



Workshop em Computação Aplicada 2024

Classificação de Inundações no Rio Grande do Sul Utilizando TempCNN em Série Temporal de Imagens do Sentinel-2

Cesar Augusto de Moraes Costa¹
Thales Sehn Körting¹

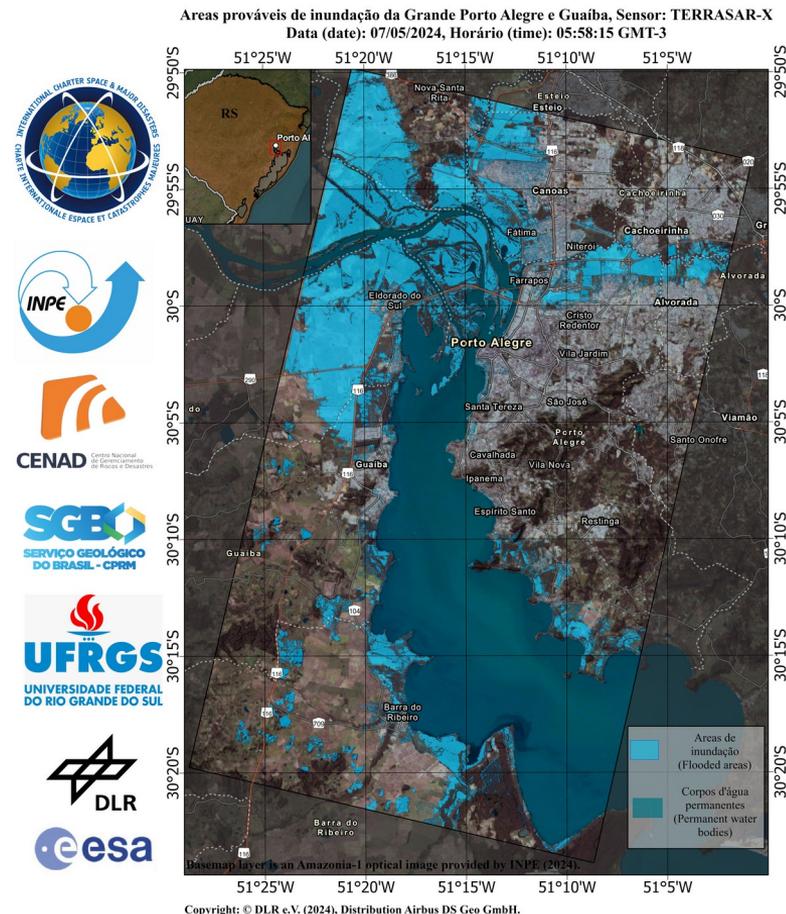
**COMPUTAÇÃO
APLICADA**

1. Instituto Nacional de Pesquisas Espaciais, SP- Brasil



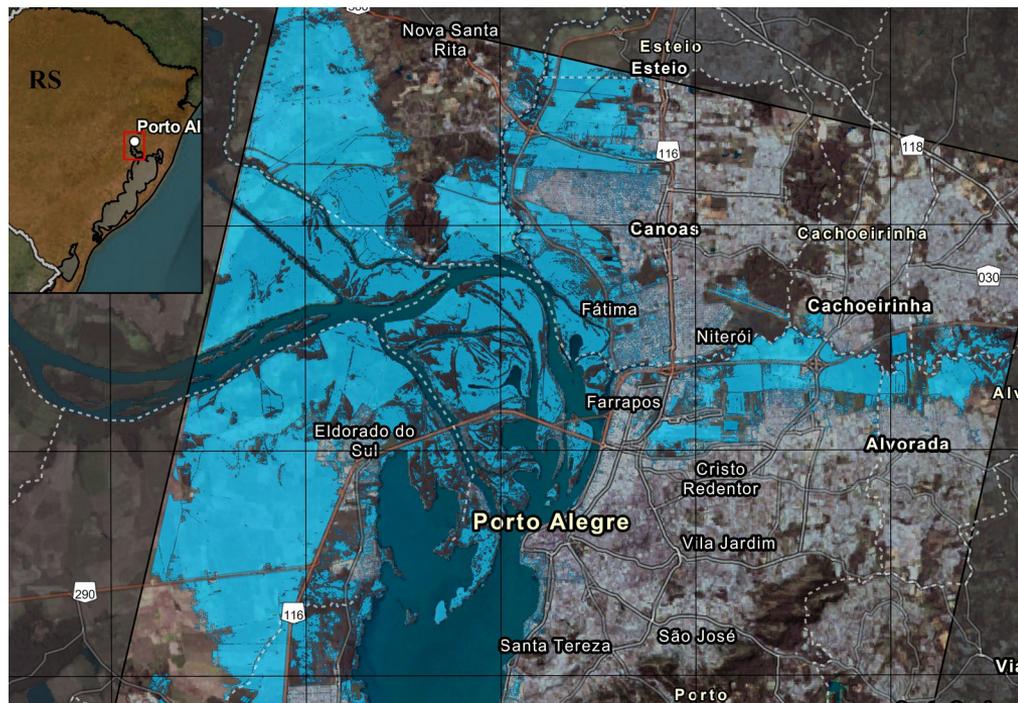
Introdução

As imagens de Sensoriamento Remoto tornaram-se essenciais para o monitoramento de desastres ambientais, permitindo respostas rápidas para resgate de vidas auxiliando órgãos competentes e agências humanitária.



