



SPRACE

# RENAFAE Workshop 2021

## Machine Learning

SANDRA S. PADULA

IFT & SPRACE – UNESP

# Outline

Breve relato → palestras envolvendo desenvolvimentos em  
Machine Learning

- Ferramenta amplamente utilizada atualmente
  - Vários métodos e aplicações em desenvolvimento
    - Breve resumo
  - Demanda recursos computacionais
  - Importante haver esforços conjuntos
    - Integração de recursos computacionais isolados de grupos diferentes
    - Troca de *expertise* e sinergia na utilização de métodos/modelos distintos
  - Relatório segue ordem cronológica (12 e 13 de julho)

# Primeiro dia: CMS

## SPRACE (Thiago Tomei)

- CMS at the HL-LHC
  - Machine Learning em HEP: geração de jatos
    - Generative Adversarial Networks (GANs)
      - Gerador + discriminador em conjunto
    - Jatos hadrônicos
      - imagens calorímetro → point-cloud datasets
  - Machine Learning em HEP: Tracking
    - Uma das tarefas computacionais mais desafiadoras no HL- LHC
    - Esforços conjuntos com Exa.TrkX
      - Geometric Deep Learning

## UFRGS, UERJ, UNICAMP (G. G. Silveira)

- Machine learning para o CMS durante HL-LHC
  - Classificação de jatos no trigger L1 (HL-LHC) (André Sznajder et al.)
    - DNN com jet constituintes
    - Implementar DNN em FPGA
    - Packages: Qkeras Quantization Aware Training (QAT), HLS4ML
  - Simulação de chuveiros: CMS ECAL (Gustavo Gil da Silveira et al.)
    - CaloGAN (Generative Adversarial Network) package: LAr (ATLAS ECAL)
    - Processamento com GridT3s: T3\_BR\_UFRGS and UNICAMP(plan)
- Sinergia natural entre os grupos

# Southern Wide-Field $\gamma$ -ray Observatory (SWGGO)

Deep Learning para a reconstrução de parâmetros de chuva nos detectors Cherenkov de água

- ❑ Grupos envolvidos: CBPF (Clécio R. de Bom) e LIP (Portugal)

## Motivação

- ❑ Usar algoritmos de Deep Learning de simulações de chuva  $\rightarrow$  executar problemas de regressão
  - Foco  $\rightarrow$  recuperação de  $x_{core}$  e  $y_{core}$  e energy fundamental  $\rightarrow$  principalmente para eventos próximos às bordas e além dos limites do detector

# ATLAS: LSD (UFBA), LPS-COPPE (UFRJ), LPNHE (FR)

Calibração de Energia para o Trigger de Elétrons no ATLAS (E. Simas)

Trigger no ATLAS: L1 ; HLT → etapa rápida e etapa precisa:

- ❑ Seleção de  $e^-$  na Etapa Rápida do HLT → via discriminador NeuralRinger
- ❑ Calibração para Etapa Rápida de trigger de  $e^-$  (proposta para o Run 3)
  - Calibração → via Gradient Boosted Decision Tree Ensemble (GBDTE)

Deep learning →

- ❑ aumentar granularidade virtual do HCAL (Philipp Gaspar)
  - Cada Hcal cell → lida por grupo de fibras → transporta sinal de luz a 2 fotomultiplicadoras
  - Nova cadeia de leitura → 1 fotomutipl. substituída por 1 MA-PMT
- ❑ Mitigar crosstalk em células do Cal. LAr (Marton Santos)
  - Cal LAr ~ 187.000 canais de leitura
- ❑ Regressão de energia
- ❑ Investigar estrutura de Recurrent NN adequada, sensível à informação temporal sobre input data para reconstruir a energia


# LPS COPPE/UFRJ (Micael V. de Araújo)

## Framework Integrado para Análise de Dados e Treinamento de Modelos de Machine Learning (Trigger Online/ATLAS)

- ❑ Orquestrar o treinamento e a exploração do espaço de hiperparâmetros de modelos de ML
- ❑ Aplicado para estudos de trigger no ATLAS

### Framework @workflow

- Para desenvolver e analisar os modelos de *Machine Learning* que vem sendo utilizados no NeuralRinger, foi desenvolvido um conjunto de pacotes que atuam nas diferentes etapas do fluxo de desenvolvimento, tais como:
  - Coleta de dados para treinamento;
  - Treinamento de modelos;
  - Avaliação e teste dos modelos.



