

Grupo de Pesquisas em Sistemas Inteligentes  
Laboratório de Sistemas Inteligentes  
Escola Superior de Tecnologia  
Universidade do Estado do Amazonas



## *Detecção Inteligente de Falhas em Pavimentações Asfálticas com Redes Neurais Convolucionais Regionais*

**Rafael Barbosa de Carvalho, Elloá B. Guedes, Carlos Maurício S. Figueiredo**

*{rbc.eng, ebgcosta, cfigueiredo}@uea.edu.br*

*III Workshop Brasileiro de Cidades Inteligentes*

*CSBC 2022 – Niterói – Rio de Janeiro*

# Agenda

- 1 Introdução
- 2 Trabalhos Resultados
- 3 Materiais e Métodos
- 4 Resultados e Discussão
- 5 Estudo de Caso em Pavimentações Asfálticas no Brasil
- 6 Considerações Finais
- 7 Agradecimentos

# Introdução

- Organização das Nações Unidas (ONU 2018)
  - 57 % da população mundial vive em áreas urbanas
  - Até 2050 essa proporção será de 68 %
  
- Cidades Inteligentes (CIs)
  - Tecnologias da Informação e Comunicação colaborem para que os serviços providos se tornem mais flrxíveis, eficientes, sustentáveis e inteligentes
  - Melhoria contínua em benefício aos seus habitantes

# Introdução

- Transporte e Mobilidade

- Melhorias no acesso, eficiência de locomoção, segurança e conforto
- Realidade: degradação avançada, inconveniência para mobilidade e infraestrutura insuficiente
- Demanda por soluções viáveis frente a esses desafios

- Pavimentação Asfáltica

- Condições precárias e defeitos estruturais (localização, condições climáticas, volume de tráfego, etc.)
- Redução da segurança e conforto
- Impacto negativo na operação de veículos automotivos (Staniek 2021)

# Introdução

- Análise de qualidade para manutenção eficiente e econômica da pavimentação
  - **Realidade:** Limitações de tecnologia, *know-how* e de recursos financeiros para aquisição de equipamentos e serviços modernos (*Arya et al. 2021a*)
  
- Transporte rodoviário é o principal sistema logístico do Brasil (**CNT 2019**)
  - 52,9% da malha rodoviária federal é pavimentada
  - Aumento no custo de manutenção dos veículos, consumo de combustível e lubrificantes, maior desgaste de pneus e freios e redução na segurança viária
  - Em 2020:
    - 63.447 acidentes nas rodovias federais brasileiras
    - Custos financeiros da ordem de R\$ 10,22 bilhões (**CNT 2020**)

# Introdução

## Objetivo do Trabalho

Avaliar o desempenho de Redes Neurais Convolucionais Regionais (R-CNNs, do inglês *Regional Convolutional Neural Networks*) da família YOLO (acrônimo para *You Only Look Once*) na tarefa de Visão Computacional de detecção (localização e classificação) de quatro tipos distintos de falhas em pavimentações asfálticas.

- Aquisição de experiência a partir de uma base de dados realística
- Potencial de detecção em tempo real e utilização em dispositivos embarcados
- Validação preliminar da solução em um estudo de caso no Brasil

# Agenda

- 1 Introdução
- 2 Trabalhos Resultados**
- 3 Materiais e Métodos
- 4 Resultados e Discussão
- 5 Estudo de Caso em Pavimentações Asfálticas no Brasil
- 6 Considerações Finais
- 7 Agradecimentos

## Trabalhos Relacionados

- *Survey* de Cao *et al.* 2020
  - Soluções seminais consideravam o uso de sensores (acelerômetro e giroscópio)
  - Soluções tradicionais de Visão Computacional combinadas com *Machine Learning*
  - Uso de *Deep Learning* com diferentes métodos (R-CNNs, SSDs, R-FCNs)
  - Dificuldade: Comparação objetiva entre as soluções
  
- *Global Road Damage Detection Challenge* (Maeda *et al.* 2020)
  - Competição promovida pelo IEEE
  - RDD2020 para treinamento e base privada para avaliação (Arya *et al.* 2021b)
  - Top-3 melhores soluções: uso de *ensemble learning*; modelos da família YOLO; e múltiplas estratégias para aumento artificial de dados (Arya *et al.* 2020)



# Trabalhos Relacionados

- Solução campeã: Hedge *et al.* 2020
  - $F_1$ -Score de 0,67 em ambas as partições de teste
  - *Test Time Augmentation*
  - Comitê de redes YOLOv5
  - 3,08 FPS
  
- Baixo FPS em virtude do tamanho dos modelos e estratégias de previsão
- Não houve aferição quanto ao número de parâmetros das soluções propostas