Introdução

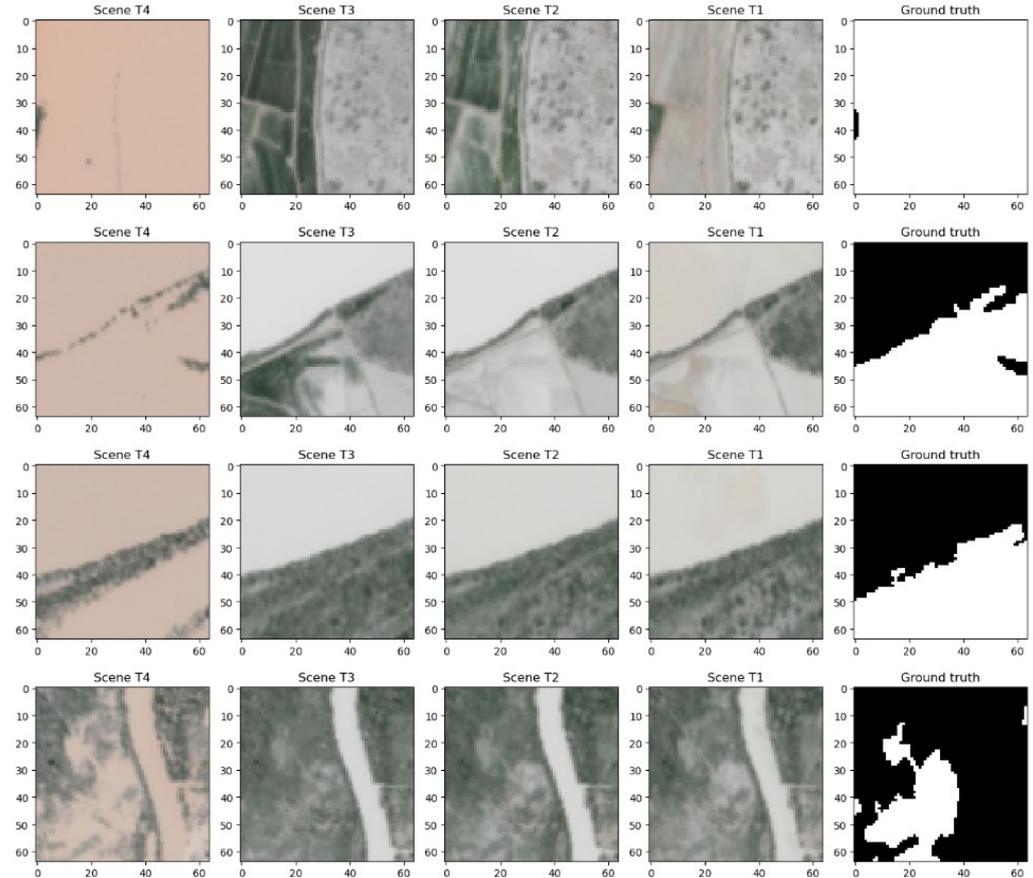
O objetivo do trabalho é classificar o evento de inundação ocorrido no Rio Grande do Sul utilizando a Rede Neural Convolucional Temporal (TempCNN).



Análise dos dados

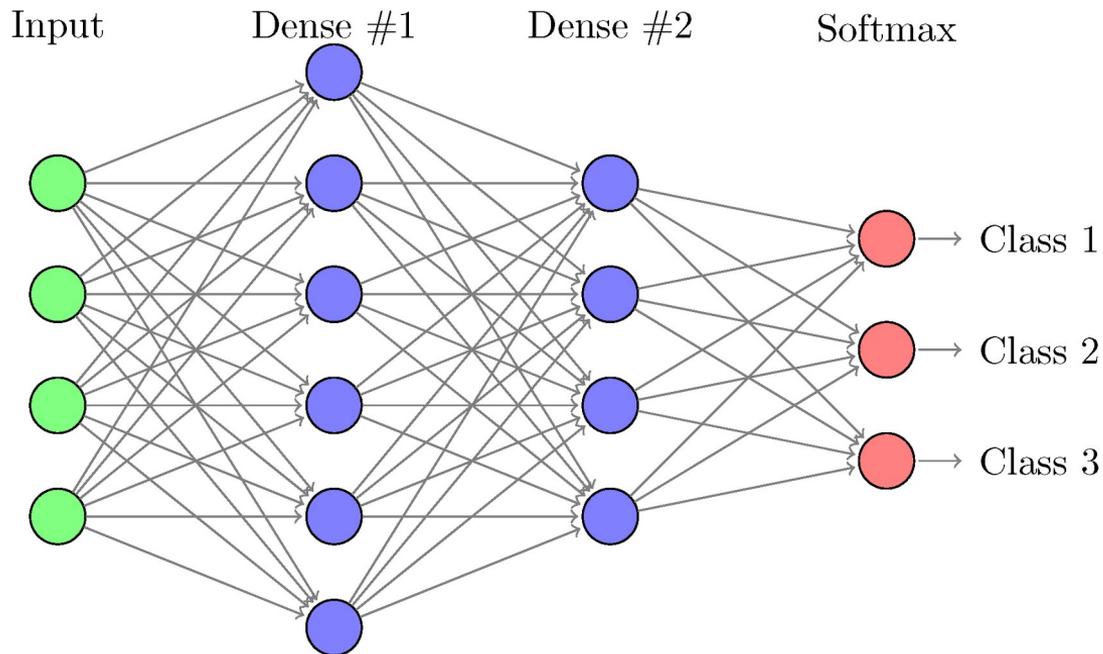
▶ Imagens multiespectrais do satélite Sentinel-2, com bandas BGR-NIR de resolução espacial de 10 metros

