

Investigação Preliminar do Aprendizado Profundo Aplicado ao Teste de Van de Castelele nas estações Maregráficas da RMPG



United Nations BigData

UNBigDataRegional Hub in Brazil

IBGE

WEBINÁRIO:
INDICADORES DE DESENVOLVIMENTO SUSTENTÁVEL
Aplicações de Inteligência Artificial no IBGE: Aprendizado Profundo em Dados Maregráficos e Codificação Automatizada

10 de fevereiro
11 horas (UTC - 3)
Transmissão em português
Legendas em espanhol e inglês

PALESTRANTES:
Arthur Beltrão
IBGE
Everton Gomes
IBGE


Inscreva-se em:
<https://hub.ibge.gov.br>

Equipe:

- **Salomão Soares**
- **Luiz Fernando Reinheimer**
- **Everton Gomes dos Santos (apresentação)**

Introdução

 O Teste de Van de Castele (TVC) -> qualidade das observações maregráficas.

 Função principal: identificar possíveis **erros sistemáticos**.

Deriva
instrumental

Discrepâncias
de escala

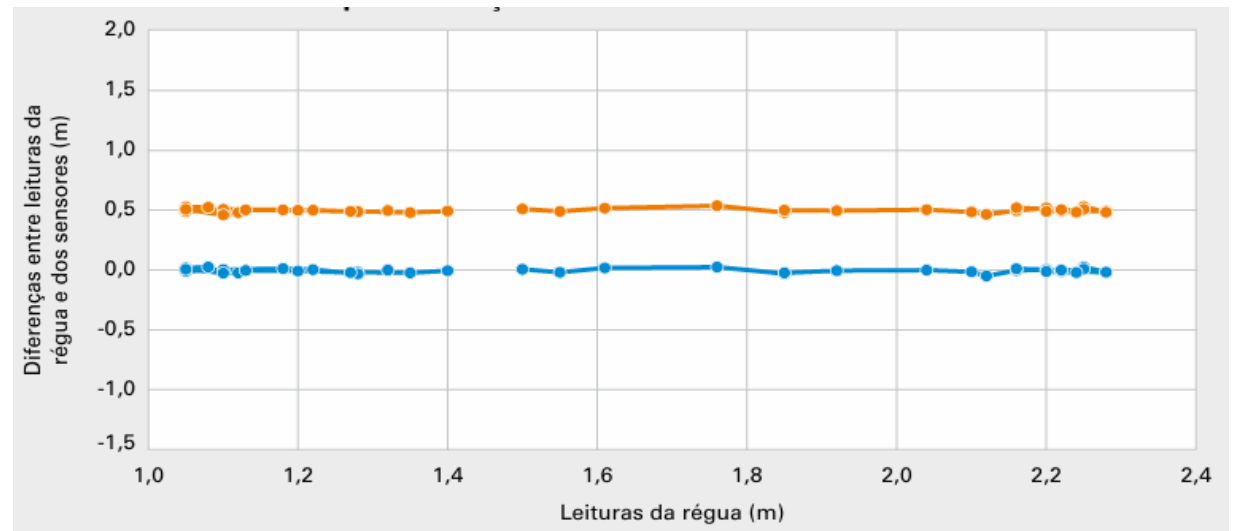
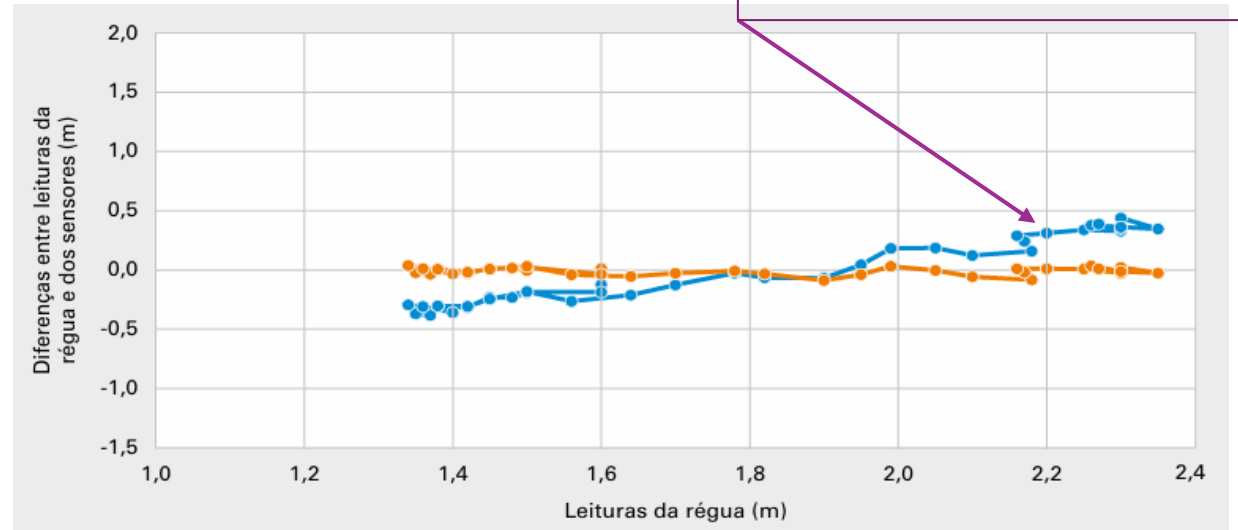
Mau
funcionamento
dos sensores

Elementos que podem comprometer a acurácia das medições do nível do mar.

Introdução



Introdução



Problema

Necessidade de observadores experientes.

Repetição contínua de leituras.

Dependência de condições ambientais favoráveis.

Tornam o método oneroso e frequentemente subutilizado.

Erros instrumentais identificados tardiamente, quando já impactaram as séries temporais.



Como tornar esse método eficiente?



Objetivo



Analisar as potencialidades do aprendizado profundo na detecção e determinação automática de valores métricos da régua de maré obtidos por meio de câmera fotográfica de baixo custo.

