



UNIVERSIDADE D
COIMBRA

Nicole Gabriela Santos Duarte

CLASSIFICAÇÃO DE COMPONENTES DE PLACAS
DE CIRCUITO IMPRESSO, DE TELEMÓVEIS,
USANDO VISÃO POR COMPUTADOR

Dissertação no âmbito do Mestrado em Engenharia Física, orientada pelos
Professores Doutores Pedro Mariano Simões Neto e Lino José Forte Marques e
apresentada ao Departamento de Física da Faculdade de Ciências e Tecnologia da
Universidade de Coimbra.

setembro 2023



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE DE
COIMBRA

DEPARTAMENTO DE FÍSICA

Nicole Gabriela Santos Duarte

**CLASSIFICAÇÃO DE COMPONENTES DE
PLACAS DE CIRCUITO IMPRESSO, DE
TELEMÓVEIS, USANDO VISÃO POR
COMPUTADOR**

Dissertação no âmbito do Mestrado em Engenharia Física, orientada pelos Professores Doutores Pedro Mariano Simões Neto e Lino José Forte Marques e apresentada ao Departamento de Física da Faculdade de Ciências e Tecnologia da Universidade de Coimbra, para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Engenharia Física.

setembro 2023



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE DE
COIMBRA

DEPARTMENT OF PHYSICS

Nicole Gabriela Santos Duarte

**VISION-BASED CLASSIFICATION OF
MOBILE PHONE PRINTED CIRCUIT BOARD
COMPONENTS**

Dissertation in the context of the Master in Engineering Physics supervised by PhD. Pedro Mariano Simões Neto and co-supervised by PhD. Lino José Forte Marques and presented to the Department of Physics of the Faculty of Sciences and Technology of the University of Coimbra.

September 2023

Agradecimentos

Começar por agradecer a oportunidade ao projeto RECY-SMARTE - PTDC/CTA-AMB/3489/2021, financiado por fundos nacionais através da FCT/MCTES (PID-DAC), onde esta dissertação se inclui. Agradeço também ao Professor Doutor Lino Marques pela atribuição da bolsa de investigação no âmbito do projeto “Warehouse of the Future” (referência: IN1167) co-financiado pelo Fundo Europeu de Desenvolvimento Regional, através do Portugal 2020 (PT2020), pelo Programa Operacional de Competitividade e Internacionalização (COMPETE 2020), e pelo Programa Operacional Regional de Lisboa 2014/2020 (LISBOA2020). Um grande obrigada ao meu orientador Professor Doutor Pedro Mariano Simões Neto pela oportunidade de colaborar com o seu grupo de investigação durante este 2 anos e por todos os conhecimentos que me transmitiu, tornando-me uma melhor profissional.

O maior agradecimento vai direcionado aos meus pais, António e Catarina. Espero que se sintam orgulhosos de tudo o que lutei para conseguir, principalmente neste caminho de 5 anos. Dizer-vos que nada é mais importante na minha vida que o nosso amor e a nossa união. Obrigada por serem sempre o meu apoio, o meu lugar seguro, o sítio a que chamo verdadeiramente casa. Obrigada por acreditarem sempre em mim, mesmo quando eu própria duvidei e a minha vida ficou sem rumo, onde só via o fundo do poço. Acreditem que o vosso abraço e carinho é o meu sítio preferido, mesmo eu sendo a pessoa mais determinada, que quer ter asas para voar e ser independente. Nada do que vos diga é suficiente para agradecer tudo o que lutam por mim, mas o único exemplo de sorte na minha vida é chamar-vos de meus pais.

Um obrigada especial às pessoas do LIP, principalmente à Professora Doutora Filomena Santos. Os 3 anos que passei convosco deram-me a bagagem certa para enfrentar o mundo da investigação e os valores certos para confrontar os problemas da vida. Obrigada por todas as conversas/partilhas (não só de conhecimento) e por me ajudarem a tornar uma pessoa mais capaz.

Agradecer, de seguida, ao meu companheiro desde o primeiro dia desta aventura, ao meu amigo, Jorge Silva. O mundo precisa de pessoas tão genuínas e trabalhadoras como tu. Obrigada por toda a partilha de conhecimento e memórias. Por fim, querid@s Afonso Marques, António Rodrigues, Bruno Midões, Bruno Santos, Dário Marcelo, Daniel Vieira, Débora Castela, Diogo Flórido, Francisco Couto, Gil Madeira, Guilherme Rodrigues, Jesús Villoria, João Costa, Jorge Pereira, Miguel Sousa, Sandra Mamede, Sérgio Rodrigues, Sílvia Santos, Valéria Carvalho e Valéria Lopes, agradecer todo o apoio e todos os momentos que passámos juntos e dizer-vos que independentemente para onde a vida nos leve estarei sempre à distância de um telefonema.

Obrigada!

Resumo

A quantidade de resíduos eletrônicos gerados, anualmente, a nível mundial tem vindo a aumentar drasticamente preocupando a comunidade científica. No caso dos telemóveis, as suas pequenas dimensões facilitam a sua deposição incorreta em aterros ou o recurso à incineração, com consequências ambientais e económicas nefastas para a sociedade. Para contornar isso, vários autores, recolhem e desmontam telemóveis obsoletos e trituram as suas placas de circuito impresso (PCBs) até ficarem em pó fino, procedendo a uma separação magnética e eletrostática, juntamente com uma análise do tamanho das partículas para classificar os materiais presentes. No entanto, este método não permite a recuperação de nenhum dos componentes para uma possível reutilização. Assim, identificar a composição dos materiais dos telemóveis e recuperá-los é a maior e mais emergente área de investigação nos domínios da reciclagem e sustentabilidade uma vez que, os PCBs são dispositivos com várias camadas de polímeros e metais, aliando esta complexidade ao tamanho reduzido das suas componentes e à elevada variabilidade de modelos de telemóveis que se reflete, por exemplo, nas cores de fundo dos PCBs e na sua geometria.

Por forma a tentar ultrapassar as referidas dificuldades, foram aplicadas técnicas de visão por computador. Mais concretamente a aplicação do algoritmo de *deep learning* YOLO-v7 para proceder à deteção e classificação das componentes presentes nos PCBs, a partir de dados RGB. A decisão de quais os componentes de interesse para uma desmontagem seletiva baseada em robôs é baseada em termos de valor material. Assim sendo, começou-se por avaliar o desempenho da fase de treino na aprendizagem das características, utilizando as imagens do conjunto de dados sem qualquer pré processamento, tratando a placa como um todo, comparando com a performance recorrendo a técnicas de aumentos de dados, centralizadas no tamanho reduzido. De seguida, aplicaram-se esses resultados a PCBs diferentes, provenientes de outro conjunto de dados, onde as placas possuem tamanhos maiores e a PCBs de telemóveis de vários modelos.

Os resultados apresentados, ainda que não possam ser comparados com os da literatura existente, evidenciam uma taxa de reconhecimento das componentes, para o caso dos telemóveis, de 75%, sustentado a possibilidade de recuperação das componentes. O estudo realizado permite ainda propor alternativas de melhoria por forma a aumentar a quantidade de componentes reutilizados e reciclados.

Palavras-Chave

Visão por Computador, Classificação, *Deep Learning*, Componentes de PCBs, Lixo Eletrónico, Reciclagem, Reutilização, Sustentabilidade.

Abstract

The quantity of electronic waste generated annually worldwide has been increasing dramatically, causing concern within the scientific community. In the case of mobile phones, their small dimensions make it easy for them to be improperly disposed of in landfills or incinerated, with detrimental environmental and economic consequences for the society. To fight this issue, several authors collect and disassemble obsolete mobile phones, grind their printed circuit boards (PCBs) into fine powder, and perform magnetic and electrostatic separation, along with particle size analysis to classify the materials' components. However, this method does not allow the recovery of any components for possible reuse. Therefore, identifying the composition of mobile phone materials and recovering them is the largest and most emerging area of research in the fields of recycling and sustainability, as PCBs are devices with multiple layers of polymers and metals. This complexity is combined with the small size of their components and the high variability of mobile phone models, that is reflected, for example, in the background colors of PCBs and their geometry.

In order to overcome the mentioned difficulties, computer vision techniques were applied. Specifically, the YOLO-v7 deep learning algorithm was used to detect and classify the components present on the PCBs, using RGB data. The decision on which components are of interest for selective robot-based disassembly is based on material value. Therefore, we started by evaluating the performance of the training phase in learning the features using the dataset images without any preprocessing, treating the board as a whole, and comparing it with the performance when using data augmentation techniques, focusing on the smaller size. Next, these results were applied to different PCBs from another dataset, where the boards are larger, and to PCBs from various models of mobile phones.

The presented results, although they cannot be compared with those in existing literature, demonstrate a component recognition rate of 75% for mobile phones, supporting the possibility of component recovery. The study also allows to propose improvement alternatives to increase the quantity of components that can be reused and recycled.

Keywords

Computer Vision, Classification, Deep Learning, PCB Components, Electronic Waste, Recycling, Reuse, Sustainability.

Conteúdo

Lista de Figuras	xv
Lista de Tabelas	xvii
1 Introdução	1
1.1 Motivação e Enquadramento	1
1.2 Objetivos	3
1.3 Estrutura da Dissertação	4
2 Estado da Arte	5
2.1 Dados e <i>Datasets</i>	5
2.2 Detecção e Classificação dos Componentes	7
2.2.1 Métodos de Processamento de Imagem	8
2.2.2 Métodos de Classificação	14
3 Metodologia	21
3.1 Dataset	21
3.1.1 Definição das classes	21
3.2 Aquisição de Imagens	24
3.3 Classificação das componentes	25
3.3.1 YOLO V7	26
3.3.2 Pré Processamento	29
4 Resultados e Discussão	33
4.1 Indicadores de desempenho	33
4.2 Resultados	36
4.2.1 Treino e Validação	36
4.2.2 Detecção	39
5 Conclusão	45
5.1 Trabalho Futuro	46
Referências	49
Apêndice A Detalhes da Arquitetura YOLO-v7	55

Lista de Figuras

1.1	Esquema do Processo de Reconhecimento e Classificação a desenvolver na dissertação, incluindo todo o projeto Recy-Smart.	4
2.1	Exemplo de imagem no espaço de cor RGB de um PCB utilizado.	8
2.2	Comparação dos Espaços de Cor.	9
2.3	Técnicas de Processamento de Imagens, aplicadas aos PCBs.	13
2.4	Esquema representativo da estrutura do modelo RCNN.	16
2.5	Esquema representativo da estrutura do modelo YOLO.	16
3.1	Exemplo de imagem do <i>dataset</i> escolhido com as respectivas identificações, referente ao PCB DuetWIFI.	22
3.2	Exemplo de imagem com a identificação das 7 componentes escolhidas, referente ao PCB DuetWIFI. De notar que, a cada classe foi atribuída uma cor. Legenda: Cor de Rosa - circuitos integrados; Vermelho - conectores; Amarelo - condensador; Verde- resistência; Roxo - transístor; Laranja - indutor; Azul - led.	23
3.3	Montagem experimental para a aquisição de imagens desenvolvido no laboratório.	24
3.4	Arquitetura da rede associada ao modelo YOLO-v7.	27
3.5	Diferença entre as imagens de um PCB de telemóvel antes e após a aplicação de pré processamento.	29
3.6	Exemplo de um resultado da aplicação da técnica de mosaico em frações de imagens do <i>dataset</i> utilizado.	31
4.1	Matriz de confusão para o treino do conjunto de dados, sem processamento.	37
4.2	Matriz de confusão para o treino do conjunto de dados, com aumento de dados.	37
4.3	Exemplos de resultados para a deteção de componentes, onde para o treino do modelo não existiu pré processamento.	39
4.4	Identificação e classificação de componentes de PCBs de maiores dimensões.	41
4.5	Identificação e classificação de componentes de PCBs de telemóveis, modelo Samsung.	42
4.6	Identificação e classificação de componentes de PCBs de telemóveis, modelo Alcatel.	43
4.7	Identificação e classificação de componentes de PCBs de telemóveis, modelo Samsung.	43

4.8	Identificação e classificação de componentes de PCBs de telemóveis, modelo InnJoo.	44
A.1	Detalhes da arquitetura do modelo YOLO-v7, para complementar a imagem 3.4	55

Lista de Tabelas

2.1	Resumo de alguns dos datasets existentes para o estudo de PCBs, utilizando câmaras.	6
2.2	Resumo dos artigos mais relevantes apresentados no estado da arte.	20
3.1	Percentagens dos vários metais que constituem as diferentes componentes dos PCBs.	23
4.1	Apresentação dos resultados do desempenho do modelo para os diferentes conjuntos de dados.	38
4.2	Taxas de reconhecimento de componentes em diferentes PCBs. . . .	40

Capítulo 1

Introdução

1.1 Motivação e Enquadramento

Devido à crescente inovação tecnológica e ao facto do tempo de vida útil dos produtos ser cada vez menor, existe uma quantidade significativa de resíduos produzida quando os vários dispositivos eletrónicos são descartados. Embora seja difícil fornecer uma estimativa precisa da produção de resíduos devido a falhas nos dados e, em alguns casos, à inexistência dos mesmos, a ONU estima que a produção global de resíduos dos equipamentos elétricos e eletrónicos (WEEE) seja de 20 a 50 milhões toneladas por ano [Arshadi et al., 2018; Hadi et al., 2015; Hao et al., 2020]. No entanto, para 2030, prevê-se que atinja perto de 75 milhões de toneladas por ano [Liu et al., 2022]. As placas de circuito impresso (PCBs) são a base dos referidos dispositivos, dado que são a plataforma sobre a qual componentes micro-eletrónicos são montados e conectados. Por isso, são considerados por vários autores o tipo de *e-waste* economicamente mais valioso dado que possuem até 60 % de metais raros e preciosos devido à sua excelente condutividade [Abdelbasir et al., 2018; Hadi et al., 2015; Hao et al., 2020]. Assim sendo, a sua reciclagem eficaz ocupa um lugar de destaque por duas razões principais: estes contém materiais tóxicos que podem causar danos ambientais se não forem tratados adequadamente e são constituídos por uma fração significativa de metais (cerca de 30-40% em média [Hao et al., 2020; Kaya, 2016]) que ao serem recuperados, torna-se algo simultaneamente económico e ecológico. No caso específico dos PCBs que integram os telemóveis, estes possuem na sua constituição aproximadamente 53.1% de metais base (ferro, cobre, alumínio e níquel), 1.87% de metais críticos (chumbo), 0.0187% de metais preciosos (prata, ouro e paládio) [Udayakumar et al., 2022], alguns plásticos e cerâmicas [Pramerdorfer and Kampel, 2015a]. Embora aparentem ser quantidades muito pequenas, o aumento do preço desses metais e o número total de telemóveis produzidos (mais de 1,2 bilhões anualmente em todo o mundo) e descartados (mais de 100 milhões [Yamane et al., 2011]) torna o seu valor bastante considerável [Hadi et al., 2015]. Por conseguinte, os resíduos eletrónicos podem ser considerados como uma fonte de matéria prima artificial ou secundário e utilizado como incentivo económico.

Desta maneira, os resíduos eletrônicos proveniente dos PCBs podem ser tratados diretamente, o que inclui aterros e incineração, ou recorrendo a reciclagem por vários tipos de tecnologias. De acordo com a Agência de Proteção Ambiental, apenas 15-20% do lixo eletrônico foi reciclado, enquanto o restante foi para aterros e incineradores [Udayakumar et al., 2022]. Por exemplo, a incineração de PCBs é um dos métodos inadequados uma vez que liberta gases tóxicos de cádmio (Cd), chumbo (Pb), arsénico (As) e crómio (Cr) que tendem a poluir a atmosfera circundante e afetam a saúde humana. Ainda que as pequenas dimensões dos telemóveis incentivem a sua deposição incorreta nos resíduos sólidos urbanos, comparado com os referidos tratamentos diretos, a sua reciclagem é mais favorável não simplesmente devido à redução de resíduos, mas pela reutilização de recursos com uma melhor viabilidade económica e menor impacto ambiental [Ning et al., 2017]. Outra alternativa, atualmente, para ao tratamento de resíduos de telemóveis à escala industrial consiste no pré-tratamento através de desmontagem manual e trituração, seguido de separação de materiais com base em diferentes propriedades (dimensões, densidade, comportamentos magnéticos e eletrostáticos, etc.) e finalmente, a recuperação do material através da extração de ácidos ou da purificação do concentrado metálico. A desmontagem é geralmente efetuada manualmente, uma vez que a elevada variabilidade do design dos artigos dificulta a rentabilidade da desmontagem automática. Neste caso, a saúde dos operadores encarregados do desmantelamento dos componentes pode ser afetada também, principalmente devido ao risco carcinogénico derivado aos metais pesados, já enunciados, que os constituem. Posto isso, a Comissão Europeia lançou a Diretiva 2002/96/EC, conhecida como Diretiva dos WEEE, que entrou em vigor em 13 de fevereiro de 2003, com o objetivo de alcançar até 70-80% de recuperação dos equipamentos elétricos e eletrónicos [Ning et al., 2017]. Desde 2015 que vários países em redor do mundo (como a China, o Brasil, o Canadá, os Estados Unidos e o Reino Unido) seguem as mesmas tendências legislativas e desenvolveram leis e diretrizes relacionadas com o WEEE. A Comissão Europeia adotou recentemente o Regulamento de Execução (UE) 2019/290, que se centra na restrição do uso de substâncias perigosas em equipamentos elétricos e eletrónicos equipamento na Diretiva REEE de 2003. A evolução das leis e regulamentos demonstra um avanço em relação aos impactos que a eliminação inadequada da eletrónica materiais que podem ter sobre o meio ambiente, assim o desenvolvimento de projetos nesta linha de a investigação reflete positivamente as atuais questões de sustentabilidade da indústria. Atualmente, a incineração, a deposição em aterro e a exportação para o estrangeiro são proibidas para a gestão de resíduos eletrónicos devido às leis mais rigorosas que são aplicadas nos países desenvolvidos, onde se incluem a União Europeia, os Estados Unidos, a Austrália e o Japão [Abdelbasir et al., 2018]. Assim, as preocupações ambientais e a presença de metais ou componentes reutilizáveis provocam a necessidade de recuperar metais pesados e preciosos dos resíduos eletrónicos, antes de os eliminar no ambiente. Contudo, as consequências ambientais e a elevada procura de energia são as principais limitações que impedem a sua utilização em grande escala. No entanto, dada a continuidade da avassaladora produção, prevê-se num futuro próximo, algo mais rigoroso como uma legislação que exija que todos os equipamentos referidos sejam desenvolvidos com a condição de desmontagem englobando as suas pré-produção, produção e pós-produção [Hadi et al., 2015].

