



Tema: Utilizando modelos de Aprendizado Profundo para detecção de falhas em linhas de amarração de plataformas em alto mar

Motivação

Plataformas flutuantes são utilizadas para exploração de recursos em alto mar. A estabilidade dessas plataformas *offshores* é mantida por seus sistemas de amarração (vide Fig.1), cuja integridade é muito importante para a operação segura da unidade [1]. O monitoramento constante da integridade das linhas de amarração é de suma importância, dado que a estrutura flutuante está sempre exposta às condições ambientais do mar (ondas, ventos e correntes).




Figura 1 - Esquema de uma produção offshore.

Objetivo

Objetivo: desenvolver um sistema de monitoramento das linhas de amarração a partir dos dados de movimento da plataforma utilizando Aprendizado Profundo (*Deep Learning* – DL). O sistema é composto por (vide Fig. 2):

- (1) Módulo DL de previsão de movimentos futuros da plataforma,
- (2) Cálculo do erro entre o movimento previsto e o medido e
- (3) Módulo de classificação do estado das linhas de amarração em função dos erros, indicando se houve ou não rompimento em alguma linha.

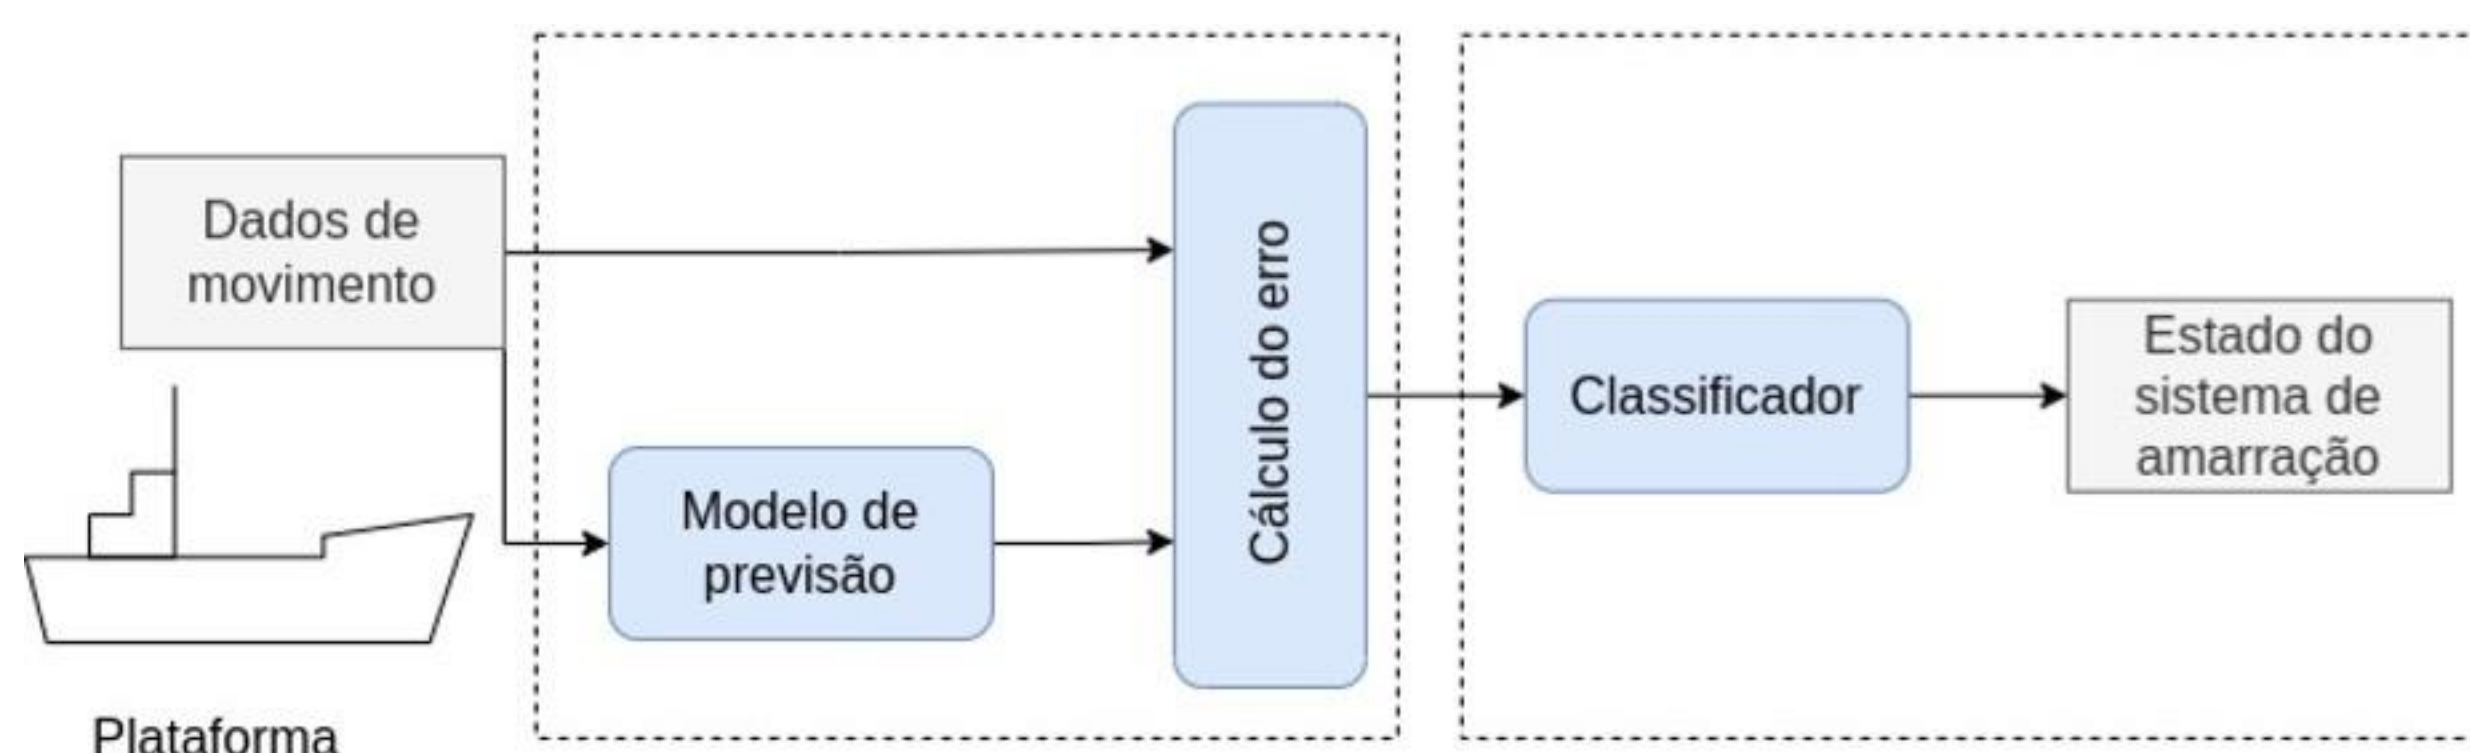


Figura 2 - Arquitetura do sistema de previsão de falha nas linhas de amarração de uma plataforma flutuante.

Metodologia

Foco: desenvolver um modelo de previsão de movimentos de alta precisão.

Modelo: optou-se pelo modelo DL recente *Temporal Fusion Transformer* (TFT) [2].

Projeto: adota uma arquitetura e ferramentas que facilitam a execução e acompanhamento de experimentos (Fig. 3).