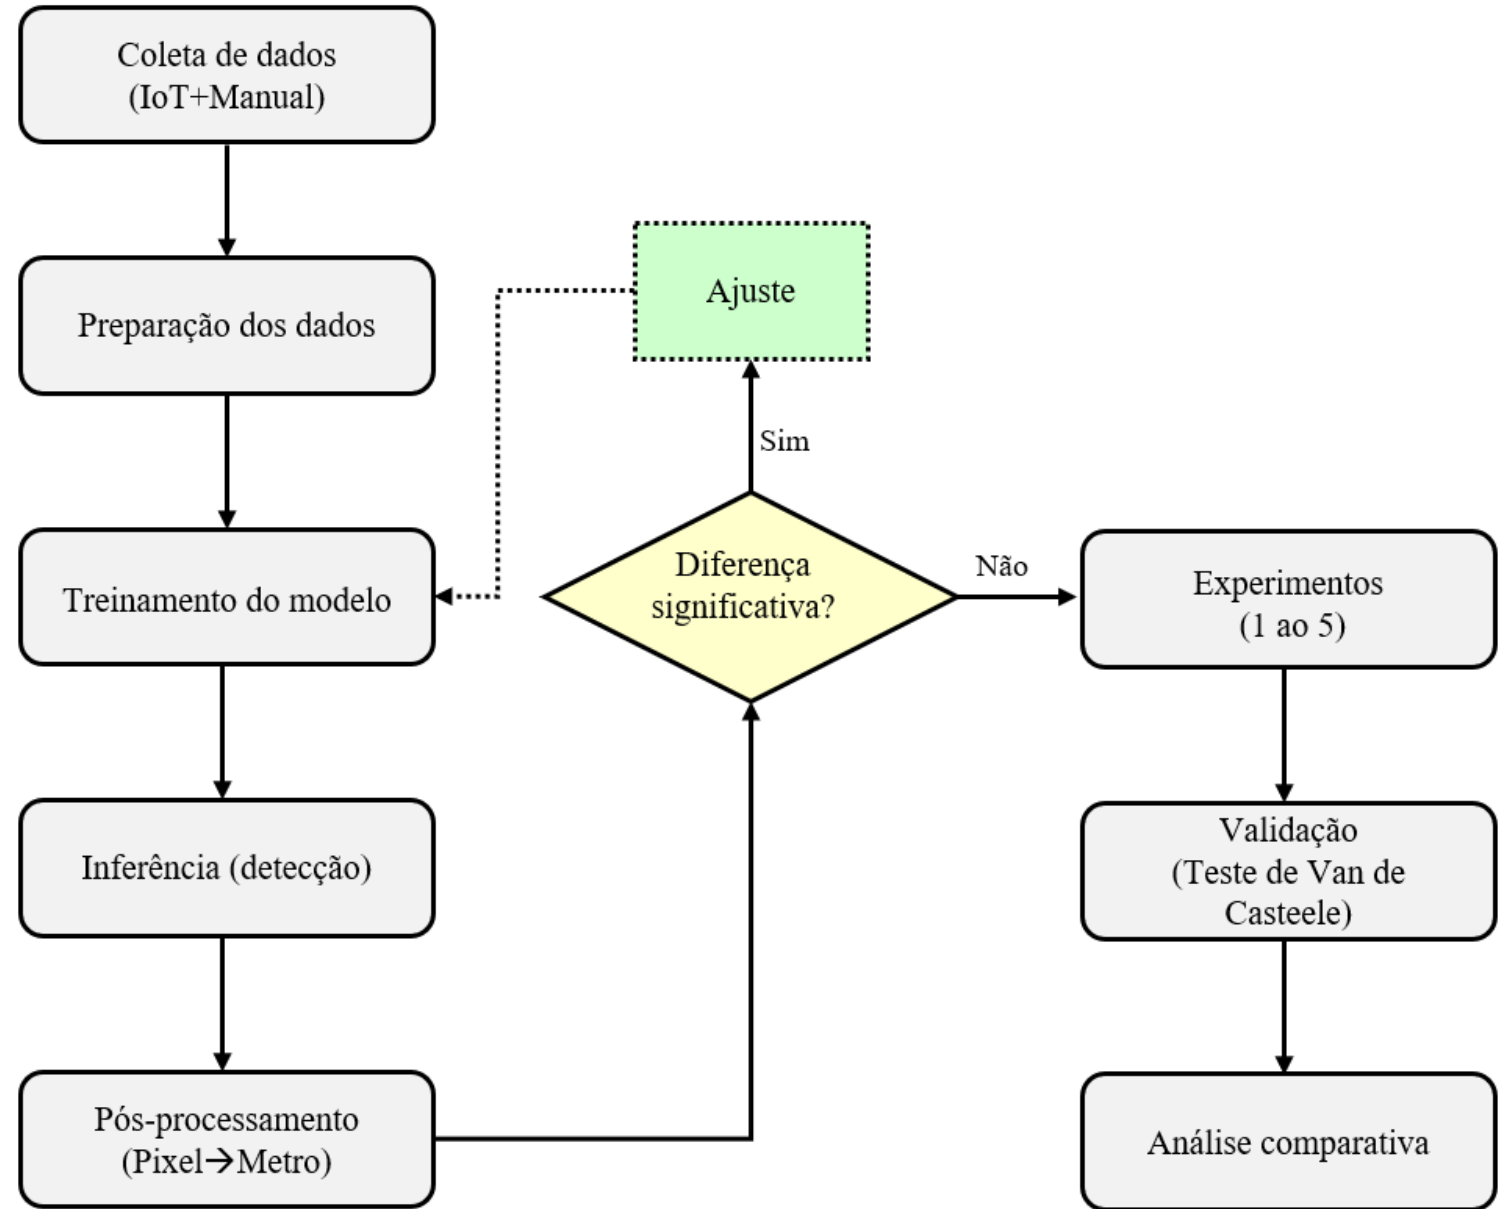
Metodologia

- Estação Maregráfica de Arraial do Cabo-RJ



Metodologia

- Fluxo



Metodologia

- Coleta de dados



a) Câmeras ESP32 CAM. b) Detalhe da instalação das câmeras c) Local de instalação das câmeras e do painel solar. d) Visão panorâmica do esquema de captura de imagens com destaque em vermelho.

