



Utilização de Técnicas de Visão Computacional para Detecção de Defeitos em Pavimentos Rodoviários

Miguel Gonçalves ¹, Tomás Marques ¹, João M. L. P. Caldeira ^{1,2}, Vasco N. G. J. Soares ^{1,2}

¹Instituto Politécnico de Castelo Branco, Escola Superior de Tecnologia, Avenida do Empresário, 6000-767 Castelo Branco, Portugal;

²Instituto de Telecomunicações, Universidade da Beira Interior, Rua Marquês d'Ávila e Bolama, 6201-001 Covilhã, Portugal

g.miguel@ipcbcampus.pt, tomas.marques@ipcbcampus.pt,
jcaldeira@ipcb.pt, vasco.g.soares@ipcb.pt

1



1.

Introdução

2

2

Introdução

- ⦿ Entidades públicas procuram novas maneiras de tornar as cidades mais preparadas para o futuro.
- ⦿ Os pavimentos rodoviários são um dos elementos integrantes de qualquer cidade.



 **Infraestruturas**
de Portugal

3

3

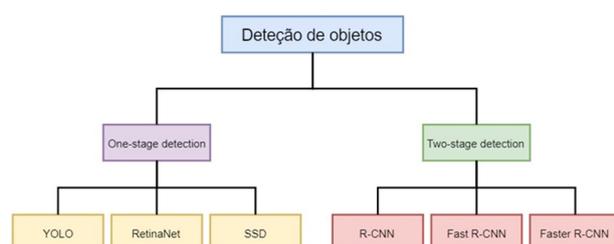
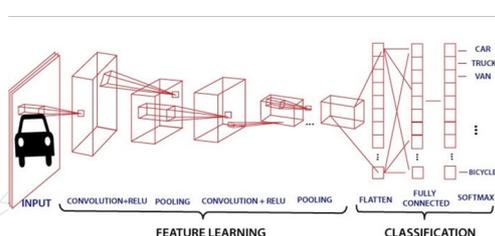
2. **Técnicas de visão computacional**

4

4

👁️ Técnicas de Visão Computacional

- ⦿ A visão computacional é o subcampo de inteligência artificial e *machine learning* que envolve o uso de computadores para obter uma compreensão detalhada de dados visuais.
- ⦿ A maioria dos algoritmos de visão computacional usa redes neurais convolucionais (CNNs), arquiteturas semelhantes, ou baseadas nestas, para a detecção de objetos presentes em imagens.



5

5

3. Desafios e Oportunidades

6

6

Desafios e Oportunidades



Algoritmo compatível



Capacidade Computacional



Qualidade da Imagem



7

7

4. Avaliação de desempenho

8

8

Descrição do Dataset

YOLO

Dataset público onde as imagens já passaram pelo processo de *labelling*. As classes definidas neste *dataset* de defeitos em pavimentos rodoviários são D00, D10, D20 e D40.

RetinaNet

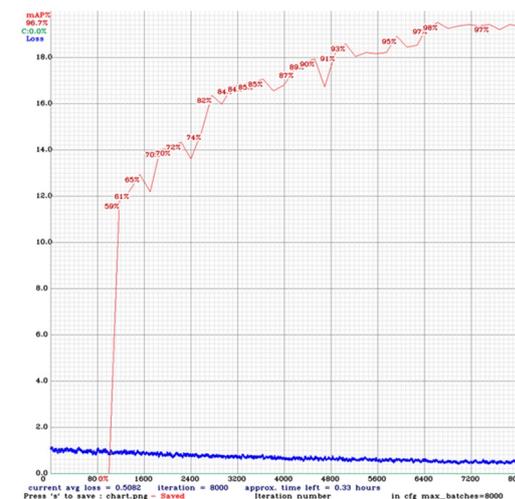
Dataset público que apresenta 665 imagens já com anotações. Apenas apresenta uma classe de defeito estrutural (D40).

SSD MobileNet

Mesmo *dataset* utilizado para o treino do YOLO, com algumas alterações. Foram definidas 9 classes de defeitos em pavimentos rodoviários: D00, D01, D10, D11, D20, D40, D43, D44 e D50.