Atualmente, devido à diversidade de materiais e componentes existentes nos PCBs a sua separação e consequente reciclagem torna-se um processo complexo e dispendioso. Pelo que, até então, a separação dos metais é realizada mecânica ou quimicamente por processos destrutivos. As linhas de reciclagem existentes não utilizam informações dos PCBs e o fluxo de entrada é fragmentado em pequenas partículas das quais os metais podem ser extraídos [Pramerdorfer and Kampel, 2015a]. Contudo, com o constante avanço tecnológico, os telemóveis são, simultaneamente, um dos dispositivos eletrónicos mais populares entre os consumidores e com um tempo de vida útil menor, tornando-se num dos maiores contribuintes para os fluxos de WEEE pelo que, a sua reciclagem é um dos problemas que mais rapidamente deve ser resolvido [Liu et al., 2022]. Ainda assim, a mão de obra disponível torna-se cada vez mais escassa e, conseqüentemente, mais dispendiosa. No entanto, visto que nos encontramos perante milhões de toneladas de equipamentos, o processo manual resulta em algo ineficiente.

1.2 Objetivos

Por forma a contornar estes desafios, surge o projeto *RECY-SMART - Sustainable approaches for recycling and re-use of discarded mobile phones* da Faculdade de Engenharia da Universidade do Porto em colaboração com o Instituto de Sistemas e Robótica do Departamento de Engenharia Eletrotécnica e Computadores e com o Laboratório de Robótica Colaborativa do Departamento de Engenharia Mecânica, ambos da Universidade de Coimbra. A primeira encontra-se responsável pelo tratamento das componentes dos PCBs, de telemóveis, utilizando processos químicos sustentáveis. Os, onde esta dissertação se enquadra, têm como objetivo o design e implementação de uma unidade de desmontagem robótica para a automatização do processo de reciclagem que contenha um sistema de classificação baseado em inteligência artificial e um robô que realize as tarefas de separação dos elementos. Como os PCBs dos telemóveis possuem um tamanho pequeno quando comparados aos dos restantes equipamentos e são fabricados em várias formas e camadas dependendo do modelo ao qual se referem a sua reciclagem e consequente recuperação dos materiais que os constituem é um dos maiores desafios da engenharia na atualidade [Hadi et al., 2015]. Por isso mesmo, um dos requisitos que o referido projeto pretende alcançar é a sua aplicabilidade a este tipo específico de PCBs. Dado o seu tamanho, também se pretende identificar as componentes com a maior precisão possível uma vez que essa informação será transmitida ao robô de desmantelamento que extrairá as componentes. Desta forma, pretendem-se implementar algoritmos de inteligência artificial por serem uma matéria bastante atual com resultados bastante favoráveis em áreas de reconhecimento e identificação mas também por existir um conteúdo muito pequeno que a associe ao reconhecimento das componentes de PCBs, tornando assim o projeto simultaneamente inovador e promissor.

Assim sendo, o trabalho descrito nesta dissertação de mestrado propõe uma alternativa mais eficiente para o reconhecimento dos vários componentes de PCBs de telemóveis, bem como a identificação precisa da sua posição, utilizando da-

dos RGB processados recorrendo a visão por computador e inteligência artificial. Sendo, os resultados posteriormente utilizados como *input* no processo de desmontagem automatizada (Fig. 1.1).

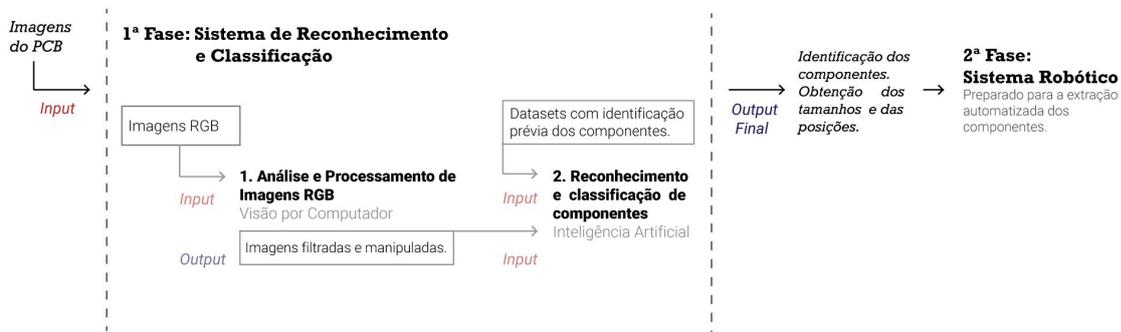


Figura 1.1: Esquema do Processo de Reconhecimento e Classificação a desenvolver na dissertação, incluindo todo o projeto Recy-Smart.

1.3 Estrutura da Dissertação

A presente dissertação contém encontra-se dividida por capítulos. Inicialmente, tem-se a Introdução onde são descritos a motivação, os objetivos, o enquadramento e a estrutura. De seguida, é apresentado o Estado da Arte, onde se realiza a revisão da literatura existente e do contexto teórico do projeto. No terceiro capítulo, são descritos os Métodos utilizados: sistema para a obtenção das imagens dos PCBs usando câmeras RGB, forma de processamento das mesmas usando visão por computador e os modelos de inteligência artificial para a classificação dos componentes. No capítulo 4 encontrar-se-ão os Resultados bem como alguns Comentários e Discussões. Por fim, serão apresentadas as Conclusões do projeto e o possível trabalho futuro.

Capítulo 2

Estado da Arte

A presente dissertação visa o desenvolvimento de algoritmos para a detecção e identificação de componentes das placas de circuito impresso, de telemóveis, com recurso a métodos de visão por computador.

Para isso, é necessário a obtenção de imagens dos referidos PCBs. Dado o seu tamanho, para além da componente RGB conseguida com as câmaras 2D, é necessário avaliar qual o tipo de sensor a utilizar para obter as imagens dos telemóveis. No entanto, para o treino do modelo pode-se recorrer a um conjunto de imagens de PCBs já existentes. Para além disso, dado que os métodos que se pretendem seguir exigem aprendizagem, antes de elaborar o algoritmo propriamente dito, é necessário identificar e classificar previamente alguns dos componentes presentes nos PCBs.

Assim, para cumprir as várias fases supra descritas torna-se imperativo elaborar um estado da arte, onde se analisem os conjuntos de dados existentes e os métodos associados à detecção e identificação de componentes, por forma a desenvolver os algoritmos pretendidos. Deste modo, ao longo deste capítulo serão apresentados os conhecimentos base e as abordagens já existentes, de modo a facilitar a compreensão do projeto. Começam-se por apresentar e explorar os *datasets* de PCBs existentes e os tipos de sensores para a obtenção das imagens de modo a compreender os principais cuidados a ter e, se necessário, reproduzir o método. Posto isto, são apresentadas e discutidas as técnicas de processamento de imagens utilizadas na detecção dos componentes. Ou seja, na seleção de áreas de interesse para, posteriormente, atribuir um rótulo de classificação. Por fim, serão explorados os algoritmos já existentes para a classificação dos componentes no âmbito da visão por computador e da inteligência artificial.

2.1 Dados e *Datasets*

A primeira etapa do projeto consiste na aquisição de imagens de PCBs. Para isso, torna-se imperativo o conhecimento dos *datasets* existentes por forma a faci-

litar o estudo associado aos métodos que englobam visão por computador.

Não existem muitos datasets de PCBs disponíveis para o estudo que se pretende desenvolver no projeto e nenhum deles contém só PCBs de telemóveis. Desta forma, alguns dos *datasets* publicados encontram-se relacionados com a deteção de defeitos nos PCBs ([Huang and Wei, 2019; Huang et al., 2020; Lu et al., 2020; Mahalingam et al., 2019; Tang et al., 2019]). Dado que essa não é a abordagem pretendida na dissertação, apenas se considerou o tipo de sensor para a aquisição das imagens. Os dois primeiros foram obtidos recorrendo a *charge coupled device* e um microscópio digital, respetivamente e os restantes utilizam câmaras DSLR (*digital single-lens reflex*). Outros, tais como os desenvolvidos por [Herchenbach et al., 2013; Li et al., 2013, 2014; Soomro et al., 2022; Zhao et al., 2022], não são de acesso público e os primeiros carecem de informações detalhadas sobre as características do conjuntos de dados que apresentam. Ainda assim o conjunto de imagens PCB-DSLR (Tabela 2.1) é uma versão sucessora de outro dos mesmos autores ([Pramerdorfer and Kampel, 2015b]) que ficou indisponível por conter imagens de baixa qualidade que se tornam inadequadas para a análise ao nível das componentes que se pretende reconhecer e classificar.

Desta forma, de seguida na tabela 2.1, encontram-se apresentados e explicitados os *datasets*, públicos, mais recentes que têm por base o uso de câmaras, devolvendo imagens RGB.

Tabela 2.1: Resumo de alguns dos datasets existentes para o estudo de PCBs, utilizando câmaras.

Identificação do dataset	# Imagens	Características das Imagens	Tipo de Sensor	Resolução (pixels/cm)	Artigo Correspondente
PCB DSLR	165 PCBs diferentes 3 a 5 imagens em cada 748 no total	Identificação de 1 componente Classificação de 1740 objetos Imagens de diferentes orientações	Câmara DSLR Nikon D4 lente f/2.8 60mm Uso de filtro de polarização	87.4	[Pramerdorfer and Kampel, 2015a]
PCB-METAL	123 PCBs diferentes 8 imagens em cada um 984 no total	Identificação de 4 componentes Classificação de 12 231 objetos Imagens obtidas de 4 graus de rotação	Câmara DSLR Canon EOS 5D Mark II	-	[Mahalingam et al., 2019]
PCB-WACV	47 PCBs diferentes	Identificação de todas as componentes Identificação de texto Classificação de 7914 objetos	Câmara DSLR não especificada e Câmeras industriais	191.0	[Kuo et al., 2019]
FICS-PCB	31 PCBs diferentes 9912 imagens no total	Identificação de 6 componentes Classificação de 77 347 objetos	Câmara DSLR Nikon D850 lente 105 mm	118.0	[Lu et al., 2020]

De notar que, embora seja o mais antigo, o PCB DSLR foi desenvolvido utilizando PCBs provenientes de reciclagem, pelo que se torna compatível com o projeto que se pretende desenvolver. O seu conjunto de dados é o que possui um número maior de PCBs em estudo, no entanto só possui identificação com caixas delimitadoras para identificar todos os *chips*. Uns anos mais tarde, [Mahalingam et al., 2019] elaboraram um novo *dataset*, com imagens de elevada qualidade para o desenvolvimento de algoritmos de deteção de 4 componentes (*chips*, condensadores, resistências e indutores), contendo até algumas imagens de PCBs provenientes de telemóveis. Importante referir que, ambos os *datasets* possuem imagens orientadas de forma arbitrária, garantindo aleatoriedade para a aplicação de métodos na fase de deteção dos componentes. No entanto, de acordo com os referidos autores, quando comparadas as performances dos dois *datasets* na

deteção de componentes verificam-se piores resultados utilizando o PCB-DSLR, uma vez que se verifica inconsistência na captura das placas, ou seja, estas são rodadas em ângulos fora do padrão (0° , 90° , 180° , 270°). O *dataset* mais recente, foi desenvolvido por [Lu et al., 2020], onde o sistema experimental para além da câmara DSLR possui uma segunda montagem que utiliza um microscópio digital para a obtenção de imagens, algo que para o presente trabalho não é exequível de reproduzir, no entanto, este método garante uma elevada precisão e aplicabilidade a diferentes tipos de condições experimentais. Para além das componentes já referidas, o conjunto de dados permite detetar díodos e transístores, ou seja, componentes cada vez mais pequenas, algo bastante aplicável na deteção de componentes de PCBs de telemóveis.

Em [Herchenbach et al., 2013] os autores utilizam uma combinação de uma câmara RGB e de um sensor de profundidade para proceder à deteção de componentes. O sensor utilizado foi o *Kinect* da Microsoft, sendo este uma alternativa às câmaras RGB convencionais uma vez que permite o acesso a informações detalhadas das imagens. No entanto, para o estudo que se pretende realizar, a resolução das imagens obtidas não garante bons resultados na segmentação de componentes.

2.2 Deteção e Classificação dos Componentes

Embora existam muitos métodos de análise de PCBs, que utilizam processamento de imagem, visão por computador, e *machine* e *deep learning*, o estudo das placas é complexo e cada vez mais evolutivo, por isso são necessárias adaptações nas técnicas existentes para ultrapassar os problemas emergentes. Assim sendo, na presente secção serão apresentados e analisados alguns dos métodos/trabalhos existentes para, posteriormente, se construir o modelo mais adequado ao caso em estudo.

Os métodos existentes baseados em inteligência artificial, normalmente, evidenciam um desempenho superior aos métodos tradicionais de visão por computador e análise de imagens. Contudo, requerem frequentemente mais dados, possuem baixa explicabilidade e podem ser difíceis de implementar quando os modelos são bastante diferentes entre si. Para superar estes desafios, os métodos de visão por computador podem ser combinados com os de inteligência artificial. Em particular, os algoritmos de visão de interpretação humana, tais como os que extraem a cor, forma e características de textura aumentam a garantia de explicabilidade do PCB. Isto permite incorporação de conhecimentos prévios, o que reduz efetivamente o número de parâmetros necessários para o desenvolvimento do algoritmo e, portanto, a quantidade de dados necessários, para alcançar uma alta precisão ao treinar ou re-treinar o modelo, diminui [Zhao et al., 2022].

2.2.1 Métodos de Processamento de Imagem

Após a apresentação dos *datasets* existentes, por forma a analisar os fatores relacionados com sistemas de aquisição de imagem que podem afetar significativamente o desempenho da detecção de componentes desenvolvidos, passa-se para a etapa seguinte que consiste na análise das imagens propriamente dita.

Recentemente, [Zhao et al., 2022] dedicaram-se à detecção e identificação dos componentes de PCBs usando métodos de processamento de imagem. No referido trabalho, procederam à comparação entre métodos de extração de informações de cor, forma e textura para imagens de PCBs. Para o primeiro, os autores confrontaram os três métodos principais: *Red, Green, Blue* (RGB), *hue, saturation, value* (HSV) e *lightness, green/red, yellow/blue* (LAB). A representação RGB é a mais comum e simples e encontra-se evidente na figura 2.1. O seu princípio consiste na sobreposição das cores primárias vermelho, verde e azul para a reconstrução das restantes cores. No entanto, o referido espaço de cor é mais orientado para o hardware, que é normalmente usado em sistemas de obtenção de imagem e visualização, e raramente é utilizado em processamento das mesmas. As cores do referido modelo podem ser afetadas pela luminosidade, dado que as três componentes se encontram fortemente correlacionadas. Ou seja, quando uma das componentes de cor muda, afetará também os restantes. Assim, utilizando a citada abordagem, torna-se desafiante, por exemplo, a distinção entre resistências e indutores dos PCBs.

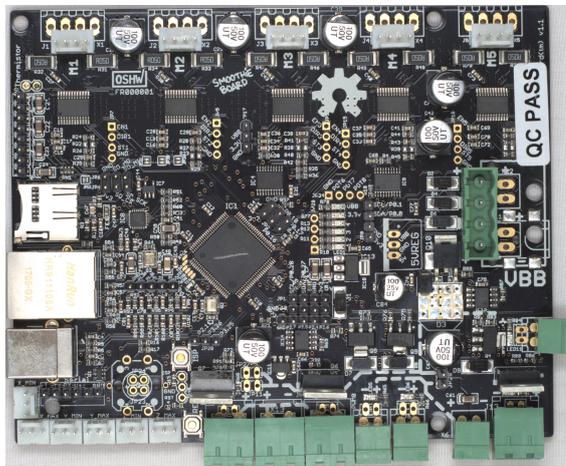
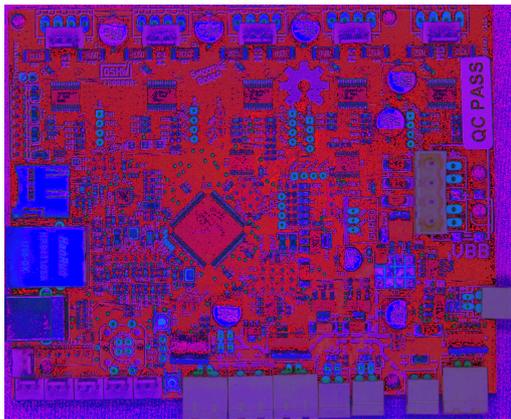


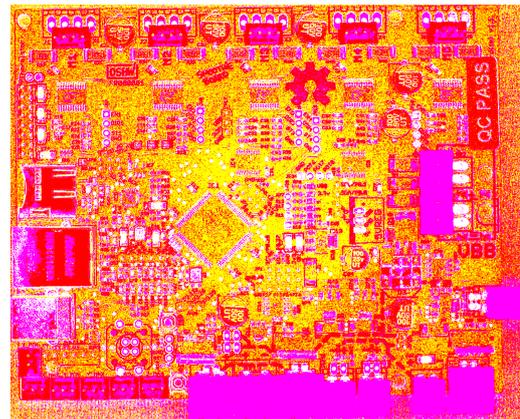
Figura 2.1: Exemplo de imagem no espaço de cor RGB de um PCB utilizado.

Por outro lado, o modelo HSV (figura 2.2a), representa a tonalidade (H), saturação (S), e valor (V). Cada atributo deste espaço de cor corresponde diretamente ao conceito básico de cor (quantidade de pigmento, vivacidade e intensidade, respetivamente) o que o torna conceptualmente mais simples e fácil de compreender. Assim, pode ser utilizado para eliminar a influência da intensidade nas cores uma vez que, quando a iluminação externa flutua ligeiramente, os valores de tonalidade variam menos do que os valores RGB. Por exemplo, duas cores

de vermelho podem ter valores de tonalidade comparáveis, mas valores de RGB muito diferentes. Assim, quando se pretende diferenciar componentes idênticos num PCB em condições de iluminação variáveis, o HSV pode devolver resultados melhores. Uma grande desvantagem centra-se no facto de que o branco, o preto e o cinzento não têm uma distinção de cromaticidade e consequentemente, estas cores são tratadas como singularidades, o que as torna difíceis de detetar. Assim, componentes, tais como, resistências, indutores, díodos poderão ser difíceis de distinguir com a utilização deste espaço de cores.



(a) Exemplo de imagem no espaço de cor HSV do mesmo PCB da figura 2.1..



(b) Exemplo de imagem no espaço de cor LAB do mesmo PCB da figura 2.1.

Figura 2.2: Comparação dos Espaços de Cor.

O último espaço de cor analisado foi o LAB, onde as suas componentes representam, respetivamente, a luminosidade, e as gamas de cores do vermelho ao verde e do amarelo ao azul (confrontar com a figura 2.2b). Este, permite a comparação e a análise direta de diferentes cores usando a distância geométrica e, por isso, devolve a cor exata, independentemente do dispositivo. Certos tipos de componentes nos PCB não possuem diferenças evidentes a olho nu, como os condensadores e as resistências. Assim, o espaço mencionado pode ser usado de forma eficaz para medir ligeiras diferenças de cor. A geração do mesmo, é relativamente complicada e torna-se menos natural e compreensível para os olhos humanos como o RGB ou outra perspetiva de cores. Este espaço de cor possui a mesma questão de singularidade que foi discutida nas limitações do espaço de cor do HSV. Para além das características de cor acima supra referidas, aferiram acerca das propriedades da forma e da textura que permitem a deteção mais eficiente dos componentes dos PCBs.