▶ Conjunto de dados de imagens de 4 tempos e bitemporais com *patches* de dimensões de 64 px x 64 px



Justificativa do Uso da Técnica

- ▶ Técnicas tradicionais de análise de imagens podem não capturar eficientemente a evolução temporal



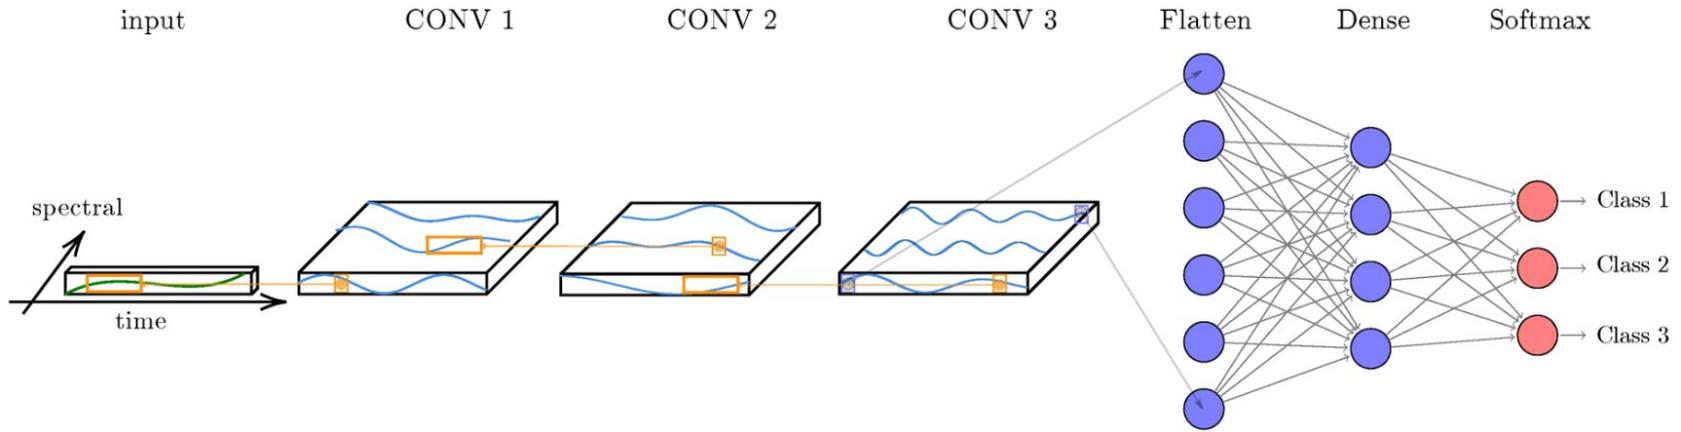
Rede Neural Totalmente Conectada [Pelletier et al., 2019].

Ambiente de Desenvolvimento

- ▶ Utilização de Python com bibliotecas como TensorFlow/Keras para o desenvolvimento da TempCNN
- ▶ Ambiente Local com uso de GPU [GeForce RTX 3050 Mobile 4GB] e RAM 16GB para acelerar o treinamento e inferência do modelo

Arquitetura TempCNN

- ▶ A arquitetura é composta por três camadas convolucionais (64 unidades), uma camada densa (256 unidades) e uma camada Softmax

