, conforme especificado na documentação técnica. Foram analisadas cinco grandezas elétricas fundamentais: INPUT U1200, 5V LV, INPUT VOLTAGE T1300 e dois pontos de *clamp* (ANCLAMP30_1 e ANCLAMP30_2), através de 20 medições sequenciais de cada parâmetro.

Os limites de especificação utilizados são os valores de referência estabelecidos pela BorgWarner na sua ficha técnica, representando os intervalos aceitáveis de operação para garantia do funcionamento adequado do sistema, cf. Tabela 33. A metodologia de análise é a mesma usada nas medições anteriores documentadas.

Tabela 33 - Tabela retirada da documentação técnica do MOPF 8KW

	Description	Measure Testpoint (TP)	TP PCBA Layer	Reference	TP PCBA Layer	Measurement			
						Min	Nom	Max	Unit
1	Measure AnClamp30_1	TP1111	BOT	TP1108 / TP1242	BOT / TOP	2.459	■	2.721	V
2	Measure AnClamp30_2	TP1114	BOT	TP1108 / TP1242	BOT / TOP	1.912	■	2.18	V
3	Measure 15V_HV	TP1305 / TP1304	BOT	TP1322 / Tprg704	BOT / TOP	14.853	-	15.910	V
4	Measure 15V_HV_HSS	TP1326 / TP1325	BOT	TP1328 / TP427	BOT / BOT	14.765	-	15.892	V
5	Measure HV Current_Offset	TP101	BOT	TP118 / Tprg704	BOT / TOP	0.370	-	0.403	V
6	Measure OvrCurr1 Signal Reference	TP113	BOT	TP120 / Tprg704	BOT / TOP	3.706	-	3.783	V
7	Measure Lacht Inputs signal	TP300	BOT	TP120 / Tprg704	BOT / TOP	4.946	-	5.038	V
8	Measure Lacht Reference signal	TP304	BOT	TP120 / Tprg704	BOT / TOP	2.449	-	2.541	V
21	Measure the voltage Vge of HSS2_IGBT	TP425	BOT	TP439	TOP	0	-	0.100	V
22	Measure the input of U1200	TP1212	BOT	TP1204 / TP1242	BOT / TOP	12.177	■	12.606	V
23	Measure the input voltage at T1300	TP1307	BOT	TP1319 / Tprgl1103	BOT / TOP	12.080	■	12.501	V

ANÁLISE Cp/Cpk - TENSÕES DO SISTEMA

INTERVALOS DE VALIDAÇÃO BASEADOS NOS LIMITES TABELADOS:

INPUT U1200: LSL = 12.177V, USL = 12.606V

5V LV: LSL = 4.95V, USL = 5.05V

INPUT VOLTAGE T1300: LSL = 12.080V, USL = 12.501V

ANCLAMP 1: LSL = 1.912V, USL = 2.18V

ANCLAMP 2: LSL = 2.459V, USL = 2.721V

INPUT U1200 (V)

Média: 12.311V

Desvio Padrão: 0.01551V

Coefficiente de Variação: 0.126%

Cp: 4.610

Cpk: 2.886

PROCESSO EXCELENTE | PROCESSO CENTRADO

5V LV (V)

Média: 5.000V

Desvio Padrão: 0.00067V

Coefficiente de Variação: 0.013%

Cp: 24.912

Cpk: 24.883

PROCESSO EXCELENTE | PROCESSO CENTRADO

INPUT VOLTAGE T1300 (V)

Média: 12.200V

Desvio Padrão: 0.01617V

Coefficiente de Variação: 0.133%

Cp: 4.340

Cpk: 2.476

PROCESSO EXCELENTE | PROCESSO CENTRADO

ANCLAMP 1 (V)

Média: 2.030V

Desvio Padrão: 0.00349V

Coefficiente de Variação: 0.172%

Cp: 12.784

Cpk: 11.236

PROCESSO EXCELENTE | PROCESSO CENTRADO

ANCLAMP 2 (V)

Média: 2.600V

Desvio Padrão: 0.00303V

Coefficiente de Variação: 0.117%

Cp: 14.406

Cpk: 13.289

PROCESSO EXCELENTE | PROCESSO CENTRADO

RESUMO DOS RESULTADOS Cp/Cpk - TENSÕES DO SISTEMA

INPUT U1200: Cp = 4.610, Cpk = 2.886

5V LV: Cp = 24.912, Cpk = 24.883

INPUT T1300: Cp = 4.340, Cpk = 2.476

ANCLAMP 1: Cp = 12.784, Cpk = 11.236

ANCLAMP 2: Cp = 14.406, Cpk = 13.289

ANÁLISE DA CAPACIDADE DO PROCESSO - TENSÕES DO SISTEMA:

SISTEMA GERAL: EXCELENTE

Figura 79 - Resultado da análise às medições de tensão na PCBA de 8KW (Google Colab)




Gráfico 13 - Gráficos Cp e Cpk das medições de valores de tensão na PCBA de 8KW (Google Colab)

Segundo os resultados apresentados na figura 79 e nos gráficos 13 e 14, da página anterior, foram analisados cinco parâmetros de tensão da PCBA 8KW. Os índices de capacidade Cpk e, quando disponível, Cp e o coeficiente de variação (CV), foram os seguintes:

- 5V LV: Cp = 24,912; Cpk = 24,883; CV = 0,013%.
- INPUT U1200: Cpk = 2,886.
- INPUT VOLTAGE T1300: Cpk = 2,476.
- ANCLAMP 1: Cpk = 11,236; CV ≤ 0,172%.
- ANCLAMP 2: Cpk = 13,289; CV ≤ 0,172%.

O valor mais baixo de Cpk registrado foi de 2,476 (INPUT VOLTAGE T1300).

Para efeitos demonstrativos, na figura 80, é possível verificar um dashboard personalizado destas medições em análise. Na parte superior, do dashboard, está uma tabela informativa com os limites de especificação (inferior e superior).




Figura 80 - Dashboard com os valores medidos e com gráfico de histórico

4 DISCUSSÃO

Este capítulo tem como objetivo realizar uma análise crítica dos resultados obtidos, interpretando o seu significado face aos objetivos iniciais, ao contexto industrial e ao estado da arte. A análise é estruturada como uma síntese comparativa, cf. Tabela 34, focando-se nas implicações práticas das evidências experimentais.