Brasil: UFRJ/COPPE UFBA; UFJF; UERJ  
Internacional: CERN, Sorbonne Université;  
Universität Bern; Universidade Nacional de La  
Plata; Indiana University Bloomington;


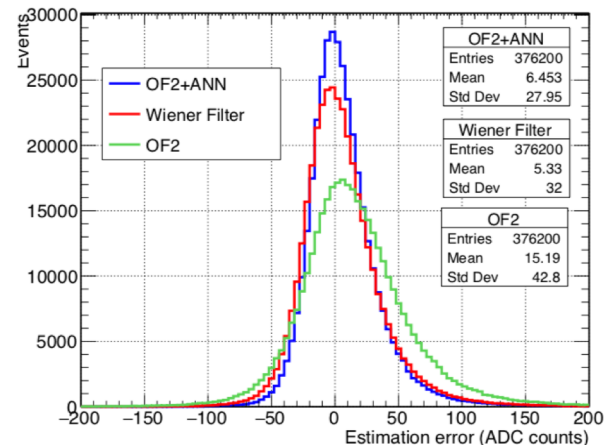
# Segundo dia – Experimentos do LHC

## ATLAS

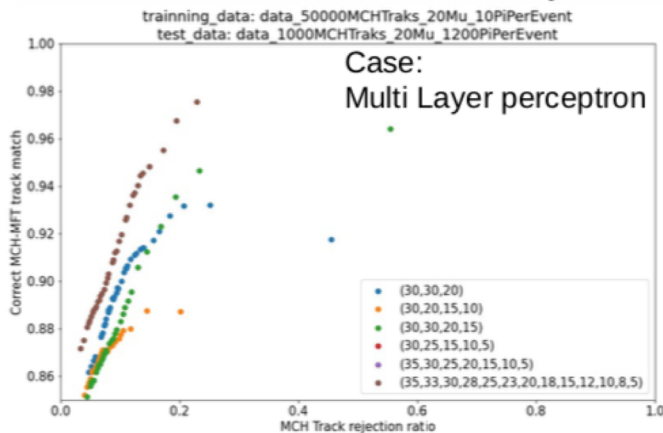
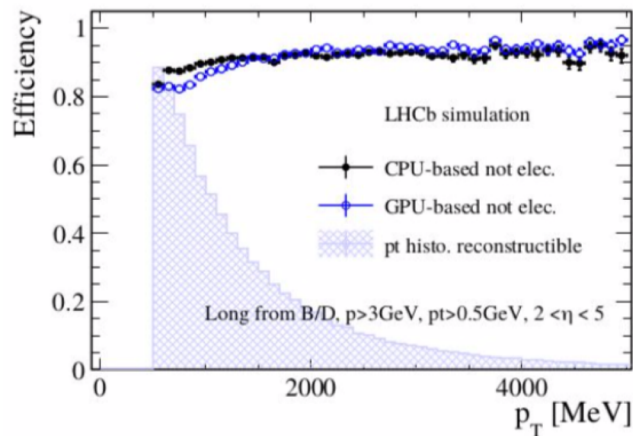
- ❑ TileCal para o HL-LHC: método OF2 + NN testado com PU=90, implementado no algoritmo do High Level Trigger (B. Peralva)

- ❑ Trigger para elétrons e fótons:

- NeuralRinger
- Investigação sobre uso de ConvNNs (elétrons) e transfer learning (elétrons  $\rightarrow$  fótons) (J. Marin)



# Machine Learning – Experimentos do LHC



## LHCb (não relata Machine Learning!)

- ❑ Real-time analysis
  - Sem trigger de nível 1
  - Readout a 30 MHz
  - Volume de dados semelhante a ATLAS-CMS para HL-LHC
- ❑ Uso de GPUs no HLT1

## ALICE

- ❑ Forward tracking demanda alto poder computacional.
- ❑ Uso de Machine Learning em Global Muon Tracking (Pezzi)
- ❑ **Sinergia** com HL-LHC: tracking em Heavy Ions ~ tracking a PU=200