



**UNIVERSITÀ
DEL SALENTO**



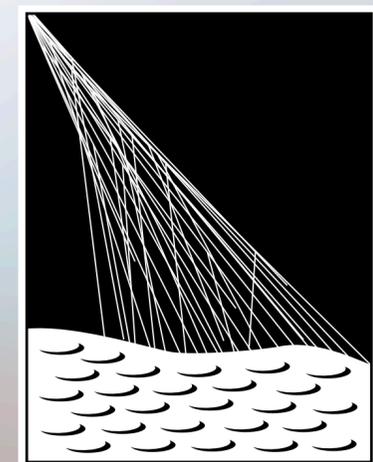
**Istituto Nazionale di Fisica Nucleare
SEZIONE DI LECCE**

Sviluppo di tecniche di machine learning per lo studio della composizione di massa dei raggi cosmici di altissima energia e della componente muonica degli sciami atmosferici estesi con i dati dell'Osservatorio Pierre Auger

"Self Organizing Map algorithms on GPUs for faster Time Series Analysis clustering"

Matteo Conte, Università del Salento, INFN - sezione di Lecce

Matteo Conte - IFAE, *Firenze 3-5 Aprile 2024*

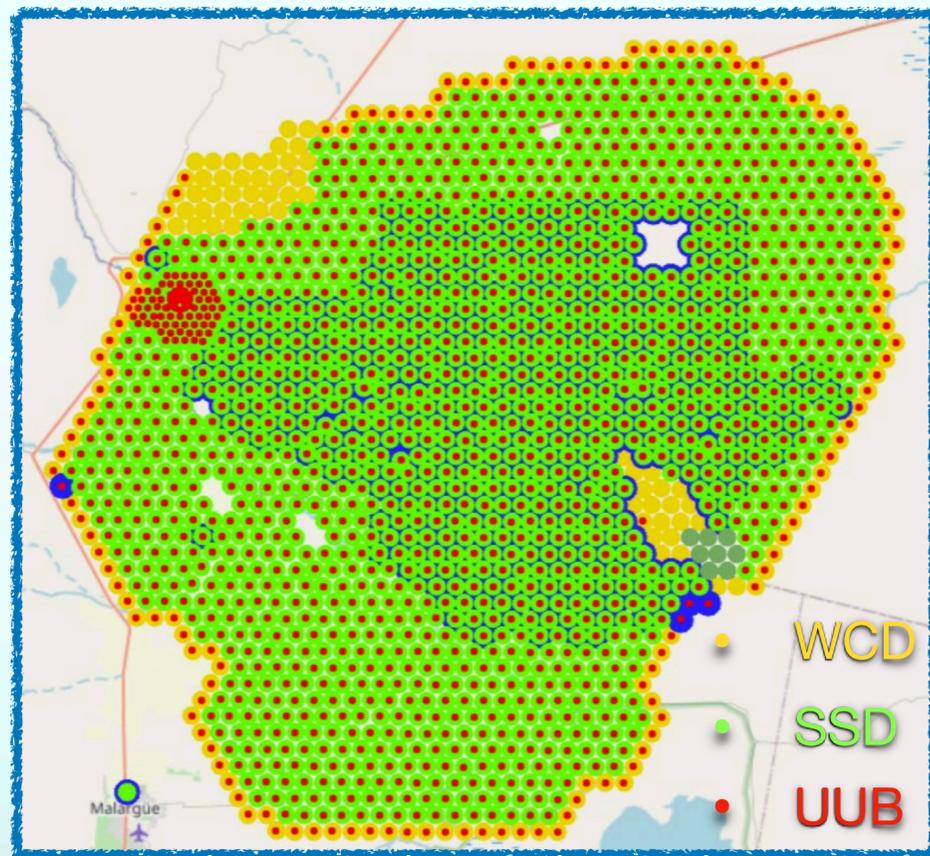


**PIERRE
AUGER
OBSERVATORY**

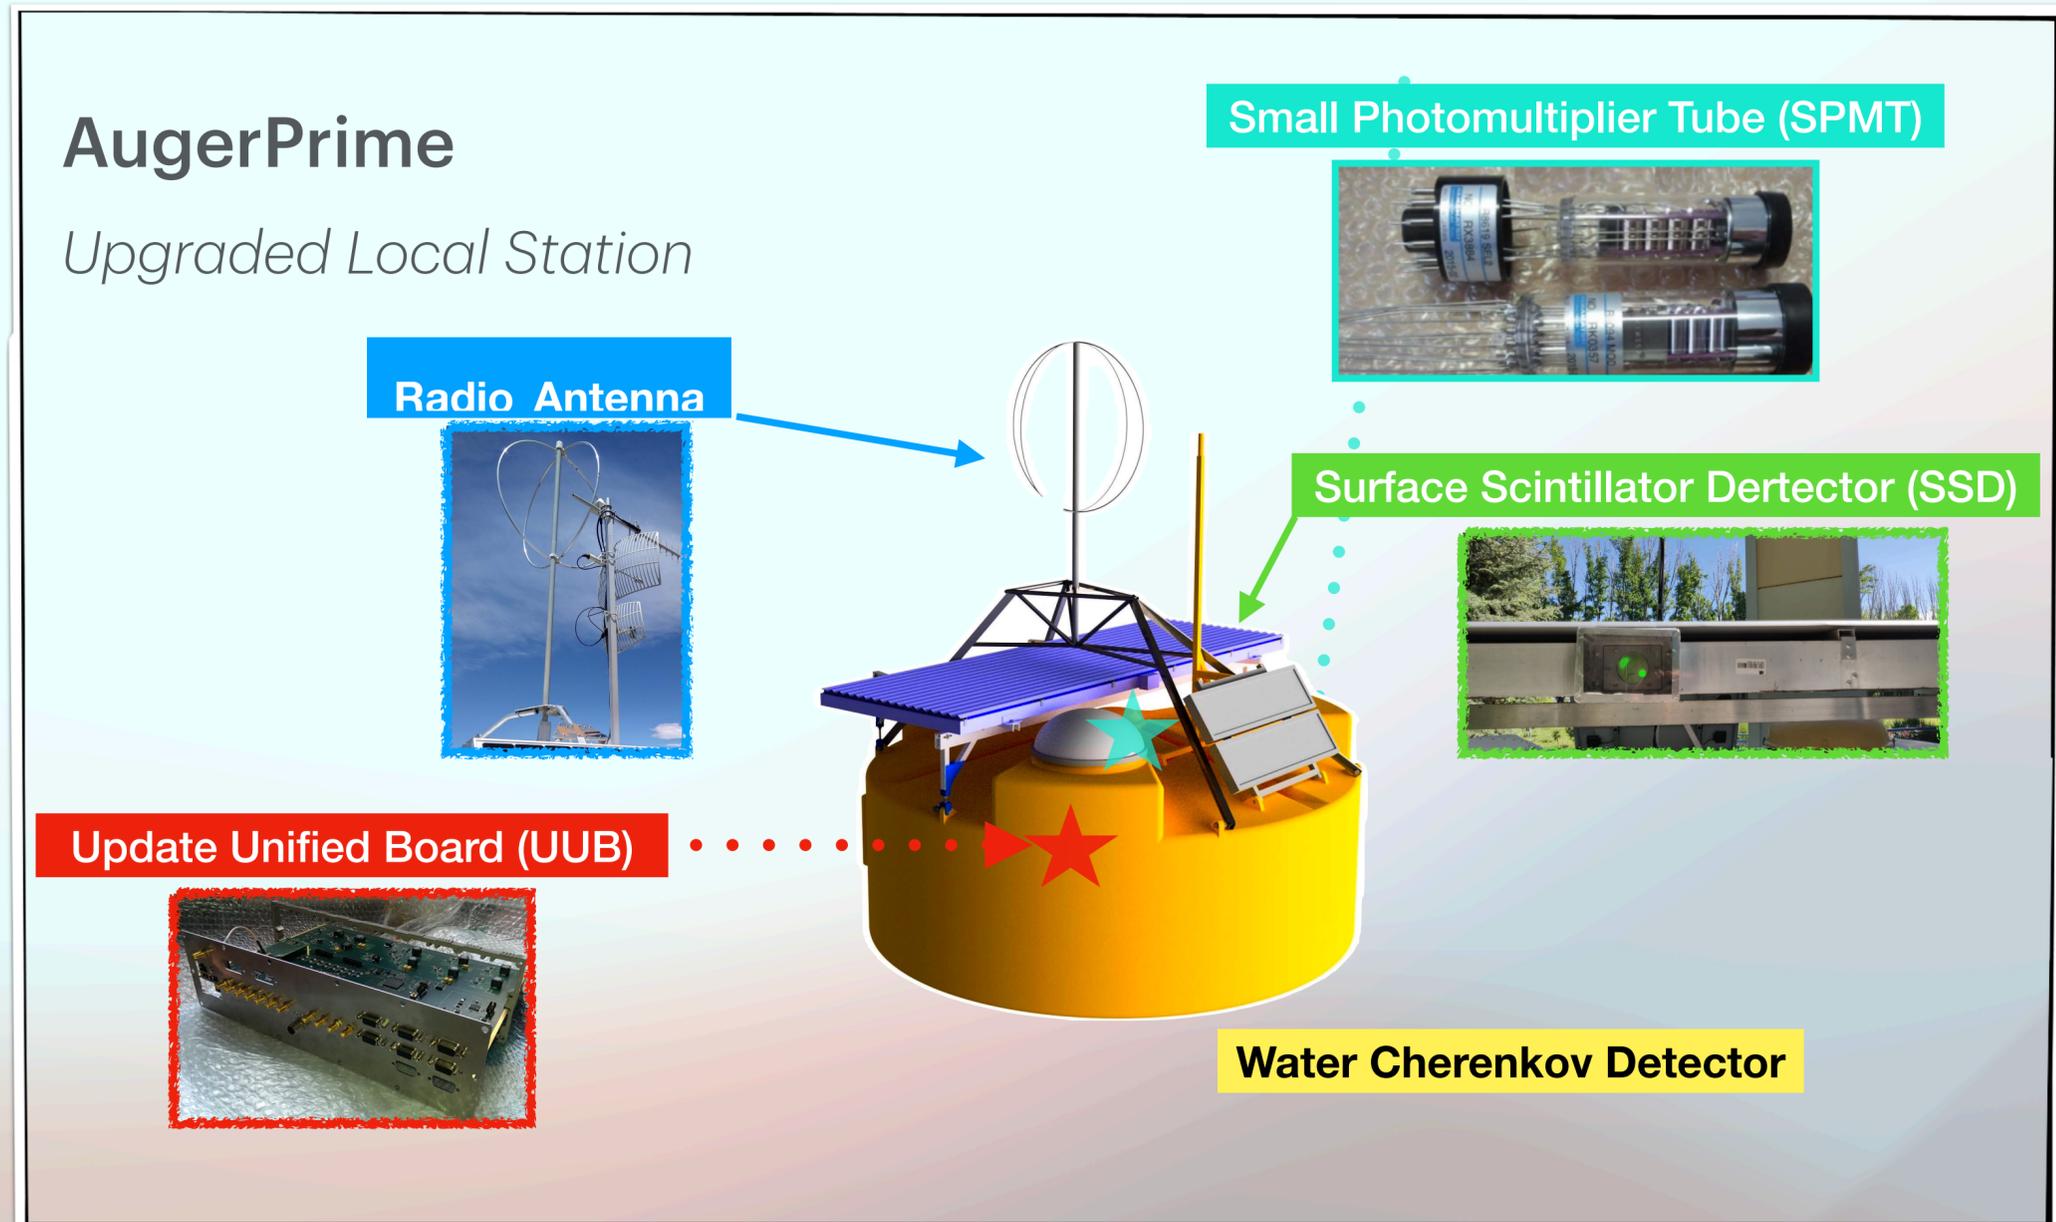
Punti chiave

- Osservatorio Pierre Auger e il suo upgrade
- Composizione di Massa dei raggi cosmici ad altissime energie
- Self Organizing Map
- Addestramento, monitoraggio e ottimizzazione
- Test preliminari per la caratterizzazione della frazione di segnale muonico f_{μ} :
 - Sui 'meta' dati di ricostruzione dello sciame atmosferico esteso
 - Sui segnali (temporali) dei PMT
- Step successivi