4.1 AVALIAÇÃO DO CUMPRIMENTO DOS OBJETIVOS PROPOSTOS

Tabela 34 - Síntese comparativa do cumprimento dos objetivos do projeto

Objetivo Inicial	Resultado Obtido	Evidência Experimental Principal	Implicação Prática / Conclusão Crítica
Identificação automática e precisa das PCBAs	Transição de uma abordagem inadequada (SSIM) para uma solução robusta baseada em <i>deep learning</i>	SSIM: Confiança $\approx 33\text{-}51\%$, SSIM médio ≈ 0.43 , falsos positivos com base vazia. YOLOv8: mAP50 de 99.5% no conjunto de validação	O SSIM, embora útil para comparação estrutural, falha como classificador por falta de semântica de objeto. A adoção do YOLOv8 demonstra que a precisão de nível industrial ($>99\%$) é acessível com <i>datasets</i> moderados (≈ 50 imagens), validando o <i>deep learning</i> como requisito para automação fiável
Execução de medições elétricas viáveis e repetíveis	Processo de medição classificado estatisticamente como "excelente" ou "altamente capaz"	Índices de Capacidade (Cpk): Valores consistentemente > 1.67	A arquitetura modular de medição introduz uma variabilidade insignificante. Isto valida a arquitetura como metrologicamente robusta , assegurando que os resultados refletem o componente sob teste e não o sistema de medição
Integração coesa de múltiplos subsistemas	Operacionalização de um <i>pipeline</i> de teste completo e automatizado, da identificação ao registo de dados	Funcionamento E2E: Execução autónoma da sequência: identificação (YOLOv8) - seleção de programa - medição robótica - armazenamento (<i>InfluxDB</i>) - visualização (<i>Grafana</i>)	O sistema modular materializa o princípio de sistema ciber-físico , onde a coordenação por <i>software</i> (<i>Python</i>) unifica domínios físicos distintos (OT/IT). A rastreabilidade automática dos dados é um salto qualitativo face a métodos manuais

A síntese da tabela 34, da página anterior, permite concluir que os objetivos fundamentais foram não apenas cumpridos, mas superados em termos de robustez quantificada. A principal conquista não é a funcionalidade isolada, mas a integração validada de tecnologias (visão, robótica, instrumentação) num sistema coeso, cuja fiabilidade foi comprovada através de métricas industriais (mAP, Cpk).

4.2 ANÁLISE COMPARATIVA COM O MÉTODO ATUAL E ENQUADRAMENTO NO ESTADO DA ARTE

A validação experimental do sistema Flex ICT suporta uma análise crítica que o posiciona não como um substituto, mas como um complemento estratégico ao método tradicional de ICT baseado em dispositivos de fixação dedicadas. A Tabela 35 sintetiza esta análise paradigmática, contrastando os dois modelos.

Tabela 35 - Análise paradigmática: ICT tradicional vs. Flex ICT

Dimensão	Método Tradicional (ICT com Fixture)	Solução Proposta (FPT Robótico - Flex ICT)	Implicação Crítica e Posicionamento
Agilidade / Flexibilidade	Nula. Dispositivo de fixação dedicado por PCBA	Alta. Reconfiguração via <i>software</i> (programa robótico, modelo YOLO).	Transfere a complexidade do <i>hardware</i> (moldes) para o <i>software</i> , criando um ativo reutilizável . Ideal para R&D, protótipos e baixos volumes.
Custo por Nova PCBA	Elevado e recorrente (fixação + tempo de <i>setup</i>)	Marginal (custo do tempo de programação interna).	Altera o modelo económico: o investimento de capital no robô é amortizado, tornando-se viável para dezenas de variantes. Reduz a barreira à entrada para testes.
Capacidade de Protótipos	Economicamente inviável	Muito alta.	Preenche uma lacuna estratégica: permite a validação iterativa de protótipos sem investimentos em <i>hardware</i> dedicado, acelerando o <i>time-to-market</i> .

Rastreabilidade e Dados	Limitada, frequentemente manual	Integrada e automática (base de dados temporal)	Habilita a análise de processo e a melhoria contínua baseada em dados, um pilar da Indústria 4.0 ausente no método tradicional
Velocidade de Teste	Muito alta (teste paralelo de todos os pontos)	Moderada (teste sequencial ponto-a-ponto)	Define o âmbito de aplicação: o sistema é ótimo para validação e caracterização , não para testes de produção em alto volume

Esta comparação evidencia que o valor da solução desenvolvida reside na sua flexibilidade operacional e agilidade económica, respondendo a um *gap* claro no ecossistema de teste: a necessidade de um sistema interno, rápido de configurar e adaptável a múltiplas PCBAs durante fases de desenvolvimento, qualificação ou para lotes de pequena série.

No contexto do estado da arte, o projeto Flex ICT alinha-se e avança sobre tendências documentadas na literatura. A sua arquitetura materializa a convergência de três pilares tecnológicos acessíveis: (1) a democratização do *deep learning*, onde *frameworks* como o *Ultralytics* tornam modelos de alto desempenho como o YOLOv8 acessíveis para tarefas específicas de visão industrial [7] [29]; (2) a adoção de robótica colaborativa como plataforma de manipulação reconfigurável [5]; e (3) a utilização de *software open-source* (*Python, Docker, InfluxDB, Grafana*) como camada de integração de sistemas [22] [54] [56].

A contribuição prática distintiva deste trabalho está em demonstrar que esta integração, quando aliada a uma metodologia de fabrico digital de baixo custo (CAD e impressão 3D FFF para componentes mecânicos [48] [49]), pode atingir um nível de robustez metrológica quantificada (através de índices de capacidade $Cpk > 1.67$) tradicionalmente associado a soluções comerciais de custo elevado. Assim, o projeto posiciona-se como um caso de estudo replicável para capacitação interna em laboratórios de

teste, oferecendo uma via para alcançar autonomia, rastreabilidade digital e agilidade de validação, sem a necessidade de investimento em soluções verticais e proprietárias.

4.3 LIMITAÇÕES E PERSPETIVAS DE TRABALHO FUTURO

Apesar do sucesso na validação da prova de conceito e do cumprimento dos seus objetivos fundamentais, é crucial reconhecer as limitações inerentes ao estado atual de desenvolvimento do sistema Flex ICT. Estas limitações, longe de invalidarem o trabalho, delimitam claramente o seu âmbito de aplicação imediato e definem trajetórias concretas para investigação e evolução futuras, visando aumentar o seu nível de maturidade tecnológica e robustez metrológica.

A limitação mais evidente prende-se com o tempo de ciclo de teste, determinado pela natureza sequencial do posicionamento robótico ponto-a-ponto. Enquanto um sistema de ICT tradicional com *bed-of-nails* testa todos os pontos em paralelo em segundos, a abordagem robótica é intrinsecamente mais lenta. Esta característica consolida o seu posicionamento como solução ideal para validação, caracterização e baixos volumes, e não para testes de alta velocidade em linhas de produção de massa.