- 1º Etapa: imagens a cada **5** minutos
- 2º Etapa: imagens a cada **2** minutos

Metodologia

- Preparação do conjunto de dados




Treinamento	Validação	TVC	Total
72	41	125	238



Diferentes condições de iluminação

Metodologia

- Preparação do conjunto de dados

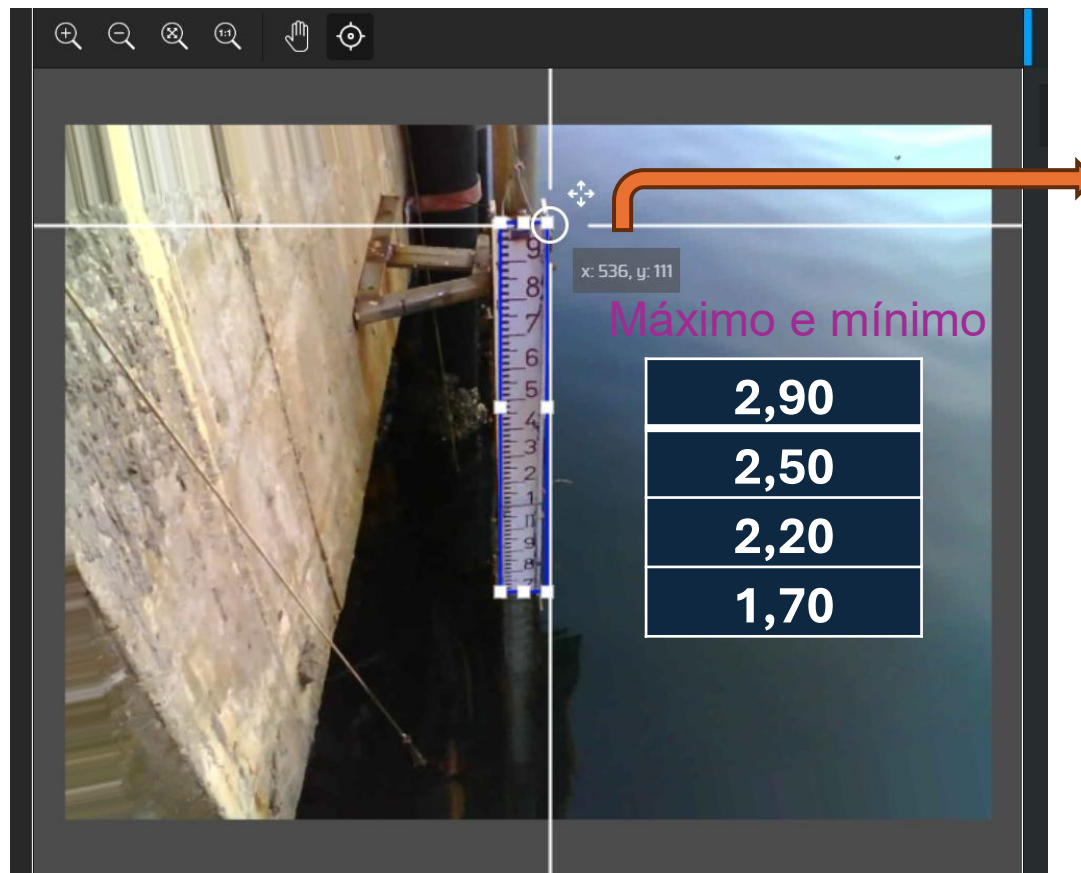


Exemplo de foto obtida pela câmera e preparação no *software* Make Sense

<https://www.makesense.ai/>

Metodologia

- Preparação do conjunto de dados



x: 536, y: 109



A	B	C	D	E	F	G	H	I	J	K
HH:00	dd/mm/yyyy	lmg	X1 (2.90m)	Y1 (2.90m)	X2 (2.50m)	Y2 (2.50m)	X3 (2.20m)	Y3 (2.20m)	X4 (1.70m)	Y4 (1.70m)
16:40:00	26/03/2025		512	146	509	300	508	391	507	511
16:45:00	26/03/2025		512	146	510	300	509	391	509	512
16:50:00	26/03/2025		511	146	510	300	510	391	509	512
16:55:00	26/03/2025		511	146	509	300	509	391	507	512
17:00:00	26/03/2025		511	146	511	300	508	391	508	512
17:05:00	26/03/2025		511	146	508	300	508	391	508	511

Metodologia


- Determinação da função de conversão de valores

Função polinomial de segundo grau.

$$f(x) = ax^2 + bx + c$$

Na qual, a, b e c são os coeficientes, ou seja, as constantes e x nesse trabalho representou o valor da caixa delimitadora inferior de cada imagem.

Relação de escala entre a régua e a imagem.



Medidas da régua de maré (m)	Y (pxl)
2,90	145,38
2,50	298,72
2,20	390,43
1,70	510,94

Metodologia

- Aprendizado profundo com **YOLO** (*You Only Look Once*)

- O aprendizado profundo destaca-se por avanços em classificação de imagens, detecção de objetos e PLN.
- Detectores de objetos podem operar em dois estágios (R-CNN, Fast/Faster R-CNN) ou em estágio único (YOLO, SSD, RetinaNet).
- Detectores de etapa única integram localização e classificação em uma única rede, oferecendo maior rapidez.
- A detecção em tempo real tornou-se essencial em áreas como veículos autônomos, robótica e vigilância.
- O trabalho utiliza o **YOLOv8-n**, variante leve e eficiente em PyTorch, adequada para aplicações em tempo real e dispositivos com recursos limitados.

Uma matriz de confusão compara o rótulo de classe real com o rótulo de classe previsto usando as imagens de teste.