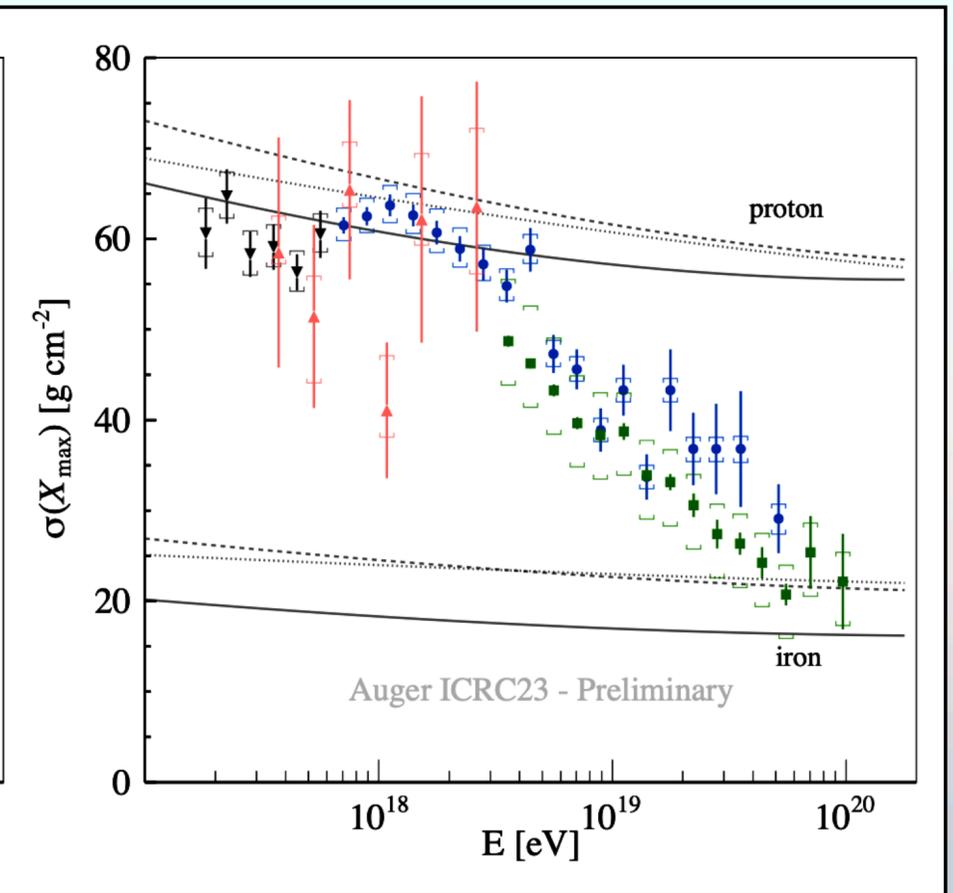
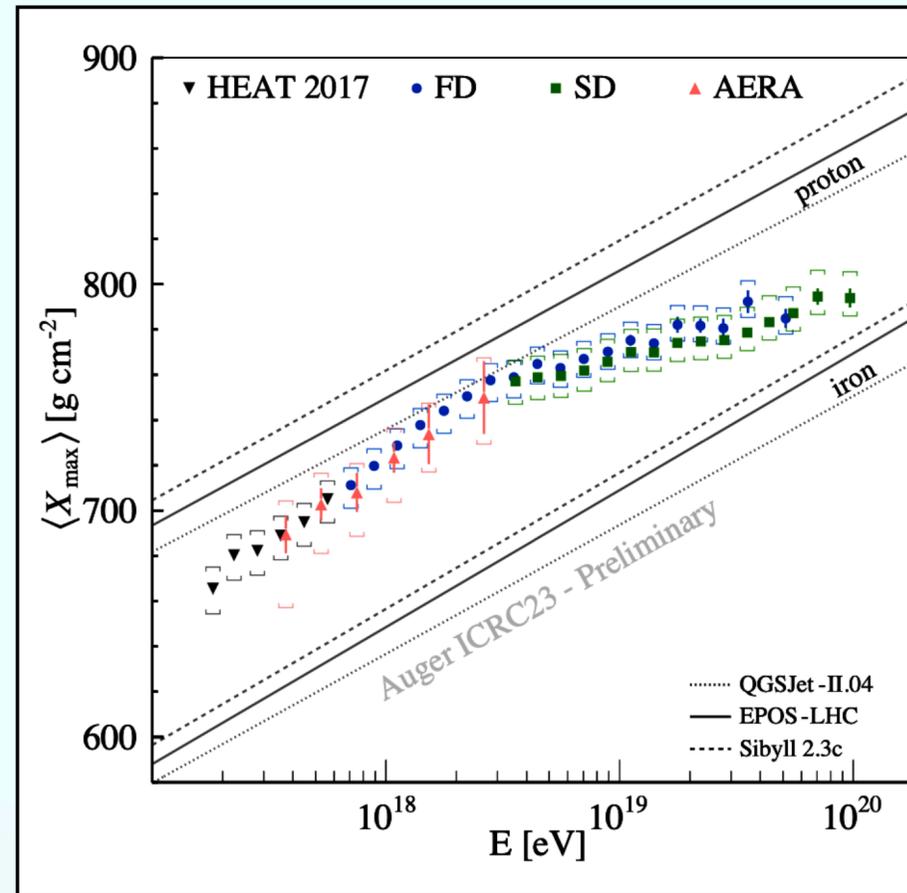