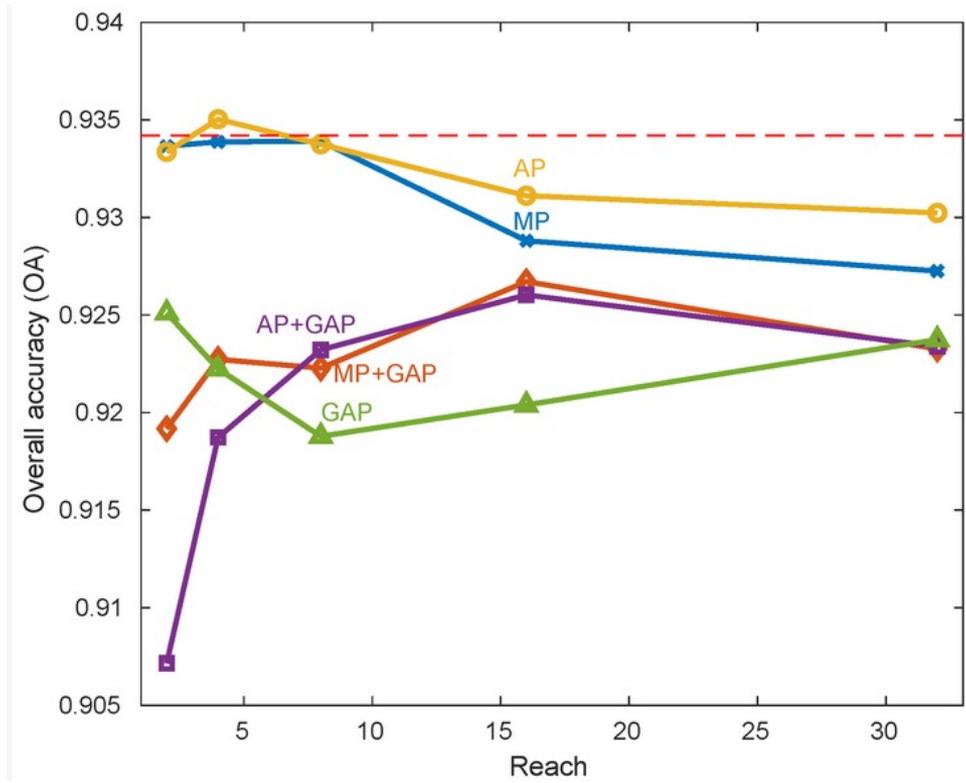


Arquitetura TempCNN [Pelletier et al., 2019].

Arquitetura TempCNN

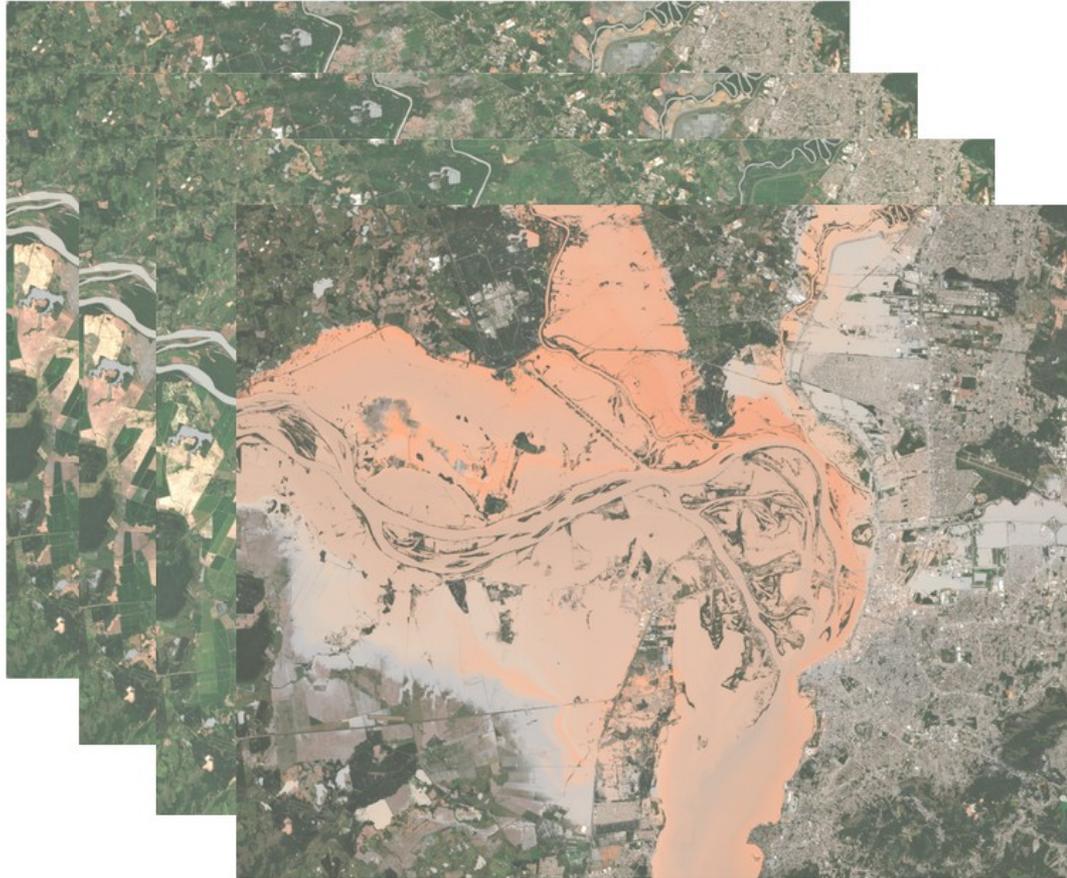
Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 1, 64, 64, 16)	0
conv3d (Conv3D)	(None, 1, 64, 64, 64)	27,712
batch_normalization (BatchNormalization)	(None, 1, 64, 64, 64)	256
activation (Activation)	(None, 1, 64, 64, 64)	0
dropout (Dropout)	(None, 1, 64, 64, 64)	0
conv3d_1 (Conv3D)	(None, 1, 64, 64, 64)	110,656
batch_normalization_1 (BatchNormalization)	(None, 1, 64, 64, 64)	256
activation_1 (Activation)	(None, 1, 64, 64, 64)	0
dropout_1 (Dropout)	(None, 1, 64, 64, 64)	0
conv3d_2 (Conv3D)	(None, 1, 64, 64, 64)	110,656
batch_normalization_2 (BatchNormalization)	(None, 1, 64, 64, 64)	256
activation_2 (Activation)	(None, 1, 64, 64, 64)	0
dropout_2 (Dropout)	(None, 1, 64, 64, 64)	0
dense (Dense)	(None, 1, 64, 64, 2)	130

Justificativa da Técnica



Camadas Pooling. Experimento com conjunto de dados de três bandas espectrais. A linha tracejada vermelha horizontal são os resultados obtidos pelo modelo sem camadas de Polling [Pelletier et al., 2019].