Integrantes: - Lucas Fentanes Machado

Professora Orientadora: - Profa. Dra. Anna H. Reali Costa

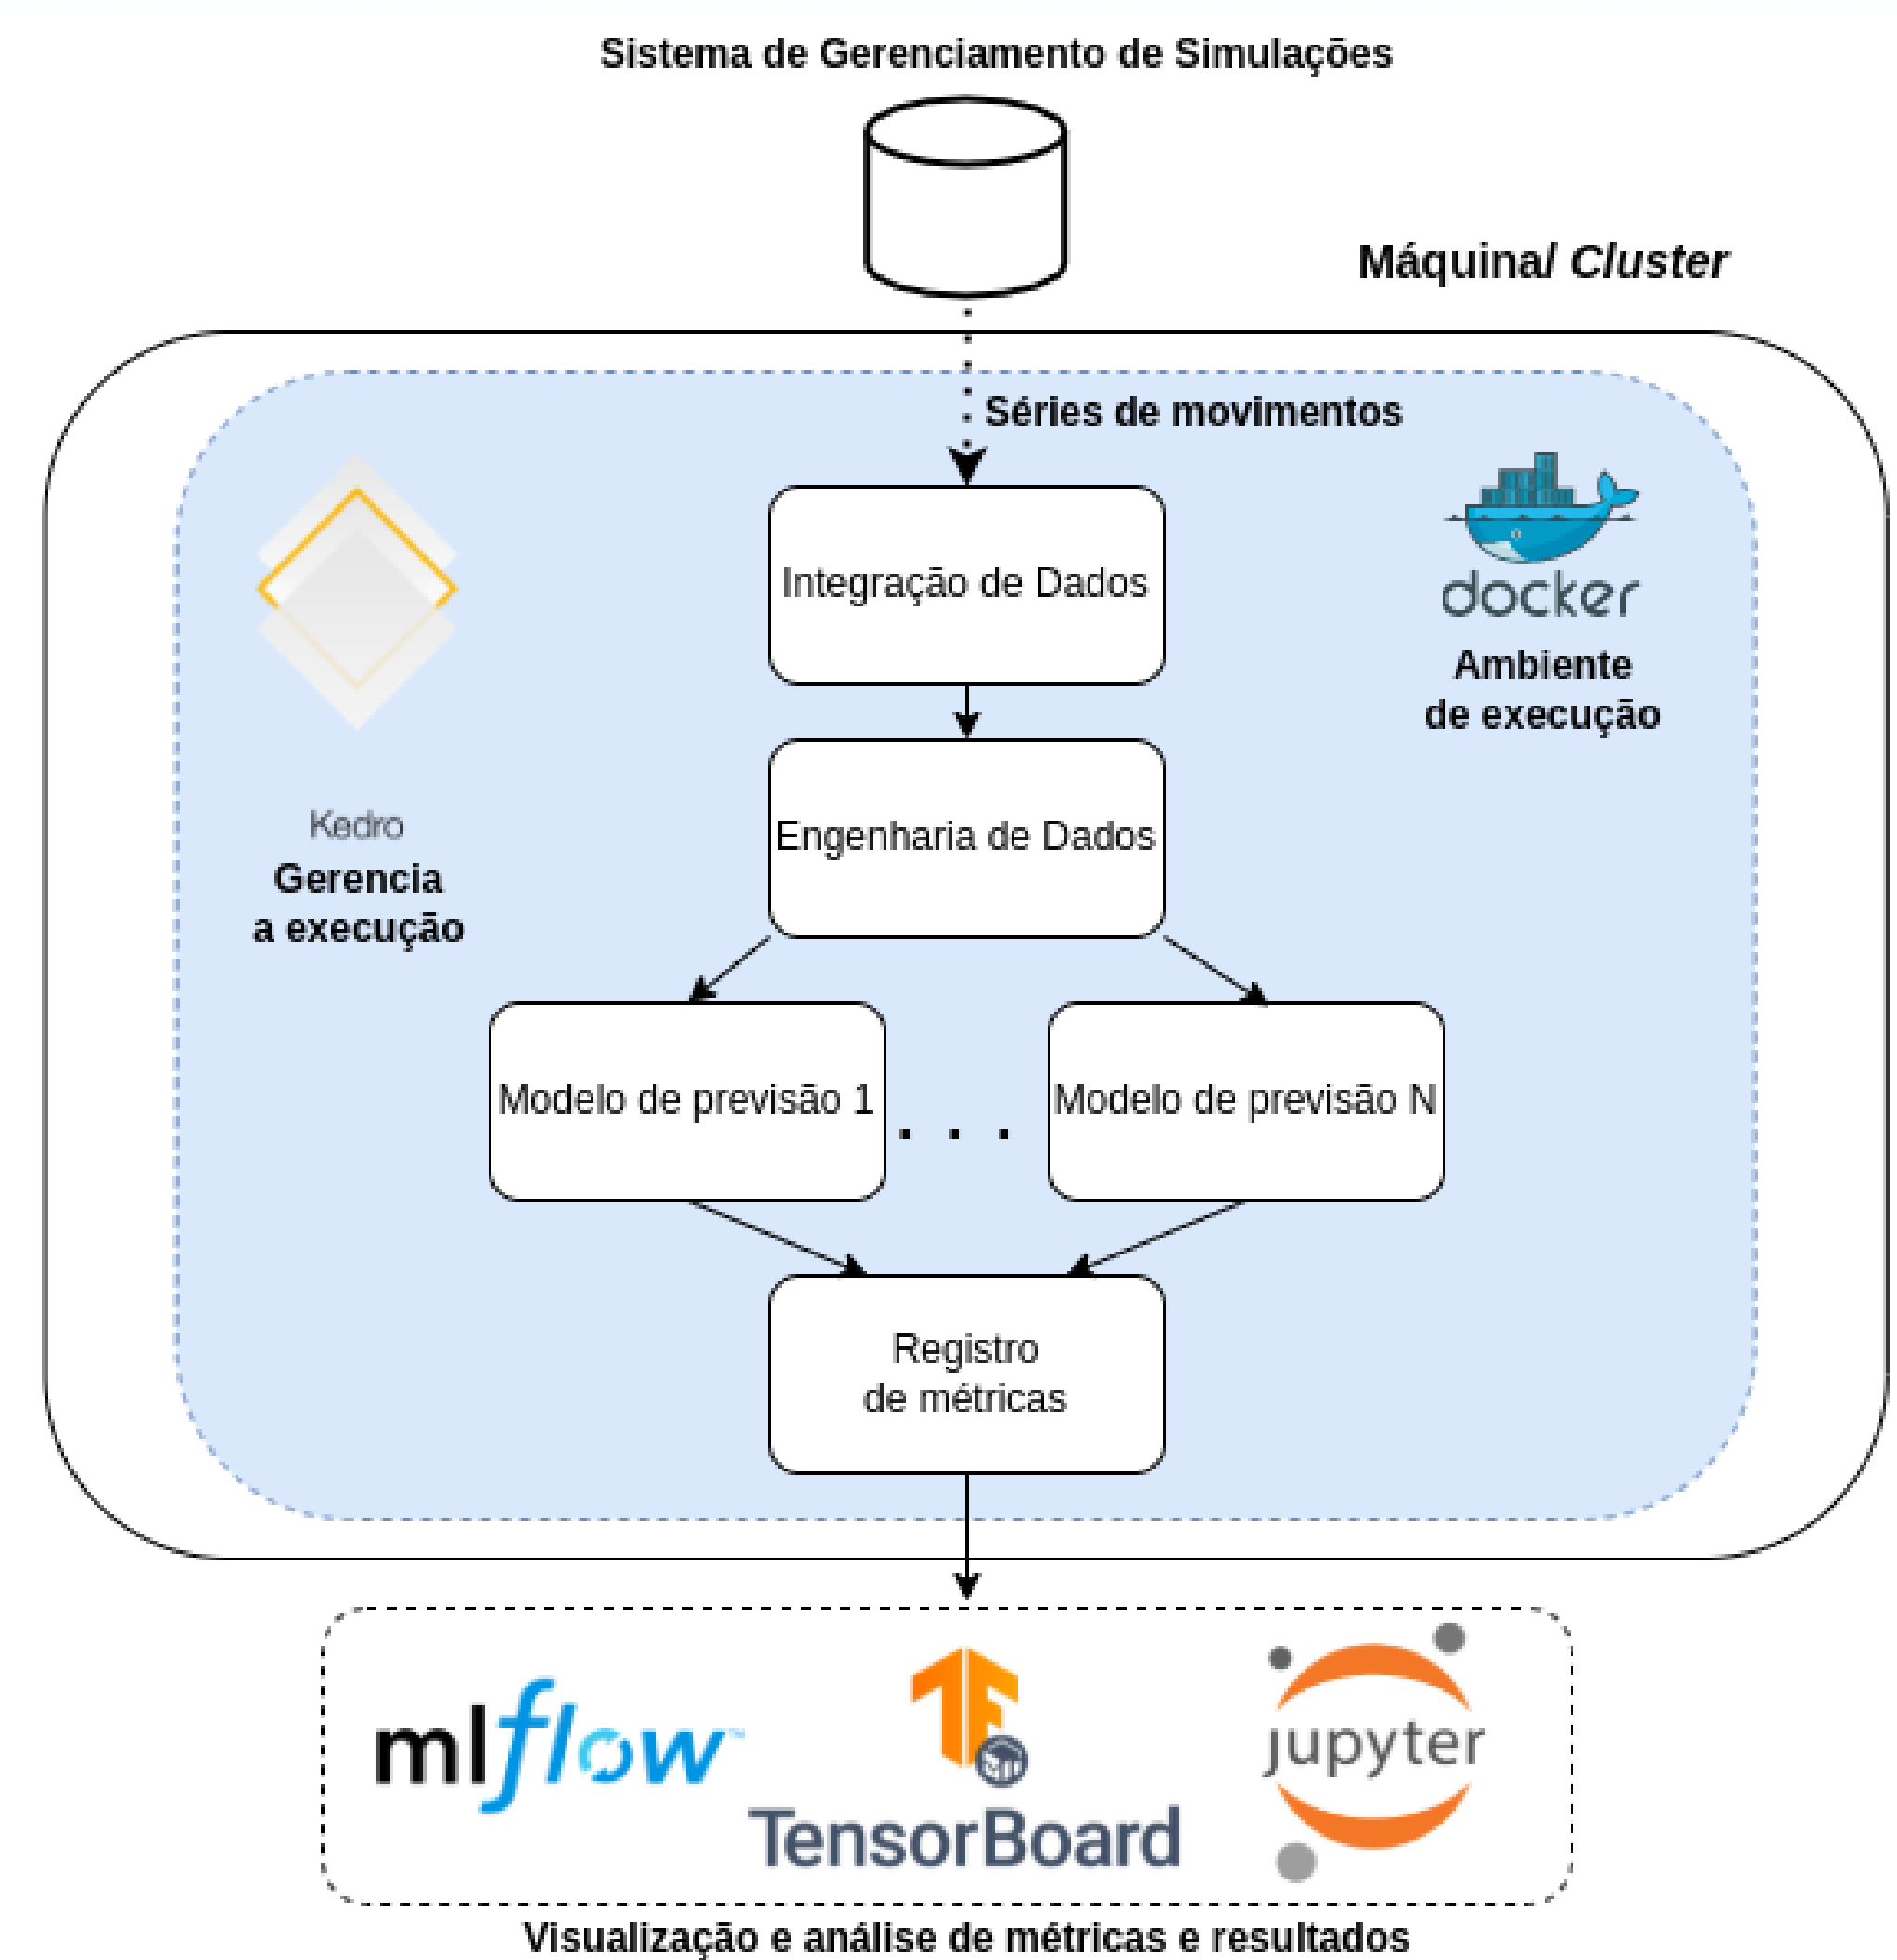


Figura 3 - Arquitetura de software para experimentação

Resultados

A previsão de movimento com o TFT resultou em desempenho bastante promissor, permitindo clara distinção no erro quando ocorre rompimento em uma linha (Fig. 4). O classificador utilizado, *CatBoost*, obteve uma taxa de acerto de 99,9% em conjunto de teste (vide Fig. 5).