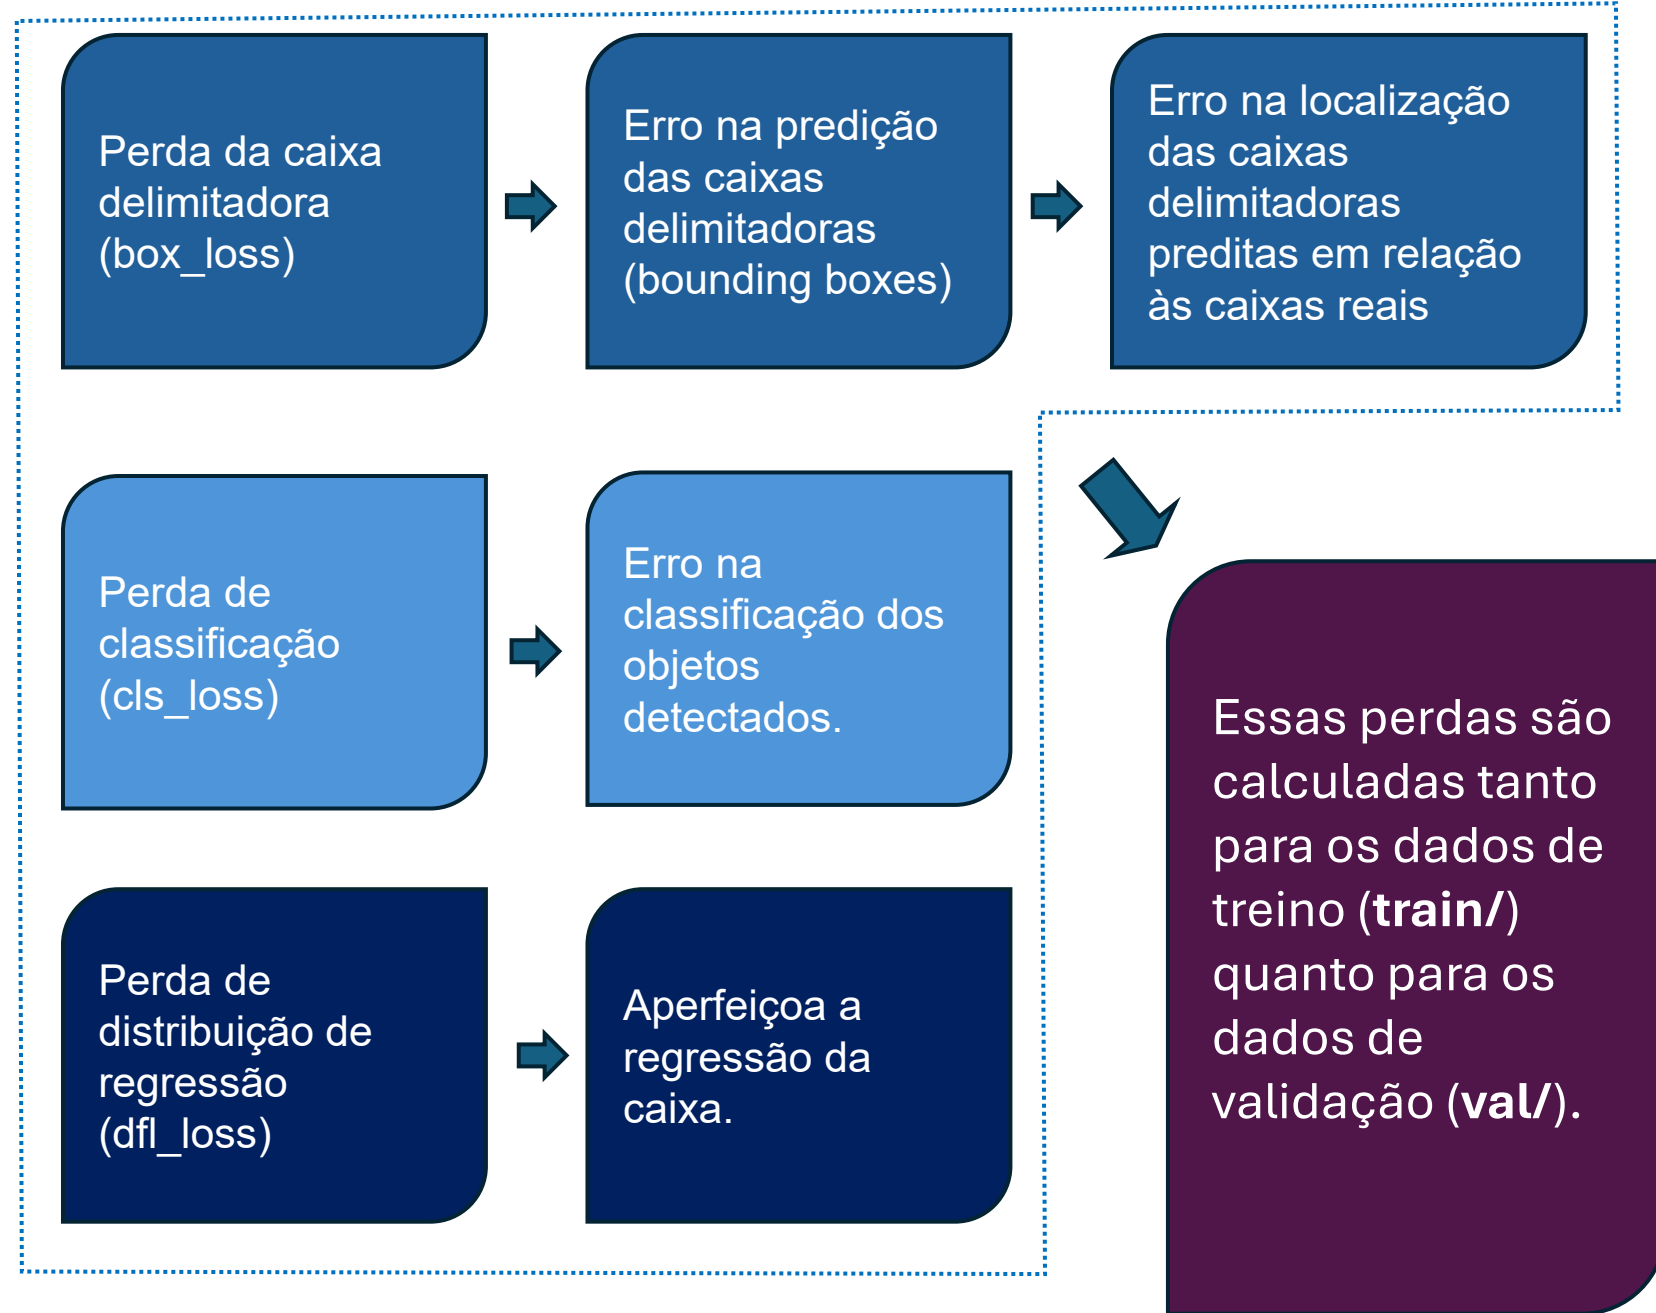
Metodologia

- Matriz de Confusão

Predito	Real Positivo	Real Negativo
Positivo	TP	FP
Negativo	FN	TN

Metodologia

- Parâmetros de erro de treinamento e validação



Metodologia

- Métricas de Avaliação

TP = True Positive
FP = False Positive
FN = False Negative
AP = Average Precision

mAP50 = IoU > 0,5
mAP50-95 = IoU 0,5 a 0,95

**Intersecção sobre União
(Intersection over Union –
IoU)**

$$IoU = \frac{\text{Área da Interseção}}{\text{Área da União}}$$

Precisão (Precision)

$$Precision = \frac{TP}{TP + FP}$$

Recuperação (Recall)

$$Recall = \frac{TP}{TP + FN}$$

**Média das precisões médias
(mean Average Precision – mAP)**

$$AP = \sum_n (Recall_n - Recall_{n-1}) \cdot Precision_n$$

$$mAP = \frac{1}{N} \sum_{i=1}^n AP_i$$

Avaliar se a diferença média encontrada entre as duas amostras é relevante.
Aplicação do teste t de **Student**.