Para a inspeção da forma, os autores discutem os métodos mais significativos para a extração das características das imagens. Começaram pelo determinante de Hessian, que deteta *binary large objects* (blob) usando uma matriz através do cálculo dos máximos. O resultado dessa aplicação pode ser observado na figura 2.3a. Este tipo de objetos são geralmente brilhantes em regiões escuras ou escuros em regiões brilhantes de uma imagem. Este método utiliza filtros de caixa em vez

do método de convolução que eliminam a dependência de tamanhos. Quaisquer componentes curvos independentemente de serem ou não circulares, tais como transístores e díodos são facilmente detetados usando este método. O referido algoritmo, no entanto, não será capaz de detetar pequenos blobs com precisão, algo que o torna inadequado ao projeto devido às dimensões dos componentes dos PCBs de telemóveis.

Uma outra abordagem necessária é a deteção de cantos ao nível do subpixel, para garantir a delimitação dos componentes e, conseqüentemente, a sua localização. Podem-se representar os vértices como os pontos dos pixel com grande variação de intensidade de todas direções. Este método é independente da escala, dos graus de rotação e da iluminação circundante. Todavia, consome mais espaço de memória para processar o algoritmo devido a redundâncias e não garante a mesma eficiência para uma imagem complexa, por exemplo, a imagem de um PCB com uma alta densidade de componentes. Resta, então, a identificação dos limites do componente, ou seja, as arestas. O processo consiste em detetar pontos consecutivos onde se verifique uma mudança súbita no brilho que forma o contorno da imagem. Para isso, na maioria das vezes, utiliza-se o algoritmo *canny* devido à sua adaptabilidade a variações presentes nas imagens aliada à possibilidade de deteção de linhas. Assim, é possível identificar componentes independentemente do seu tamanho, sendo esta uma característica fortemente apreciada. No entanto, a identificação das extremidades porque evidenciar desvios para linhas horizontais e verticais, existindo uma probabilidade de aproximação errada na simetria das rotações, algo comumente verificado na maioria dos PCBs.

Embora as características associadas à forma desempenhem um papel significativo na extração das características das imagens, elas não são, por si só, suficientes para identificar e detetar de forma única os componentes no PCB. A textura indica a distribuição espacial dos pixels, que, juntamente com a forma e a cor, podem melhorar a precisão da deteção do PCB componentes. Por isso, abordar-se-à em detalhe alguns métodos para alcançar as características da textura.

O primeiro, consiste na aplicação do filtro de Gabor, e pode ser observada na figura 2.3c. Este, é um filtro linear que analisa a existência de frequências específicas na imagem, em direções pertencentes à zona circundante da região de análise. Para descrever a frequência local o núcleo do filtro adiciona uma função de janela ao sinal. Este é insensível a mudanças de luz e invariante à rotação, para um certo grau de rotação e distorção da imagem, pode mesmo devolver melhores resultados. Uma limitação é o facto de não ser ortogonal, o que resultará em diferentes proporções para características redundantes. Além disso, motivado pela presença de altas frequências, podem surgir artefactos em forma de anel, algo que gera problemas para análise de imagem e identificação dos componentes.

De seguida, menciona-se a abordagem denominada por matriz de co-ocorrência de níveis de cinzento, associada à figura 2.3d. Foi proposta por Haralick et al. em

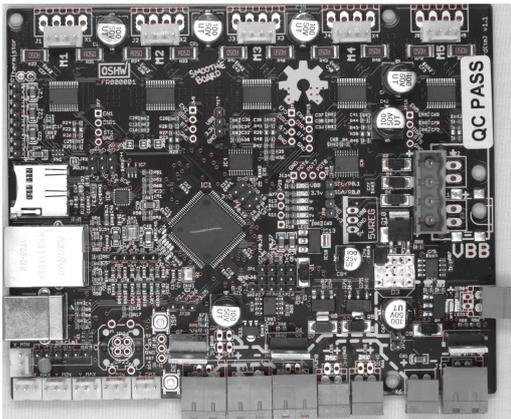
1973, e apresenta uma forma simples de descrever texturas através do estudo da distribuição de diferentes níveis de cinzento correspondentes a diferentes texturas no espaço. Ou seja, avalia a correlação espacial em imagens em escala de cinzentos e possui uma forte adaptabilidade e robustez. As suas características podem ser produzidas para quaisquer orientações. No entanto, por ser um método estatístico possui menos correlação com modelos visuais humanos e carece da utilização de informação global. Para além disso, exige um elevado nível computacional associado a longo tempo de execução. Esta técnica não é adequada para distinguir entre diferentes fontes de texto e é por isso que esta característica enfrenta dificuldades na deteção de marcações de referência para componentes de um PCB.

A última técnica centra-se no estudo dos padrões binários locais e encontra-se evidente na figura 2.3b. Define-se um janela como operador e, para avaliar o seu pixel central, efetua-se a comparação com os valores de pixel dos seus vizinhos. Assim, as posições circundantes serão atribuídas como 0 ou 1, de acordo com a referida comparação. Obtém-se, então, um número binário de 8 bits, que será convertido para um número decimal, utilizado para devolver a informação sobre a textura da área. De notar que, à medida que a imagem roda, a posição do pixel muda, e o valor do pixel também mudará em conformidade, conseqüentemente, os valores das características dadas serão muito diferentes. Para contornar isso, Maenpaa et al. desenvolveram uma estratégia para alcançar a invariância com a rotação, que consiste na rotação contínua da imagem para obter os valores iniciais possíveis e considerar o valor mínimo. O tempo de cálculo está correlacionado com o número de pixel na imagem. Além disso, o ruído, e qualquer outro efeito perturbador como, por exemplo, os artefactos têm impactos notáveis no desempenho do método. Assim, é necessário garantir que as imagens utilizadas se encontram desprovidas desses efeitos.

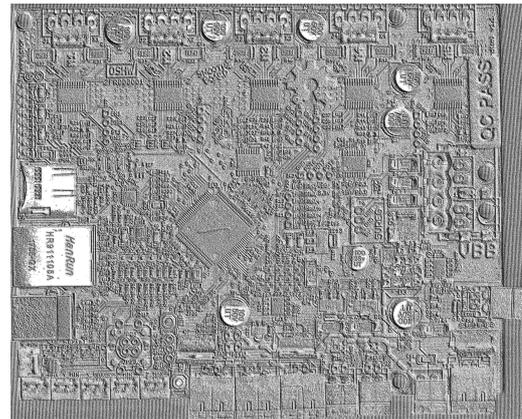
Tendo em conta a integridade do que foi descrito anteriormente e os resultados publicados em [Zhao et al., 2022], infere-se que os métodos baseados no estudo das cores são mais rápidos na sua execução e mais precisos na deteção de componentes de PCB. Embora a extração da forma e textura se verifiquem abordagens geralmente mais lentas e menos precisas, revelam uma maior eficácia aquando da classificação dos componentes propriamente dita. Ainda assim, devido à sua sensibilidade para com a iluminação e a resolução das imagens, devem ser implementados anteriormente algoritmos de pré processamento por forma a garantir a pretendida generalidade.

Do mesmo modo, [Li et al., 2013] também utilizaram métodos de segmentação com base na cor e na forma para identificar *chips*. Utilizaram também um método de pré-processamento (*unsharp masking*) para enfatizar as linhas finas dos limites do dispositivo impresso com o objetivo de melhorar o contraste e compensando alguma possível falta de homogeneidade na iluminação. De notar que, tendo por base os métodos de deteção das delimitações dos componentes, por vezes existem candidatos que efetivamente não são componentes que evidenciam

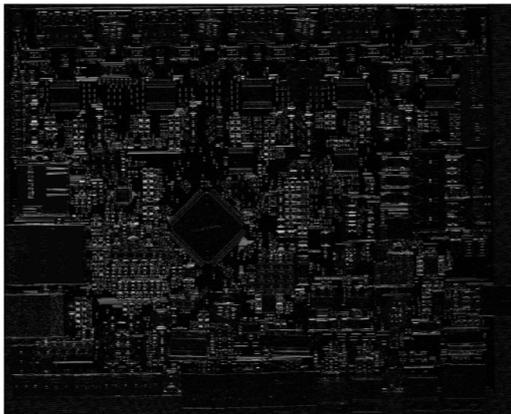
estruturas semelhantes, tais como, por exemplo, etiquetas de texto. Para suprimir esse acontecimento, elabora-se a análise da textura da região local, através dos métodos já descritos. Evidentemente, os componentes possuem características diferentes de textura, quando comparados a etiquetas. Aplicando às imagens de PCBs que disponho o resultado obtido foi a imagem original com alterações quase imperceptíveis (figura 2.3d). Outro método, centra-se na execução de uma avaliação hierárquica que descreve a probabilidade de um candidato ser efetivamente uma extremidade de um componente. O processo inverso também pode ser implementado, ou seja, o reconhecimento de texto evidente nos componentes ou em etiquetas de identificação, tal como proposto em [Li et al., 2014]. Até mesmo para a verificação da orientação dos próprios componentes, por forma a facilitar a sua remoção. Outro inconveniente acontece na presença de artefactos que, em algumas situações, provoca a deteção múltipla, devido à sobreposição dos mesmos com as fronteiras reais. Para o remover, os autores sugerem a aplicação do método *non maximum suppression*. Para além disso, a semelhança entre as cores da base do PCB e do componente, para a maioria dos algoritmos de segmentação conduz a resultados pouco satisfatórios. Desta forma, [Li et al., 2013] propõem uma análise baseada nos máximos de distribuições (*Ridge-based analysis*). Ou seja, as distribuições podem ser determinadas para cores diferentes, mesmo que aparentem apenas ligeiras diferenças ou uma elevada variação na iluminação e, conseqüentemente, cores com a mesma distribuição aparecerem fundidas. A superfície dos PCB é, então, separada em regiões de acordo com as distribuições de cores. Através do histograma de valores de tonalidade definidos recorrendo ao espaço HSV, a cor de fundo é selecionada como a cor dominante valores no histograma, resolvendo a questão da similitude.



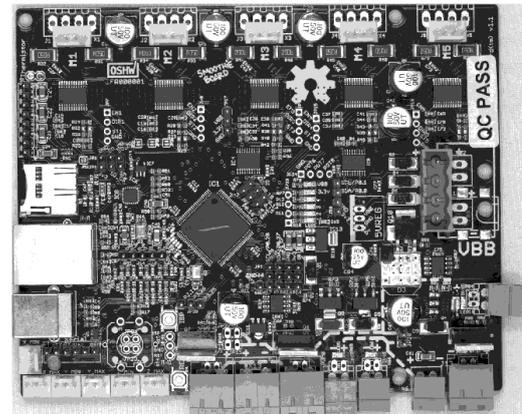
(a) Exemplo de detecção de blobs, identificados a vermelho, para o mesmo PCB da figura 2.1.



(b) Exemplo da aplicação da técnica de estudo dos padrões binários locais, para o mesmo PCB da figura 2.1.



(c) Exemplo de aplicação do filtro de Gabor para um comprimento de onda de 90 pixels/ciclo para a imagem do mesmo PCB da figura 2.1.



(d) Exemplo de aplicação da matriz de co-ocorrência de níveis de cinzento para a imagem do mesmo PCB da figura 2.1.

Figura 2.3: Técnicas de Processamento de Imagens, aplicadas aos PCBs.

2.2.2 Métodos de Classificação

Com o avanço tecnológico, a variabilidade de modelos de PCBs aumenta drasticamente e aliada à diminuição do tamanho das componentes, tornam o desempenho dos algoritmos de processamento de imagem por si só menos eficientes. Mais detalhadamente, os componentes dos PCB mostram-se semelhantes entre classes e apresentam baixa distinção dentro da mesma classe, o que dificulta a sua classificação. Alguns dos componentes são muito pequenos em tamanho o que dificulta, ainda mais, a sua deteção. Além disso, podem ser da mesma cor que o próprio PCB, tornando o uso de recursos de cores desafiador juntamente com o facto, tal como já foi discutido, que alguns conjuntos de dados têm uma alta variação em termos de iluminação, resolução, artefatos de imagem, etc. Importante referir também que os PCBs são fabricados por diferentes empresas em vários tipos de formas e cores, daí, a sua aparência, tamanhos relativos e funcionalidades variarem muito. Assim, para extrair características de alto nível em objetos cada vez menores é imperativo o uso de métodos de *deep learning* [Li et al., 2022]. Estes, aplicados à deteção de objetos foram explorados e analisados ao detalhe por forma a melhor o poder computacional pelos autores [Kaushal et al., 2018] e [Pathak et al., 2018].

Tal como foi referido para os métodos que usam processamento de imagem, a identificação dos caracteres de texto que se encontram nos componentes pode ser útil, embora não seja o objetivo proposto. Assim, utilizando uma *Efficient-Net*, [Gang et al., 2021] realizaram uma análise detalhada para proceder a essa classificação. Esta foi desenvolvida em 2019 e possui velocidade de computação e precisão suficientes para a referida aplicação, apesar da velocidade de aprendizagem ser um pouco menor quando comparada com os métodos previamente existentes.

Por outro lado, os algoritmos de deteção de objetos podem ser divididos em dois grupos: os que recorrem apenas a uma fase (de regressão) e os que são executados por meio de duas etapas (de classificação). A deteção de objetos usando os primeiros devolve diretamente a probabilidade de pertencer a determinada categoria e valores de coordenadas da posição dos componentes e tem-se, por exemplo, os modelos *you only look once* (YOLO), *single-shot multibox detector* (SSD), e *corner network*, que realizam diretamente a tarefa de regressão considerando a imagem como um todo. Para os de duas fases é necessária a existência, *a priori*, de propostas de possíveis regiões de estudo com informações sobre a localização do componente e, posteriormente, a classificação das zonas candidatas em diferentes grupos. Para representar estes algoritmos, podem-se considerar, as várias *region convolutional neural network* (R-CNN) e *spatial pyramid network* [Zeng et al., 2022]. Para a classificação de componentes previamente detetados, os métodos mais comuns centram-se no uso de *support vector machine* (SVM) e *k-nearest neighbors* (KNN).

Mais detalhadamente, o YOLO é um algoritmo que permite a detecção de diferentes classes, simultaneamente, presentes numa imagem, tratando a imagem de forma global executando, por isso, o algoritmo apenas uma vez e utilizando uma única CNN para prever a detecção das componentes. A ideia geral é que uma única rede neuronal divide a imagem em regiões e depois prevê várias caixas de delimitação para cada região [Silva et al., 2021]. Os objetos são classificados com base nas suas características distintas, tais como a sua forma, tamanho e cor. Como a atribuição de uma classe aos múltiplos objetos acontece juntamente com a previsão da sua localização este método devolve uma velocidade de execução superior, acabando por simplificar o problema evitando canais complexos como acontece na aplicação das R-CNN [Arya and Rawat, 2020]. Estas últimas, especificando, começam por selecionar na imagem cerca de duas mil zonas de interesse (não incluindo regiões de fundo) e, de seguida, por meio das CNN ocorre a extração de características, onde cada área candidata é analisada verificando se se enquadra numa das classes a atribuir. Foi proposto inicialmente por [Girshick et al., 2014], onde apresentam o processo dividido em quatro etapas: (1) Extração das regiões a ser alvo de estudo, ou seja, áreas candidatas a identificação; (2) Extração de características para cada região candidata recorrendo à referida CNN; (3) A característica é enviada para cada classe do classificador SVM para determinar se efetivamente pertence a essa classe e (4) aplicação de uma *bounding box regression* para reduzir o erro de localização dos componentes, refinando as regiões de interesse. Este método combina uma *regional recommendation network* com uma CNN. No entanto, as R-CNN não são suficientemente rápidas no que concerne à detecção em tempo real, uma vez que o algoritmo necessita de processar cada operação da CNN para cada área proposta para um possível objeto. Assim, surgem as Fast R-CNN, por [Girshick, 2015], que perfazem uma adaptação do método anterior mas que executa de forma mais rápida e eficiente o proposto, uma vez que realiza os cálculos necessários numa única operação utilizando *multi-task loss*. Mais tarde, são desenvolvidas ainda as Faster R-CNN que consiste numa *Proposal Network*, que partilha características provenientes das CNN com a detecção a jusante da rede neuronal para permitir a detecção em tempo real com um menor esforço computacional. Este tipo de método acaba por se tornar lento, comparativamente aos de regressão, uma vez que executa previsões e extração de características para cada região pré selecionada, e algumas destas podem não corresponder efetivamente a um objeto de interesse, ou seja, o tempo de computação despendido, nesses casos, foi irrelevante [Manojkumar et al., 2023; Zou, 2019]. É evidente também, a dificuldade em encontrar uma solução globalmente ótima devido à separação das fases de geração de propostas, extração de características e classificação de regiões em componentes distintos que não podem ser otimizadas em conjunto.

Em [Li et al., 2021], os autores aplicaram uma estrutura de rede neural convolucional de *deep learning* SSD à detecção de elementos PCB. Começam por apresentar a estrutura e descrever a CNN utilizada. Entretanto, elaboram a comparação entre outros métodos de redes de aprendizagem profunda para evidenciar as vantagens dos diferentes algoritmos no processo de inspeção de imagem PCB. No entanto, os métodos aos quais foi comparado não são os mais utilizados na área

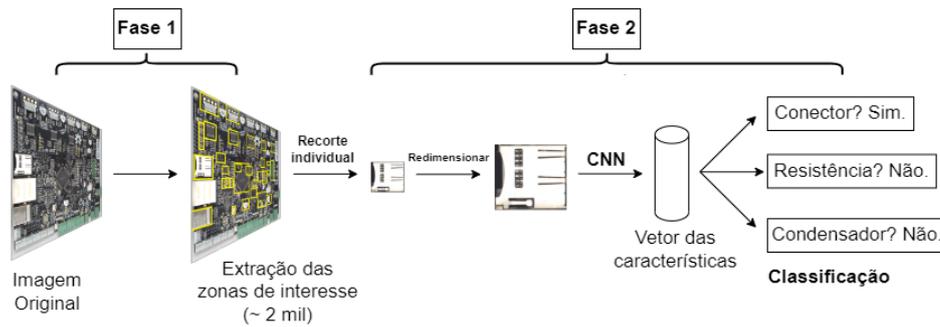


Figura 2.4: Esquema representativo da estrutura do modelo RCNN.

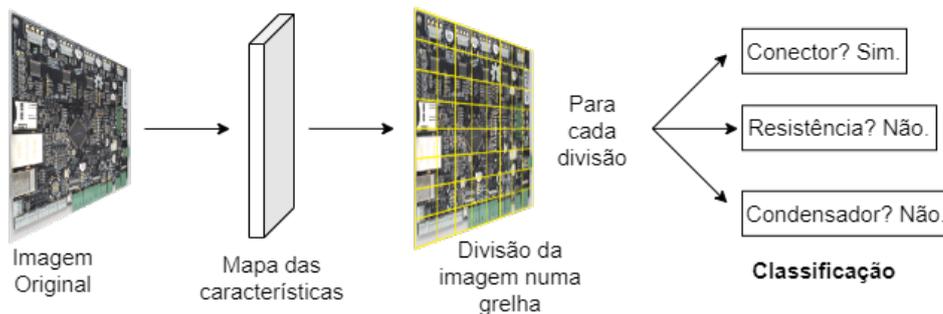


Figura 2.5: Esquema representativo da estrutura do modelo YOLO.

que se pretende desenvolver na presente dissertação.