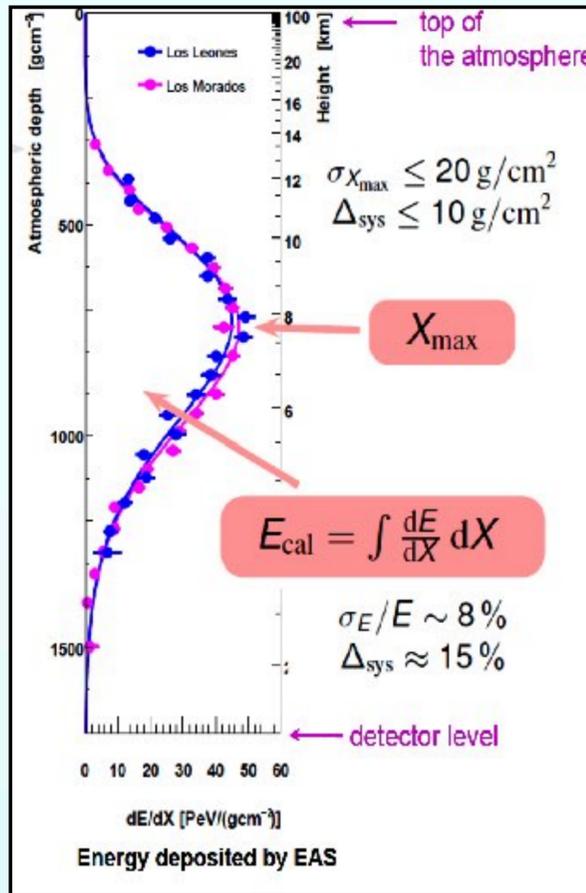
Il Rivelatore di Superficie dell'Osservatorio Pierre Auger