Metodologia

- Avaliação estatística

S_1 = Desvio padrão

n_1 = tamanho da amostra

\bar{x} = médias amostrais

Erro padrão combinado

$$EP_c = \sqrt{\frac{S_1}{n_1} + \frac{S_2}{n_2}}$$

Teste t de Student

$$t = \frac{|\bar{x}_1 - \bar{x}_2|}{EP_c}$$

Graus de liberdade

$$GL = n_1 + n_2 - 2$$

Metodologia

- Processamento

Script em linguagem Python


Google colab

 YOLOv8

Resultados

Matriz de confusão

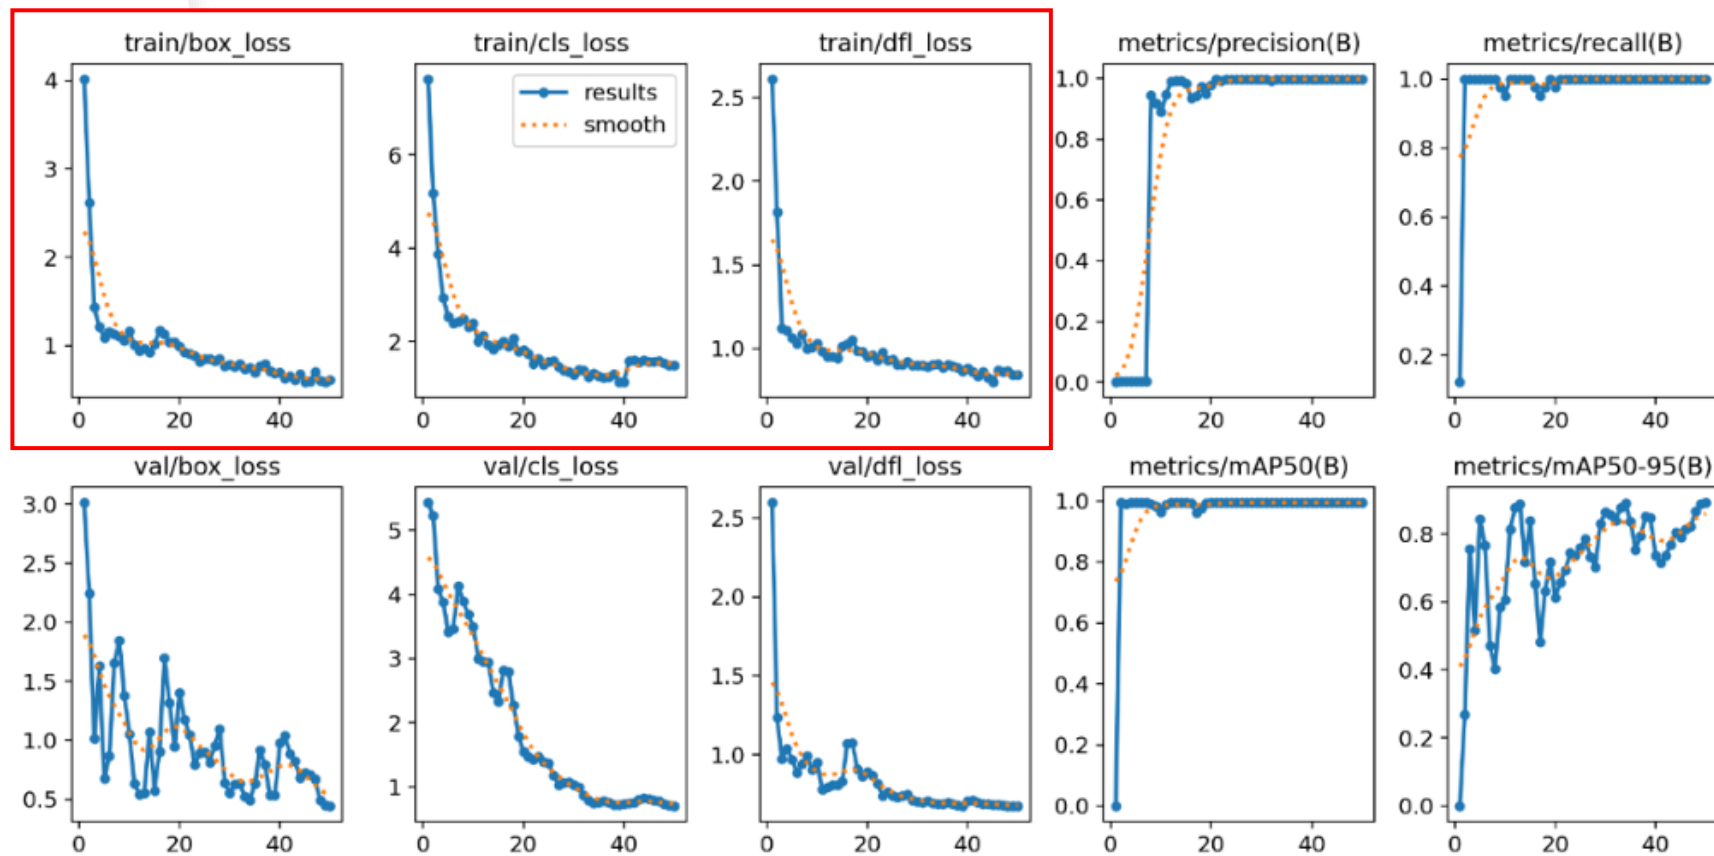
Verdadeiro/Predito	Régua de maré	Fundo
Positivo	41	0
Negativo	0	0