Adicionalmente, embora os resultados de precisão e capacidade do processo ($Cpk > 1,67$) indiquem desempenho compatível com critérios industriais, não foi conduzido um estudo formal de *Measurement System Analysis* (MSA), nomeadamente um ensaio de *Gage R&R* (*Repeatability and Reproducibility*), segundo as diretrizes AIAG [66]. A realização dessa análise permitiria quantificar explicitamente a contribuição da variabilidade do sistema de medição face à variabilidade total observada, distinguindo componentes de repetibilidade, reprodutibilidade e variação entre peças. A integração desta metodologia numa fase futura reforçaria a validação metrológica do sistema e suportaria uma eventual transição para contextos industriais mais exigentes.

A arquitetura mecânica atual, baseada num *dual gripper*, cumpre a sua função, mas introduz complexidade e um volume que poderia ser otimizado para maior robustez e simplicidade estrutural.

Para superar estas limitações e evoluir a plataforma para um sistema de diagnóstico completo, mais autónomo e com melhor desempenho dinâmico, propõem-se as seguintes linhas de ação prioritárias:

1. **Integração "Eye-in-Hand" e Otimização do End-Effector:** A evolução mais impactante seria a substituição do *dual gripper* por um *end-effector* único e multifuncional, fabricado aditivamente, que integrasse no seu corpo as pontas de prova e um módulo de câmara compacto (ex.: baseado em ESP32-S3). Esta configuração "câmara-no-effector" permitiria implementar um sistema de correção de tolerâncias em tempo real. Antes de cada medição, a câmara capturaria a imagem de um marcador (*fiducial*) na PCBA ou na base, calculando o desvio de posição e enviando uma correção às coordenadas do robô. Esta abordagem, documentada como crítica para aumentar a robustez de sistemas de visão robótica [47], compensaria imprecisões de montagem, calibração e efeitos térmicos, garantindo um contacto mais fiável e preciso.
2. **Expansão Funcional para Diagnóstico e Reprogramação In-Situ:** Para transformar a estação de teste num verdadeiro sistema de reparação autónoma, propõe-se a integração de um programador de microcontroladores profissional (suportando JTAG/SWD) na rede de controlo. A automação deste processo exigiria:
 - O desenvolvimento de um módulo *software* em *Python* para controlo remoto do programador via Ethernet/SCPI [64].
 - A criação de um sistema de gestão que associasse automaticamente cada PCBA identificada ao respetivo *firmware* armazenado.
 - A implementação de um sequenciamento automatizado que, após uma falha detetada, posicionasse o robô, executasse uma leitura de memória para diagnóstico e, se necessário, iniciasse uma rotina de reprogramação, seguindo práticas de gestão de *firmware* em linha [63].
3. **Reforço da Rastreabilidade e Analytics Avançada:** A dupla persistência de eventos (em log textual e na base de dados temporal *InfluxDB*) criaria um histórico auditável completo. A exploração destes dados através de técnicas de *machine learning* poderia permitir a deteção precoce de *drifts* nos

parâmetros dos componentes ou a correlação de falhas com versões específicas de *firmware*, elevando o sistema de um mero executor de testes para uma ferramenta proativa de melhoria de processo e garantia de qualidade.

4. **Otimização Cinemática e Redução do Tempo de Ciclo:** Uma evolução natural do sistema consiste na aplicação de técnicas de otimização cinemática ao manipulador robótico. O planeamento eficiente de trajetórias é um problema central em robótica, envolvendo tanto cinemática inversa como otimização de percurso sob restrições dinâmicas [67].

A implementação destas perspetivas não só mitigaria as limitações atuais, como transformaria a plataforma Flex ICT num sistema ciber-físico de diagnóstico e provisionamento completo. A integração de validação metrológica formal (MSA/Gage R&R) e de otimização cinemática consolidaria o seu posicionamento científico e tecnológico, aproximando-o progressivamente de um sistema robusto, escalável e alinhado com os princípios da Indústria 4.0.

5 CONCLUSÕES

O presente trabalho teve como objetivo principal o desenvolvimento e validação de uma estação de teste, com arquitetura modular, automatizada e flexível para PCBAs de HVCH, concebida para colmatar uma lacuna crítica no processo de validação em ambiente laboratorial da BorgWarner TTT. Os resultados obtidos demonstram, de forma inequívoca, que o sistema desenvolvido não só cumpriu este objetivo como estabeleceu um novo paradigma para a validação ágil e flexível de PCBAs na organização.

A transição de uma arquitetura de teste dependente de dispositivos de fixação específicos para uma solução robótica de FPT guiada por visão artificial revelou-se uma mais valia. O núcleo desta inovação reside no sistema de identificação automática, onde a substituição do algoritmo SSIM pelo modelo de *deep learning* YOLOv8 foi crucial. Enquanto o primeiro, adequado para comparação de imagens, mas não para deteção de objetos [6], falhava consistentemente, o segundo atingiu uma precisão de 99.5% (mAP50) [7], garantindo a fiabilidade necessária para a automação total. Esta mudança está alinhada com a tendência industrial de adoção de visão computacional robusta para inspeção automatizada [29].

A validação do sistema vai além da mera funcionalidade; assenta numa análise quantitativa de fiabilidade. A aplicação de índices de capacidade do processo (Cp/Cpk) às medições elétricas, uma prática fundamental para a garantia de qualidade em engenharia [61], comprovou a excelente repetibilidade e precisão do sistema. Valores de Cpk consistentemente superiores a 1.67 nas medições de parâmetros críticos em IGBTs classificam o processo como "excelente" ou "altamente capaz" [39], assegurando que a variabilidade introduzida pela automação é insignificante face às especificações dos componentes. Esta conclusão é corroborada pelos resultados da validação de precisão realizados nas placas de 5.2KW e 8KW, onde as diferenças relativas entre as medições automáticas e uma referência manual foram consistentemente inferiores a 0.03% para praticamente todos os pontos de medição (como resistências e tensões em IGBTs e diversos pontos de medição no circuito LV), estando dentro dos limites estabelecidos por normas técnicas da indústria [1, 72]. A excelente concordância

observada, com diversas medições a registarem diferenças relativas nulas ou na ordem dos 0.001%, valida a precisão metrológica do sistema automatizado.

A integração foi bem-sucedida graças a uma arquitetura de *software* modular em *Python*, que gere de forma coesa todos os subsistemas – robô, visão, instrumentos de medição, instrumentos de apoio - e garante a rastreabilidade dos dados através de uma *stack* temporal com *InfluxDB* e *Grafana*. A metodologia de prototipagem rápida, utilizando CAD e impressão 3D, seguindo os princípios de *Design for Additive Manufacturing* [48], foi fundamental para o desenvolvimento ágil e económico dos componentes mecânicos personalizados, como suportes de alojamentos, demonstrando a viabilidade de uma abordagem em ambiente laboratorial para a automação industrial.