- Oltre 1600 Stazioni Water Cherenkov
- Oltre 1400 SSD



Misura della composizione di massa degli UHECRs



<https://doi.org/10.22323/1.444.0365>

X_{\max} è un'osservabile sensibile alla massa

Evoluzione generale del trend di massa dalle misure dei primi due momenti di X_{\max}

La composizione del flusso di UHECRs sopra i 100 PeV è descritta come:

- La grande maggioranza di UHECR primari sono **nuclei atomici ionizzati**.
- All'aumentare dell'energia, la massa media di questi nuclei prima decresce, raggiungendo il punto più leggero a 3 EeV, e dopo aumenta significativamente.

Misura della composizione di massa degli UHECRs

- ▶ Le misure ibride soffrono di bassa statistica (FD 15% duty cycle)
- ▶ Migliorare l'analisi alle più alte energie con i dati del Surface Detector (100% duty cycle).

- Metodi data-driven usando il tempo di salita medio dalle stazioni SD in un evento (Δ) collegato alla prossimità del massimo dello sciame da terra



Maximum Rigidity

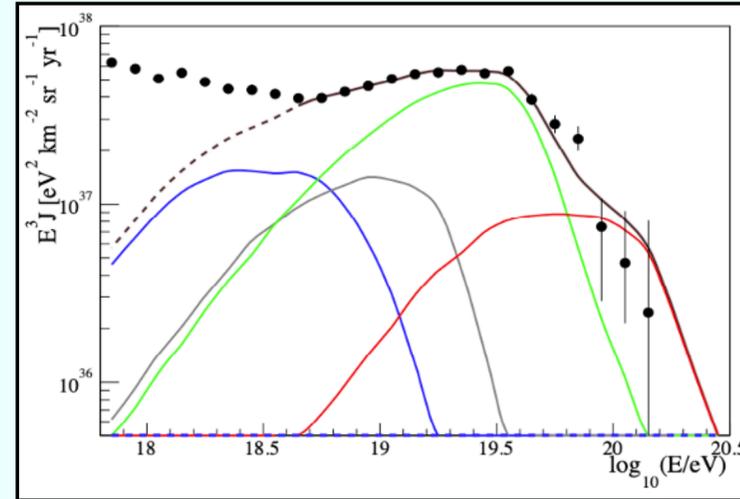
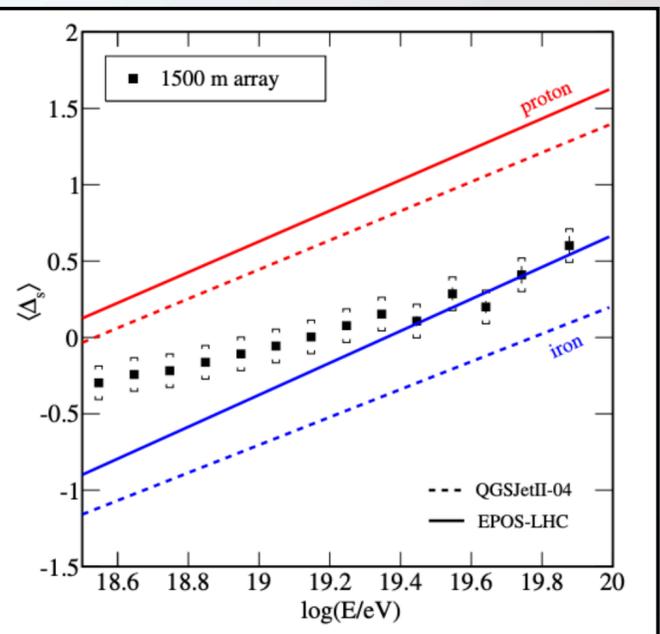
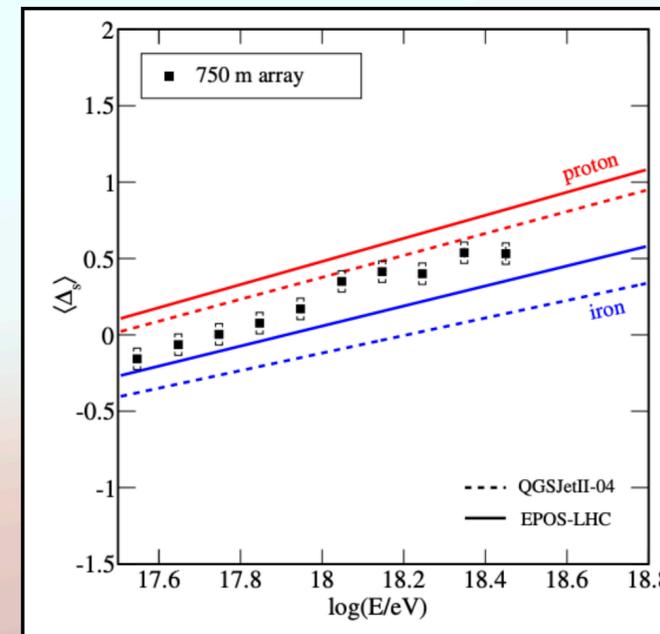
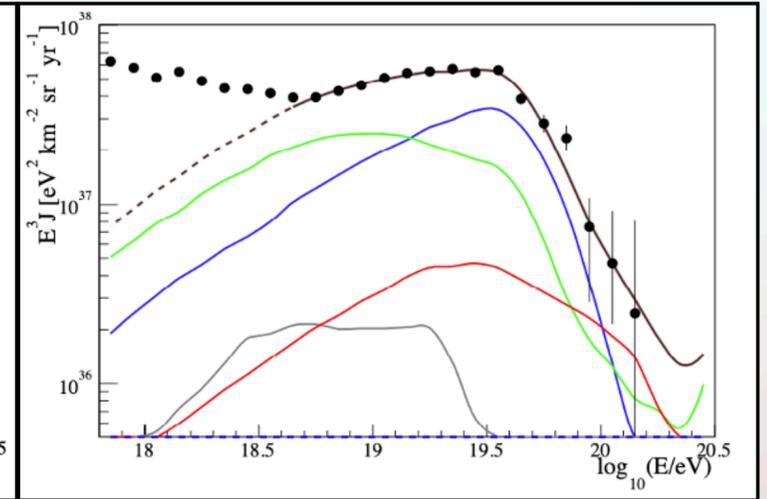