Materiais e Métodos - Série temporal de 4 imagens



Imagens de datas: 28/12/2023, 14/01/2024, 03/02/2024 e 06/05/2024.

Materiais e Métodos

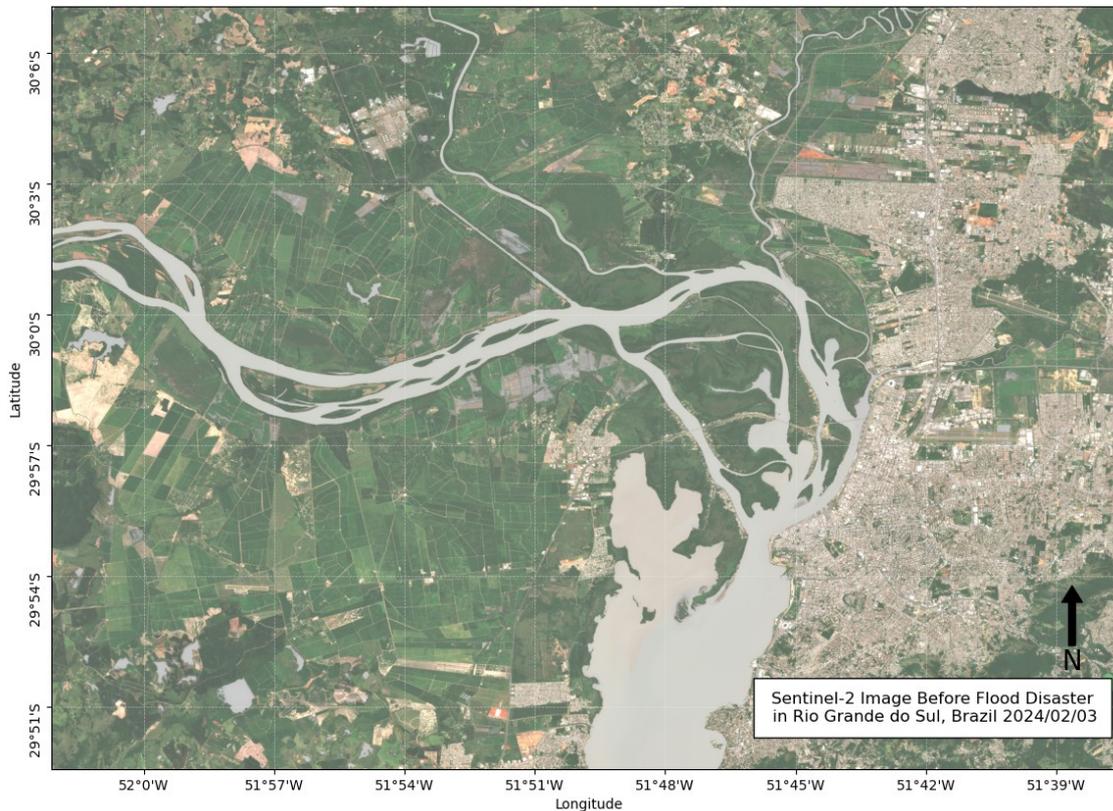


Imagem Sentinel-2 de antes das inundações no Rio Grande do Sul, data 06/05/2024.