Resultados e Discussão - YOLO



```

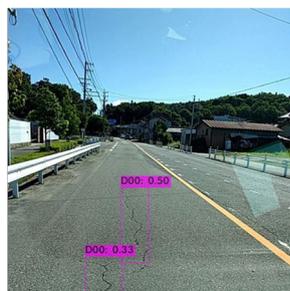
detections count = 739, unique truth count = 292
class_id = 0, name = D00, ap = 99.85% (TP = 170, FP = 17)
class_id = 1, name = D10, ap = 92.28% (TP = 58, FP = 13)
class_id = 2, name = D20, ap = 100.00% (TP = 28, FP = 3)
class_id = 3, name = D40, ap = 95.52% (TP = 25, FP = 1)

for conf_thresh = 0.25, precision = 0.89, recall = 0.91, F1-score = 0.90
for conf_thresh = 0.25, TP = 265, FP = 34, FN = 27, average IoU = 70.26 %

IoU threshold = 50 %, used Area-Under-Curve for each unique Recall
mean average precision (mAP@0.50) = 0.967135, or 96.71 %
Total Detection Time: 25 Seconds

Set -points flag:
-points 101 for MS COCO
-points 11 for PascalVOC 2007 (uncomment 'difficult' in voc.data)
-points 0 (AUC) for ImageNet, PascalVOC 2010-2012, your custom dataset

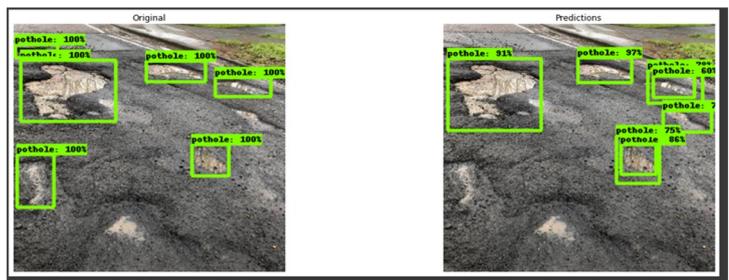
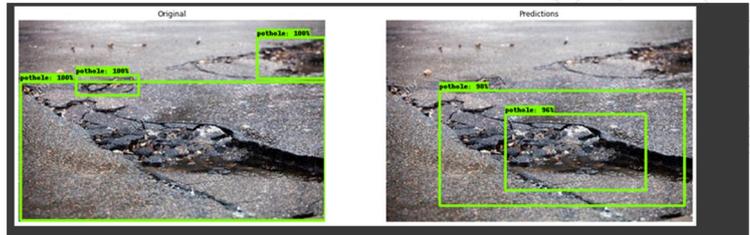
mean_average_precision (mAP@0.50) = 0.967135
    
```