Este sistema modular valida um paradigma radicalmente mais eficiente para o teste de PCBAs em contexto de I&D. Perante um método atual que implica custos elevados e prazos de três meses para desenvolver dispositivos de fixação específicos com camas de agulhas para determinados pontos, a solução proposta reduz o tempo de configuração para a ordem das horas ou dias, elimina esses custos recorrentes e oferece flexibilidade total para adaptação a novos designs. O sistema constitui, assim, uma resposta tangível aos desafios da Indústria 4.0, onde a agilidade, a digitalização e a integração de sistemas são imperativas.

A trajetória científica deste projeto foi marcada não apenas pelo seu desenvolvimento e validação interna, mas também pela sua disseminação e validação externa junto da comunidade académica. A proposta conceptual e metodológica foi apresentada e discutida no *SASYR 2025* [64], um fórum dedicado a jovens investigadores. Esta participação, ocorrida numa fase inicial de prova de conceito, permitiu uma validação precoce da relevância da abordagem e antecipou alguns dos desafios técnicos que viriam a ser superados. Os resultados finais e conclusivos aqui apresentados representam, assim, a materialização e confirmação experimental do trabalho cujas fundações foram publicamente validadas, completando o seu ciclo de investigação aplicada. O trabalho realizado não só cumpre os objetivos inicialmente propostos, como estabelece uma base sólida e tecnologicamente madura para futuras evoluções, nomeadamente a expansão para diagnósticos avançados, consolidando o seu potencial como uma ferramenta

transformadora para a capacitação interna em ambiente laboratorial da BorgWarner.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Hornacek, D., & Tanuska, P. (2024). *A predictive quality inspection framework for the manufacturing process in the context of Industry 4.0*. *Sensors*, 24(17), 5644. <https://www.mdpi.com/1424-8220/24/17/5644>
- [2] QDA Solutions. (2021). *Automotive QM – Quality management and Industry 4.0*. <https://www.qda-solutions.com/app/uploads/sites/2/2021/09/pb-automotive-qm-en.pdf>
- [3] GermanEdge. (2021). *Automotive Industry 4.0: Product portfolio*. https://www.germanedge.com/app/uploads/sites/2/2021/08/Automotive_Product-portfolio_Germanedge_ENG.pdf
- [4] Kinali. (n.d.). *Automation of PCBA testing at BTL Medical Technologies s.r.o.* <https://www.kinali.cz/en/robotic-systems/automated-product-testing/automation-of-pcba-testing-at-btl-medical-technologies-s-r-o/>
- [5] Villani, V., Pini, F., Leali, F., & Secchi, C. (2018). Survey on human–robot collaboration in industrial settings: Safety, intuitive interfaces and applications. *Mechatronics*, 55, 1–16. <https://www.sciencedirect.com/science/article/pii/S0957415818300321?via%3Dihub>
- [6] Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600–612. <https://www.cns.nyu.edu/pub/lcv/wang03-preprint.pdf>
- [7] Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2023). *YOLOv8: Real-time object detection and segmentation*. Ultralytics Technical Report
- [8] SPEA. (2025, March 27). *ICT vs flying probe test: Pros, cons & best use*. SPEA. <https://www.spea.com/en/news/ict-vs-flying-probe-test>
- [9] Matric. (2023, September 20). *ICT vs. Flying probe testing: Key differences*. Matric Blog. <https://blog.matric.com/ict-testing-vs-flying-probe-testing>
- [10] Acculogic. (2024, September 25). *Flying probe vs. In-Circuit test*. Acculogic. <https://www.acculogic.com/blog/flying-probe-vs-in-circuit-test>
- [11] Forwessun. (2025, October 23). *In-Circuit testing vs flying probe: Complete comparison guide*. Forwessun. <https://forwessun.net/blog/in-circuit-testing-v-flying-probe>
- [12] PCBWay. (2025, March 15). *PCB flying probe test: Principles, advantages, and applications*. PCBWay.

https://www.pcbway.com/blog/PCB_Manufacturing_Information/PCB_Flying_Probe_Test_Principles_Advantages_and_Applications_bc222b0f.html

[13] International Federation of Robotics. (2022). *World Robotics Report 2022*. IFR. <https://ifr.org/worldrobotics>

[14] Colgate, J. E., & Peshkin, M. A. (1996). *Cobots: Robots for collaboration with human operators*. Northwestern University. http://peshkin.mech.northwestern.edu/publications/1996_Colgate_CobotsRobotsCollaboration.pdf

[15] Universal Robots. (2021). *Collaborative robotic automation*. <https://www.universal-robots.com/>

[16] Matthias, B., & Thomas, C. (2016). *Human-Robot Collaboration – New Applications in Industrial Robotics*. COMA '16 International Conference on Competitive Manufacturing. Ruhr-Universität Bochum.

[17] Murtua, I., et al. (2017). Human–robot collaboration in industrial applications. *International Journal of Advanced Robotic Systems*, 14(3), 1–10. <https://journals.sagepub.com/doi/10.1177/1729881417716010>

[18] INGUN. (2023). *Collaborative robots in ICT applications*. INGUN Prüfmittelbau GmbH.

[19] Montini, E., Daniele, F., Confalonieri, M., Cutrona, V., Bettoni, A., Rocco, P., & Ferrario, A. (2024). Collaborative robotics: A survey from literature and practitioners perspectives. *Journal of Intelligent & Robotic Systems*, 110(117). <https://link.springer.com/article/10.1007/s10846-024-02141-z>

[20] KUKA. (2025). *Cobots: Collaborative robots as colleagues*. <https://www.kuka.com/en-us/future-production/human-robot-collaboration/cobots>

[21] IEEE Instrumentation and Measurement Society. (2019). *Standard Commands for Programmable Instruments (SCPI)*. IEEE.

[22] Oliphant, T. E. (2007). Python for scientific computing. *Computing in Science & Engineering*, 9(3), 10–20. <https://ieeexplore.ieee.org/document/4160250>

[23] Murtua, I., Ibarra, A., Kildal, J., Susperregi, L., & Sierra, B. (2017). Human–robot collaboration in industrial applications. *International Journal of Advanced Robotic Systems*, 14(3), 1–10. <https://journals.sagepub.com/doi/10.1177/1729881417716010>

