

Reconhecimento Automático de Placas de Veículos (ALPR)

Desafios e Soluções

Rayson Laroca

rblsantos@inf.ufpr.br

15 de outubro de 2022



- Introdução e Desafios;
- Abordagem proposta para ALPR;
 - Detector YOLO;
 - Resultados Experimentais.
- Trabalhos em Andamento.

Reconhecimento Automático de Placas de Veículos (ALPR)



Reconhecimento Automático de Placas de Veículos (ALPR).

- Muitas **aplicações práticas**, tais como *cobrança automática de pedágios*, *controle de acesso em áreas restritas*, e *monitoramento do tráfego rodoviário*.
- Apesar do notável progresso alcançado usando técnicas baseadas em **deep learning**, **ainda existem muitos desafios em aberto** no contexto de ALPR.

Desafios - Cenários do Mundo Real

A maioria das soluções existentes opera muito bem **apenas em ambientes controlados**, tendo o desempenho prejudicado à medida que se aumenta a complexidade.

- Um cenário **ideal**:



Fonte: <https://github.com/openalpr/benchmarks/tree/master/endtoend/br/>

Desafios - Cenários do Mundo Real

A maioria das soluções existentes opera muito bem **apenas em ambientes controlados**, tendo o desempenho prejudicado à medida que se aumenta a complexidade.

- Um cenário do **mundo real**:



Fonte: <http://platesmania.com/cn/>

Desafios - Acurácia vs Tempo de Execução

"Tempo Real"

- ① Uma operação rápida o suficiente para não perder um único objeto que se move pela cena.
- ② Um sistema capaz de processar pelo menos 30 *frames* por segundo (FPS).



Fonte: <https://github.com/icarofua/vehicle-rear>

Desafios - Diferentes Layouts de Placa



Exemplos de diferentes layouts de placa nos Estados Unidos.

Desafios - Diferentes Layouts de Placa



Exemplos de diferentes layouts de placa nos Estados Unidos.



Padrão MERCOSUL de placas, e padrões adotados anteriormente na Argentina, Brasil e Paraguai.

Objetivo: um único sistema ALPR que seja robusto para diferentes layouts de placa.

Proposta - Sistema ALPR



O pipeline do sistema ALPR proposto¹.

- Cada estágio do sistema é tratado como uma tarefa de **detecção de objetos**.

¹Todo o sistema ALPR proposto – isto é, as arquiteturas e pesos dos modelos – está **disponível publicamente** em <https://web.inf.ufpr.br/vri/publications/layout-independent-alpr/>.

Detecção de Objetos

Como a detecção de objetos era realizada **até alguns anos atrás?**



Amostras **positivas**



Amostras **negativas**

Detecção de Objetos

Janelas Deslizantes (*Sliding Windows*)



Detecção de Objetos

Janelas Deslizantes (*Sliding Windows*)



Desvantagem:

- Custo computacional

Como detectar objetos em tempo real?

²J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “*You only look once: Unified, real-time object detection*,” in IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 779–788.

Detecção de Objetos

Como detectar objetos em tempo real?

*You Only Look Once (YOLO)*²

- **Open source:** <https://pjreddie.com/darknet/yolo/>
 - YOLOv7 [versão mais recente]: <https://github.com/AlexeyAB/darknet/>



²J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “*You only look once: Unified, real-time object detection*,” in IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 779–788.

Detecção de Objetos

Como detectar objetos em tempo real?

You Only Look Once (YOLO)²


- **Open source:** <https://pjreddie.com/darknet/yolo/>
 - YOLOv7 [versão mais recente]: <https://github.com/AlexeyAB/darknet/>
- Resultados **estado-da-arte** em **tempo real**.



²J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” in IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 779–788.


You Only Look Once (YOLO)

A imagem de entrada é dividida em uma grade de tamanho $T \times T$.





You Only Look Once (YOLO)

Cada célula prediz N *bounding boxes* e valores de confiança P (Objeto):




You Only Look Once (YOLO)

Cada célula prediz ***bounding boxes*** e valores de confiança **P (Objeto)**:





You Only Look Once (YOLO)

Cada célula prediz ***bounding boxes*** e valores de confiança **P** (Objeto):





You Only Look Once (YOLO)

Cada célula também prediz **probabilidades de classe**.
Condicionadas no objeto: $P(\text{Mesa de jantar} \mid \text{Objeto})$



You Only Look Once (YOLO)

As previsões de *bounding boxes* e de classes são combinadas.





- Exploramos os seguintes modelos: *Fast-YOLOv2*, *YOLOv2*, *Fast-YOLOv3* e *YOLOv3*.



- Exploramos os seguintes modelos: *Fast-YOLOv2*, **YOLOv2**, *Fast-YOLOv3* e *YOLOv3*.
- **YOLOv2** + **modificações** (tamanho de entrada; *anchor boxes*, número de filtros);

Detecção de Veículos

- Estratégias de **aumento de dados** (*data augmentation*).