Resumos gráficos do treinamento e validação

Resultados

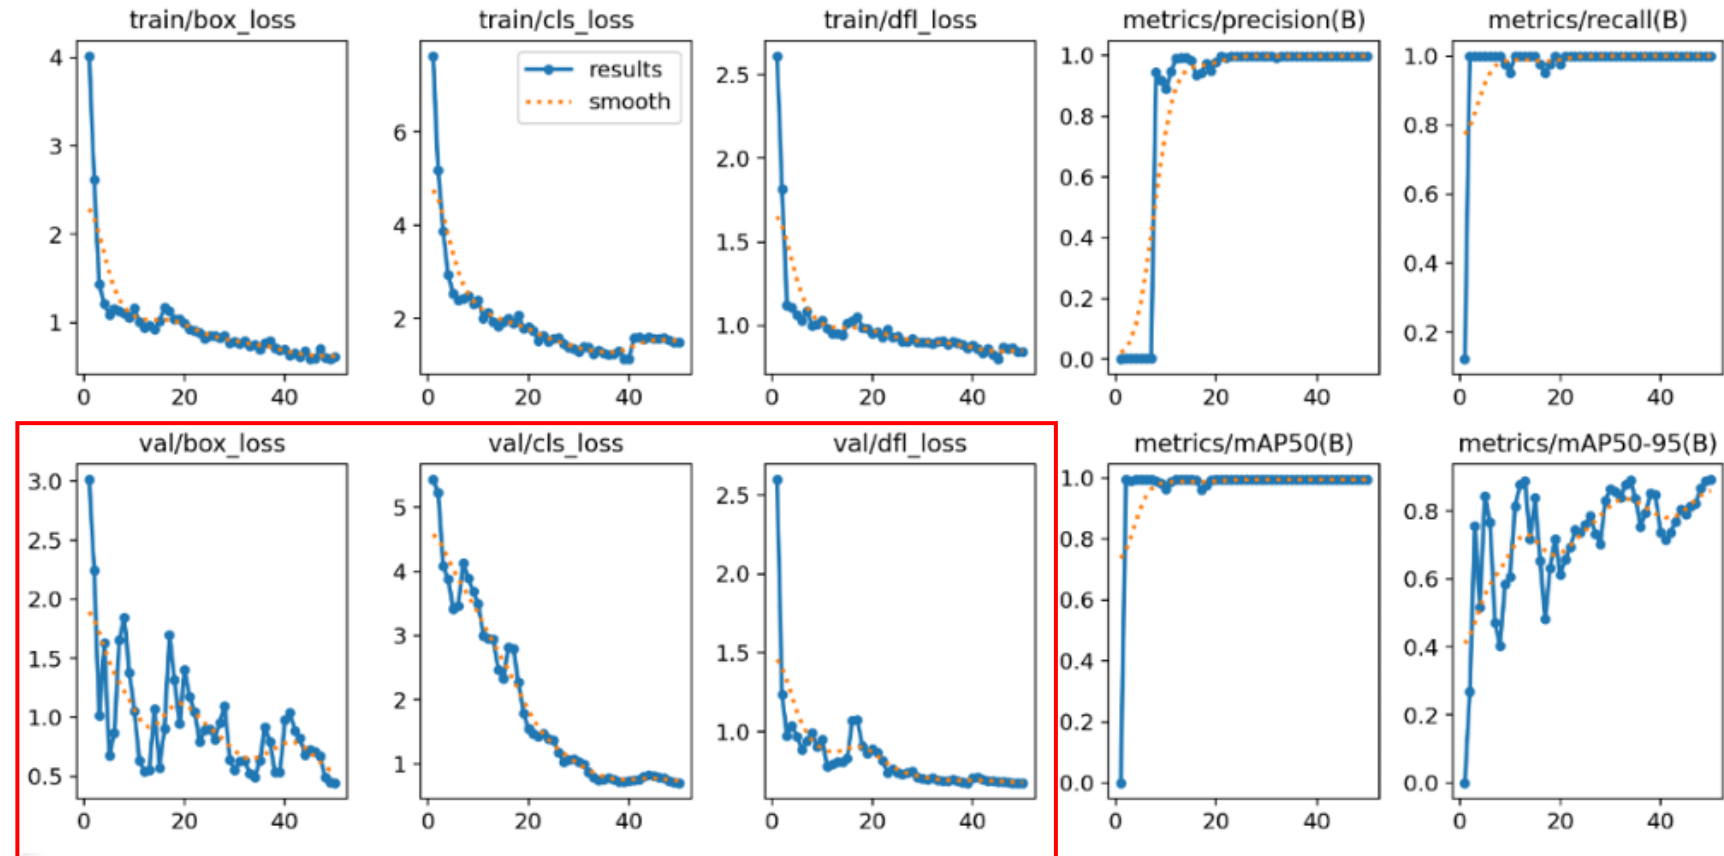
Redução progressiva e estável. Aprendizado consistente do modelo.



Resumos gráficos do treinamento e validação

Maior variabilidade, porém com declínio geral.
Demonstra capacidade de generalização.