Resultados e Discussão - RetinaNet

```

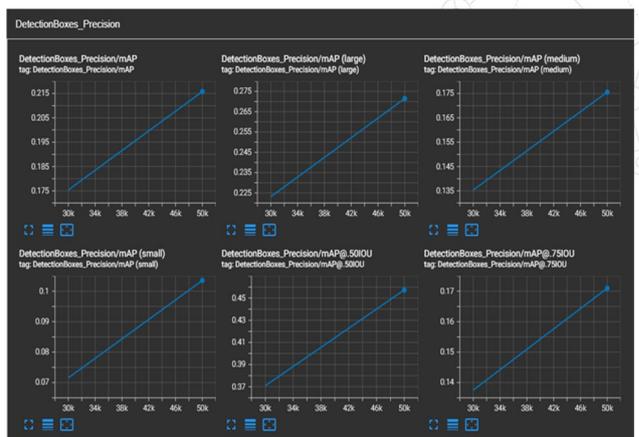
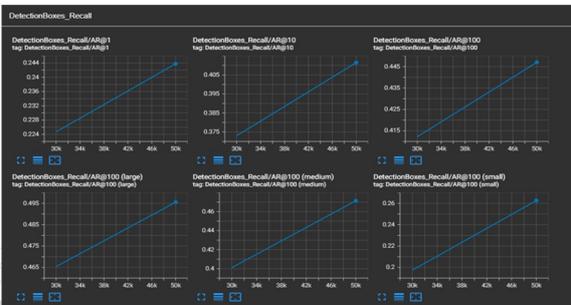
trainer_test(itModel)
  creating index...
  index created!
  Testing 100%
  Running per image evaluation...
  Evaluate annotation type 'bbox'
  DONE (t=0.01s)
  Accumulating evaluation results...
  DONE (t=0.01s)
  IOU metric: bbox
  Average Precision (AP) @[ IoU=0.50:0.95 | area= all | maxDets=100 ] = 0.242
  Average Precision (AP) @[ IoU=0.50 | area= all | maxDets=100 ] = 0.534
  Average Precision (AP) @[ IoU=0.75 | area= all | maxDets=100 ] = 0.821
  Average Precision (AP) @[ IoU=0.50:0.95 | area= small | maxDets=100 ] = -1.980
  Average Precision (AP) @[ IoU=0.50:0.95 | area= medium | maxDets=100 ] = 0.467
  Average Precision (AP) @[ IoU=0.50:0.95 | area= large | maxDets=100 ] = 0.221
  Average Recall (AR) @[ IoU=0.50:0.95 | area= all | maxDets= 1 ] = 0.857
  Average Recall (AR) @[ IoU=0.50:0.95 | area= all | maxDets= 10 ] = 0.529
  Average Recall (AR) @[ IoU=0.50:0.95 | area= all | maxDets=100 ] = 0.529
  Average Recall (AR) @[ IoU=0.50:0.95 | area= small | maxDets=100 ] = -1.000
  Average Recall (AR) @[ IoU=0.50:0.95 | area= medium | maxDets=100 ] = 0.590
  Average Recall (AR) @[ IoU=0.50:0.95 | area= large | maxDets=100 ] = 0.540
  DATADUMPER TEST RESULTS
  (*AP: tensor(0.2417, dtype=torch.FloatTensor))
  [*AP: 0.2416913778439492]
  
```



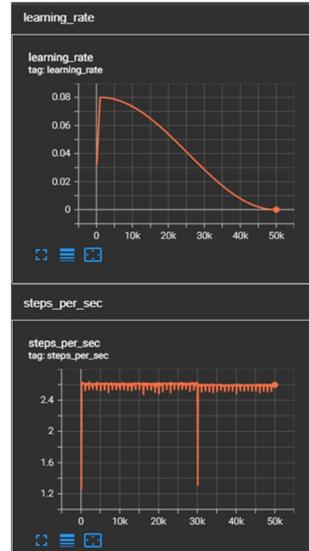
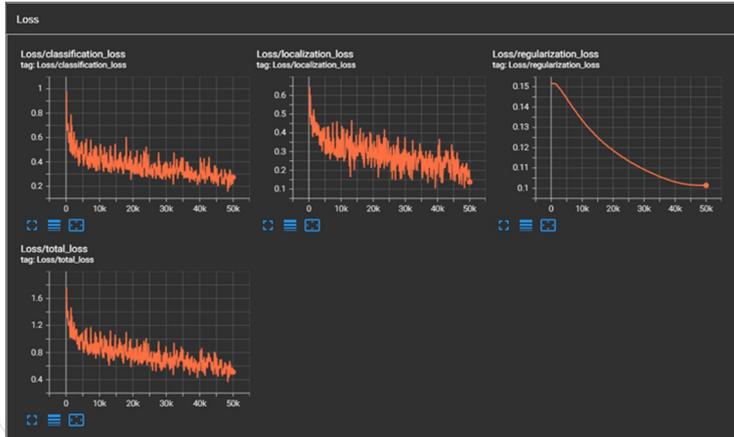
Resultados e Discussão - SSD MobileNet

```

Accumulating evaluation results...
DONE (t=1.88s)
Average Precision (AP) @[ IoU=0.50:0.95 | area= all | maxDets=100 ] = 0.216
Average Precision (AP) @[ IoU=0.50 | area= all | maxDets=100 ] = 0.457
Average Precision (AP) @[ IoU=0.75 | area= all | maxDets=100 ] = 0.171
Average Precision (AP) @[ IoU=0.50:0.95 | area= small | maxDets=100 ] = 0.184
Average Precision (AP) @[ IoU=0.50:0.95 | area= medium | maxDets=100 ] = 0.176
Average Precision (AP) @[ IoU=0.50:0.95 | area= large | maxDets=100 ] = 0.272
Average Recall (AR) @[ IoU=0.50:0.95 | area= all | maxDets= 1 ] = 0.244
Average Recall (AR) @[ IoU=0.50:0.95 | area= all | maxDets=10 ] = 0.411
Average Recall (AR) @[ IoU=0.50:0.95 | area= all | maxDets=100 ] = 0.447
Average Recall (AR) @[ IoU=0.50:0.95 | area= small | maxDets=100 ] = 0.263
Average Recall (AR) @[ IoU=0.50:0.95 | area= medium | maxDets=100 ] = 0.471
Average Recall (AR) @[ IoU=0.50:0.95 | area= large | maxDets=100 ] = 0.496
INFO:tensorflow:Eval metrics at step 50000
  