Detecção de Veículos - Resultados

Acertos (99,92% || 3765/3768 veículos):



Detecção de Veículos - Resultados

Erros:



Detecção de Placa e Classificação de Layout



Detecção de Placa e Classificação de Layout

O layout de cada placa é detectado e classificado em uma das seguintes classes:

- **Americana, Brasileira, Chinesa, Europeia ou Taiwanesa.**




(a) Americana



(b) Chinesa



(c) Europeia




(d) Taiwanesa

- **Fast-YOLOv2 + modificações.**
 - Acurácia: **99,51%** (300+ FPS)

Detecção de Placa e Classificação de Layout



Detecção de Placa e Classificação de Layout



Reconhecimento de Placa



- Nós empregamos o **CR-NET**³, modelo baseado no YOLO, para o reconhecimento de placa.
 - 35 classes (0-9, A-Z, onde a letra 'O' é detectada/reconhecida juntamente com o dígito '0').

³S. M. Silva and C. R. Jung, "Real-time license plate detection and recognition using deep convolutional neural networks," in Journal of Visual Communication and Image Representation, p. 102773, 2020.

Reconhecimento de Placa - Heurísticas

O número **mínimo** e **máximo** de caracteres a ser considerado em placas de cada layout:

Layout	# Caracteres	
	Mín.	Máx.
Americana	4	7
Brasileira	7	7
Chinesa	6	6
Europeia	5	8
Taiwanesa	5	6

Reconhecimento de Placa - Heurísticas

O número **mínimo** e **máximo** de caracteres a ser considerado em placas de cada layout:

Layout	# Caracteres	
	Mín.	Máx.
Americana	4	7
Brasileira	7	7
Chinesa	6	6
Europeia	5	8
Taiwanesa	5	6

Dígitos e letras são trocados de acordo com o layout de placa.

- Por exemplo, em uma placa brasileira, A**8**C-123**G** (**x**) → A**BC**-123**6** (**✓**);
- Assim, evitamos erros em caracteres que muitas vezes são classificados incorretamente:
 - 'B' e '8', 'G' e '6', 'I' e '1', entre outros.

Resultados (Avaliação Geral)

Dataset	Layout	Ref. 1	Ref. 2	Ref. 3	Ref. 4	Ref. 5	<i>Sighthound</i>	<i>OpenALPR</i>	Sem Classificação de Layout*	Sistema Proposto
<i>Caltech Cars</i>	Americana	—	—	—	—	—	95.7 ± 2.7	99.1 ± 1.2	96.1 ± 1.8	98.7 ± 1.2
<i>EnglishLP</i>	Europeia	97.0	—	—	—	—	92.5 ± 3.7	78.6 ± 3.6	95.5 ± 2.4	95.7 ± 2.3
<i>UCSD-Stills</i>	Americana	—	—	—	—	—	98.3	98.3	97.3 ± 1.9	98.0 ± 1.4
<i>ChineseLP</i>	Chinesa	—	—	—	—	—	90.4 ± 2.4	92.6 ± 1.9	95.4 ± 1.1	97.5 ± 0.9
<i>AOLP</i>	Taiwanesa	—	99.8	—	—	—	87.1 ± 0.8	—	98.4 ± 0.7	99.2 ± 0.4
<i>OpenALPR-EU</i>	Europeia	—	—	93.5	—	—	93.5	91.7	96.7 ± 1.9	97.8 ± 0.5
<i>SSIG-SegPlate</i>	Brasileira	—	—	88.6	88.8	85.5	82.8	92.0	96.9 ± 0.5	98.2 ± 0.5
<i>UFPR-ALPR</i>	Brasileira	—	—	—	—	64.9	62.3	82.2	82.5 ± 1.1	90.0 ± 0.7
Média	Todos	—	—	—	—	—	87.8 ± 2.4	90.7 ± 2.3	94.8 ± 1.4	96.9 ± 1.0

* Uma versão modificada do nosso sistema sem classificação de layout e regras heurísticas.

Ref. 1: IEEE TITS || Refs. 2-3: ECCV || Ref. 4: SIBGRAPI || Ref. 5: IJCNN

- O sistema proposto **supera** os trabalhos anteriores e dois sistemas comerciais em quatro conjuntos de dados públicos;
 - **Resultados competitivos** nos demais.
- É capaz de processar em **tempo real** mesmo quando há vários veículos em cena.

Estágio	Modelo Adaptado	Tempo (ms)	FPS
Detecção de Veículos	YOLOv2	8.54	117
Detecção de Placa e Classificação de Layout	Fast-YOLOv2	3.09	324
Reconhecimento de Placa	CR-NET	1.99	502
Sistema Completo	-	13.62	73

Resultados Qualitativos

Exemplos de placas que foram reconhecidas **corretamente:**



UFD69K



018VFJ



281SGL




3WVM533



MCA9954



HJN2081



IOZ3616



AUG0936



AK6972



CG0815



AK8888



A36296

Resultados Qualitativos


Exemplos de placas que foram reconhecidas **corretamente**:



ZG806KF



DU166BF



317J939




WOBVWMK4



0750J0



UH7329



F9F183



6B7733

Resultados Qualitativos

Exemplos de placas que foram reconhecidas **incorretamente**:



AB0416 (AR0416)



2MFE674 (2MFF674)



HOR8361 (HDR8361)



AK04I3 (AK0473)



AYH5087 (AXH5087)



430463TC (30463TC)



YB8096 (Y88096)



DJ9A4AE (DJ944AE)



RL0020- (L0020I)



ATT4026 (ATT4025)



ZG594TSH (ZG594TS)



4NTU770 (4NIU770)


Resultados Adicionais - Placas Mercosul



Nosso sistema pode ser **facilmente** ajustado para layouts de placa adicionais.