Em 2022, [Lu et al., 2022] recorreram ao algoritmo YOLO-v3 para treinar o conjunto de dados que os próprios produziram e classificar os componentes eletrónicos dos PCBs em categorias específicas. De notar que, no estudo desenvolvido pelos autores, os componentes eletrónicos são obtidos através da desmontagem manual de PCBs de vários eletrodomésticos. De forma semelhante, [Huang et al., 2019] utilizaram o mesmo algoritmo, no entanto combinado com uma *mobilenet*, para a promoção de equilíbrio entre a precisão da deteção e a sua velocidade de execução. Esta última é baseada numa arquitetura otimizada que utiliza redes neuronais profundas e leves. Importante referir que, nos dois estudos anteriores, os componentes são classificados isoladamente algo que diverge do objetivo deste projeto, uma vez que este pretende eliminar a desmontagem manual e, conseqüentemente, analisar a placa de circuito impresso como um todo.

Em [Silva et al., 2021] é utilizado o *dataset* apresentado na literatura [Pramerdorfer and Kampel, 2015a], para avaliar a viabilidade económica da reciclagem de circuitos integrados (IC). Mais detalhadamente, o método proposto pode ajudar a decidir se se deve desmantelar o PCB antes do processo de reciclagem, recorrendo a uma estimativa da área IC que conduzirá ao cálculo do seu peso utilizando a densidade superficial e, conseqüentemente permite estimar a quantidade de metal que pode ser recuperada através da reciclagem. Para, então, estimar a área

utiliza-se o método YOLO-v3. O melhor resultado foi obtido recorrendo à divisão da análise de cada imagem através de uma janela deslizante, criando assim novas imagens de dimensões menores. Neste caso, verifica-se apenas a fiabilidade de um algoritmo YOLO na deteção da referida componente e mais algum detalhe sobre os metais que a constituem.

De notar que, na literatura o desempenho, a memória e a previsão do algoritmo de segmentação YOLO-v5 são testados para as necessidades de deteção, classificação e segmentação de PCBs de microcontroladores [Glučina et al., 2023]. Embora seja utilizado um dos algoritmos YOLO mais recente, a classificação centra-se ao nível dos modelos de microcontroladores algo que diverge do que pretendemos desenvolver, uma vez que propomos a classificação das componentes propriamente ditas. No entanto, na literatura diferente existe a utilização YOLO-v5 combinado com um algoritmo proposto de classificação baseado na hierarquia [Chen et al., 2022]. O objetivo da implementação centra-se na validação e avaliação do desempenho do modelo desenvolvido pelos autores na deteção e classificação de componentes de PCBs, embora que não sejam de telemóveis.

Utilizando os mesmos algoritmos, [Naito et al., 2021] desenvolveram um sistema completo de reciclagem de PCBs desde a classificação até à recuperação dos componentes. As placas, no caso, de computadores portáteis são divididas em pequenas peças que se deslocam através de um tapete rolante. Para o reconhecimento de componentes, treinaram e comparam o desempenho de duas CNN. A câmara implementada deteta cada componente do PCB e classifica-o numa das cinco classes de acordo com a informação proveniente do algoritmo de *deep learning*. Com base nas informações da câmara é comunicada uma informação ao manipulador robótico que extrai e separa as componentes. As peças são classificadas em recipientes separados. No entanto, os autores reconhecem a necessidade de aumentar a precisão do desempenho. Embora esta seja a literatura que apresenta uma maior proximidade com o objetivo global do projeto, nas classes identificadas não constam apenas componentes. Ou seja, constam PCBs completos, 3 componentes e a identificação de metal propriamente dita, algo que diverge do que se pretende classificar. É de salientar que o facto de serem componentes de computadores portáteis o tamanho das componentes será bastante diferente do que se pretende estudar. Ainda assim é um trabalho realizado com vista à reciclagem dos PCBs.

Ainda que a exatidão dos dos algoritmos R-CNN seja satisfatória, estes requerem um esforço de computação elevado, o que leva a uma baixa velocidade de deteção quando se utilizam computadores ditos normais. Como resultado da exploração de arquiteturas de redes neuronais profundas eficientes, os autores [Li et al., 2023] apresentaram o PCBDet, uma *attention condenser network* que fornece taxa de transferência de última geração, alcançando desempenho de deteção de componentes de PCB elevados em comparação com outras arquiteturas. Encontramo-nos perante um algoritmo de apenas uma fase que engloba um processo mais eficiente de deteção quando comparados com métodos de duas fases.

Apresenta ainda um desempenho aumentado quando comparada com SSD ou YOLO, também já referidos. Os modelos foram treinados e testados utilizando as imagens do conjunto de dados anteriormente apresentado FICS-PCB [Lu et al., 2020].

Recentemente, o interesse pela detecção de pequenos componentes (não só de PCBs) encontra-se refletido número de publicações na área, [Hu et al., 2018; Li et al., 2017, 2019; Lin et al., 2017; Liu et al., 2018, 2019]. De notar que, na literatura [Tong et al., 2020] é apresentado e discutido o estado da arte associado à detecção de pequenos componentes. Uma das estratégias mais aceites na comunidade científica centra-se na utilização de algoritmos de *Feature Pyramid Networks* (FPN) que permitem a detecção de objetos de tamanho reduzido e ainda com diferentes escalas, sendo possível a sua adaptação a alguns dos algoritmos já referidos anteriormente. O formato de pirâmide surge devido à sensação de que a mudança de escala de uma imagem é compensada pela deslocação ao longo dos níveis da pirâmide. O referido método tem por base o modelo *featurized image pyramid* que utiliza uma pirâmide de imagens para construir uma pirâmide de resultados. Estes, são calculados para cada uma das escalas de imagens de forma independente conduzindo a um algoritmo bastante lento. Posto isto, surgiu a implementação de CNN como se fosse a pirâmide de imagens mas na verdade apenas necessita de uma imagem de entrada, tornando o algoritmo mais rápido. Além disso, a formação de CNN de ponta a ponta numa pirâmide de imagens é inviável em termos de memória, o que cria uma inconsistência entre a inferência do tempo de teste. Por estas razões, modelos R-CNN optam por não utilizar pirâmides de imagem sob configurações padrão. Assim, o surge o algoritmo proposto por [Lin et al., 2017] que combina as duas etapas supra descritas mas acrescentando alguma precisão, permitindo a sua adaptação aos algoritmos que utilizam *Region Proposal Network* (RPN) para a geração de propostas de caixas de delimitação para a identificação de zonas de estudo e em R-CNN para a detecção de objetos atribuindo diferentes regiões de interesse para a cada nível da pirâmide. Para complementar o referido método, [Li et al., 2019] desenvolveram uma *trident network*. Assim, os autores pretendem reduzir a quantidade de imagens de treino necessárias e diminuir a probabilidade de ocorrência *overfitting* para cada escala.

Muito recentemente, mantendo o esquema de pirâmide, os autores [Mantravadi et al., 2023] desenvolveram uma rede neural leve e inovadora *Dilated Involutorial Pyramid Network* (DInPNet), para a classificação dos componentes de PCB no conjunto de dados FICS-PCB anteriormente referido [[Lu et al., 2020]]. DInPNet faz uso de involuções substituindo convoluções. Desenvolveram a *dilated involutorial pyramid* (DInP), que possui como objetivo a transformação do mapa de recursos de entrada para um mapa de baixa dimensões para diminuir o custo computacional, seguido por um par fusão piramidal de involuções dilatadas que reabastecem o mapa de recursos inicial, por forma a reduzir consideravelmente o número de parâmetros. De notar que, foi realizada uma abordagem ao nível de componentes com a utilização de 7 classes, algo que se assemelha à abordagem que se pretende seguir.

Para além da variabilidade entre os tamanhos das componentes outro aspeto também a considerar aquando do estudo dos PCBs, é a diferente disposição dos mesmo na placa propriamente dita. Mais detalhadamente, estão em locais da imagem arbitrários, de diferentes escalas, dentro de diferentes categorias, e o seu número pode variar entre diferentes imagens. A maioria dos métodos ainda se concentra no reconhecimento de objetos separadamente. Os algoritmos baseados em R-CNN têm na sua maioria uma estrutura de rede simples e regular não sendo garantida a sua eficácia na presença das irregularidades referidas. Para fazer face à evidente aleatoriedade, os autores de [Hu et al., 2018] desenvolveram um algoritmo denominado *relation networks*.

Em sequência,[Kuo et al., 2019] pretendem resolver as limitações que surgem ao usar técnicas de análise de processamento de imagem na identificação de componentes de PCBs, motivadas pela variação na resolução das imagens e pelas diferentes condições de iluminação que tornam difícil a generalização da aplicabilidade desses métodos perante a distribuição altamente aleatória do tipo de componentes, a sua elevada semelhança entre si, a variedade de modelos de PCBs e devido ao esforço de rotular manualmente as componentes. Por outro lado, pretende diminuir a quantidade de dados necessários para treino das redes neurais, mantendo a elevada precisão. O modelo proposto encontra-se dividido em 3 fases: *class-agnostic regional proposal network*, *similarity prediction network* e *graph network*. A primeira tem como objetivo a deteção dos objetos sem saber a que classe pertencem. Ou seja, propõe uma possível localização para os componentes, delimitando-os. De seguida, acontece o cálculo do grau de semelhança através da comparação com componentes de PCBs de teste. Assim, é devolvida uma probabilidade de semelhança entre cada par. Para isto, são utilizados algoritmos *low-shot* que permitem classificar novos dados quando apenas se possuem alguns elementos de treino e a *triplet loss* que usa a lógica de reduzir a diferença entre objetos semelhantes e aumentá-la para objetos diferentes. Na última etapa, a informação da fase anterior é otimizada através da verificação da dependência entre dados do mesmo PCB. Cada nó do grafo contém a característica associada a um dado componente e, dessa forma, cada par de nós relaciona a semelhança entre componentes.

Por último, focando em projetos aplicados concretamente a telemóveis, os autores [Li et al., 2022] estudaram um método de identificação de grandes componentes de telemóveis (como por exemplo, bateria, câmara, PCB e parafusos) que combina processamento de imagem e o algoritmo YOLOv5m. Outros autores sugeriram uma adaptação do algoritmo SSD de modo a detetar, tal como a literatura anterior, as diferentes partes do telemóvel [Huang et al., 2021]. Assim, propõem um Cross Stage Partial com melhoria da estrutura da rede, utilizando informação de fluxo gradiente, utilizando a desconvolução e a transformação multi-escala. No entanto, torna-se evidente que no projeto que pretendemos desenvolver procuramos uma análise ao nível de outro tipo de componentes.

De seguida apresenta-se uma tabela for forma a facilitar a comparação entre a diversa literatura existente e a verificar como se enquadra no projeto que se ambiciona desenvolver.

Tabela 2.2: Resumo dos artigos mais relevantes apresentados no estado da arte.

Artigo	Sustentabilidade e/ou Reciclagem	Modelo YOLO	Classificação de Componentes de PCBs	Relacionado com Telemóveis
[Li et al., 2023]	não			
[Kuo et al., 2019]	não	não	sim	não
[Naito et al., 2021]	sim			
[Mantravadi et al., 2023]	sim			
[Li et al., 2022]	sim		não	sim
[Glučina et al., 2023]	não	sim	não	
[Silva et al., 2021]	sim		sim (apenas ICs)	não
[Chen et al., 2022]	sim		sim	

Tendo em vista o que foi apresentado anteriormente verifica-se efetivamente que existe uma preocupação com a sustentabilidade e com a quantidade de lixo eletrónico produzido e a necessidade de procurar uma solução para os componentes de qualquer tipo PCBs. No entanto, é bastante evidente que a aplicabilidade aos telemóveis ainda não é o principal foco dos grupos de investigação algo que se pode relacionar com o tamanho reduzido que apresentam. Ainda assim, as tendências apresentadas na literatura atual indicam um crescimento no interesse pela deteção e classificação de pequenos objetos, tais como os PCBs de telemóveis. Aliado ao tamanho, existe ainda a elevada semelhança entre as diferentes classes de componentes daí que se reconheça a necessidade de continuar a investigação nesse sentido, por forma a otimizar todo o processo e a garantir elevada precisão. Dito isto, o projeto onde se encontra inserido esta dissertação possui a oportunidade de se tornar pioneiro na implementação de um algoritmo que permita resolver a questão associada à reciclagem de um dos dispositivos eletrónicos que mais contribui para o aumento do lixo eletrónico atualmente.

Capítulo 3

Metodologia

No capítulo que se segue serão descritos os métodos e as técnicas utilizadas no desenvolvimento do projeto. Apresenta-se o *dataset* utilizado para proceder ao treino do modelo uma vez que o número de telemóveis recolhidos foi insuficiente para a elaboração. São divulgadas as formas de obtenção das imagens dos PCBs dos telemóveis e a arquitetura do modelo utilizado para a classificação dos seus componentes.

3.1 Dataset

Como já foi referido, não existem conjuntos de dados que integrem PCBs de telemóveis, pelo que, foi necessário utilizar os conteúdos disponíveis para se proceder à aprendizagem do modelo.

Assim, começou-se por verificar em detalhe os *datasets* existentes, supra apresentados. Utilizou-se, então, para proceder ao treino do modelo desenvolvido, o PCB-WACV [Kuo et al., 2019] que possuía imagens com componentes de tamanho reduzido e também uma identificação bastante detalhada de tudo o que constituía a placa, incluindo todo o texto, o modelo e tipo de componentes. No total, o referido conjunto de dados, possui apenas 28 imagens de PCBs, algo que será discutido no final deste capítulo.

3.1.1 Definição das classes

Para o estudo que se pretende realizar, a quantidade de itens identificados, tal como é evidente na imagem anterior, é inviável. Mais detalhadamente, todo o texto presente nas imagens estava identificado, algo irrelevante para o projeto que se pretende desenvolver e, existiam componentes também classificados que não se encontram presentes nos PCBs de telemóveis. De notar que, dada a especificidade da marcação do *dataset*, a uma dada cor, na maioria das vezes, corresponde uma classe diferente, associada a um modelo de componente ou texto, acabando,

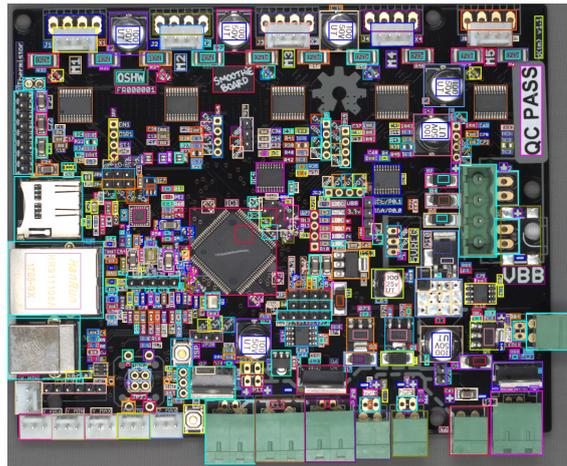


Figura 3.1: Exemplo de imagem do *dataset* escolhido com as respetivas identificações, referente ao PCB DuetWIFI.

assim, por se repetirem as cores para diferentes classes. Indicar o número de classes é uma tarefa difícil já que, para todos os componentes, as classificações eram realizadas ao nível do tipo de componente e da sua referência, por exemplo, "text R146", "text C138", "resistor R97", "connector P39", etc. Acabando por existir uma atribuição de cores que não corresponde necessariamente a classes iguais, ou seja existem vários tipos de componentes com a mesma cor (confrontar com a figura 3.1). Posto isto, foi necessário realizar uma triagem e, conseqüentemente, adaptar a identificação das componentes, fazendo uma seleção das mesmas e recriando as classes existentes.

Mesmo os projetos mais recentes desenvolvidos na área de reciclagem de resíduos eletrônicos apresentam, quase na totalidade, como método base a fragmentação dos equipamentos seguida de separação magnética e eletrostática ou a utilização de técnicas relacionadas com a área da química. Assim sendo, os resultados associados à constituição não correspondem ao nível das componentes integrantes do PCB, mas para a placa como um todo. A maioria das publicações sobre o tema, devolvem ainda percentagens generalizadas dos vários elementos químicos presentes em PCBs, sem referência qualquer referência ao equipamento correspondente [Abdelbasir et al., 2018; Andrade et al., 2022; Gorewoda et al., 2020; Rocchetti et al., 2018; Tantawi and Hua, 2021; Udayakumar et al., 2022]. No entanto, os estudos desenvolvidos nas literaturas [Wu et al., 2022] e [Lu et al., 2022] apresentam as percentagens de elementos químicos presentes na constituição das várias componentes. Apesar de não constar que são PCBs de telemóveis é a abordagem mais próxima do que pretendemos desenvolver. A tabela 3.1 que se segue é uma adaptação da informação que se encontra nos referidos artigos. Importante reforçar que, dada a existência de diferentes modelos de cada componente, o conjunto de metais que a constitui varia, tal como é evidente na referida tabela.

Desta maneira, é possível observar que se encontram presentes alguns metais preciosos como o ouro e a prata pelo que a recuperação e reciclagem desses com-

Tabela 3.1: Percentagens dos vários metais que constituem as diferentes componentes dos PCBs.

Componentes	Elementos químicos constituintes das componentes			
	50%	50-20%	20-1%	1%
condensador	Al	Ta ou Ba ou	Fe, Zn ou Fe, Sn, Ni ou Fe, Ni, Ti, Pb, Ag, Cu, Sn, Nb ou Mg, Fe, Sn, Cu, Si	Sn, Cu, Ni ou Ag, Mn ou Au, Bi, Pd, Al, Mn ou Zn, Ni, Pb, Ag, Sb
circuito integrado	Al	Fe, Si	Cu ou Sn, Ni, Al, Pb, Ag	Au, Ag, Pd, Pt, Pb, Ni, Fe, Al, Cr ou Mg, Zn, Cu, Sb
transistor	Cu	Al, Fe, Sb	Zn, Sn, Cu, Ni, Pb ou Al, Zn, Sb	Mg, Si, Ag ou Au, Ag, Sn, Pb
indutor	Cu	Fe	Al, Si	Sn, Ni, Pb, Ag, Mg, Zn
led			Fe	Cu, Ni, Pb, Au, Ag, As, In, Ga
resistência	Ni	Cu ou Al ₂ O ₃	Al, Sn, Si ou Sn, Cu, Fe	Mg, Fe, Zn, Pb, Ag, Sb Cr

ponentes acrescia de vantagens económicas. No entanto, é evidente também a presença de chumbo e níquel que, por serem um metais pesados, apresentam, em grande escala, riscos para a saúde e para o ambiente sendo, por isso, igualmente importante a sua reutilização.