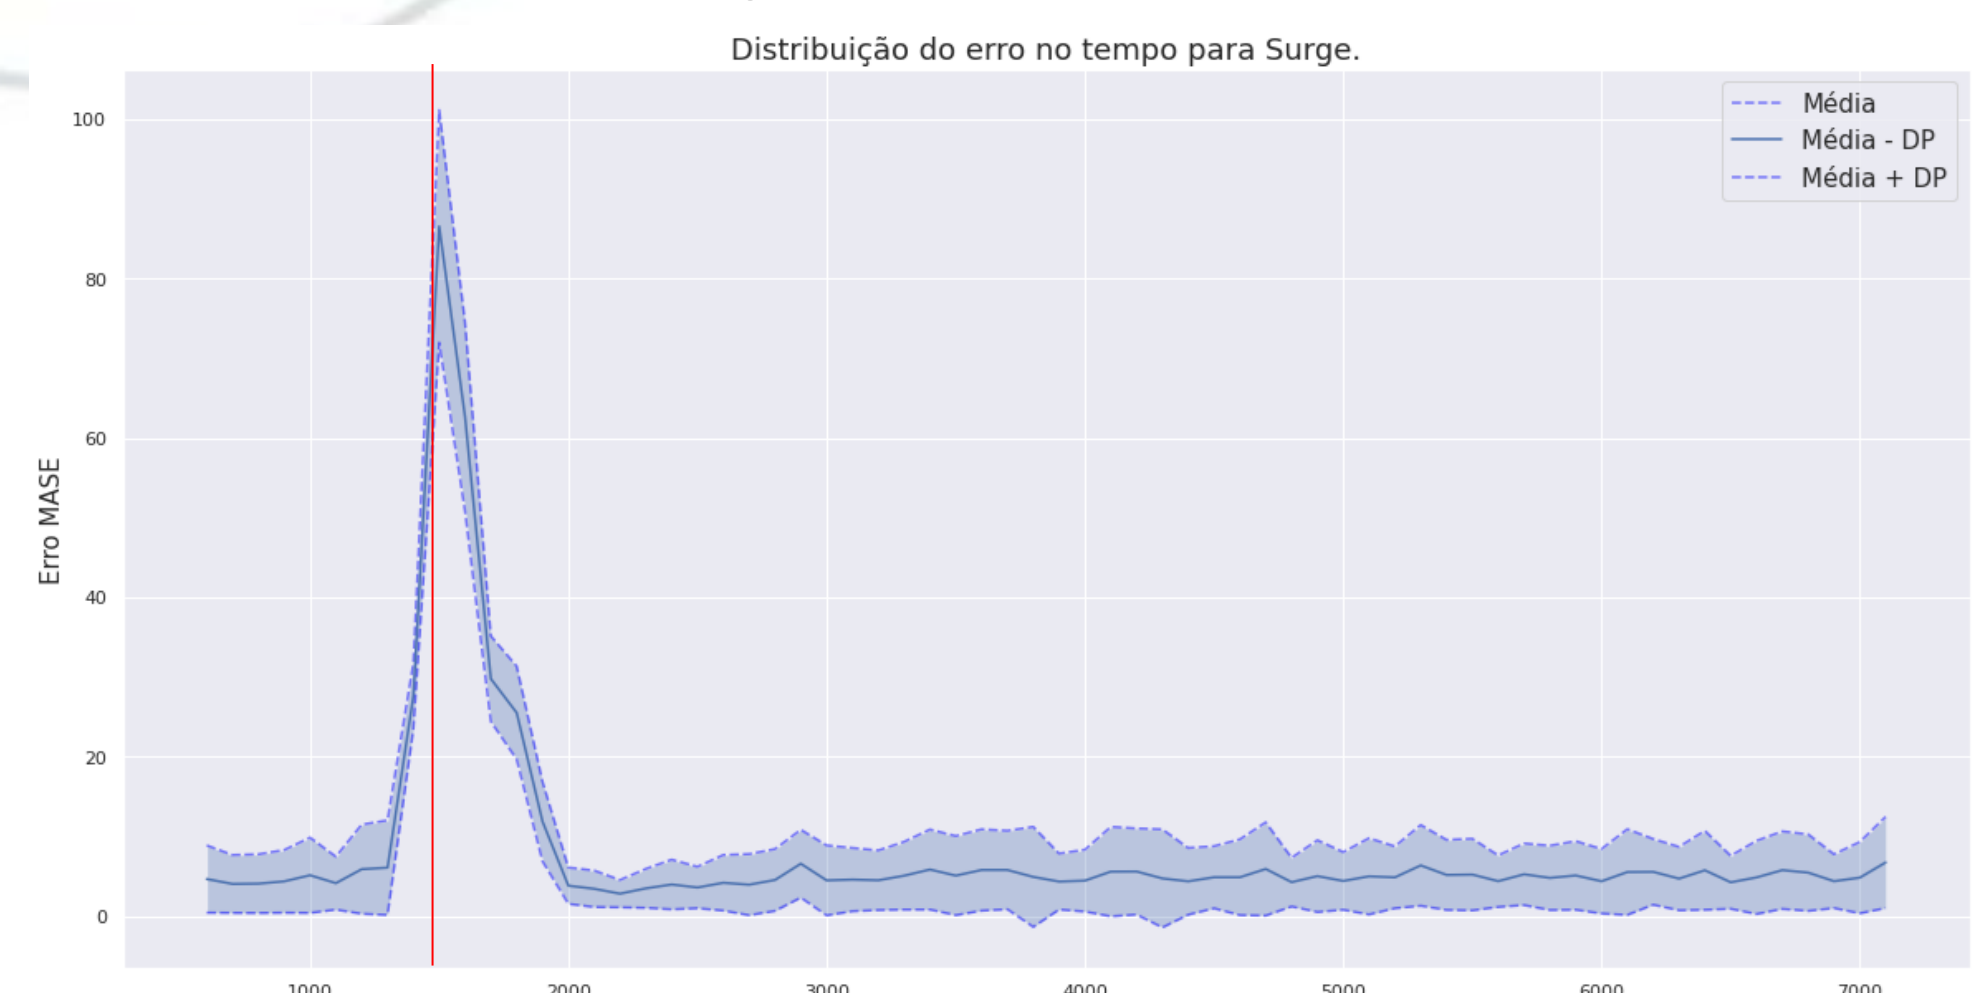


Figura 4 - Distribuição temporal de erro MASE quando há rompimento (na linha vermelha).