- [24] Calabrese, A., Quer, S., & Squillero, G. (2021). Smart techniques for flying-probe testing. *Proceedings of the 18th International Conference on Computer Systems and Technologies (CompSysTech'21)*, 105823, 1–10. SCITEPRESS. Disponível em: <https://www.scitepress.org/Papers/2021/105823/105823.pdf>
- [25] Ultralytics. (2023). *YOLOv8 — Models* (Documentation). Ultralytics. <https://docs.ultralytics.com/models/yolov8/>
- [26] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://www.nature.com/articles/nature14539>
- [27] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- [28] De Ketelaere, B., et al. (2017). Data-driven quality control: Integrating machine learning in industrial vision systems. *Computers in Industry*, 86, 42–53. <https://www.sciencedirect.com/science/article/pii/S0166361517300428?via%3Dihub>
- [29] Haffner, O., Kučera, E., & Rosinová, D. (2024). Applications of Machine Learning and Computer Vision in Industry 4.0. *Applied Sciences*, 14(6), 2431. <https://www.mdpi.com/2076-3417/14/6/2431>
- [30] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788. <https://ieeexplore.ieee.org/document/7780460>
- [31] Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*. <https://arxiv.org/pdf/2004.10934>
- [32] Terras, N., Pereira, F., Silva, A. R., Santos, A. A., Lopes, A. M., da Silva, A. F., Cartal, L. A., Apostolescu, T. C., Badea, F., & Machado, J. (2023). Integration of Deep Learning Vision Systems in Collaborative Robotics for Real-Time Applications. *Applied Sciences*, 15(3), 1336. <https://www.mdpi.com/2076-3417/15/3/1336>
- [33] Raj, A. M., et al. (2025). *Design and Implementation of a LIN Driver in AUTOSAR Architecture*. *International Journal of Engineering Research & Technology (IJERT)*, 14(9), 32–40. Disponível em: <https://www.ijert.org/research/design-and-implementation-of-a-lin-driver-in-autosar-architecture-IJERTV14IS090032.pdf>
- [34] Kvaser. (2023). *Introduction to the LIN bus*. Disponível em: <https://kvaser.com/about-can/can-standards/linbus/>

- [35] Songle Relay Datasheet – SRD-05VDC-SL-C. *Songle Electronics*. Disponível em: <https://www.circuitbasics.com/wp-content/uploads/2015/11/SRD-05VDC-SL-C-Datasheet.pdf>
- [36] Rashid, M. H. (2022). *Power Electronics: Circuits, Devices, and Applications* (4th ed.). Pearson. https://api.pageplace.de/preview/DT0400.9780273785149_A24589219/preview-9780273785149_A24589219.pdf
- [37] Holm, R. (2000). *Electric Contacts: Theory and Application* (4th ed.). Springer-Verlag.
- [38] Slade, P. G. (Ed.). (2014). *Electrical Contacts: Principles and Applications* (2nd ed.). CRC Press.
- [39] O'Connor, P. D. T., & Kleyner, A. (2012). *Practical Reliability Engineering* (5th ed.). Wiley.
- [40] Altium. (2023). *Automated PCB Testing With FixtureFab*. OnTrack Podcast, Altium Designer Learning Hub.
- [41] FixturFab. (2024). *Hardware Test Solutions: Dispositivos de fixação, Systems & Software*.
- [42] James Arthur. (2025). *PCB Test Fixture: Types, Design, and Best Practices*. PCBASIC Blog.
- [43] ZMorph S.A. (2019). *3D Printed Test Dispositivos de fixação for Electronics – Questpol Case Study*.
- [44] Kontaxis, L. C., Zachos, D., Georgali-Fickel, A., Portan, D. V., Zaoutsos, S. P., & Papanicolaou, G. C. (2025). *3D-Printed PLA Mechanical and Viscoelastic Behavior Dependence on the Nozzle Temperature and Printing Orientation*. *Polymers*, 17(7), 913. <https://doi.org/10.3390/polym17070913>
- [45] Cui, C., Han, Z., & Yu, T. (2021). *Design of Mechanical Fixture Based on Computer CAD Research*. *Journal of Physics: Conference Series*, 2074(1), 012030. Disponível em: https://www.researchgate.net/publication/354945187_Design_of_Mechanical_Fixture_Based_on_Computer_CAD_Research
- [46] Fantoni, G., Santochi, M., Dini, G., Tracht, K., Scholz-Reiter, B., Fleischer, J., Kristoffer, L., Hansen, H. N., & Verl, A. (2014). Grasping devices and methods in automated production processes. *CIRP Annals*, 63(2), 679-701. <https://www.sciencedirect.com/science/article/pii/S0007850614001887?via%3Dihub>

- [47] Miseikis, J., Ruther, M., Walzel, B., Hirte, M., & Ibrahimi, A. (2017). *On the importance of eye-in-hand calibration for tool mounting in robotic vision*. In 2017 18th International Conference on Advanced Robotics (ICAR) (pp. 140-146). IEEE. <https://ieeexplore.ieee.org/document/8023489>
- [48] Thompson, M. K., Moroni, G., Vaneker, T., Fadel, G., Campbell, R. I., Gibson, I., Bernard, A., Schulz, J., Graf, P., Ahuja, B., & Martina, F. (2020). Design for Additive Manufacturing: Trends, opportunities, considerations, and constraints. *CIRP Annals*, 69(2), 1-24. <https://www.sciencedirect.com/science/article/pii/S0007850616301913>
- [49] Gibson, I., Rosen, D., & Stucker, B. (2021). *Additive manufacturing technologies: 3D printing, rapid prototyping, and direct digital manufacturing* (3rd ed.). Springer.
- [50] Wang, L., Zhang, Y., & Li, J. (2022). A review on thermal management systems for power batteries in electric vehicles: Technologies, challenges, and future directions. *Journal of Power Sources*, 521, 230957. <https://www.sciencedirect.com/science/article/pii/S0378775321014403?via%3Dihub>
- [51] Keithley. (2021). *Series 2200 Programmable DC Power Supplies User's Manual*. Tektronix, Inc.
- [52] Docker Inc. *Docker Desktop Documentation*. Disponível em: <https://docs.docker.com/desktop/>
- [53] MERKEL, D. *Docker: Lightweight Linux Containers for Consistent Development and Deployment*. *Linux Journal*, v. 2014, n. 239, p. 2, 2014.
- [54] BOETTIGER, C. *An introduction to Docker for reproducible research*. *ACM SIGOPS Operating Systems Review*, v. 49, n. 1, p. 71–79, 2015.
- [55] PAHL, C.; BROGI, A. *Cloud Container Technologies: A State-of-the-Art Review*. *IEEE Transactions on Cloud Computing*, v. 7, n. 3, p. 677–692, 2019.
- [56] InfluxData Inc. *InfluxDB Documentation*. <https://docs.influxdata.com/>
- [57] Grafana Labs. *Grafana Documentation*. <https://grafana.com/docs/>
- [58] Python Software Foundation. (2023). *The Python Standard Library*. Python Documentation. <https://docs.python.org/3/library/>
- [59] Ison, J. (2022). *ttkbootstrap: A theme extension for ttk*. GitHub Repository. <https://github.com/israel-dryer/ttkbootstrap>

