



# Além do Desempenho: Um Estudo da Confiabilidade de Detectores de Deepfakes



Lucas Lopes, Rayson Laroca, André Gregio



Universidade Federal do Paraná  
Pontifícia Universidade Católica do Paraná

# Motivação



World / Asia

## Finance worker pays out \$25 million after video call with deepfake 'chief financial officer'


By Heather Chen and Kathleen Magramo, CNN  
2 min read · Published 2:31 AM EST, Sun February 4, 2024

Facebook X Email Print



# Fundamentação

## Geração de Deepfakes



# Fundamentação

## Métodos de Detecção

1



Inconsistências  
Físicas

2



Aprendizado  
por Dados

3




Detecção de  
Artefatos

4





Métodos  
Híbridos

# Desafios



# Solução Proposta



# Solução Proposta

## Transferibilidade

$$T = \frac{1}{N} \sum_{i=1}^N \text{Score}_{\text{cross}}(i)$$

AUC ou ACC  
obtida em cada  
dataset não visto

Número de  
datasets não  
vistos

# Solução Proposta

## Robustez

$$R = \frac{1}{3} \left( \frac{1}{C} \sum_{i=1}^C \text{Score}_{\text{comp}}(i) + \frac{1}{P} \sum_{j=1}^P \text{Score}_{\text{perturb}}(j) + \frac{1}{A} \sum_{k=1}^A \text{Score}_{\text{adv}}(k) \right)$$

Número de testes  
de perturbação

Número de testes  
de compressão

Número de testes  
com ataques  
adversários

# Solução Proposta

## Interpretabilidade

Critério	Valor	Descrição
Nenhuma explicação	0,0	Modelo “caixa-preta”, sem qualquer visualização ou justificativa
Visualizações básicas	0,3 – 0,5	Uso de técnicas como Grad-CAM (mapas de saliência) ou t-SNE, sem análise crítica
Análises interpretativas	0,6 – 0,8	Aplicação de métodos como LIME ou SHAP, com explicações baseadas em atributos.
Explicabilidade integrada	0,9 – 1,0	Mecanismos explicativos integrados ao modelo

# Solução Proposta

## Eficiência Computacional

$$E = \begin{cases} 1.0, & \text{se } P < 10^7 \\ 0.8, & \text{se } 10^7 \leq P < 5 \times 10^7 \\ 0.6, & \text{se } 5 \times 10^7 \leq P < 10^8 \\ 0.4, & \text{se } 10^8 \leq P < 3 \times 10^8 \\ 0.2, & \text{se } 3 \times 10^8 \leq P < 10^9 \\ 0.0, & \text{se } P \geq 10^9 \end{cases}$$

Número de  
parâmetros  
utilizados na etapa  
de inferência

# Resultados

Aplicação do framework no estado da arte:

SCLoRA



OSDFD e CFM



FrePGAN



TruthLens



# Resultados

## Robustez dos métodos

Método	Métrica	Score (comp)	Score (perturb)	Score (adv)	Robustez (R)
SCLoRA	AUC	0,70	0,00	0,00	0,23
OSDFD	AUC	0,79	0,87	0,00	0,55
CFM	AUC	0,93	0,80	0,00	0,58
FrePGAN	Acurácia	<b>0,99</b>	<b>0,97</b>	0,00	<b>0,65</b>
TruthLens	Acurácia	0,94	0,00	0,00	0,31

# Resultados: Avaliação

## Avaliação de Confiabilidade

T = Transferibilidade  
R = Robustez  
I = Interpretabilidade  
E = Eficiência Comp.

Método	Métrica	T	R	I	E	SCG
OSDFD	AUC	0,82	0,55	0,62	0,62	0,62
SCLoRA	AUC	0,72	0,23	0,20	0,60	0,44
CFM	AUC	0,84	0,58	0,50	<b>0,80</b>	<b>0,68</b>
FrePGAN	Acurácia	0,76	<b>0,65</b>	0,30	0,58	0,57
TruthLens	Acurácia	<b>0,94</b>	0,31	<b>1,00</b>	0,00	0,56

$$SCG = \frac{1}{4} (T + R + I + E)$$

# Considerações finais

- Transferibilidade ainda limitada entre domínios distintos
- Robustez pouco explorada (para ataques adversários)
- Interpretabilidade pouco acessível
- Trade-off entre desempenho e custo computacional

# Trabalhos futuros

- Expandir análise para mais detectores
- Focar em interpretabilidade e eficiência
- Desenvolvimento de um detector orientado às métricas de confiabilidade

- Lucas Lopes, Rayson Laroca, André Grégio
- [lopes.lucas@ufpr.br](mailto:lopes.lucas@ufpr.br)