# Agenda

- 1 Introdução
- 2 Trabalhos Resultados
- 3 Materiais e Métodos**
- 4 Resultados e Discussão
- 5 Estudo de Caso em Pavimentações Asfálticas no Brasil
- 6 Considerações Finais
- 7 Agradecimentos

# Materiais e Métodos

- Tarefa de detecção (localização e classificação) mediante Aprendizado Supervisionado com R-CNNs da família YOLO
- Dados Experimentais: RDD2020 (Aryal *et al.* 2021b)
  - Trincas longitudinais (D00)
  - Trincas transversais (D10)
  - Malha tipo “couro de jacaré” (D20)
  - Buracos (D40)

# Materiais e Métodos: Dados Experimentais




(a) Trinca longitudinal



(b) Trinca transversal

Figura 1: Exemplos de imagens da base de dados RD2020.

## Materiais e Métodos: Dados Experimentais



(a) Malha “couro de jacaré”



(b) Buraco

Figura 2: Exemplos de imagens da base de dados RD2020.

## Materiais e Métodos: Dados Experimentais




Figura 3: Base de dados RD2020 (21.041 imagens).

## Materiais e Métodos: Dados Experimentais




Figura 4: Dados experimentais após limpeza e pré-processamento (18.667 imagens).

## Materiais e Métodos: Modelos

- YOLO (*You Only Look Once*) (Redmond *et al.* 2016)
  - R-CNN *single-shot*
  - Muito utilizada em aplicações de detecção em tempo real (Miichelucci 2019)
- YOLOv4 (Bochkovskiy *et al.* 2020)
  - Novas abordagens de aumento artificial de dados, extração de características e regularização
  - Treinamento exclusivamente com aceleração em hardware via GPU
- YOLOv5 (Jocher *et al.* 2020)
  - Redução significativa na quantidade de pesos com melhorias na acurácia, velocidade de treinamento e inferência
  - Desenvolvida nativamente com Pytorch



# Materiais e Métodos: Parâmetros e Hiperparâmetros

- Transferência de aprendizados com pesos oriundos da base MS COCO
- Regularização com *early stopping*
- Arquitetura: YOLOv4:
  - Configuração 1. Tamanho do *batch*: 64; Tamanho máximo do *batch*: 4.000; Taxa de aprendizado:  $10^{-3}$ ; *Steps*: 6.400;
  - Configuração 2. Tamanho do *batch*: 64; Tamanho máximo do *batch*: 4.000; Taxa de aprendizado:  $10^{-2}$ ; *Steps*: 3.200;
- Arquitetura: YOLOv5:
  - Configuração 3. Tamanho da arquitetura: Pequeno; Tamanho do *batch*: 16; Taxa de aprendizado:  $10^{-2}$ ; *Épocas*: 300;
  - Configuração 4. Tamanho da arquitetura: Médio; Tamanho do *batch*: 16; Taxa de aprendizado:  $10^{-2}$ ; *Épocas*: 300;

# Avaliação de Desempenho

- Validação cruzada *holdout*
  - 70% para treinamento, 10% para validação e 20% para testes
  
- Métricas de desempenho:
  - Precisão
  - Revocação
  - $F_1$ -Score
  - *Mean Average Precision* (mAP@0.5)

# Agenda

- 1 Introdução
- 2 Trabalhos Resultados
- 3 Materiais e Métodos
- 4 Resultados e Discussão**
- 5 Estudo de Caso em Pavimentações Asfálticas no Brasil
- 6 Considerações Finais
- 7 Agradecimentos

# Resultados e Discussão

Tabela 1: Síntese dos resultados experimentais.

Métrica	YOLOv4		YOLOv5	
	Configuração 1	Configuração 2	Configuração 3	Configuração 4
Precisão	66,00 %	59,00 %	54,11 %	57,21 %
Revocação	18,00 %	22,00 %	52,28 %	52,08 %
F <sub>1</sub> -Score	28,00 %	32,00 %	53,18 %	54,53 %
<b>mAP@0.5</b>	31,27 %	31,43 %	50,70 %	53,19 %

## Resultados e Discussão




Figura 5: Matriz de confusão do teste da YOLOv5 Configuração 4.

## Resultados e Discussão

- ① Aquém da melhor solução na literatura, com decréscimo percentual de 18,61 % no  $F_1$ -Score
- ② Contorna as limitações no tocante ao tempo de previsão, com 64 FPS versus 3,08 FPS (aumento percentual de 1.977,92 %)
- ③ Possui significativamente menos parâmetros, uma vez que a solução de referência usa um comitê de 3 redes YOLOv5;
- ④ Treinada com significativamente menos exemplos (30 %) que a solução do estado da arte

# Agenda

- 1 Introdução
- 2 Trabalhos Resultados
- 3 Materiais e Métodos
- 4 Resultados e Discussão
- 5 Estudo de Caso em Pavimentações Asfálticas no Brasil**
- 6 Considerações Finais
- 7 Agradecimentos

# Estudo de Caso

- *Road Traversing Knowledge Dataset* (RTK dataset) (Rateke *et al.* 2019)



Figura 6: Exemplos do RTK *dataset* com rótulos de classes mapeados.