- [60] Clark, A. (2015). *Pillow (PIL Fork) Documentation*. Python Pillow.
<https://pillow.readthedocs.io/en/stable/>
- [61] Montgomery, D. C. (2019). *Introduction to Statistical Quality Control* (8th ed.). John Wiley & Sons.
- [62] Bisong, E. (2019). Google Colaboratory. In *Building Machine Learning and Deep Learning Models on Google Cloud Platform* (pp. 59-64). Apress, Berkeley, CA.
- [63] M. Simic et al., "Firmware Management in Cyber-Physical Production Systems: A Survey of Methodologies and Challenges," *Journal of Industrial Information Integration*, vol. 28, 2022. <https://www.sciencedirect.com/science/article/pii/S2667345221000055>
- [64] "Standard Commands for Programmable Instruments (SCPI) - 1999.0", SCPI Consortium, 1999. <https://www.ivifoundation.org/downloads/SCPI/scpi-99.pdf>
- [65] Gama, M., Lomba, E., & Lopes, S. Flex ICT – Flexible and intelligent robotic platform for laboratory ICT. In: *Proceedings of the 5th Symposium of Applied Science for Young Researchers (SASYR 2025) – Book of Abstracts*. Bragança: Instituto Politécnico de Bragança; 2025. p. 79-82. <https://bibliotecadigital.ipb.pt/entities/publication/b17cc192-2625-4cfd-b5e1-08d907c8dff4>
- [66] AIAG. (2010). *Measurement Systems Analysis (MSA) (4th ed.)*. Automotive Industry Action Group.
- [67] Siciliano, B., Sciavicco, L., Villani, L., & Oriolo, G. (2016). *Robotics: Modelling, planning and control*. Springer.
https://people.disim.univaq.it/~costanzo.manes/EDU_stuff/Robotics_Modelling,%20Planning%20and%20Control_Sciavicco_extract.pdf
- [68] Slade, P. G. (Ed.). (2014). *Electrical contacts: Principles and applications* (2nd ed.). CRC Press.

ANEXOS

Os anexos que se seguem contêm documentação técnica complementar, fundamental para a compreensão e replicação do trabalho desenvolvido. Incluem-se o poster de participação no Sasyr 2025, desenhos técnicos dos componentes mecânicos personalizados, já concebidos e detalhados pelo Centro de Interface Tecnológico Industrial (CiTin), que materializam a solução e interação física do sistema automatizado.

A disponibilização desta documentação visa fornecer uma referência completa para a fabricação dos componentes e para eventuais desenvolvimentos futuros.

ANEXO I – POSTER PARTICIPAÇÃO SASYR 2025



Symposium of
Applied Science for
Young Researchers

FLEX ICT

Márcio Gama, Emanuel Lomba e Sérgio Lopes

marciogama@ipvc.pt, sil@estg.ipvc.pt

Márcio Gama¹, Emanuel Lomba², Sérgio Lopes²

¹Department of Maintenance, Borgwarner TTT Viana do Castelo, Portugal

²Assistant Professor School of Technology and Management Polytechnic University of Viana do Castelo, Portugal

► BACKGROUND

- This project proposes a flexible, intelligent in-circuit test (ICT) station for BorgWarner Turbo and Thermal Technology.
- The solution integrates a collaborative robot to automate measurements, along with a computer vision system to identify different PCBAs (Printed Circuit Board Assembly), and adapt testing procedures.
- Traditional manual methods and dedicated test fixtures lack flexibility, reducing efficiency and increasing costs.
- Recent advancements show that combining collaborative robotics with machine vision improves test coverage, accuracy, and operational safety.

► OBJECTIVES


1. Develop an automated and accurate measurement system
2. Automate measurement using a collaborative robot
3. Implement a computer vision system for identification
4. Integrate communication and programming protocols
5. Develop monitoring software



► METHODOLOGY

- **Requirements Definition**
Identification of system requirements and technical specifications to ensure robustness and adaptability.
- **Communication Interfaces Analysis**
Study of hardware and software communication protocols to ensure full system integration and interoperability.
- **Test Points and Measurements**
Definition of electrical quantities and corresponding test points on PCBAs, followed by manual bench testing to validate procedures.
- **Fixture Design**
Development of a dedicated fixture to ensure correct and repeatable PCBA positioning during testing.
- **Automated Measurement System**
Design and implementation of a custom measurement system operated by a collaborative robot for precision and repeatability.
- **Collaborative Robot Integration**
Automation of traditionally manual tasks using a robot to enhance testing efficiency and consistency.
- **Vision System Implementation**
Integration of a computer vision system for automatic PCBA identification and dynamic test adaptation.
- **Monitoring Software**
Real time measurements and results


► RESULTS



► BIBLIOGRAPHY


- Anjum, M.U., Khan, U.S., Qureshi, W.S., Hamza, A., Khan, W.A. (2023): Vision-Based Hybrid Detection For Pick And Place Application.
- Sufyan, M. (2023). Flying Probe Test: An Extensive Guide to the Technology and Applications. September 28.
- Puttero, Stefano., Verna, Elisa., Gentà, Gianfranco., Galetto, Maurizio. (2025). Journal of Intelligence Manufacturing: Collaborative robots for quality control.
- Duda, R.O.; Hart, P.E.; Stork, D.G. Pattern classification and scene analysis; Vol. 3, Wiley New York, 1973.
- Vitali, R. A. P., Clemente, A. O., & Rosário, J. M. (2022). Robot inspection and visual location using vision guided robot (VGR). Journal of Engineering Research, 2(5). Campinas State University (UNICAMP), Brazil.
- Daneshjoo, N., Malega, P., Hübnerová, J., & Štuller, P. (2022). Implementation of Simulation in the Design of Robotic Production Systems. TEM Journal, 11(1), 179–188. Doi: 10.18421/TEM111-22

ANEXO II – DUAL GRIPPER



Dept.	Technical reference	Created by	Approved by
DML_CiTin		Francisco Claro 07/01/2025	
		Document type	Document status
		PDF	fechado
		Title	DWG No.
		DUAL grip V3	nº1
		Rev.	Date of issue
		1	28/10/2025
		Sheet	1/1

ANEXO III – ADAPTADOR DE SUPORTES DE MEDIÇÃO



APÊNDICES

No âmbito do desenvolvimento da estação de teste automatizada descrita no presente trabalho, foram produzidos diversos artefactos técnicos fundamentais para a implementação e funcionamento do sistema.

Este apêndice compila os elementos técnicos essenciais, organizados da seguinte forma:

- **Esquemas de ligação** do Esp32/módulo de relés e da Interface de comunicação LIN.
- **Planos** dos componentes mecânicos personalizados, concebidos por mim e otimizados para impressão pelo departamento de desenho do CiTin, para a prototipagem rápida e que suportam fisicamente a operação do sistema.
- **Tabelas** de valores de medições de componentes para estudos estatísticos.

A disponibilização destes elementos visa permitir uma compreensão aprofundada da arquitetura do sistema e a sua potencial reprodução ou adaptação em contextos futuros.