Materiais e Métodos

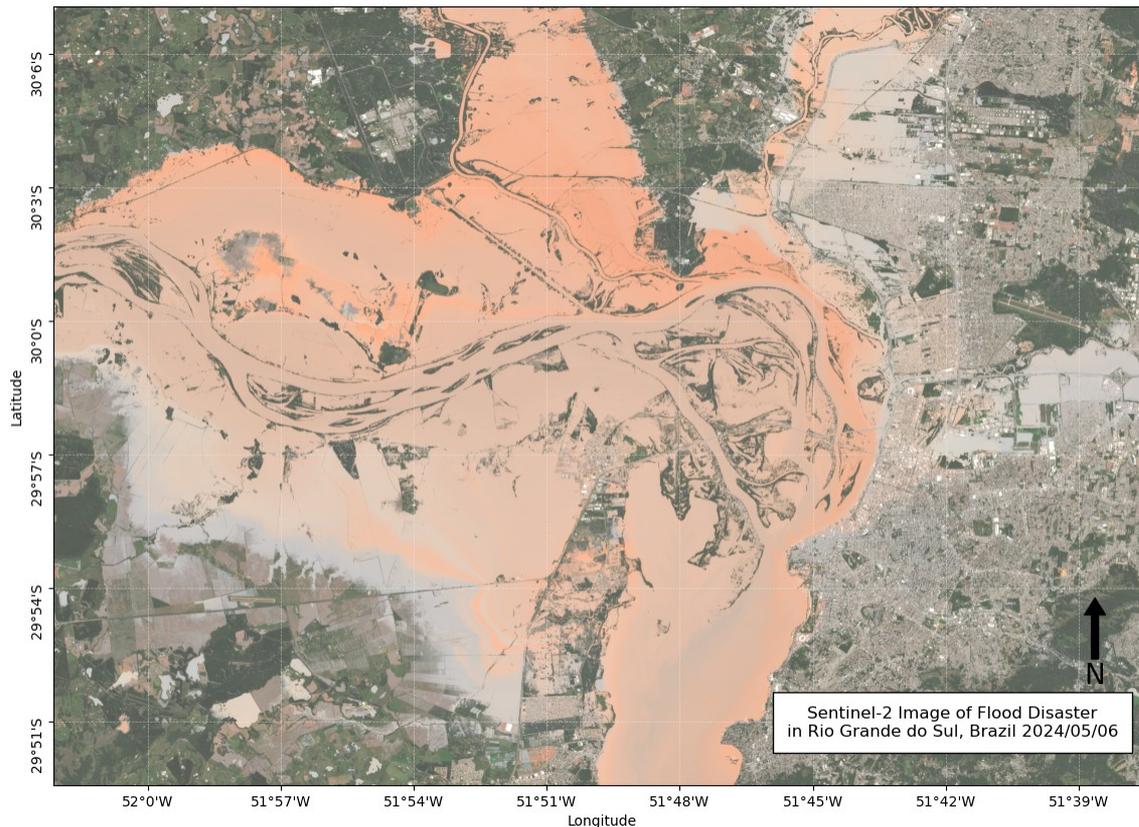
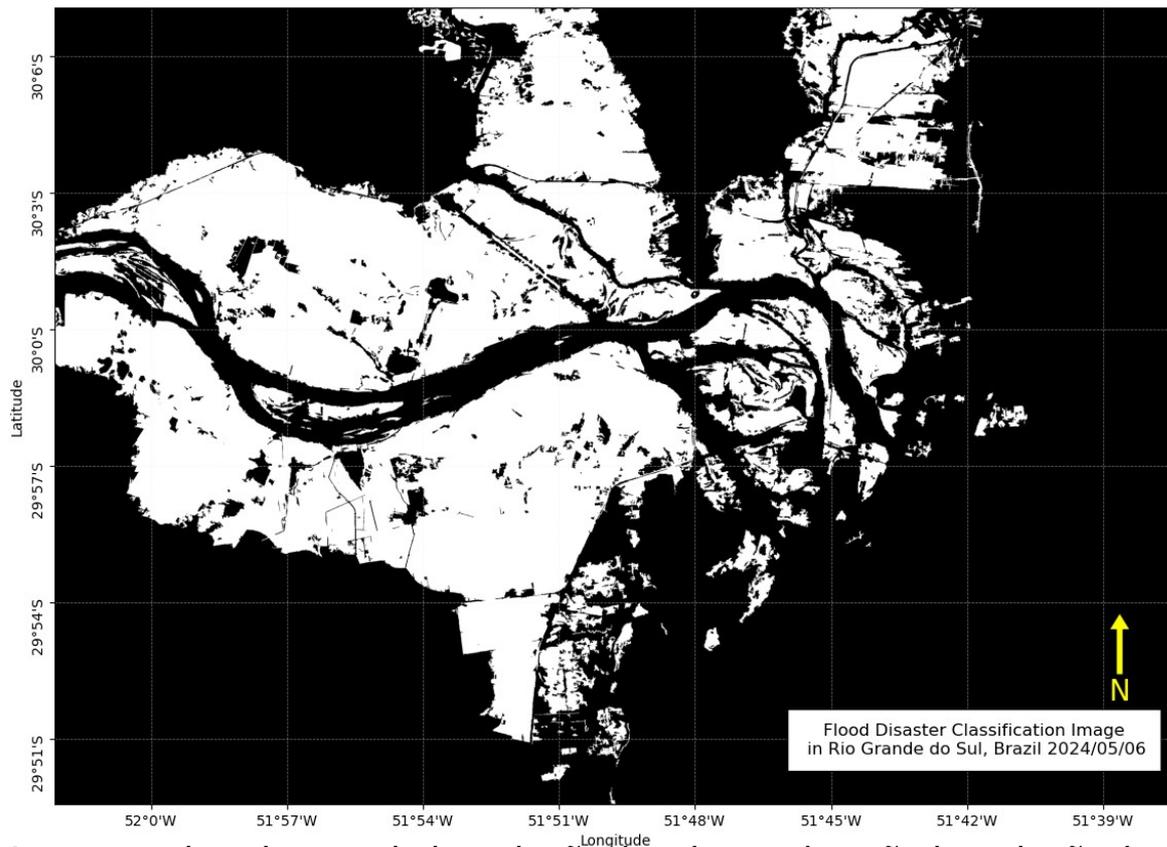