Publicações e Distinções

- Artigo - *International Joint Conference on Neural Networks (IJCNN)*
 - **É o trabalho mais citado entre os 760 artigos apresentados na mesma conferência**, de acordo com ambos [IEEE Xplore](#) e [Google Scholar](#) (360+ citações).
 - Foi coberto no [NVIDIA News Center](#), com grande importância sendo dada aos resultados obtidos, ao conjunto de dados por nós apresentado, e às aplicações potenciais.



Researchers Develop AI System for License Plate Recognition

April 5

Researchers in Brazil developed a **deep learning** system that captures license plate data in real-time, resulting in better performance than most commercially available products in Brazil.

Trabalhos em Andamento

Na era do deep learning, como alcançar resultados melhores?

Na era do deep learning, como alcançar resultados melhores?

Tendo mais dados de treinamento!

Na era do deep learning, como alcançar resultados melhores?

Tendo mais dados de treinamento!

- Dados rotulados são caros;
- Preocupações crescentes relacionadas à privacidade (LGPD, GDPR, etc.).

Na era do deep learning, como alcançar resultados melhores?

Tendo mais dados de treinamento!

- Dados rotulados são caros;
- Preocupações crescentes relacionadas à privacidade (LGPD, GDPR, etc.).

Como alcançar resultados melhores sem coletar e rotular mais imagens?

Na era do deep learning, como alcançar resultados melhores?

Tendo mais dados de treinamento!

- Dados rotulados são caros;
- Preocupações crescentes relacionadas à privacidade (LGPD, GDPR, etc.).

Como alcançar resultados melhores sem coletar e rotular mais imagens?

Aumento de dados usando Redes Adversárias Generativas (GANs)

Trabalhos em Andamento - Aumento de dados usando GANs

pix2pix (<https://phillipi.github.io/pix2pix/>)

- Conversão pareada de imagem-para-imagem:



Trabalhos em Andamento - Aumento de dados usando GANs

Treinamento:



entrada



saída



entrada



saída



entrada



saída




entrada



saída



entrada



saída



entrada



saída



entrada



saída



entrada



saída



entrada



saída



entrada



saída



entrada



saída



entrada



saída

Trabalhos em Andamento - Aumento de dados usando GANs

Imagens geradas (☆ totalmente rotuladas ☆):



- **Qualquer** sequência de caracteres pode ser gerada.

Trabalhos em Andamento - Resultados Preliminares

Conjunto de dados **CLPD**⁴: 1,200 imagens coletadas da internet.

- Todas as imagens são de veículos com placas chinesas.

Taxas de reconhecimento alcançadas pelo nosso melhor método (treinado com milhares de imagens geradas por GANs) e por modelos estado-da-arte no conjunto de dados CLPD.


Método	Imagens reais de placas chinesas usadas para treinamento	O mesmo modelo funciona para outros layouts de placa?	Taxa de Reconhecimento
Fan et al. (2022)	100,000	✓	79.3%
Zhang et al. (2021d)	100,000	✗	82.5%
Sighthound (2022)	?	✓	85.5%
Attentional Net (Zhang et al., 2021c)	100,000	✗	86.1%
Attentional Net (Zhang et al., 2021c) + CycleGAN	100,000	✗	87.6%
Fan et al. (2022) + CycleWGAN	100,000	✓	88.5%
Liu et al. (2021)	10,000	✗	91.7%
OpenALPR (2022)	?	✗	86.5%
Zou et al. (2020)	100,000	✗	94.0%
SCR-Net (Wang et al., 2021c)	100,000	✗	95.3%
Nosso método (TRBA) + aumento de dados + retificação	500	✓	96.2%

Resultados estado-da-arte.

⁴https://github.com/wangpengnorman/CLPD_dataset

Trabalhos em Andamento - Baixa Resolução // Baixa Qualidade

Abordagens ALPR existentes não podem ser aplicadas a imagens capturadas por muitas câmeras de vigilância de tráfego espalhadas pelas cidades.



Um exemplo que mostra que pode ser difícil reconhecer visualmente a placa mesmo em imagens de alta resolução (a imagem acima tem 1920×1080 pixels).

pix2pix


- Conversão pareada de **baixa resolução** → **alta resolução**.

Trabalhos em Andamento - Resultados Preliminares


pix2pix

- Conversão pareada de **baixa resolução** → **alta resolução**.


Resultados preliminares:



AYR-8H48



RHC-0I91



AWJ-7748



APX-6704

Obrigado!

<https://raysonlaroca.github.io/>