APÊNDICE I – ESQUEMAS

Esquema de ligação Esp32/Módulo de relés/pontas de prova

Nota: Para medições de tensões o ponto GND é comum ao da interface de comunicação LIN


Esp32	Placa Desen. Esp32 MRD066A	Módulo de Relés
GPIO13/D13	P22	IN7
GPIO14/D14	RX	IN6
GPIO25/D25	P19	IN2
GPIO26/D26	GND	IN1
GPIO27/D27	P21	IN5
GPIO32/D32	P5	IN4
GPIO33/D33	P18	IN3
VIN	GND	VCC
GND	P23	GND

Sequência de Relés IGBTs 5.2KW			Sequência de Relés IGBTs 8KW		
LSS	HSS	Medição	LSS	HSS	Medição
R4/R5		E-C Díodo	R1/R2		E-C Díodo
R4/R5		E-C RES	R1/R5		E-C RES
R1/R2		G-E RES	R4/R6		G-E RES
	R3/R6	C-E RES		R3/R2	C-E RES
	R1/R5	E-C RES		R4/R5	E-C RES
	R4/R6	G-E RES		R1/R2	G-E RES






Esquema de ligação Interface Comunicação LIN

Nota: Para medições de tensões o ponto GND é comum ao da interface de comunicação LIN






APÊNDICE II – PLANOS

Suporte acoplador para medição de resistências




Dept. DML_CiTin	Technical reference	Created by Francisco Claro 03/06/2025	Approved by	
escala 1:1 mm		Document type PDF	Document status fechado	
		Title Garra IGBTs	DWG No. nº1	
		Rev. 1	Date of issue 28/10/2025	Sheet 1/1

Suporte acoplador para medição de tensões





Dept.	Technical reference	Created by	Approved by
DML_CiTin		Francisco Claro 03/06/2025	
escala 1:1 mm		Document type PDF	Document status fechado
		Title Garra medição individual	DWG No. nº1
Rev.	Date of issue	Sheet	
1	28/10/2025	1/1	

Suporte acoplador para microcontroladores




Base para fixação de PCBAs Lado A







Base para fixação de PCBAs Lado B




Torres de fixação




Punho de aperto




Tampa base relés




Base relés



Caixa Esp32



Tampa Esp32



APÊNDICE II – TABELAS ESTATÍSTICAS

TABELA 20 MEDIÇÕES, PCBA 5.2KW IGBT 2 LSS

Nº Medição	Resistência E-C (Ω)	Resistência G-E (Ω)	Díodo E-C (V)
1	116182.3	3308.46	0.767
2	116726.6	3310.53	0.769
3	115679.3	3308.85	0.767
4	116270.5	3316.85	0.767
5	116344.4	3319.84	0.769
6	116055.8	3319.77	0.769
7	115994.9	3319.64	0.769
8	116277.4	3319.86	0.769
9	116478.0	3319.84	0.769
10	115896.7	3320.20	0.769
11	116207.8	3324.20	0.772
12	116430.0	3325.33	0.774
13	116478.1	3325.91	0.774
14	115603.0	3326.10	0.774
15	116708.1	3326.45	0.775
16	116117.8	3326.76	0.775
17	116059.3	3327.64	0.776
18	116253.0	3320.78	0.778
19	115679.3	3308.85	0.767
20	116726.6	3310.53	0.769

TABELA 20 MEDIÇÕES, PCBA 5.2KW IGBT 3 HSS

Nº Medição	Resistência E-C (Ω)	Resistência G-E (Ω)	Resistência C-E (Ω)
1	100666.6	72917.57	1051842
2	100633.4	72783.62	1051814
3	100140.4	73620.58	1044806
4	100700.3	72900.89	1043655
5	100489.4	73611	1050855
6	100304.7	72935.28	1052329
7	100270.2	72972.17	1052101
8	100304.4	73213.94	1052244
9	100287.8	73321.76	1052148
10	100302.5	73267.9	1052302
11	100307.1	72904.48	1046448
12	100301.0	72928.74	1052607
13	100302.3	73411.46	1052578
14	100299.1	73472.9	1052558
15	100300.6	73596.12	1052566
16	100301.8	73014.34	1052585
17	100297.6	73025.87	1052579
18	100300.6	73070.13	1052644
19	100708.3	73279	1052699
20	100700.3	72987.89	1050855

TABELA 20 MEDIÇÕES, PCBA 5.2KW VALORES DE TENSÃO

Nº Medição	VCC Digital Isolator V	TP1137 TprgL1104 V	TP1135 TprgL1102 XresLV V	TP1133 TprgL1100 SWDIOLV V	CONETOR LV V
1	4.997	4.996	4.982	4.992	12.987
2	4.997	4.996	4.982	4.991	12.989
3	4.997	4.996	4.982	4.835	12.989
4	4.997	4.996	4.982	4.865	12.989
5	4.997	4.996	4.982	4.991	12.989
6	4.997	4.996	4.982	4.820	12.989
7	4.997	4.996	4.981	4.868	12.987
8	4.996	4.995	4.981	4.967	12.988
9	4.996	4.995	4.981	4.965	12.987
10	4.996	4.996	4.981	4.972	12.989
11	4.996	4.996	4.981	4.869	12.988
12	4.996	4.996	4.981	4.972	12.989
13	4.996	4.996	4.981	4.979	12.975
14	4.996	4.996	4.981	4.978	12.987
15	4.996	4.996	4.982	4.980	12.987
16	4.997	4.997	4.981	4.927	12.987
17	4.996	4.996	4.981	4.957	12.987
18	4.996	4.996	4.981	4.980	12.987
19	4.996	4.996	4.981	4.962	12.987
20	4.996	4.996	4.981	4.820	12.987

TABELA 20 MEDIÇÕES, PCBA 8KW IGBT1 HSS

Nº Medição	Resistência C-E (Ω)	Resistência E-C (Ω)	Resistência G-E (Ω)
1	649771.7	32763.14	8879.11
2	648949.3	32855.67	8881.99
3	649555.1	32916.29	8880.56
4	648951.6	32966.77	8885.29
5	648934.2	33004.40	8886.35
6	648962.4	33030.73	8886.14
7	648551.6	32462.77	8885.75
8	649203.1	32069.07	8866.32
9	648358.0	32120.48	8863.52
10	648730.1	32855.67	8812.22
11	649540.1	32916.29	8864.09
12	649800.14	32966.77	8820.17
13	648958.4	33404.46	8880.56
14	649120.4	32035.73	8845.23
15	648900.2	33562.23	8856.34
16	649110.1	32039.07	8823.14
17	649400.7	33487.09	8885.71
18	649220.1	33048.21	8836.32
19	649030.1	32671.03	8863.52
20	648790.1	33010.23	8854.76