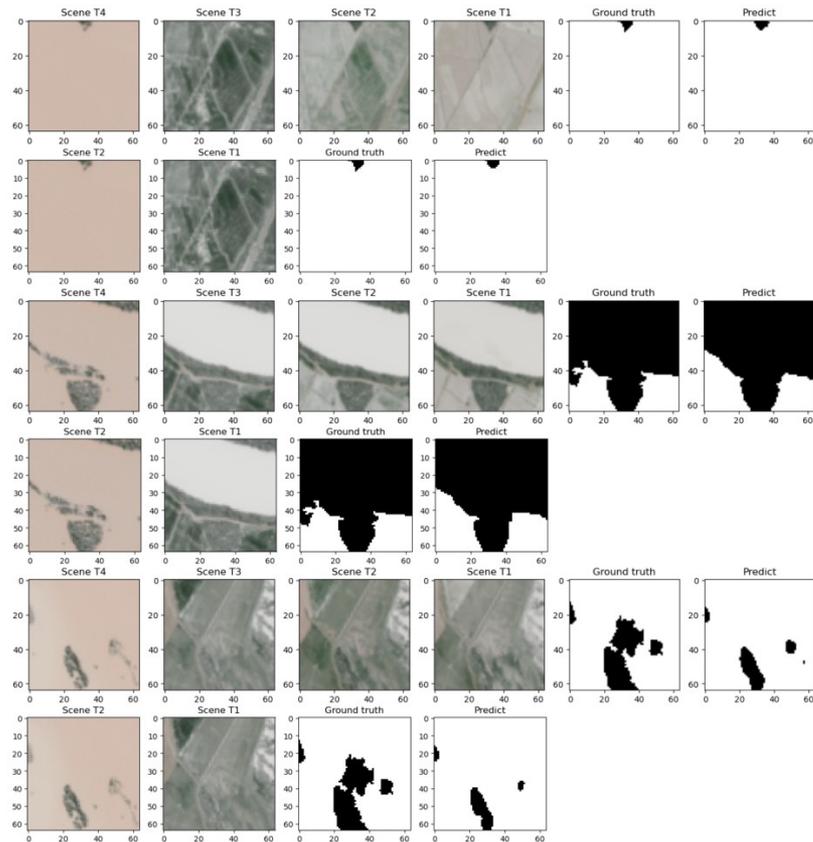
Imagem (RGB-NIR) Sentinel-2 das áreas prováveis de inundações no Rio Grande do Sul, data 06/05/2024.

Materiais e Métodos



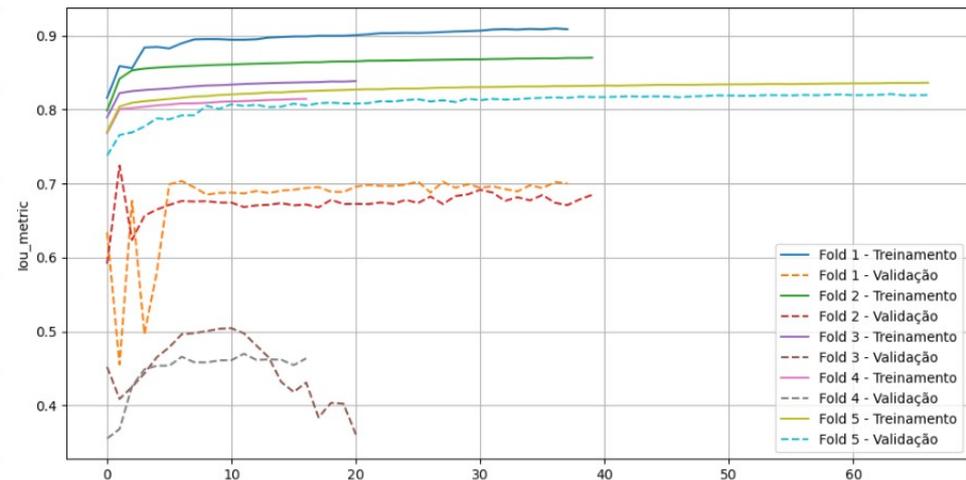
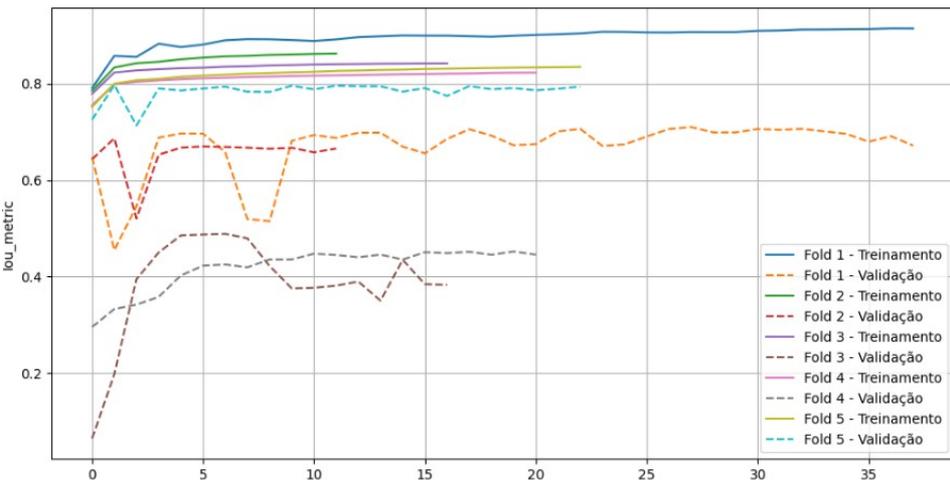
Amostras das classes de inundação (em branco) e não inundação (em preto) feitas comparando imagens do Sentinel-2 de antes e após o desastre.