Tendo isto referido, a seleção de componentes a identificar pelo modelo desenvolvido contempla não só os 6 explícitos na tabela 3.1 mas também os conectores uma vez que se encontram presentes em grande número no *dataset* mencionado no início deste capítulo e nos telemóveis.

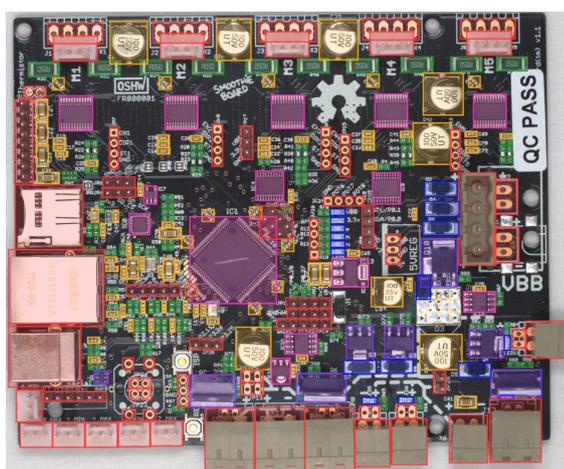


Figura 3.2: Exemplo de imagem com a identificação das 7 componentes escolhidas, referente ao PCB DuetWiFi. De notar que, a cada classe foi atribuída uma cor. Legenda: Cor de Rosa - circuitos integrados; Vermelho - conectores; Amarelo - condensador; Verde- resistência; Roxo - transistor; Laranja - indutor; Azul - led.

Assim sendo, foi necessário remarcar, individualmente, as classes de todas as imagens de PCBs que constituíam o dataset escolhido e eliminar todas as marcações de texto. Ou seja, encontram-se identificadas apenas as 7 classes sendo que, para cada imagem, a uma dada cor encontra-se associada efetivamente uma só classe, tal como é evidente na figura 3.2. O resultado é público e encontra-se disponível em <https://universe.roboflow.com/yolov7-0fxiu/pcb-components-ifux1>. Finalmente, o ficheiro proveniente do conjunto de dados inicial onde as anotações de cada imagem se encontravam registadas não era compatível com o algoritmo YOLO, pelo que foi necessário realizar a conversão recorrendo ao *software* MakeSense.ia.

3.2 Aquisição de Imagens

Para realizar o estudo pretendido, foi então necessário recolher telemóveis e desmontá-los por forma a obter unicamente o PCB, por forma a adicionar imagens ao *dataset* inicial. Posto isto, realizou-se a captura das imagens dos mesmos.

Com esse intuito, construiu-se um suporte para a câmara e utilizou-se um mini estúdio fotográfico que garante uma iluminação constante e um fundo uniforme por forma a evitar ruído.

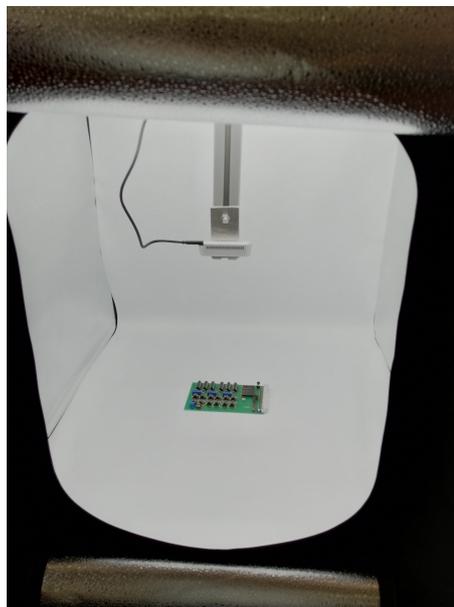


Figura 3.3: Montagem experimental para a aquisição de imagens desenvolvido no laboratório.

O modelo de câmara utilizado para obtenção das imagens foi o Intel REAL-SENSE depth camera D405 ao invés do Intel REALSENSE depth camera D435i também disponível no laboratório. Apesar do último apresentar uma resolução RGB superior para um mesmo número de frames por segundo (1920×1080 vs

1280 × 720), o alcance ideal para o modelo escolhido compreende-se em 7 a 50cm contrastando com o intervalo 0,3 a 3m da outra câmara. Dito isto e considerando a reduzida dimensão e o elevado detalhe das placas que se pretendiam fotografar fica sustentada a referida utilização.

3.3 Classificação das componentes

Tendo em consideração tudo o que foi referido no capítulo 2, é necessário definir a estratégia a implementar na presente dissertação, tendo por base estudos que se dedicaram à comparação da performance dos algoritmos já referidos. De notar que, neste trabalho a deteção das componentes acontece offline no entanto, o objetivo global do projeto RECY-SMART, tal como se pode verificar no esquema da figura 1.1, centra-se na utilização da localização das componentes como entrada para um sistema robótico com a finalidade da extração das mesmas. Desta maneira o que foi dito, aliado ao interesse da reciclagem e recuperação de componentes, faz com que a deteção dos mesmos deva acontecer em tempo real, pelo que o algoritmo escolhido deve considerar esse facto. Portanto, analisou-se a velocidade e precisão de deteção para os vários modelos anteriormente descritos. Vários resultados experimentais demonstram que YOLO é o algoritmo mais adequado para realizar deteções em tempo real. Quanto à questão referente à velocidade de deteção, é transversal na literatura que o modelo YOLO é o mais rápido: pode conseguir-se cerca de 1000 vezes mais rápido do que o algoritmo R-CNN e 100 vezes mais rápido do que o Fast-CNN [Arya and Rawat, 2020; Kim et al., 2020; Neethidevan and Anand, 2021; Srivastava et al., 2021; Tan et al., 2021]. Aliada à maior velocidade de treino e deteção, como a informação global da imagem é tida em consideração durante a previsão existe uma redução dos erros de *background*. Ainda assim, o YOLO impõe, ocasionalmente, restrições espaciais às previsões de localização uma vez que, quando existe um elevado número de classes e objetos numa parte da imagem, alguns podem não ser detetados [Zou, 2019]. No entanto, apesar de, nestas situações, não ser tão preciso, quanto falamos em problemas de tempo real, abdica-se de uma precisão um pouco mais elevada, para a implementação de grandes melhorias na velocidade. Tendo isto dito, o YOLO será o algoritmo utilizado no desenvolvimento do referido projeto. Desta maneira, considerando as diversas versões do modelo, torna-se imperativo averiguar as características em que diferem e conhecer a evolução do mesmo. Estas variantes têm como objetivo resolver algumas das limitações do algoritmo YOLO original, tais como melhorar a precisão, reduzir a complexidade computacional e aumentar ainda mais a velocidade de deteção.

O YOLO-v1 foi lançado em 2016 e foi o primeiro modelo de deteção de objetos em tempo real a atingir uma elevada precisão, no entanto eram evidentes alguns erros de localização. Um ano depois, surge a versão 2 que introduziu uma nova arquitetura para a CNN com menos camadas que a anterior, tornando assim o modelo mais rápido e eficiente, melhorando a previsão da localização dos objetos e a etapa de treino. Todavia não era capaz de detetar objetos de pequenas dimensões. A versão seguinte introduziu ainda uma nova CNN com a finalidade

de melhorar a detecção, mais profunda e mais poderosa que a anterior. Utilizou FPN para para detetar objetos a diferentes escalas, melhorando ainda mais a precisão. Ainda assim, apresentava baixa precisão na detecção de objetos de médio e grande tamanho. O YOLO-v4 introduziu novas técnicas para aumentar a eficiência e a precisão aliada à detecção de objetos de diferentes escalas, aumentando ainda a estabilidade na etapa do treino do modelo. No entanto, tornou-se difícil de implementar devido ao elevado esforço computacional. A versão 5 foi desenvolvida por uma empresa de software de inteligência artificial, não sendo um lançamento oficial dos criadores originais do YOLO. Esta foi concebida para ser mais rápida e mais precisa do que a anterior. O YOLO-v6 introduziu várias novas funcionalidades, incluindo a utilização de mecanismos de auto-atenção para melhorar a precisão da detecção. O YOLO-v7 foi desenvolvido pela comunidade e introduziu a utilização de arquiteturas baseadas em transformadores para a detecção de objetos, antecipando menos falsos positivos [Nazir and Wani, 2023].

3.3.1 YOLO V7

A arquitetura YOLO-v7 é notável pela sua eficiência e precisão na identificação de objetos em tempo real. Para o presente projeto, compreender a estrutura é fundamental para inferir sobre o seu funcionamento e contribuição para a visão computacional. A arquitetura YOLO-v7 é dividida em três etapas principais, tal como se pode observar na figura 3.4, *Backbone*, *Neck* e *Head*, cada uma desempenhando um papel crucial no processo de detecção. A primeira fase é responsável por extrair as características importantes da imagem. É através de uma rede neural convolucional profunda (no caso, *Extended Efficient Layer Aggregation Network* (E-ELAN)) que realiza várias camadas convolucionais e de *Max-pooling* para capturar as informações relevantes da imagem. De seguida, essas características extraídas são processadas para criar pirâmides de características, no *Neck*. Este é responsável por aumentar a resolução das características extraídas na etapa anterior e pode estar envolvido na fusão de informações de diferentes imagens usando a operação *UPSample*. Essas pirâmides consistem em várias escalas de características, permitindo que o modelo detete objetos de diferentes tamanhos e resoluções na imagem, algo que ajuda a melhorar a capacidade de detecção, especialmente para objetos pequenos. A parte final da rede, a *Head*, é responsável por gerar as detecções finais. É composta por camadas convolucionais adicionais que mapeiam as características da pirâmide por forma a definir as caixas delimitadoras e atribuir as classes de objetos correspondentes. Ou seja, produz as previsões finais de detecção de objetos na imagem. No entanto, ainda se encontra intimamente ligada ao cálculo da função de perda (*Loss*), sendo esta uma medida que quantifica o quão bem as previsões do modelo correspondem efetivamente às classes dos dados de treino. Por outras palavras, calcula a diferença entre as previsões do modelo e os valores reais esperados. O objetivo do treino da rede neural é minimizar essa perda, ajustando os pesos das conexões entre as camadas para melhorar a precisão das previsões.

Mais detalhadamente, no módulo denominado ConvModule (confrontar com o Apêndice A) a convolução é combinada com a *batch normalization* (BN). Esta última é uma técnica comumente usada em redes neurais para estabilizar e acelerar o processo de treino. Envolve a normalização das ativações de uma camada usando a média e a variância. No entanto, quando o modelo treinado é usado para fazer previsões nos novos dados, usar as estatísticas anteriores para a normalização pode não ser ideal. No módulo apresentado a BN é integrada nesse processo. Assim, a média e a variância calculadas durante o treino são incorporadas nos parâmetros da camada convolucional [Shankar and Muthulakshmi, 2023].

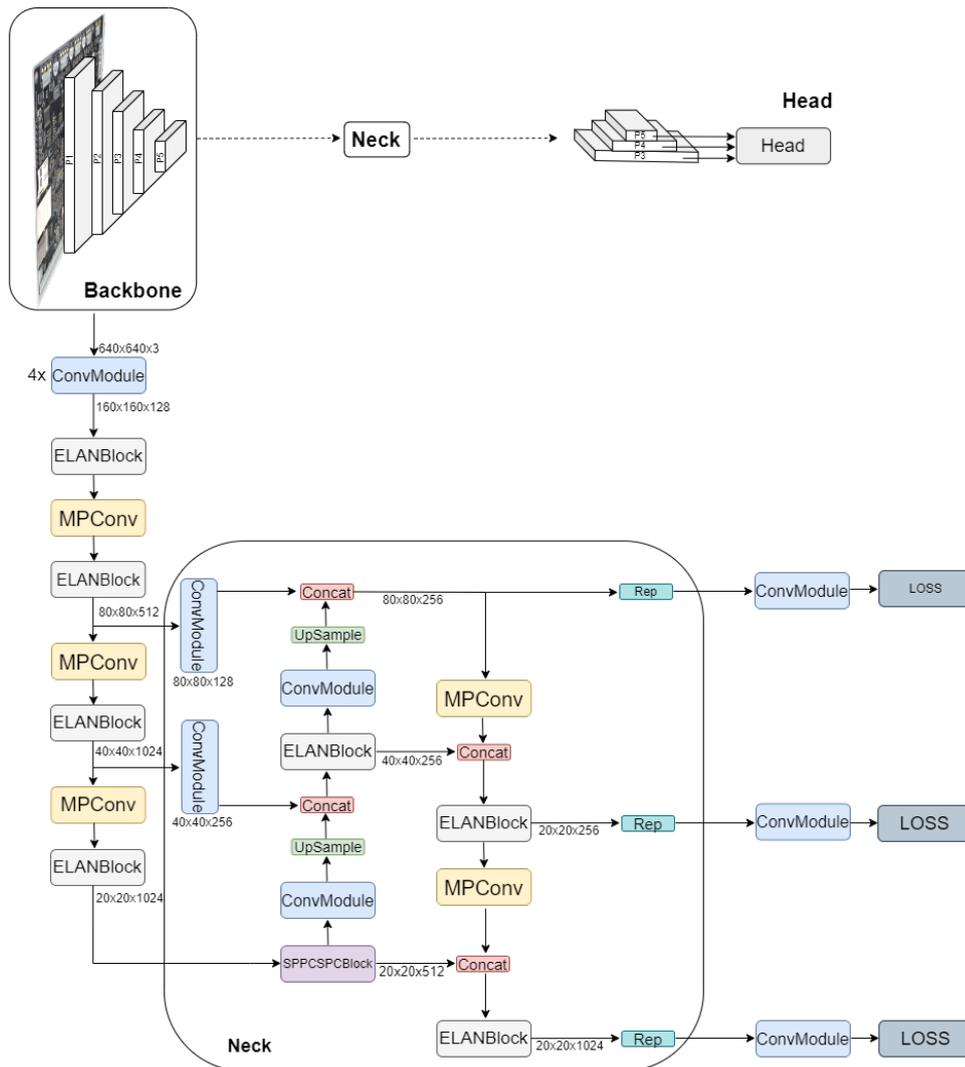


Figura 3.4: Arquitetura da rede associada ao modelo YOLO-v7.

Ainda na etapa da *Backbone*, encontra-se presente a E-ELAN que é uma abordagem utilizada para otimizar e melhorar a rede YOLOv7. A rede atinge sempre um estado de equilíbrio, independentemente do gradiente, da direção do gradiente, do comprimento do caminho e do número total de operações básicas constituintes da uma arquitetura de rede neural. Isto é, em todos os casos acontece a otimização da rede para que esta alcance uma configuração onde a perda durante

o treino é minimizada e os pesos dos parâmetros convergem para valores adequados, sendo fundamental para o seu bom desempenho. No entanto, esses estados de equilíbrio podem ser destruídos e a utilização dos parâmetros principais será reduzida se a combinação de operações não for adequada. O algoritmo E-ELAN utiliza a expansão, a codificação aleatória e a fusão de cardinalidades para melhorar continuamente a capacidade de aprendizagem da rede sem destruir o caminho original do gradiente, e também para orientar os diferentes grupos de blocos computacionais para aprender as características. Ou seja, é uma estratégia que permite a um modelo aprender e convergir de forma mais eficiente [Patel et al., 2022].

Além disso, o *max-pooling* (representado na figura 3.4 por MPCnv) é uma operação usada nas camadas convolucionais da rede para reduzir a dimensionalidade da saída, mantendo as características mais importantes. Ou seja, à medida que a rede neural processa dados através das várias camadas convolucionais, as dimensões dos mapas de características tendem a aumentar, conduzindo a um elevado número de parâmetros e aumento da carga computacional. Desta forma, o *max-pooling* ajuda a reduzir as dimensões, tornando a rede mais eficiente. Opera em janelas retangulares que percorrem os mapas de características. Para cada janela, a referida operação seleciona o valor máximo. Uma das vantagens do *max-pooling* é sua invariância a pequenas translações nas entradas. Isso significa que, se um objeto numa dada imagem se move um pouco, a saída não muda drasticamente, uma vez que o valor máximo ainda será detetado dentro da mesma janela. Também pode ajudar a tornar a rede mais resistente a ruído. Selecionar o valor máximo na janela tende a preservar as características mais dominantes e reduzir o impacto de ruídos ou informações menos importantes, focando as características mais importantes e reduzindo o risco de *overfitting*.

Passando para a etapa do *Neck*, é evidente a operação *Upsample*. Esta envolve o aumento da resolução espacial do mapa de características, muitas vezes recorrendo a técnicas como interpolação para preencher valores entre os existentes. Isso é frequentemente usado para restaurar detalhes espaciais perdidos, especialmente para permitir a fusão ao transmitir informações de uma fase anterior da rede para uma posterior. Tal como é demonstrado na figura 3.4, a referida operação geralmente é usada em conjunto com outras que ajudam a fundir informações de resoluções diferentes, permitindo que a rede capture detalhes finos e contextos mais amplos. Isso é útil para integrar informações de diferentes resoluções ou para gerar saídas finais com a mesma resolução das entradas.

A sigla SPPCSPC corresponde efetivamente a dois processos: SPP (*Spatial Pyramid Pooling*) e CSPC (*Cross Stage Partial Connection*). A primeira é uma técnica que divide o mapa de entrada em várias regiões ou sub-regiões e aplica operações de *max-pooling* para cada uma delas, por forma a que a rede capture informações contextuais em diferentes escalas, sem a necessidade de redimensionar as entradas originais. O SPP tem como objetivo melhorar a capacidade de captura de contexto em várias resoluções. A CSPC envolve a conexão cruzada de informa-

ções de fases anteriores da rede com estados posteriores, para melhorar o fluxo de informações através da rede e melhorar a qualidade das representações [Yu and Shao, 2023].

Ainda no *Neck*, tem-se a convolução reparametrizada (representada por Rep na figura 3.4) que consiste no ajuste da operação de convolução de uma forma específica, para melhorar o desempenho da rede neuronal. A convolução tradicional, já discutida anteriormente, utiliza um conjunto fixo de parâmetros, que são aprendidos durante o treino da rede. A ideia por trás desta maneira de implementar a convolução é modificar ou ajustar os parâmetros de uma maneira específica. No caso do YOLO-v7, verifica-se o uso funções de ativação personalizadas, ou seja, em vez de aplicar uma função de ativação padrão (como a ReLU), utilizou-se SiLU com o objetivo de melhorar a precisão do modelo.

3.3.2 Pré Processamento

Por forma a aumentar a precisão e velocidade dos modelos de *deep learning*, por vezes recorre-se à implementação de um tratamento prévio das imagens e ao aumento dos dados.

No projeto desenvolvido, começou-se efetivamente por eliminar a moldura de fundo circundante do PCB, proveniente do método de captura das imagens, recorrendo ao uso da biblioteca OpenCV. Desta forma, para todas as imagens utilizadas foi recortado o excesso de fundo, ou seja, apenas era representado o PCB na sua totalidade, evitando a sobrecarga da rede neuronal com detalhes que não teriam qualquer utilidade no objetivo pretendido, tal como é evidente na figura 3.5.