```



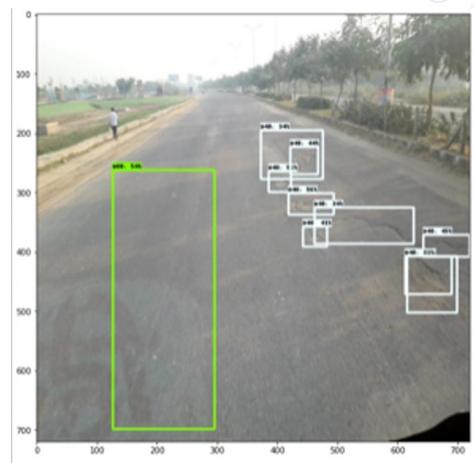
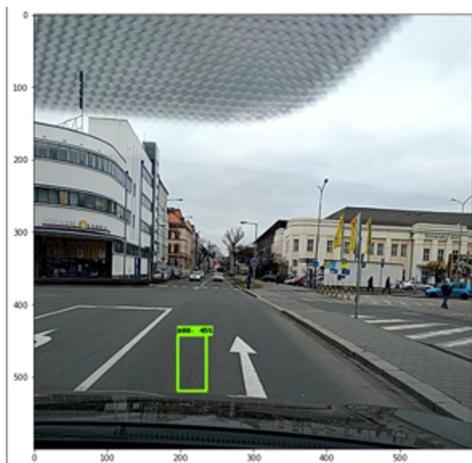
Resultados e Discussão - SSD MobileNet



13

13

Resultados e Discussão - SSD MobileNet



14

14

5.

Conclusões e Trabalho Futuro

15

15

Conclusões e Trabalho Futuro

- ◎ Conclusões
 - Técnicas de visão computacional permitem a automatização da deteção de defeitos em pavimentos rodoviários.
 - A deteção e alerta de defeitos evita perigos para os cidadãos, e em relação à sinistralidade rodoviária.
- ◎ Trabalho futuro
 - Mais testes, com diferentes parâmetros, em diferentes ambientes, e com a utilização de novas técnicas
 - Desenvolvimento e testes de um protótipo
 - Avaliação do desempenho da proposta

16

16



RTCM
Rede Temática de
Comunicações Móveis



Instituto Politécnico
de Castelo Branco
Escola Superior
de Tecnologia

Utilização de Técnicas de Visão Computacional para Deteção de Defeitos em Pavimentos Rodoviários

Miguel Gonçalves ¹, Tomás Marques ¹, João M. L. P. Caldeira ^{1,2}, Vasco N. G. J. Soares ^{1,2}

¹Instituto Politécnico de Castelo Branco, Escola Superior de Tecnologia, Avenida do Empresário, 6000-767 Castelo Branco, Portugal;

²Instituto de Telecomunicações, Universidade da Beira Interior, Rua Marquês d'Ávila e Bolama, 6201-001 Covilhã, Portugal

g.miguel@ipcbcampus.pt, tomas.marques@ipcbcampus.pt,
jcaldeira@ipcb.pt, vasco.g.soares@ipcb.pt