## Estudo de Caso

Tabela 2: Descrição estatística do pré-processamento do RTK *dataset*.

	Comprimento			Largura			Exemplos
	Média	Máx	Mín	Média	Máx	Mín	Quantidade
<b>Classe D00</b>	$43.27 \pm 26.06$	98	6	$33.61 \pm 21.17$	87	3	36
<b>Classe D10</b>	$18.76 \pm 21.00$	107	2	$42.24 \pm 47.70$	345	5	390
<b>Classe D40</b>	$13.92 \pm 10.11$	62	3	$34.52 \pm 17.38$	93	4	105

## Estudo de Caso

- Transferência de Aprendizado da YOLOv5 Configuração 4
- Validação cruzada *holdout*


## Estudo de Caso

- Transferência de Aprendizado da YOLOv5 Configuração 4
- Validação cruzada *holdout*

Tabela 3: Desempenho da rede na previsão de falhas em pavimentações asfálticas no Brasil.

	<b>Precisão</b>	<b>Revocação</b>	<b>F<sub>1</sub>-Score</b>	<b>mAP@0.5</b>
<b>Todas as Classes</b>	43,8 %	51,0 %	47,1 %	45,6 %
<b>Classe D00</b>	18,7 %	23,4 %	20,8 %	11,5 %
<b>Classe D10</b>	42,6 %	45,0 %	43,8 %	40,9 %
<b>Classe D40</b>	70,2 %	84,6 %	76,7 %	84,3 %

## Estudo de Caso



(a) Exemplo 1 – Desejado



(b) Exemplo 1 – Previsto

Figura 7: Exemplos de previsão do modelo no cenário brasileiro.

## Estudo de Caso



(a) Exemplo 2 – Desejado



(b) Exemplo 2 – Previsto

Figura 8: Exemplos de previsão do modelo no cenário brasileiro.

# Estudo de Caso

- Transferência de Aprendizado negativa
  - mAP@0.5 sofreu um decréscimo percentual de 14,25 % quando comparado aos resultados apresentados anteriormente
  - Baixa resolução das imagens
  - Baixo quantitativo de exemplos
  - Diferenças entre domínio de origem (RDD2020) e domínio alvo (RTK dataset)
  
- **Tarefa crucial:** Elaboração de bases de dados representativas do Brasil para esse problema

# Agenda

- 1 Introdução
- 2 Trabalhos Resultados
- 3 Materiais e Métodos
- 4 Resultados e Discussão
- 5 Estudo de Caso em Pavimentações Asfálticas no Brasil
- 6 Considerações Finais**
- 7 Agradecimentos

# Considerações Finais

- Resultados experimentais das R-CNNs YOLOv4 e YOLOv5 para detecção automática de falhas em pavimentações asfálticas
  - Contexto realístico
  - Colabora no monitoramento inteligente para soluções de transporte
  - Estudo de caso da solução proposta em um contexto realístico nacional
- **Trabalhos futuros**
  - Explorar mais estratégias de aumento de dados e ajuste fino de parâmetros
  - Necessidade de propor bases de dados para construir soluções inteligentes que fomentem a inspeção automática da qualidade da pavimentação asfáltica no Brasil



# Agenda

- 1 Introdução
- 2 Trabalhos Resultados
- 3 Materiais e Métodos
- 4 Resultados e Discussão
- 5 Estudo de Caso em Pavimentações Asfálticas no Brasil
- 6 Considerações Finais
- 7 Agradecimentos

## Agradecimentos

Os autores agradecem ao Laboratório de Sistemas Inteligentes da Universidade do Estado do Amazonas pela disponibilização dos recursos computacionais que viabilizaram a realização deste trabalho.



Grupo de Pesquisas em Sistemas Inteligentes  
Laboratório de Sistemas Inteligentes  
Escola Superior de Tecnologia  
Universidade do Estado do Amazonas



## *Detecção Inteligente de Falhas em Pavimentações Asfálticas com Redes Neurais Convolucionais Regionais*

**Rafael Barbosa de Carvalho, Elloá B. Guedes, Carlos Maurício S. Figueiredo**

*{rbc.eng, ebgcosta, cfigueiredo}@uea.edu.br*

*III Workshop Brasileiro de Cidades Inteligentes*

*CSBC 2022 – Niterói – Rio de Janeiro*