(a) Imagem original do PCB, capturada pela forma apresentada em 3.3.



(b) Imagem do mesmo PCB depois do recorte da moldura de fundo.

Figura 3.5: Diferença entre as imagens de um PCB de telemóvel antes e após a aplicação de pré processamento.

Tal como foi referido, outra das técnicas bastante utilizadas é o aumento de dados. O seu objetivo principal centra-se no aumento da diversidade e da quantidade de dados para treinar a rede neuronal. Um vez que, tal como já foi referido,

o conjunto de dados utilizado possui um número bastante reduzido de imagens, existe a necessidade de implementar alguns métodos para ampliar artificialmente o número de imagens. No caso, o aumento de dados pode ser especialmente vantajoso, uma vez que não é necessária a aquisição de mais amostras e realizar a anotação das classes, ou seja as técnicas de aumento permitem gerar diversas instâncias de treino a partir dos dados já existentes.

A resolução do problema da insuficiência de dados de treino é crucial, uma vez que os dados estão no centro de qualquer modelo. A falta de exemplos suficientes é frequentemente responsável por maus desempenhos na detecção de objetos, conduzindo a perda de generalidade. Assim sendo, existem 3 categorias para realizar o aumento de dados: transformações geométricas e fotométricas e oclusão aleatória. As primeiras são responsáveis pela alteração da posição do pixel da imagem e incluem rotação, redimensionamento, inversão, corte, preenchimento, etc. Por outro lado, as transformações fotométricas alteraram valores de intensidade em vez de posições de pixel. São baseadas na mudança dos componentes de cor de uma imagem e incluem mudanças no brilho, contraste, saturação e ruído da imagem. Por último, um bom modelo de detecção de objetos deve ser indiferente às oclusões presentes na imagem. Ou seja, deve ser capaz de detetar objetos corretamente, mesmo que alguma parte do objeto ou da imagem não seja visto ou esteja obstruído. As técnicas de oclusão mais comuns passam por apagar aleatoriamente, recortar e ocultar frações da imagem.

A aplicação destas técnicas para aumentar o número de dados de treino vai de encontro a vários objetivos. Mais detalhadamente, o aumento de dados permite uma exposição do modelo a uma gama mais alargada de variações e cenários, conduzindo ao aumento da generalidade. Ao aplicar transformações como rotações, translações e variações de escala, os dados passam a simular variações reais que o modelo pode encontrar durante a sua execução. Assim, este aprender características mais robustas e variadas, levando a um melhor desempenho para os diversos dados de teste. Consequentemente, reduz a possibilidade da existência de *overfitting*. Isto é, situações em que o modelo se torna demasiado especializado nos dados de treino e não consegue generalizar para os de teste. Ao introduzir variações, o modelo aprende a ser mais robusto e menos sensível a pequenas alterações nos dados de entrada. Por outro lado, o aumento de dados expande efetivamente o tamanho do conjunto das imagens de de treino sem exigir esforços adicionais de anotação manual.

Para efetuar comparações de resultados foram geradas várias versões do conjunto de dados primário, recorrendo às ferramentas de pré processamento e aumento de dados do *Roboflow*. Assim inicialmente utilizaram-se as imagens completas e sem nenhuma alteração, apenas uma divisão de 80% para treino e 20% para teste, correspondendo a 20 e 8 imagens, respetivamente. Posto isto, foi necessário ter em atenção o tamanho reduzido das componentes que se pretendiam detetar para aplicar as técnicas de pré processamento mais adequadas, por forma a melhorar a precisão de detecção de objetos pequenos Assim, dividiu-se cada

imagem em blocos, em forma de grelha 9x9 e aplicou-se a técnica denominada mosaico, onde se combinaram frações de imagens diferentes numa só, técnica representada na figura 3.6. Foi ainda adicionado aleatoriamente ruído Gaussiano, provocando desfoque na imagem, por forma permitir ao modelo uma menor resistência à qualidade do foco da câmara. Como resultado, o conjunto de dados era composto por 10386 imagens de treino e 2428 para validação.

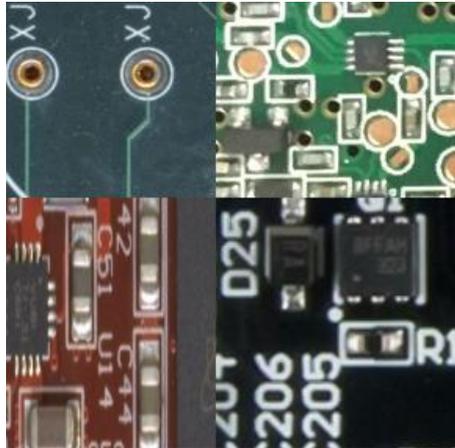


Figura 3.6: Exemplo de um resultado da aplicação da técnica de mosaico em frações de imagens do *dataset* utilizado.

Por fim, referir que para a deteção, por forma a avaliar efetivamente a capacidade do modelo para o objetivo proposto, foram usadas 8 imagens do conjunto de dados PCB-DSLR já referido na tabela 2.1 e 11 imagens de telemóveis de diferentes modelos, recolhidos e desmantelados manualmente no laboratório para o âmbito do projeto.

Capítulo 4

Resultados e Discussão

No presente capítulo serão apresentados os resultados do modelo descrito ao longo da dissertação, bem como a discussão dos mesmos. Desta forma, inicialmente serão apresentadas e explicadas as métricas de avaliação deste tipo de modelos e posteriormente, a divulgação dos resultados das fases de treino e validação, acompanhados da sua interpretação.

4.1 Indicadores de desempenho

Para avaliar a eficácia do modelo é necessário compreender os parâmetros provenientes do treino do mesmo. Assim, nesta subsecção serão definidas as seguintes métricas: *mean average precision* (mAP@0.5, mAP@0.5:0.95), *precisão*, *recall* e *F1-score*.

Mais detalhadamente, a mAP é um desses parâmetros usados como uma medida de desempenho do modelo de visão computacional, dado pela área da curva da relação *precisão-recall*, ou seja:

$$AP = \int_0^1 \text{Precision} \times \text{Recall} \, dr \quad (4.1)$$

O resultado final é igual ao valor médio das métricas de precisão média de todas as classes individualmente. Por outro lado, as curvas de treino de mAP@0.5 e mAP@0.5:0.95 permitem a avaliação da capacidade do modelo na deteção de objetos com diferentes graus de limiares de Intersecção sobre União (IoU). A mAP@0.5 centra-se principalmente na capacidade de deteção do modelo com um limiar de IoU de 0,5, enquanto o mAP@0.5:0.95 calcula a média da precisão média numa gama de limiares de IoU de 0,5 a 0,95, fornecendo assim uma visão geral abrangente do desempenho do modelo. Sendo,

$$\text{IoU} (A, A') = \frac{|A \cap A'|}{|A \cup A'|}, \quad (4.2)$$

onde A corresponde à área da previsão da caixa delimitadora e A' caixa delimitadora real. Entenda-se por caixa delimitadora a identificação propriamente dita

da localização do componente. Desta forma, um valor elevado de IoU indica que as previsões do modelo têm uma sobreposição significativa com as identificações verdadeiras, o que é um indicador positivo de precisão na deteção. Um valor baixo de IoU, contudo, sugere que as previsões do modelo têm pouca sobreposição com a realidade. É usado para determinar se uma deteção é verdadeira ou falsa e é comumente usado como critério para considerar se uma deteção é válida. A relação entre mAP e IoU reside no facto de que o IoU é frequentemente usado como parte do processo de avaliação para determinar se uma deteção é verdadeira ou falsa. Durante o cálculo da mAP para uma classe específica, só se considera uma deteção como correta se o IoU entre a caixa delimitadora prevista e a verdadeira exceder um limite de IoU específico, isto significa que, para calcular a precisão da classe, se usa o IoU como critério para decidir se a deteção é um verdadeiro positivo ($\text{IoU} \geq \text{limite}$) ou um falso positivo ($\text{IoU} < \text{limite}$).

Por outro lado, a precisão avalia a percentagem de quantos dos objetos detetados se encontram efetivamente bem identificados em relação a todas as atribuições de classes realizadas e a *recall* determina a proporção de deteções que o modelo identifica com sucesso, relativamente a todas as identificações teoricamente bem realizadas. A precisão mede, então, a qualidade das identificações realizadas associadas efetivamente a componentes do PCB e o *recall* mede a capacidade do modelo identificar todas as componentes presentes. De igual forma, são calculados tendo por base valores de IoU. Desta forma, para os valores compreendidos entre 0.5 e 0.7 está associado um verdadeiro positivo (TP) e a um IoU menor que 0,3 corresponde um falso positivo (FP). As expressões associadas ao cálculo dessas grandezas são as seguintes:

$$\text{Precisão} = \frac{TP}{FP + TP} \quad (4.3)$$

$$\text{Recall} = \frac{TP}{FN + TP}, \quad (4.4)$$

sendo que por FN se entendem falsos negativos. Importante referir que quanto maiores (mais próximo de 1) forem estes valores, melhor será o desempenho do modelo. Importante referir que, para o caso em estudo, por TP se entendem as classificações totalmente corretas, a FP correspondem os casos em que a classe atribuída a um componente não é a correta, por outro lado, os FN acontecem quando não existia nenhum tipo de componente e mesmo assim lhe foi atribuída uma classe e, por fim, quando o modelo distingue corretamente o fundo do PCB não lhe atribuindo nenhum componente tem-se os TN.

Posto isto, é ainda necessária a avaliação dos diferentes tipos de valores de perda, que desempenha um papel fundamental na avaliação e melhoria do modelo. Essencialmente, esse tipo de funções quantificam a disparidade entre as previsões do modelo e os valores reais, sendo que uma perda menor significa um melhor desempenho do modelo. Além disso, analisando estes valores, podemos deduzir se o modelo é suscetível de sobreajuste. Uma evidência clássica de sobreajuste é observado quando, após um declínio contínuo no valor da perda, se

atinge um ponto em que a perda começa a estabilizar ou mesmo a aumentar. Isto indica que, embora o modelo possa ter um desempenho excepcionalmente bom nos dados de treino, a sua eficácia em dados com pequenas diferenças nos dados de validação pode ser comprometida, levantando assim preocupações sobre o seu poder de previsão e generalização. Por conseguinte, a análise destas perdas pode esclarecer até que ponto o modelo está a aprender bem e onde podem ser feitas melhorias. Neste estudo, foram considerados três tipos de perdas, cada um dos quais abordando diferentes aspetos do desempenho do modelo, proporcionando assim uma avaliação abrangente da avaliação abrangente da eficácia da aprendizagem do modelo.

Começando pela perda associada às identificações das localizações dos componentes com o retângulo delimitador (*box_Loss*). O objetivo deste tipo de regressão centra-se em corrigir e ajustar as coordenadas dos retângulos delimitadores para corresponder o mais possível às coordenadas da identificação real. No contexto da deteção de objetos uma forma comum de medir o erro associado a essa diferença é utilizar o erro quadrático médio (MSE). O MSE calcula a média das diferenças quadráticas entre os valores previstos e os valores reais. Suponhamos que as coordenadas do retângulo delimitador efetivo sejam (x_i, y_i, w_i, h_i) e as coordenadas da caixa delimitadora prevista $(\hat{x}_i, \hat{y}_i, \hat{w}_i, \hat{h}_i)$. Aqui, (x, y) representam o centro e (w, h) representam a largura e a altura, respetivamente. A expressão de cálculo seria então:

$$\sum_{i=0}^N \left[(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 + \left(\sqrt{w_i} - \sqrt{\hat{w}_i} \right)^2 + \left(\sqrt{h_i} - \sqrt{\hat{h}_i} \right)^2 \right] \quad (4.5)$$

Esta medida fornece o valor da diferença entre as identificações previstas e as verdadeiras. O objetivo é minimizar essa perda para melhorar a precisão das previsões.

O segundo tipo é a perda de classificação (*cls_loss*), é usada para medir o quão bem o modelo classifica os objetos depois de os identificar, ou seja, avalia se as classes atribuídas correspondem efetivamente ao componente. A decisão da classe tem por base um vetor de comprimento igual ao número de classes, com um 1 para a classe a atribuir e um 0 para as restantes. O objetivo é prever uma distribuição de probabilidades entre essas classes que seja tão próxima quanto possível da distribuição real. A perda logarítmica é frequentemente utilizada para esta tarefa uma vez que mede a diferença entre as referidas distribuições, da seguinte forma:

$$L(y, \hat{y}) = - \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i)], \quad (4.6)$$

sendo y o vetor binário onde apenas a classe verdadeira é 1, e todas as outras são 0 e \hat{y} o vetor de probabilidades previstas pelo modelo para cada classe.

Finalmente, perda relacionada com os objetos (*obj_loss*), é uma componente adicional da função de perda nos modelos YOLO, e é usada para equilibrar a detecção de objetos em relação a regiões sem objetos (fundo). Isso ajuda o modelo concentrar-se na detecção precisa de objetos em vez de prever retângulos delimitadoras em regiões vazias onde não há componentes. Esta pode envolver cálculos específicos, dependendo da arquitetura do modelo, mas geralmente centra-se em penalizar a previsão de caixas delimitadoras que não contém realmente objetos.

4.2 Resultados

Na etapa de treinar o modelo recorrendo ao YOLO-v7, tal como já foi referido, foram combinadas várias técnicas de pré processamento e de aumento de dados para se proceder à comparação dos resultados de cada uma, por forma a obter a maior qualidade na detecção de componentes possível.

4.2.1 Treino e Validação

Para o caso em que não existiu qualquer tipo de processamento a quantidade de imagens utilizadas era bastante reduzida para o tipo de abordagem que se pretendia realizar e por isso a qualidade dos resultados que se esperava era fraca.

Tendo em que consideração a matriz de confusão apresentada na figura 4.1 verifica-se que os indutores, os LEDs e os transístores não são identificados em nenhuma das imagens, acabando sempre por serem considerados como fundo, correspondendo, por isso, na sua totalidade a falsos negativos. Das restantes classes de componentes os circuitos integrados (ic) são os que evidenciam uma percentagem considerável de deteções corretas. Para além disso, são evidentes, ainda que com valores pouco significativos, bastantes falsos positivos para um mesmo componente, algo que revela a indecisão do modelo em relação ao tipo de componente que lhe é apresentado, motivado pelo reduzido número de imagens.

Por outro lado, aplicando pré processamento focado no aumento de dados, os resultados da matriz correspondente (figura 4.2) melhoram significativamente e o aspeto geral da mesma aproxima-se de uma matriz diagonal, onde se localizam todos os verdadeiros positivos, revelando um desempenho correto na identificação do tipo de componente. O número de falsos negativos, por sua vez, também diminui refletindo uma maior assertividade na atribuição das classes. Embora essa quantidade apresente valores menores, ainda demonstra que existe uma quantidade significativa de componentes presentes no PCB que não conseguem ser detetados, no entanto são consideramos como fundo e não como outra classe, algo que, ainda assim, pode ser preferível. Isto pode acontecer devido ao reduzido número de placas de circuito impresso presente no conjunto de dados

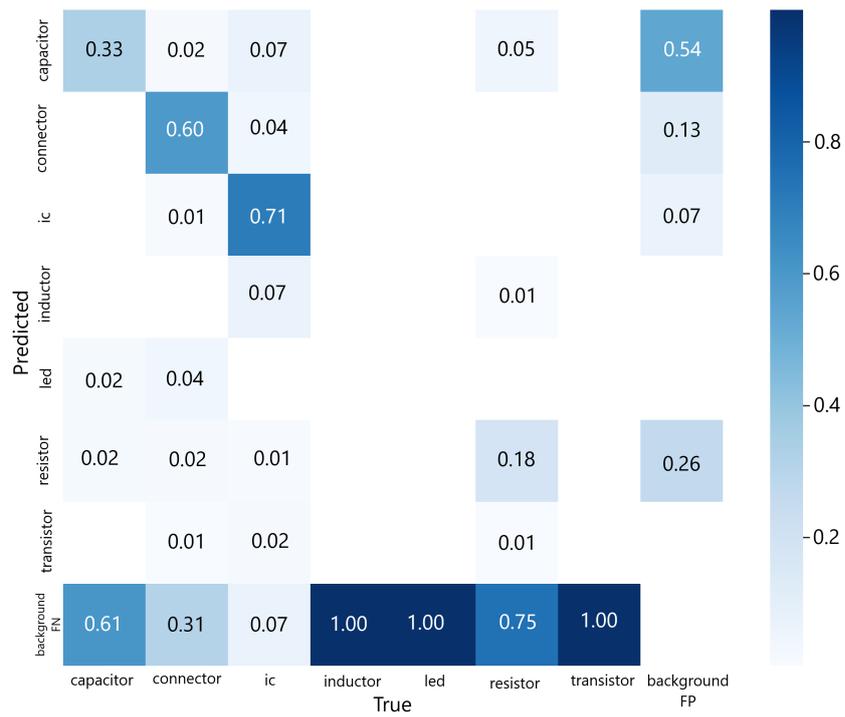


Figura 4.1: Matriz de confusão para o treino do conjunto de dados, sem processamento.

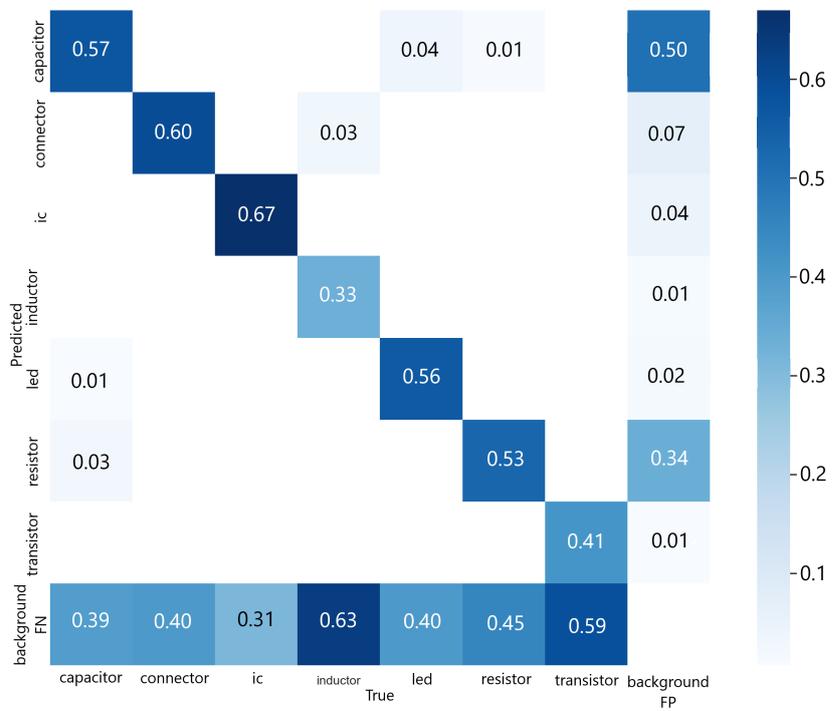


Figura 4.2: Matriz de confusão para o treino do conjunto de dados, com aumento de dados.

inicial traduzindo num menor número de exemplos utilizados para o modelo extrair as características das classe, como é o caso dos indutores e dos transístores.

