

Esplorazione analisi interattiva con l'esperimento CMS

A. Cagnotta – WP5 meeting 24/05/2023

Use case

- ❑ Analisi dati in corso della Collaborazione CMS → top quark+MET analysis
- ❑ All'analisi sta lavorando il Gruppo CMS di Napoli → Antimo Cagnotta (50%), Orso Iorio (10%)
- ❑ fase di sviluppo dell'analisi → al momento stiamo lavorando su dataset MC della collaborazione
- ❑ Il framework di base da cui partiamo è in pyROOT → intenzione di portarlo in RDataFrame - prototipo funzionante già realizzato

Workflow analisi (STEP 1)

STEP 1 (NON in porting all'analisi interattiva)

- ❑ Data preprocessing, evaluation tramite modello ML
 - ❑ Input data: formato NanoAOD (ROOT-pla quasi plain di CMS)
 - ❑ Operazioni: preselezione minima, evaluation candidati top quark con modello Machine Learning dedicato
 - ❑ Output: nuovo file formato NanoAOD di size leggermente inferiore all'originale (stesso ordine di grandezza) salvato su Tier2
 - ❑ Strumenti utilizzati: CMS NanoAOD tools (pyROOT-based) e CRAB




Modello ML **allenato separatamente** su una parte dei MC utilizzati.
A questo step accediamo al solo modello finale salvato in formato h5

Workflow analisi (STEP 2)


Work in progress

STEP 2: in porting all'analisi interattiva

- ❑ Skimming e selezione
 - ❑ Input: output dello step1 (file presi dal tier)
 - ❑ Operazioni: selezione eventi di interesse, estrazione candidato top, calcolo variabili di interesse + calcolo sistematiche
 - ❑ Output: file di istogrammi per combine e snapshot da RDataFrame per eventuali controlli
 - ❑ strumenti utilizzati: RDataFrame con Dask su INFN AF



- ❑ Ultimo step (fit, calcolo limiti) → pyROOT (Combine?)



Implementazione STEP 2

- ❑ Grazie al supporto di Diego Ciangottini, Tommaso Diotallevi e Tommaso Tedeschi, abbiamo iniziato il porting di questo step su JupyterLab (<https://inf-cms-analysisfacility.readthedocs.io/en/latest/introduction/>)
- ❑ Cosa fa al momento il notebook implementato:
 1. Legge i file in input dal Tier2 di Pisa tramite global redirect “root://cms-xrd-global.cern.ch/” in un RDataFrame
 2. Viene girata la selezione e definite variabili utili per l’analisi tramite cluster Dask
 3. In output produce file ROOT in cui vengono salvati gli istogrammi per controlli/step successive
 4. Guadagno: con RDataFrame girando su metà dei file circa 2h, usando il cluster su tutti i file circa 30minuti
- ❑ Cosa manca :
 - ❑ creazione di snapshot per controlli vari → e conseguente gestione della memoria, da implementare trasferimento file utilizzando davix (?), al momento i file di output sono di piccola size
 - ❑ calcolo pesi e sistematiche
 - ❑ ottimizzazione delle performance tramite supporto degli esperti
- ❑ Implementazione STEP 1 tramite analisi interattiva: non nei piani immediati