TABELA 20 MEDIÇÕES, PCBA 8KW IGBT2 HSS

Nº Medição	Resistência C-E (Ω)	Resistência E-C (Ω)	Resistência G-E (Ω)
1	647509.5	32104.57	14989.27
2	647727.4	32232.04	14988.78
3	646991.9	32249.53	14988.32
4	647707.6	32099.78	14989.09
5	647285.2	32106.34	14963.84
6	647720.8	32255.88	14988.16
7	645721.8	32571.17	14990.37
8	647179.4	31834.64	14978.91
9	646814.0	31830.4	14965.22
10	646879.4	31928.48	14989.52
11	647070.9	31961.58	14988.22
12	646982.7	31678.92	14988.04
13	646727.5	31745.61	14980.63
14	647215.4	32056.93	14955.37
15	647112.9	31812.37	14957.82
16	646743.1	32502.74	14970.28
17	646898.5	32415.39	14973.95
18	647289.6	31984.25	14977.42
19	647732.9	32207.16	14960.49
20	646915.4	32341.82	14985.27

TABELA 20 MEDIÇÕES, PCBA 8KW IGBT3 HSS

Nº Medição	Resistência C-E (Ω)	Resistência E-C (Ω)	Resistência G-E (Ω)
1	647214.5	32619.18	14966.36
2	647255.8	32699.47	14965.89
3	647259.0	32755.55	14965.26
4	647285.2	32806.34	14963.84
5	647281.6	32836.53	14965.67
6	647327.5	32851.28	14965.68
7	646958.7	32583.69	14968.56
8	647230.4	32337.42	14967.27
9	646940.0	32569.14	14970.22
10	647112.3	32474.64	14945.62
11	646923.7	32745.21	14947.18
12	648145.6	31988.16	14949.77
13	647801.2	32203.71	14952.33
14	648399.8	32519.42	14954.91
15	646987.4	31990.81	14957.46
16	647298.9	32811.09	14959.82
17	648210.5	32057.33	14962.27
18	647654.1	32632.52	14965.14
19	646735.0	32745.91	14968.59
20	647876.4	32672.56	14956.82

TABELA 20 MEDIÇÕES, PCBA 8KW IGBT4 LSS

Nº Medição	Resistência E-C (Ω)	Resistência G-E (Ω)	Díodo E-C (V)
1	116424.1	7350.98	0.814
2	116730.4	7354.06	0.814
3	116922.2	7356.05	0.815
4	117057.7	7357.23	0.815
5	117155.1	7358.14	0.815
6	117167.3	7358.28	0.815
7	116884.7	7319.50	0.811
8	116634.2	7330.49	0.811
9	117212.8	7331.17	0.812
10	117351.2	7332.55	0.812
11	116512.8	7331.72	0.812
12	116789.3	7334.89	0.812
13	117024.3	7337.15	0.814
14	117398.1	7340.62	0.811
15	117045.9	7344.08	0.812
16	116754.9	7347.93	0.812
17	116998.6	7359.74	0.814
18	117145.7	7354.66	0.813
19	117398.1	7351.47	0.811
20	116762.4	7320.45	0.814

TABELA 20 MEDIÇÕES, PCBA 8KW IGBT5 LSS

Nº Medição	Resistência E-C (Ω)	Resistência G-E (Ω)	Díodo E-C (V)
1	113624.1	7347.91	0.814
2	113890.6	7350.57	0.814
3	114105.1	7352.51	0.815
4	114227.8	7353.73	0.815
5	114330.2	7361.40	0.815
6	114138.2	7354.68	0.815
7	114464.5	7355.77	0.815
8	114027.7	7317.99	0.812
9	114839.2	7334.12	0.812
10	114538.2	7327.11	0.813
11	114465.9	7328.32	0.813
12	114572.7	7329.32	0.813
13	113961.3	7361.40	0.812
14	113184.1	7333.78	0.814
15	114073.4	7352.81	0.813
16	114298.7	7337.46	0.812
17	114487.9	7345.63	0.814
18	114845.9	7320.87	0.814
19	113514.9	7330.12	0.814
20	114739.5	7341.02	0.814

TABELA 20 MEDIÇÕES, PCBA 8KW IGBT6 LSS

Nº Medição	Resistência E-C (Ω)	Resistência G-E (Ω)	Díodo E-C (V)
1	116262.2	7356.14	0.814
2	116460.1	7358.51	0.815
3	116620.1	7360.20	0.815
4	116733.5	7361.43	0.815
5	116818.6	7362.34	0.816
6	116920.5	7363.57	0.816
7	115742.1	7323.80	0.814
8	115359.2	7336.07	0.813
9	115440.5	7336.89	0.813
10	116589.3	7337.89	0.814
11	116432.6	7341.56	0.815
12	116785.3	7324.12	0.814
13	115763.2	7330.64	0.815
14	116701.4	7327.45	0.814
15	116245.1	7353.28	0.814
16	115147.4	7345.98	0.813
17	115872.9	7334.21	0.813
18	115523.4	7322.39	0.814
19	115498.7	7356.04	0.814
20	116457.5	7350.42	0.813

TABELA 20 MEDIÇÕES, PCBA 8KW VALORES DE TENSÃO BOTTON OVERLLAY

Nº Medição	INPUT U1200 V (V)	INPUT VOLTAGE T1300 (V)	5V_LV	AnClamp30_1 TP1114 (V)	AnClamp30_2 TP1114 (V)
1	12.31494	12.20366	5.000717	2.601644	2.029914
2	12.31664	12.20482	5.00063	2.60175	2.02977
3	12.31686	12.20727	4.9999	2.60155	2.03045
4	12.31799	12.20670	5.00019	2.60180	2.03069
5	12.31699	12.20587	5.00028	2.60173	2.03013
6	12.32192	12.21366	5.000331	2.602141	2.030767
7	12.32184	12.21007	5.00023	2.603671	2.031703
8	12.32261	12.21246	4.999999	2.603344	2.032243
9	12.32355	12.21237	5.000099	2.603072	2.032401
10	12.2898	12.1786	5.00035	2.596325	2.02604
11	12.29034	12.1789	5.000213	2.596731	2.02591
12	12.2898	12.17891	5.000474	2.596624	2.025838
13	12.29898	12.17887	5.000297	2.596546	2.026177
14	12.29013	12.17952	4.999978	2.595969	2.037277
15	12.29101	12.18021	5.000271	2.59354	2.020306
16	12.29064	12.18049	4.999988	2.598931	2.03091
17	12.32781	12.21785	5.000281	2.602083	2.031077
18	12.32895	12.21855	5.000543	2.601987	2.031301
19	12.32753	12.21586	4.998325	2.601721	2.031164
20	12.3277	12.21734	4.998094	2.602023	2.031291