Nas duas matrizes é ainda expressivo a não existência de verdadeiros negativos, sendo evidente que na maioria das vezes o fundo é associado a um condensador (*capacitor*) ou a uma resistência (*resistor*). Isto pode encontrar-se associado ao facto dos dois componentes referidos serem os de tamanho mais reduzido e a placa onde estes se encontram soldados possuir um fundo heterogéneo, podendo partes dele serem então confundidas como essas componentes de tamanho inferior. Para resolver esta questão, poder-se-ia considerar nas classes do modelo a identificação de fundo, por forma a extrair as características associadas que seriam efetivamente diferentes.

O que foi dito encontra-se refletido nas métricas que avaliam o desempenho do modelo. Na tabela 4.1 encontram-se os resultados provenientes do treino do modelo e onde é possível proceder à comparação entre os conjuntos de dados utilizados.

Tabela 4.1: Apresentação dos resultados do desempenho do modelo para os diferentes conjuntos de dados.

	mAP@0.5 %	mAP@0.5:0.95 %	Precisão %	Recall %	box_loss %	cls_loss %	obj_loss %
Sem Processamento	21.67	11.58	53.17	26.67	6.56	0.72	1.51
Aumento de Dados	59.97	32.14	79.97	55.67	1.55	0.17	1.19

Assim, para fazer o paralelismo entre as matrizes de confusão e os indicadores de performance do modelo é necessário atentar nos valores da precisão e da *recall* uma vez que, essas grandezas avaliam a quantidade de deteções corretamente realizadas considerando todas as outras. Verifica-se, desta forma, que recorrendo ao aumento de dados os valores das mesmas aumentam mais de 25%, evidenciando efetivamente que nesse caso existe um maior número de deteções e classificações corretas, algo também verificado na aproximação da matriz de confusão a uma matriz de diagonal, tal como já foi referido.

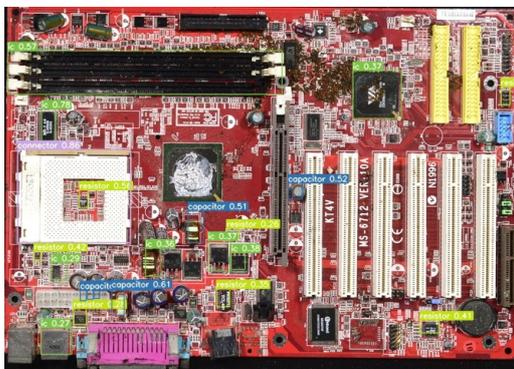
Por outro lado, para validar as localizações dos componentes previstas com o retângulo delimitador, devem observar-se as duas primeiras colunas da mesma tabela. Posto isto, é extremamente evidente que para o conjunto de dados original as percentagens são muito inferiores (menos de metade), traduzindo numa fraca validação dos resultados de treino, ou seja, as identificações realizadas não correspondem à realidade, pois quanto maior for o valor da mAP, maior será a sobreposição das deteções. Visualmente, o que isto pode traduzir-se num deslocamento do retângulo limitador, não considerando a componente na sua totalidade ou este ser maior que a mesma podendo até incluir um outro componente mais próximo.

Passando agora, às questões relacionadas com a função de perda não há dúvidas que, mais uma vez, a utilização de pré processamento manifesta uma maior aproximação do modelo à realidade visto que, para os 3 parâmetros de avaliação os seu valores são menores, tal como se pretende. Assim sendo, a qualidade de aprendizagem do modelo e a consequente qualidade na deteção para PCBs novos é deveras confiável.

4.2.2 Deteção

Passando, agora, para a etapa da deteção propriamente dita onde as condições do modelo pré treinado foram aplicadas em placas completamente novas, ou seja, que não foram utilizadas na fase de treino. Tal como foi dito anteriormente, começaram por se utilizar placas maiores de um conjunto de dados já existente para verificar o desempenho do modelo e, posteriormente, com base nesses resultados transitou-se, efetivamente, para as placas de telemóveis.

Após a análise dos resultados obtidos para o treino das imagens onde não existiu qualquer tipo de processamento, as qualidade e quantidade de deteção esperadas não eram muito elevadas, o que de facto se verificou. Para os PCBs maiores, realizando a média para as 8 placas referidas, a taxa de reconhecimento apresentou um valor de 34.53%, onde na maioria das vezes a classe atribuída não era correta refletindo a existência relevante de falsos positivos existente na matriz de confusão 4.1. Para o caso dos 11 telemóveis a mesma taxa possui um valor médio inferior a 10%.



(a) PCB maior, proveninete do conjunto de dados PCB-DSLR.



(b) PCB de um telemóvel Samsung.

Figura 4.3: Exemplos de resultados para a deteção de componentes, onde para o treino do modelo não existiu pré processamento.

Tal como se pode verificar pela figura 4.3 o número de deteções conseguidas e a percentagem de confiança são bastante reduzidas, o que direciona para a atribuição errada de classes. Ainda assim, algo ainda evidente é o facto dos retângulos delimitadores, em algumas situações, não integram somente a componente pela

sua fronteira, traduzindo o que foi discutido na fase de treino associado aos baixos valores de mAP.

Por outro lado, quando se recorre ao uso de pré processamento já ficou demonstrado que a eficiência do modelo melhora consideravelmente. Mais detalhadamente, para o mesmo número de PCBs mencionado, a taxa de reconhecimento aumentou para 89.60% para os PCBs de maiores dimensões e para 75.02% para o caso dos telemóveis. A tabela 4.2 apresenta mais algum detalhe sobre essas taxas para alguns PCBs a título de exemplo.

Tabela 4.2: Taxas de reconhecimento de componentes em diferentes PCBs.

	Identificação do PCB	Taxa de Reconhecimento (%)
PCBs maiores	figura 4.4a	92.40
	figura 4.4b	87.27
PCBs de telemóveis	figura 4.5	88.69
	figura 4.7	78.57
	figura 4.8	75.51
	figura 4.6	71.43

Para as placas maiores, de um modo geral, as classes atribuídas correspondem verdadeiramente ao componente descrito, onde as probabilidades de confiança visíveis demonstram uma maior confiabilidade nesse aspeto. No entanto, observando mais atentamente as imagens da figura 4.4 são evidentes duas situações. A primeira, centra-se na deteção dos indutores, isto é, nas imagens 4.4b e 4.4a a componente ou é classificada como sendo um condensador (*capacitor*) ou não lhe é atribuída qualquer classe. Isto pode estar relacionado com a quantidade de indutores presentes no conjunto de dados original. Porque, importante referir, embora se tenha recorrido ao aumento de dados para facilitar a deteção das componentes mais pequenas e para colocar alguma aleatoriedade nas características, o número de exemplos dessa componente não deixa ser bastante reduzido. De notar que, inicialmente o número total de imagens de PCBs era 28, onde a quantidade de componentes de cada classe não era, de todo, uniforme. A segunda questão centra-se em torno de, por vezes, componentes da mesma classe serem visualmente semelhantes e nuns casos são corretamente identificadas e noutros não lhes é atribuída nenhuma classe sendo, por isso, considerados TN. A origem deste cenário pode estar em diferentes contextos. Mais detalhadamente, o conjunto de dados de treino utilizado pode não ser representativo o suficiente em termos de variedade de objetos da mesma classe, havendo um desequilíbrio. Se o modelo for treinado principalmente em exemplos de objetos específicos dentro de uma classe, este pode não ser capaz de generalizar bem para outros casos. Por exemplo, no conjunto de imagens utilizado, na maioria dos casos, os condensadores são componentes de forma retangular inseridos na placas, todavia são apresentados, ainda que em muito menor quantidade, outros de forma cilíndrica.

Assim, nesses últimos, o modelo nem sempre é capaz de os identificar, mesmo sendo visualmente semelhantes a outros que identificou corretamente. Por outro lado, dado que as imagens, inicialmente, foram anotadas na totalidade pelos autores das mesmas apenas tendo sido realizada uma triagem das classes, podem existir erros de anotação e por isso existir confusões na detecção de objetos semelhantes. Ainda no exemplo anterior, os condensadores de forma cilíndrica podem ser perfeitamente trocados por indutores e, por isso, existir uma dificuldade do modelo em compreender as características dos mesmos. Importante referir que esta geometria para as componentes referidas apenas se encontra nos PCBs de maiores dimensões, não sendo aplicada na questão dos telemóveis.

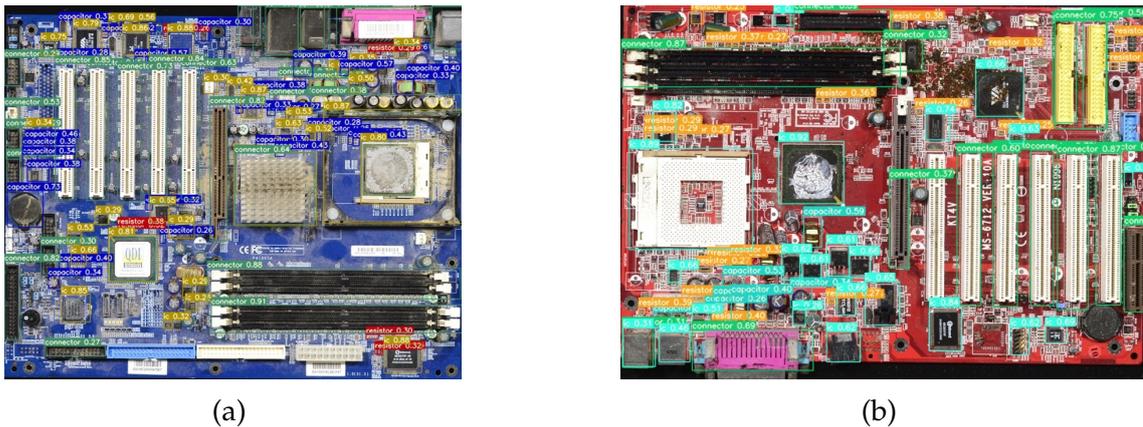


Figura 4.4: Identificação e classificação de componentes de PCBs de maiores dimensões.

Passando para a análise das placas de telemóveis propriamente ditas, verifica-se que existem, tal como acabou de ser referido, componentes visualmente semelhantes que não são igualmente detetados em todos os casos detetados. Ainda assim, o motivo para este sucedido pode ser ligeiramente diferente. Ou seja, pode acontecer devido ao facto do modelo não ter sido treinado recorrendo a placas de telemóveis e, por isso, o tamanho das componentes nas duas fases passar a ser uma questão bastante considerável, levando à avaliação dessas componentes como fundo da placa. No entanto, é importante destacar que em alguns dos telemóveis, onde a câmara dos mesmos se encontra na imagem, esta é classificada, erradamente, como sendo um conector. Verifica-se, de igual forma, a questão de componentes visualmente semelhantes não serem sempre detetadas. Para além do que foi discutido e sugerido, existe uma outra técnica que pode ser uma possível solução para a melhoria dessa dificuldade de deteção, que se centra na utilização exclusiva das componentes, ou seja, cada componente é individualmente recortado ficando o número de imagens do conjunto de dados igual à quantidade de componentes identificadas e cada imagem corresponde a um exemplo. No entanto, o tempo de computação irá aumentar consideravelmente. Ainda assim, a maioria das componentes encontra-se corretamente identificada indo ao encontro das elevadas taxas de reconhecimento.

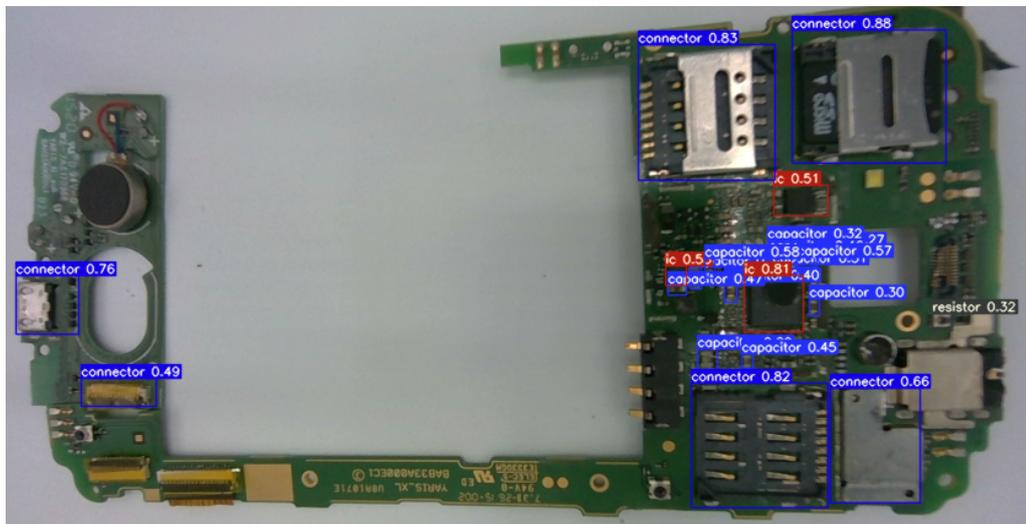


Figura 4.6: Identificação e classificação de componentes de PCBs de telemóveis, modelo Alcatel.

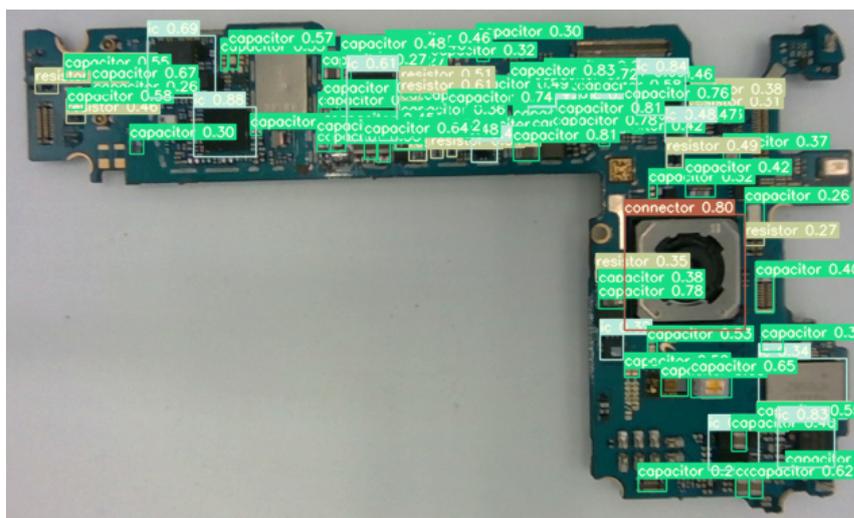


Figura 4.7: Identificação e classificação de componentes de PCBs de telemóveis, modelo Samsung.

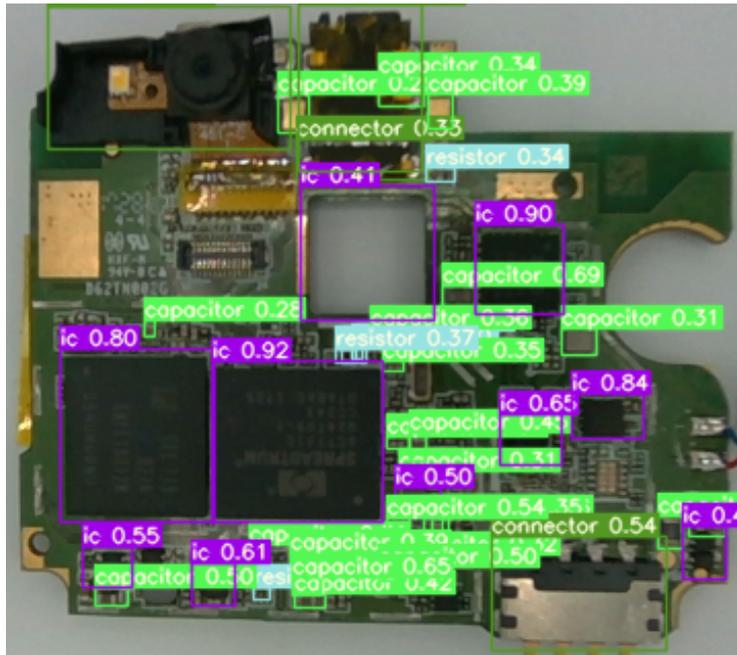


Figura 4.8: Identificação e classificação de componentes de PCBs de telemóveis, modelo InnJoo.

Capítulo 5

Conclusão

O principal objetivo da presente dissertação consistia na classificação de componentes de PCBs de telemóveis recorrendo a técnicas de visão por computador, por forma a automatizar e otimizar todo o processo de reciclagem e, conseqüente, reutilização. Neste ponto do projeto é possível concluir, então, que o referido objetivo foi alcançado, aumentando de forma impactante a forma de interpretar o problema do tratamento do lixo eletrônico proveniente dos telemóveis.

Assim sendo, tendo em conta os resultados já apresentados no Capítulo 4 é possível obter conclusões importantes sobre a forma de resolver a questão inicial recorrendo à estratégia apresentada. Começar por inferir que, para uma forma pioneira de abordar a questão principal, as percentagens conseguidas são um bom ponto de partida, indo de encontro ao esperado, revelando sucesso na extrapolação da fase de treino do modelo para a fase de deteção, descartando a existência de sobreajuste. Ou seja, utilizando PCBs que não foram visto inicialmente pelo modelo, durante a aprendizagem das características, este conseguiu generalizar de forma eloqüente. No entanto verificou-se que o modelo é mais capaz de identificar componentes para PCBs de tamanho semelhante àqueles que foram utilizadas para o treino (Tabela 4.2).

Começando pela questão da seleção do conjunto de dados de treino, verificou-se que existem poucos com imagens aplicáveis ao estudo que se pretendia realizar. Mais detalhadamente, ou os *datasets* não eram públicos ou não se encontravam com as componentes identificadas (ou apenas só uma classe), direcionando o procedimento para a utilização de PCBs maiores para depois aplicar os resultados de aprendizagem ao caso dos telemóveis, recorrendo às imagens utilizadas.

Relativamente à fase de treino, verifica-se efetivamente que a utilização de técnicas de pré processamento confere uma melhoria bastante significativa na aprendizagem das características, algo que também se enquadra no esperado, uma vez que o número de imagens inicial, por si só, era altamente reduzido. Ainda nessa etapa, é relevante entender que o número de exemplos dos vários componentes não é homogêneo ao longo das imagens utilizadas, pelo que, pode influenciar

também a qualidade da detecção. Tendo em conta o que foi dito nos últimos dois parágrafos é possível concluir que, a elaboração de um conjunto de imagens de telemóveis devidamente anotadas, pode ser uma solução para implementar uma melhoria das taxas de reconhecimento. Resultando, assim, numa maior semelhança entre os tamanhos das componentes na fase de treino e detecção e numa distribuição de exemplos de componentes mais próxima da finalidade necessária.