Resultados



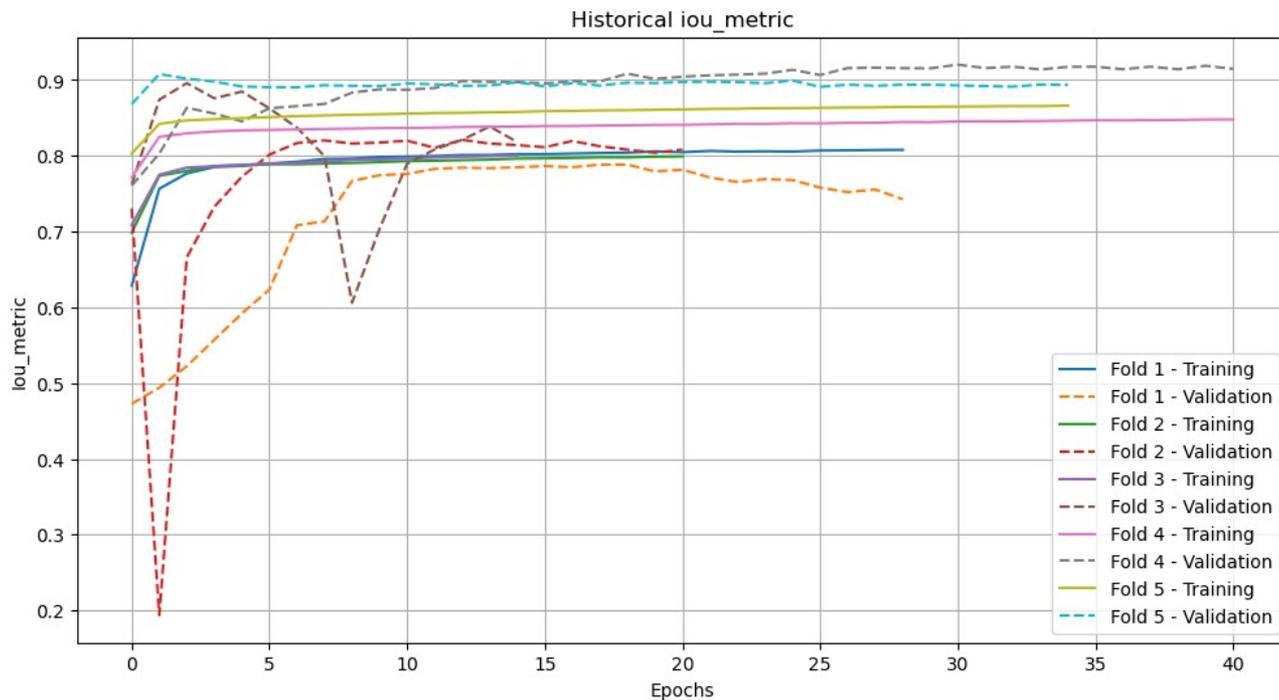
Resultados visuais da classificação de inundações no Rio Grande do Sul.

Resultados



Resultados da validação cruzada ($k=5$) de IoU (Intersection over Union) no treinamento do modelo TempCNN para SITS 4T (à esquerda) e bitemporal 2T (à direita) com composição de imagens BGR-NIR usando dados desbalanceados.

Resultados



Resultados da validação cruzada ($k=5$) de IoU no treinamento do modelo TempCNN para SITS 4T composição de imagens GR-NIR usando dados balanceados.

Resultados

Dados desbalanceados. Tamanho da imagem: (3200, 4000)

Treinamento. Patches com inundações: **1.098**; Patches com não-inundações: **762**.

Píxels com valor 1: **2.635.821**; Píxels com valor 0: **4.982.739**.

Teste. Patches com inundações: **383**; Patches com não-inundações: **857**.

Píxels com valor 1: **1.161.314**; Píxels com valor 0: **3.917.726**.

	Inferência 4T	Inferência 2T
F1-score (<i>weighted</i>)	0.96747	0.96673
Acurácia	0.96719	0.96631
Média IoU	0.84623	0.84616

Métricas de F1-score, Acurácia e mIoU obtidas no conjunto de inferência com a TempCNN para série temporal de 4 imagens (4T) e bitemporal (2T), com dados desbalanceados.

Dados balanceados.

Tamanho da imagem: (2200, 3036)

Píxels com valor 1: **3.339.817**;

Píxels com valor 0: **3.339.383**.

	Inferência 4T
F1-score (<i>weighted</i>)	0.9282
Acurácia	0.9280
Média IoU	0.7372

Métricas obtidas no conjunto de inferência com a TempCNN para série temporal de 4 imagens (4T) com dados balanceados.

Conclusão

- ▶ Os resultados mostram que a TempCNN tem um aprendizado muito forte para SITS do Sentinel-2 de alta resolução espectral
- ▶ Para a classificação de mudanças (de inundação e não inundação) na superfície terrestre, a TempCNN teve uma boa qualidade na análise visual, como também na análise quantitativa com a métrica IoU
- ▶ Em trabalhos futuros será explorado novas arquiteturas de modelos híbridos que combinem CNN+RNN como a CONVLSTM e a ReCNN

Referências

Charter, D. (2024).

Flooding in brazil , available in: <https://disasterscharter.org/web/guest/activations/-/article/flood-in-brazil-activation-875->. access in: 05 aug.

Pelletier, C., Webb, G. I., and Petitjean, F. (2019).

Temporal convolutional neural network for the classification of satellite image time series.

Remote Sensing, 11(5):523.

WORCAP

Workshop em Computação Aplicada 2024

OBRIGADO!
THANKS

**COMPUTAÇÃO
APLICADA**