Resultados

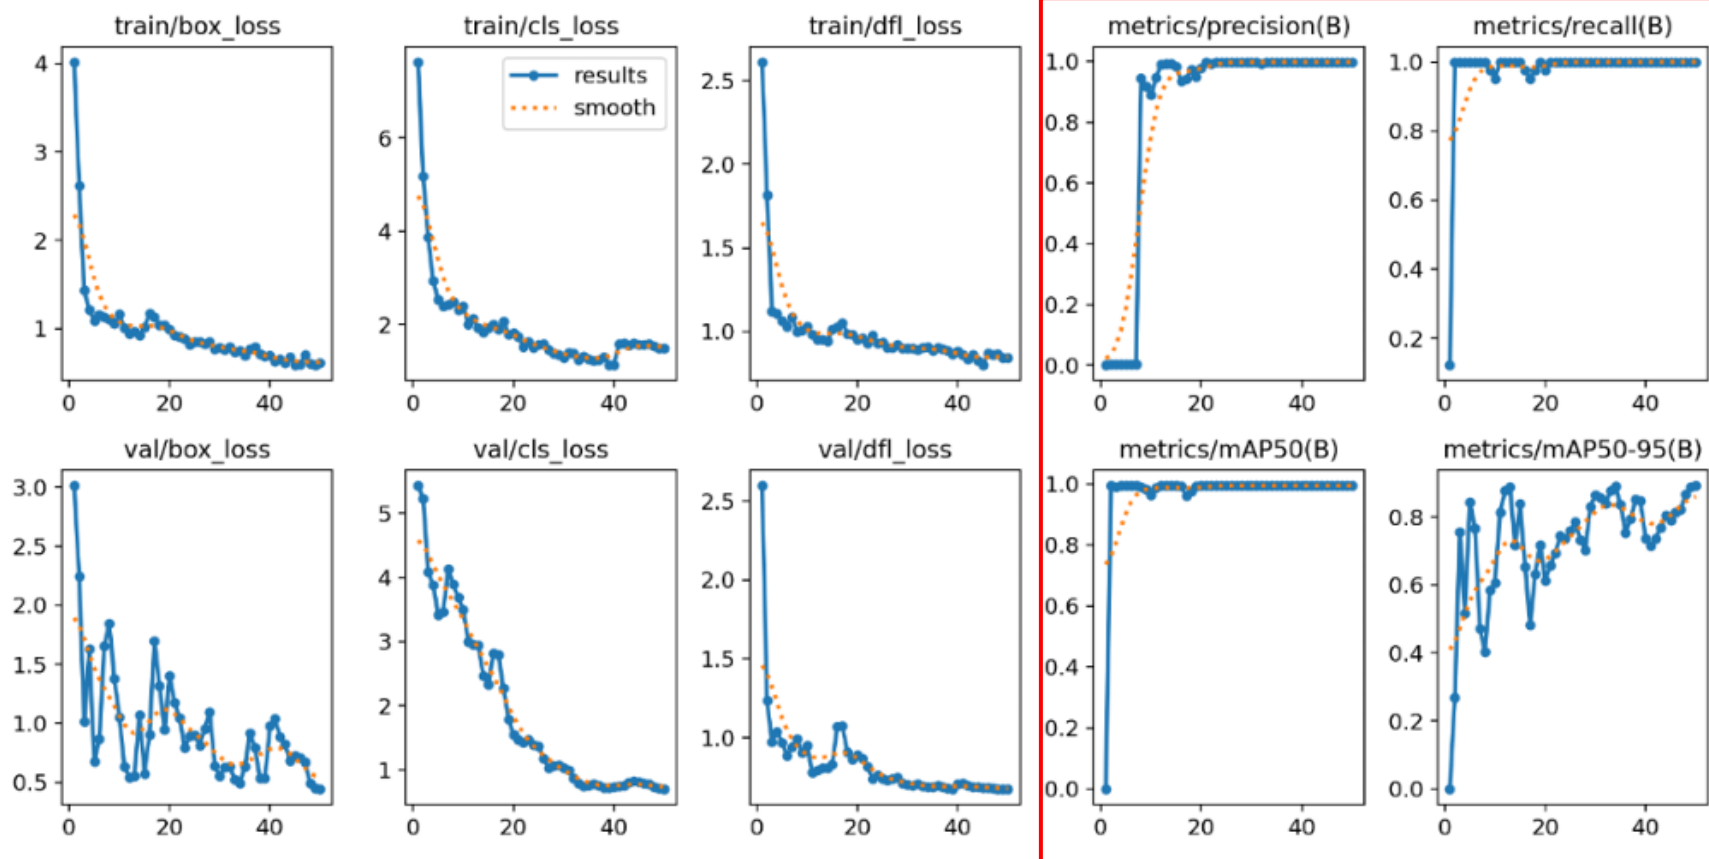


Resumos gráficos do treinamento e validação

Precisão: baixas taxas de falsos positivos e falsos negativos.

mAP50 = **0,995**; mAP50-95 = **0,088** :
desempenho robusto.

Resultados



Resultados

Resumo estatístico

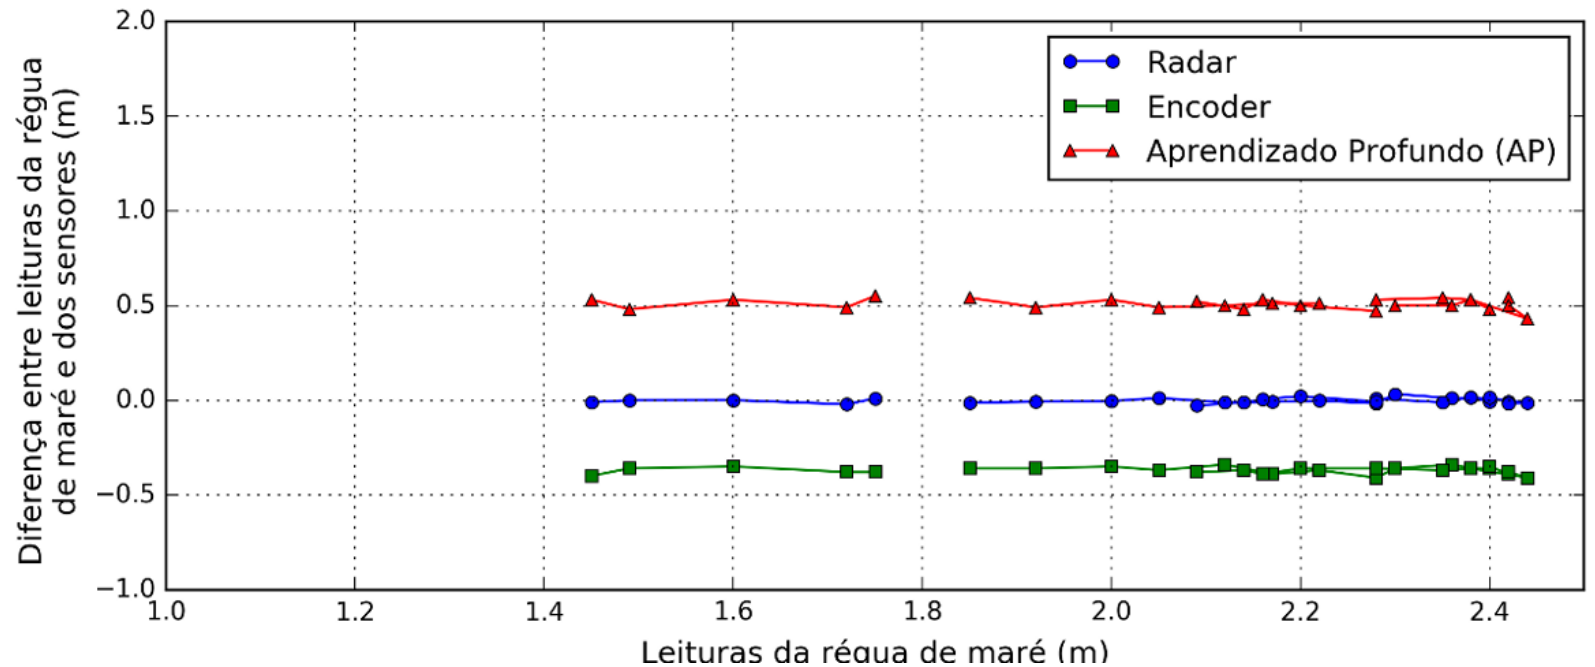
Estatística	Observações gabinete (m)	Aprendizado profundo (m)
Média	2,14	2,15
Erro Padrão	0,02	0,02
Desvio Padrão	0,26	0,26
Mínimo	1,40	1,43
Máximo	2,46	2,49

Resultados

Experimento, utilizando valores de **campo** do TVC.

Desvio padrão

- **Aprendizado profundo** = 0,027m
- **Sensor radar** = 0,014 m
- **Sensor encoder** = 0,019 m.