No que diz respeito à assertividade da classificação foram exploradas as várias questões associadas, na subsecção 4.2.2. É possível observar que os ICs e os conectores são bastante bem detetados, com confiança elevada, resultando da sua presença em número expressivo no conjunto de dados de treino e da sua reduzida variabilidade entre os PCBs, no geral. Todavia, tendo em consideração as imagens representativas dos PCBs de telemóveis verifica-se que existe uma variabilidade significativa entre os modelos dos PCBs, por exemplo, na cor do fundo, na geometria e na forma das componentes. Assim sendo, percebe-se que é importante a consideração nas imagens de treino de identificação de fragmentos do fundo do PCB, por forma as componentes de tamanho reduzido não serem consideradas como tal.

Estabelecendo, agora, o paralelismo com o objetivo principal do projeto *RECY-SMART*, que visa à extração das componentes detetadas. Assim, verifica-se que a quantidade e qualidade das classificações realizadas como um bom ponto de partida para iniciar o processo de reutilização das componentes. É, de facto, importante garantir um valor o mais baixo possível (próximo de 0) para o parâmetro *box_loss* e o mais elevado (próximo de 1) para a métrica *mAP*, por forma ao robô conseguir planear a abertura da sua garra de forma mais precisa. Se o retângulo de identificação se encontrar desalinhado com a componente a probabilidade da extração se concretizar acabar por ser reduzida. Algo também a diminuir é a existência de falsos negativos, com o objetivo de evitar ações inúteis por parte do robô.

Em suma, conclui-se que o objetivo principal da dissertação foi alcançado de forma satisfatória, com os recursos disponíveis. No entanto, reconhecem-se formas de melhoria e apresentam-se possíveis alternativas de resolução das questões que surgiram aquando da execução do projeto.

5.1 Trabalho Futuro

Todos os modelos computacionais podem ser melhorados tornando-os mais eficazes e especializados e, o apresentado neste projeto, tal como já foi defendido, também pode. Começando pela recolha de um número considerável de telemóveis com vista à criação de um conjunto de imagens dos seus PCBs e proceder à

identificação das suas componentes e de porções de fundo das várias placas. No entanto, seria um processo realizado por humanos e, conseqüentemente, manual.

Outra melhoria, pode centrar-se na implementação da versão mais recente do algoritmo de classificação, YOLO-v8, que surgiu quando este projeto se encontrava em desenvolvimento, no entanto ainda não se fazia acompanhar de literatura suficiente para a sua compreensão.

É importante ainda, redirecionar as classificações realizadas com o objetivo final do projeto que se centra na extração das componentes, previamente selecionadas, por um robô. Considerando este aspeto, é fundamental, como já foi referido, que as características das componentes sejam corretamente conhecidas, por forma ao braço robótico conseguir planear a força e a trajetória corretas. Assim sendo, por forma a obter informações mais detalhadas da posição e profundidade de encaixe das componentes, pode ser considerar-se a integração de um mapa de profundidade captado, de igual forma, com os sensores da Intel, referidos na secção 3. Ainda assim, a profundidade dos PCBs pode não ser significativa para a sua deteção dada a reduzida espessura dos telemóveis a que estamos familiarizados.

Desta forma, todas essas melhorias transformariam a implementação em algo mais complexo e mais especificado no casos dos telemóveis.

Referências

- Sabah M Abdelbasir, Chakinaz T El-Sheltawy, and Dina M Abdo. Green processes for electronic waste recycling: a review. *Journal of Sustainable Metallurgy*, 4(2): 295–311, 2018.
- Daniel Fernandes Andrade, Jeyne Pricylla Castro, José Augusto Garcia, Raquel Cardoso Machado, Edenir Rodrigues Pereira-Filho, and Dulasiri Amarasiriwardena. Analytical and reclamation technologies for identification and recycling of precious materials from waste computer and mobile phones. *Chemosphere*, 286:131739, 2022.
- M Arshadi, S Yaghmaei, and SM Mousavi. Content evaluation of different waste pcbs to enhance basic metals recycling. *Resources, Conservation and Recycling*, 139:298–306, 2018.
- Mukesh Chandra Arya and Anchal Rawat. A review on yolo (you look only one)-an algorithm for real time object detection. *J Eng Sci*, 11:554–7, 2020.
- Jun Chen, Erdemt Bao, and Jingyu Pan. Classification and positioning of circuit board components based on improved yolov5. *Procedia Computer Science*, 208: 613–626, 2022.
- Sumyung Gang, Ndayishimiye Fabrice, Daewon Chung, and Joonjae Lee. Character recognition of components mounted on printed circuit board using deep learning. *Sensors*, 21(9):2921, 2021.
- Ross Girshick. Fast r-cnn. In *Proceedings of the IEEE international conference on computer vision*, pages 1440–1448, 2015.
- Ross Girshick, Jeff Donahue, Trevor Darrell, and Jitendra Malik. Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 580–587, 2014.
- Matko Glučina, Nikola Anđelić, Ivan Lorencin, and Zlatan Car. Detection and classification of printed circuit boards using yolo algorithm. *Electronics*, 12(3): 667, 2023.
- Tadeusz Gorewoda, Marcus Eschen, Jadwiga Charasińska, Magdalena Knapik, Sylwia Kozłowicz, Jacek Anyszkiewicz, Michał Jadwiński, Martyna Potempa, Marta Gawliczek, Andrzej Chmielarz, et al. Determination of metals' content in components mounted on printed circuit boards from end-of-life mobile phones. *Recycling*, 5(3):20, 2020.

- Pejman Hadi, Meng Xu, Carol SK Lin, Chi-Wai Hui, and Gordon McKay. Waste printed circuit board recycling techniques and product utilization. *Journal of hazardous materials*, 283:234–243, 2015.
- Juanjuan Hao, Yishu Wang, Yufeng Wu, and Fu Guo. Metal recovery from waste printed circuit boards: A review for current status and perspectives. *Resources, Conservation and Recycling*, 157:104787, 2020.
- Daniel Herchenbach, Wei Li, and Matthias Breier. Segmentation and classification of thcs on pcbas. In *2013 11th IEEE International Conference on Industrial Informatics (INDIN)*, pages 59–64. IEEE, 2013.
- Han Hu, Jiayuan Gu, Zheng Zhang, Jifeng Dai, and Yichen Wei. Relation networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3588–3597, 2018.
- Rui Huang, Jinan Gu, Xiaohong Sun, Yongtao Hou, and Saad Uddin. A rapid recognition method for electronic components based on the improved yolo-v3 network. *Electronics*, 8(8):825, 2019.
- Weibo Huang and Peng Wei. A pcb dataset for defects detection and classification. *arXiv preprint arXiv:1901.08204*, 2019.
- Weibo Huang, Peng Wei, Manhua Zhang, and Hong Liu. Hripcb: a challenging dataset for pcb defects detection and classification. *The Journal of Engineering*, 2020(13):303–309, 2020.
- Zhe Huang, Zhenyu Yin, Yue Ma, Chao Fan, and Anying Chai. Mobile phone component object detection algorithm based on improved ssd. *Procedia Computer Science*, 183:107–114, 2021.
- Manisha Kaushal, Baljit S Khehra, and Akashdeep Sharma. Soft computing based object detection and tracking approaches: State-of-the-art survey. *Applied Soft Computing*, 70:423–464, 2018.
- Muammer Kaya. Recovery of metals and nonmetals from electronic waste by physical and chemical recycling processes. *Waste management*, 57:64–90, 2016.
- Jeong-ah Kim, Ju-Yeong Sung, and Se-ho Park. Comparison of faster-rcnn, yolo, and ssd for real-time vehicle type recognition. In *2020 IEEE international conference on consumer electronics-Asia (ICCE-Asia)*, pages 1–4. IEEE, 2020.
- Chia-Wen Kuo, Jacob D Ashmore, David Huggins, and Zsolt Kira. Data-efficient graph embedding learning for pcb component detection. In *2019 IEEE Winter Conference on Applications of Computer Vision (WACV)*, pages 551–560. IEEE, 2019.
- Brian Li, Steven Palayew, Francis Li, Saad Abbasi, Saejith Nair, and Alexander Wong. Pcbdet: An efficient deep neural network object detection architecture for automatic pcb component detection on the edge. *arXiv preprint arXiv:2301.09268*, 2023.

- Dashuang Li, Lei Xu, Guangzai Ran, and Zhanling Guo. Computer vision based research on pcb recognition using ssd neural network. In *Journal of Physics: Conference Series*, volume 1815, page 012005. IOP Publishing, 2021.
- Jianan Li, Xiaodan Liang, Yunchao Wei, Tingfa Xu, Jiashi Feng, and Shuicheng Yan. Perceptual generative adversarial networks for small object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1222–1230, 2017.
- Jie Li, Xunxun Zhang, and Pei Feng. Detection method of end-of-life mobile phone components based on image processing. *Sustainability*, 14(19):12915, 2022.
- Wei Li, Bernhard Esders, and Matthias Breier. Smd segmentation for automated pcb recycling. In *2013 11th IEEE International Conference on Industrial Informatics (INDIN)*, pages 65–70. IEEE, 2013.
- Wei Li, Stefan Neullens, Matthias Breier, Marcel Bosling, Thomas Pretz, and Dorit Merhof. Text recognition for information retrieval in images of printed circuit boards. In *IECON 2014-40th Annual Conference of the IEEE Industrial Electronics Society*, pages 3487–3493. IEEE, 2014.
- Yanghao Li, Yuntao Chen, Naiyan Wang, and Zhaoxiang Zhang. Scale-aware trident networks for object detection. In *Proceedings of the IEEE/CVF international conference on computer vision*, pages 6054–6063, 2019.
- Tsung-Yi Lin, Piotr Dollár, Ross Girshick, Kaiming He, Bharath Hariharan, and Serge Belongie. Feature pyramid networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2117–2125, 2017.
- Hongguo Liu, Jingjing Hai, Lin Li, and Fengfu Yin. An efficient disassembly process generation method for large quantities of waste smartphones. *Procedia CIRP*, 105:140–145, 2022.
- Shu Liu, Lu Qi, Haifang Qin, Jianping Shi, and Jiaya Jia. Path aggregation network for instance segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 8759–8768, 2018.
- Songtao Liu, Di Huang, and Yunhong Wang. Learning spatial fusion for single-shot object detection. *arXiv preprint arXiv:1911.09516*, 2019.
- Hangwei Lu, Dhvani Mehta, Olivia Paradis, Navid Asadizanjani, Mark Tehranipoor, and Damon L Woodard. Fics-pcb: A multi-modal image dataset for automated printed circuit board visual inspection. *Cryptology ePrint Archive*, 2020.
- Yingqi Lu, Bo Yang, Yichun Gao, and Zhenming Xu. An automatic sorting system for electronic components detached from waste printed circuit boards. *Waste Management*, 137:1–8, 2022.

- Gayathri Mahalingam, Kevin Marshall Gay, and Karl Ricanek. Pcb-metal: A pcb image dataset for advanced computer vision machine learning component analysis. In *2019 16th International Conference on Machine Vision Applications (MVA)*, pages 1–5. IEEE, 2019.
- PC Manojkumar, Lakshmi Sutha Kumar, and B Jayanthi. Performance comparison of real time object detection techniques with yolov4. In *2023 International Conference on Signal Processing, Computation, Electronics, Power and Telecommunication (IConSCEPT)*, pages 1–6. IEEE, 2023.
- Ananya Mantravadi, Dhruv Makwana, Sai Chandra Teja R., Sparsh Mittal, and Rekha Singhal. 2023 isqed makwanaetal pcb component classification. 2023.
- Kohei Naito, Aya Shirai, Shin-ichiro Kaneko, and Genci Capi. Recycling of printed circuit boards by robot manipulator: A deep learning approach. In *2021 IEEE International Symposium on Robotic and Sensors Environments (ROSE)*, pages 1–5. IEEE, 2021.
- Aabidah Nazir and Mohd Arif Wani. You only look once-object detection models: A review. In *2023 10th International Conference on Computing for Sustainable Global Development (INDIACom)*, pages 1088–1095. IEEE, 2023.
- V Neethidevan and S Anand. A real time object detection system using a webcam with yolo algorithm. *Annals of the Romanian Society for Cell Biology*, pages 1876–1881, 2021.
- Chao Ning, Carol Sze Ki Lin, David Chi Wai Hui, and Gordon McKay. Waste printed circuit board (pcb) recycling techniques. *Chemistry and Chemical Technologies in Waste Valorization*, pages 21–56, 2017.
- Krishna Patel, Chintan Bhatt, and Pier Luigi Mazzeo. Improved ship detection algorithm from satellite images using yolov7 and graph neural network. *Algorithms*, 15(12):473, 2022.
- Ajeet Ram Pathak, Manjusha Pandey, and Siddharth Rautaray. Application of deep learning for object detection. *Procedia computer science*, 132:1706–1717, 2018.
- Christopher Pramerdorfer and Martin Kampel. A dataset for computer-vision-based pcb analysis. In *2015 14th IAPR International Conference on Machine Vision Applications (MVA)*, pages 378–381. IEEE, 2015a.
- Christopher Pramerdorfer and Martin Kampel. Pcb recognition using local features for recycling purposes. In *VISAPP (3)*, pages 71–78, 2015b.
- Laura Rocchetti, Alessia Amato, and Francesca Beolchini. Printed circuit board recycling: A patent review. *Journal of Cleaner Production*, 178:814–832, 2018.
- R Shankar and M Muthulakshmi. Comparing yolov3, yolov5 & yolov7 architectures for underwater marine creatures detection. In *2023 International Conference on Computational Intelligence and Knowledge Economy (ICCIKE)*, pages 25–30. IEEE, 2023.

- Leandro H de S Silva, Agostinho AF Júnior, George OA Azevedo, Sergio C Oliveira, and Bruno JT Fernandes. Estimating recycling return of integrated circuits using computer vision on printed circuit boards. *Applied Sciences*, 11(6):2808, 2021.
- Iftikhar A Soomro, Anser Ahmad, and Rana H Raza. Printed circuit board identification using deep convolutional neural networks to facilitate recycling. *Resources, Conservation and Recycling*, 177:105963, 2022.
- Shrey Srivastava, Amit Vishvas Divekar, Chandu Anilkumar, Ishika Naik, Ved Kulkarni, and V Pattabiraman. Comparative analysis of deep learning image detection algorithms. *Journal of Big data*, 8(1):1–27, 2021.
- Lu Tan, Tianran Huangfu, Liyao Wu, and Wenying Chen. Comparison of yolo v3, faster r-cnn, and ssd for real-time pill identification. 2021.
- Sanli Tang, Fan He, Xiaolin Huang, and Jie Yang. Online pcb defect detector on a new pcb defect dataset. *arXiv preprint arXiv:1902.06197*, 2019.
- Omar Tantawi and Inez Hua. Temporal evolution of metallic element composition and environmental impact in consumer electronic devices: A study of smartphones. *Resources, Conservation and Recycling*, 175:105886, 2021.
- Kang Tong, Yiquan Wu, and Fei Zhou. Recent advances in small object detection based on deep learning: A review. *Image and Vision Computing*, 97:103910, 2020.
- Sanjith Udayakumar, Muhammad Irfan Bin Abd Razak, and Suhaina Ismail. Recovering valuable metals from waste printed circuit boards (wpcb): A short review. *Materials Today: Proceedings*, 2022.
- Changfa Wu, Abhishek Kumar Awasthi, Wenqing Qin, Wei Liu, and Congren Yang. Recycling value materials from waste pcbs focus on electronic components: A review on technologies, obstruction and prospects. *Journal of Environmental Chemical Engineering*, page 108516, 2022.
- Luciana Harue Yamane, Viviane Tavares de Moraes, Denise Croce Romano Espinosa, and Jorge Alberto Soares Tenório. Recycling of weee: characterization of spent printed circuit boards from mobile phones and computers. *Waste Management*, 31(12):2553–2558, 2011.
- Gengchen Yu and Birui Shao. Garbage classification and detection based on improved yolov7 network. In *2023 International Conference on Pattern Recognition, Machine Vision and Intelligent Algorithms (PRMVIA)*, pages 103–107. IEEE, 2023.
- Nianyin Zeng, Peishu Wu, Zidong Wang, Han Li, Weibo Liu, and Xiaohui Liu. A small-sized object detection oriented multi-scale feature fusion approach with application to defect detection. *IEEE Transactions on Instrumentation and Measurement*, 71:1–14, 2022.
- Wenwei Zhao, Suprith Reddy Gurudu, Shayan Taheri, Shajib Ghosh, Mukhil Azhagan Mallaiyan Sathiaseelan, and Navid Asadizanjani. Pcb component detection using computer vision for hardware assurance. *Big Data and Cognitive Computing*, 6(2):39, 2022.

Xinrui Zou. A review of object detection techniques. In *2019 International conference on smart grid and electrical automation (ICSGEA)*, pages 251–254. IEEE, 2019.

Apêndice A

Detalhes da Arquitetura YOLO-v7

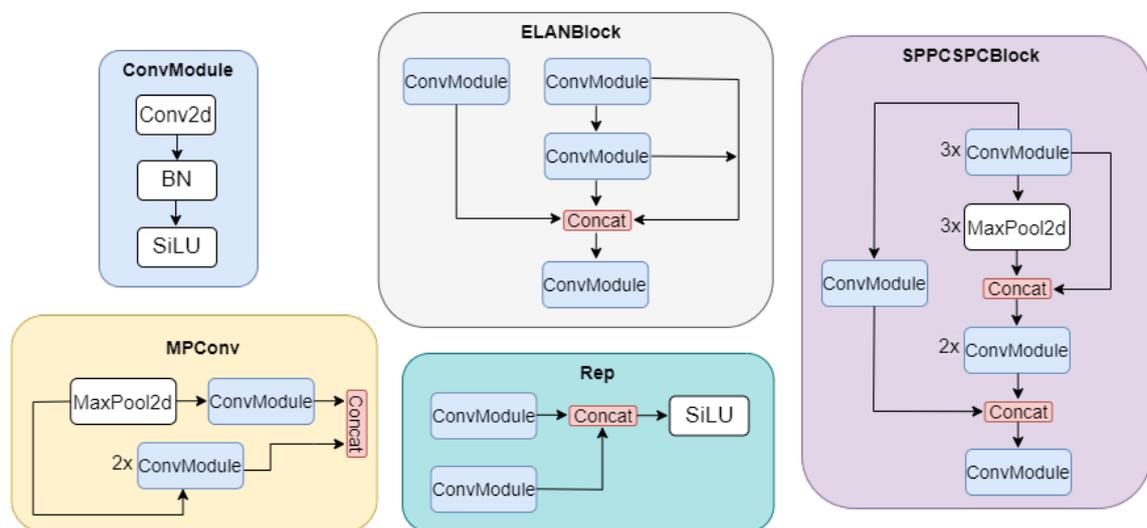


Figura A.1: Detalhes da arquitetura do modelo YOLO-v7, para complementar a imagem 3.4