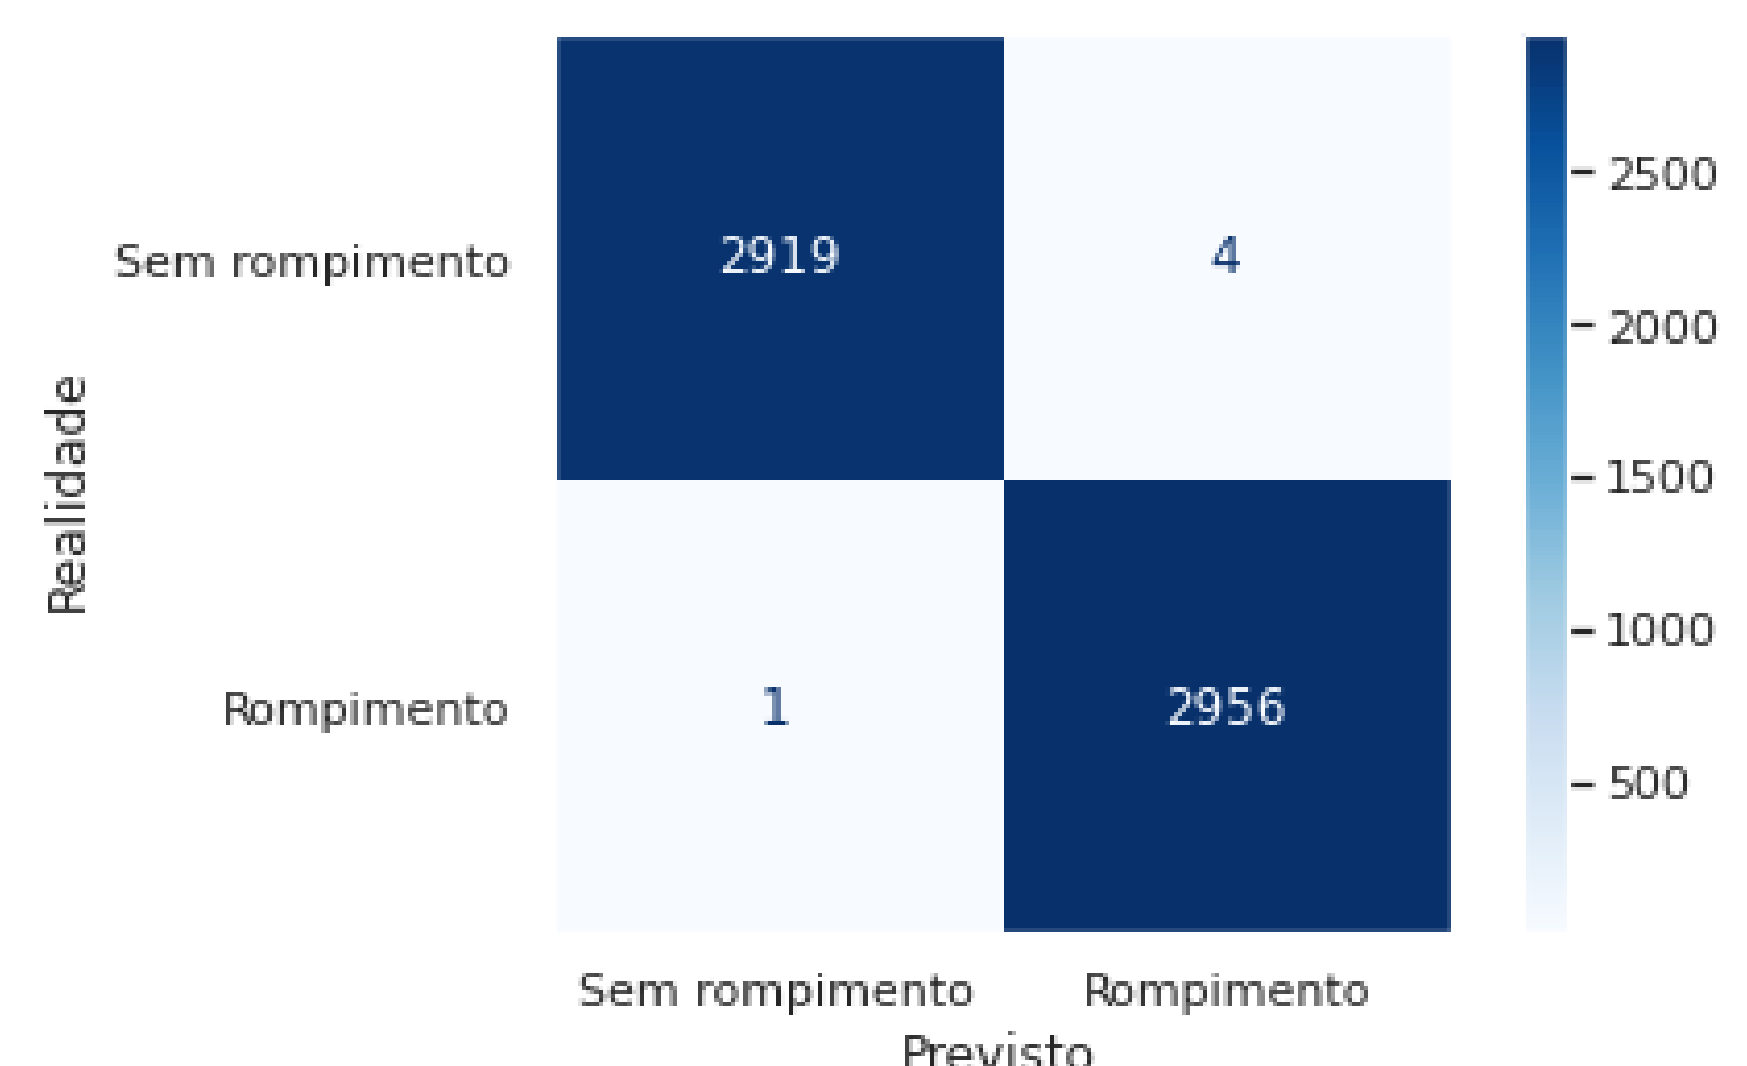


Figura 5 - Matriz de confusão da classificação do conjunto de teste: há somente 5 classificações erradas de um total de 2923 casos sem rompimento e 2957 com rompimento. Das 5 erradas, 4 não resultariam em falha catastrófica.

Referências

- [1] BROWN, M.G.; HALL, T.D.; MARR, D.G.; et al. Floating Production Mooring Integrity JIP - Key Findings. In: Offshore Technology Conference. Houston, Texas: Offshore Technology Conference, 2005.
- [2] LIM, Bryan; ARIK, Sercan Ö.; LOEFF, Nicolas; et al. Temporal Fusion Transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, v. 37, n. 4, p. 1748–1764, 2021.