Resultados

2º Etapa (em andamento)

Experimentos

Avaliação de modelos em condições de amostragem temporal variada com validação metrológica pelo *Teste de Van de Castele* (27 de março de 2025).



Experimento 1 Linha de Base

- Imagens a cada 5 minutos Dias 26 e 27 de março
- 50 épocas

86 Imagens do dia 27



Experimento 2 Mudança de Intervalo

- Capturas a cada 2 minutos Dias 26 e 27 de março
- Pesos do Exp. 1

363 Imagens do dia 27



Experimento 3 Dados Mistos

- Imagens de 2 e 5 minutos Câmeras 1 e 2
- 100 épocas

317 Imagens do dia 27



Experimento 4 Somente 2 Minutos

- Apenas intervalos de 2 minutos Dias 26 e 27 de março
- 100 épocas

226 Imagens do dia 27



Experimento 5 Dia Único

- Apenas Imagens do dia 27 Treino e teste em 2 minutos
- 100 épocas

67 Imagens do dia 27



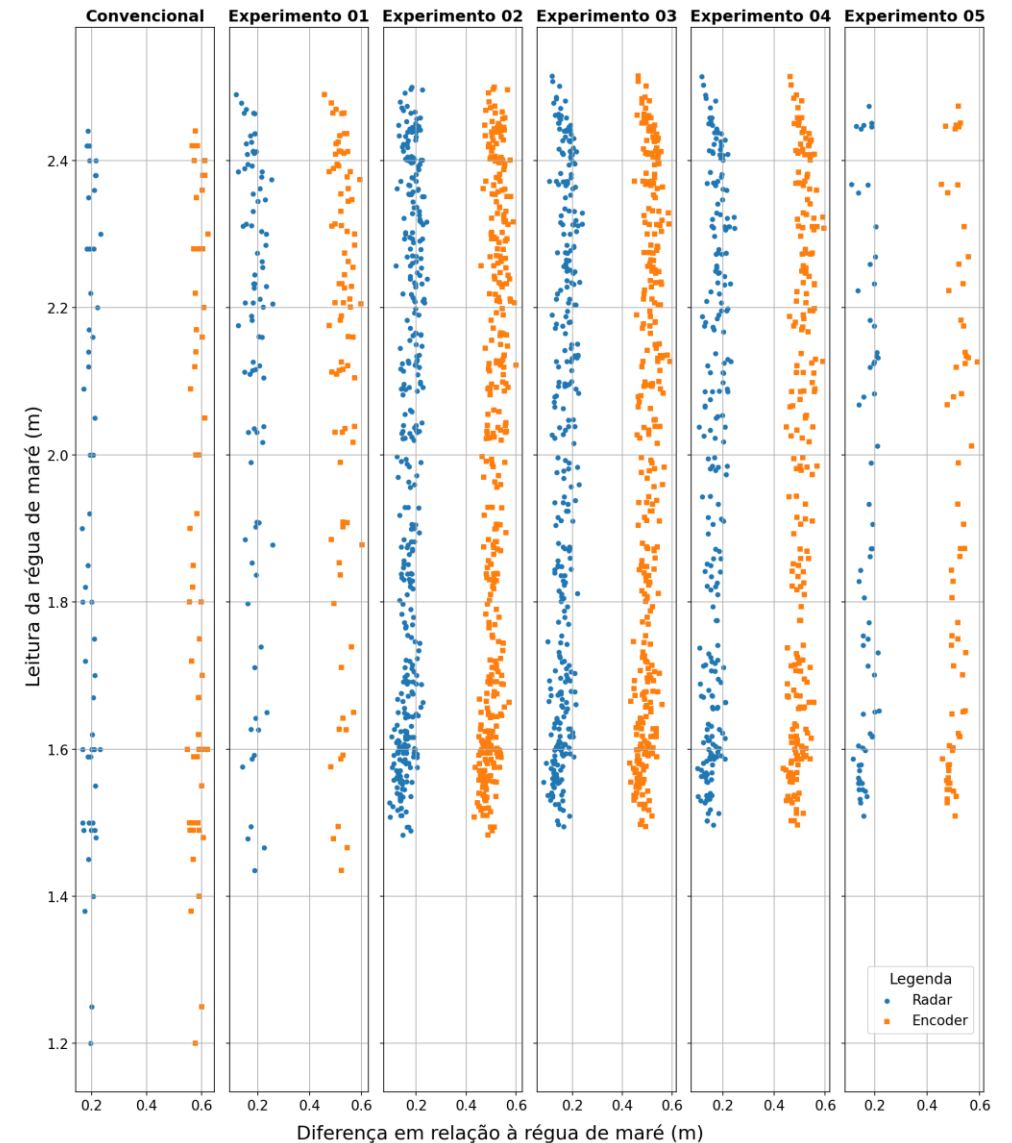
Análise Metrológica: Teste de Van de Castele

Resultados

2º Etapa (em andamento)

Aprendizado profundo X Sensores (radar e encoder)

Estatística	Convencional		Experimento 1		Experimento 2		Experimento 3		Experimento 4		Experimento 5	
	RAD	ENC	RAD	ENC	RAD	ENC	RAD	ENC	RAD	ENC	RAD	ENC
Média	0,00	0,84	-0,01	0,83	-0,03	0,81	-0,04	0,81	-0,03	0,81	-0,03	0,81
DP	0,02	0,02	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03



Conclusões

- 💡 O uso de aprendizado profundo no Teste de Van de Castele mostra alto potencial para modernizar o controle de qualidade de estações maregráficas.
- 🔧 O modelo automático apresentou alta precisão, recall e mAP, com treinamento estável.
- ☀️ Houve forte concordância entre os valores do modelo e os obtidos em gabinete, reforçando a confiabilidade do método.
- ✨ A abordagem permite transformar o TVC em um processo contínuo e proativo, reduzindo perdas de dados e aumentando a eficiência no monitoramento.

Conclusões



Próxima etapa...

Em andamento

- Foi desenvolvida uma câmera com melhor resolução e automatizada remotamente.
- Realizada uma coleta de 5 dias contínuos (cerca de 1500 imagens).
- Duas coletas realizadas por observador.
- 3 sensores radar funcionando simultaneamente no período.

Objetivo

- Fazer um treinamento mais robusto
- Consolidar a técnica
- Aplicar em todas as estações da RMPG



Obrigado!

-
- **Equipe:**
 - **Salomão Soares**
 - **Luiz Fernando Reinheimer**
 - **Everton Gomes dos Santos**