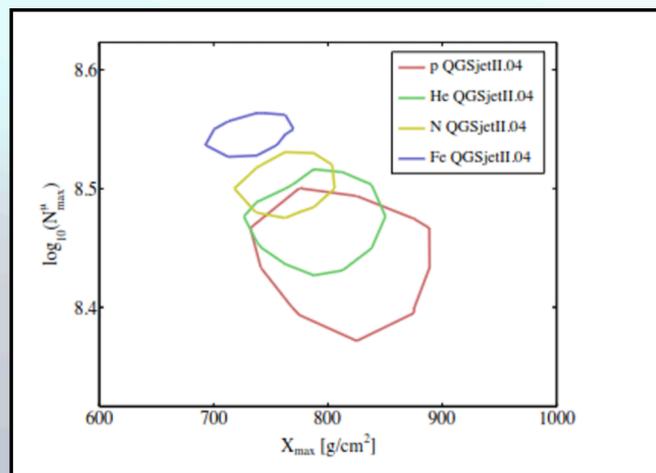
Photo-disintegration



Estrazione delle componenti elettromagnetica e muonica in superficie

► AugerPrime

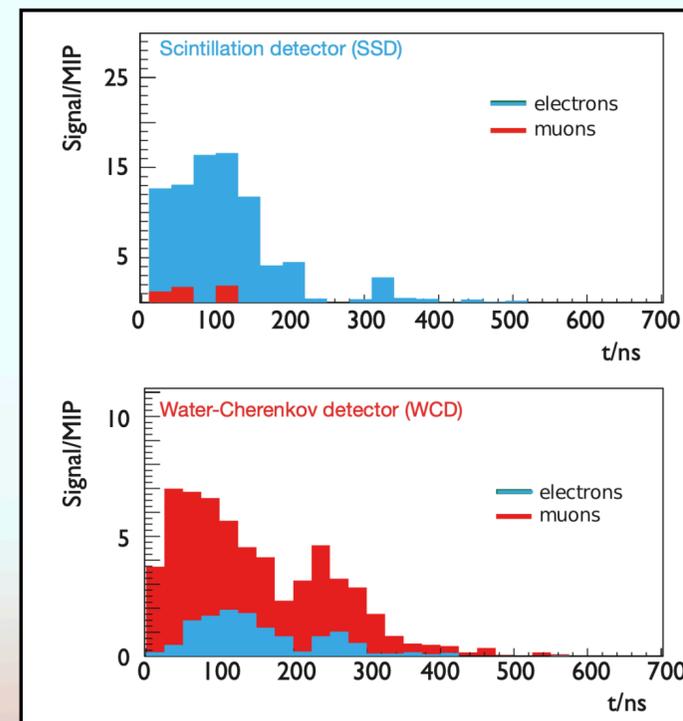
- Due misure indipendenti (WCD + SSD)
- Algoritmi di Machine learning per estrarre il segnale muonico e stimare parametri correlati alla massa del primario



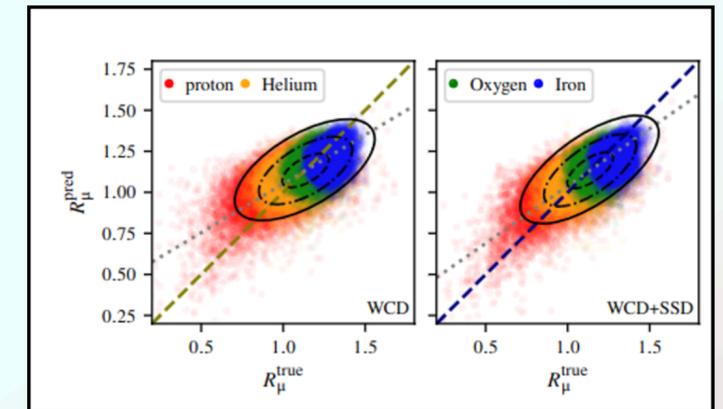
Matrix Inversion

$$\mathcal{F}_{\text{em}} = \frac{1}{\lambda - \beta} \left(\frac{S_{\text{SSD}}}{\mathcal{A}_{\text{SSD}}} - \frac{S_{\text{WCD}}}{\mathcal{A}_{\text{WCD}}} \right),$$

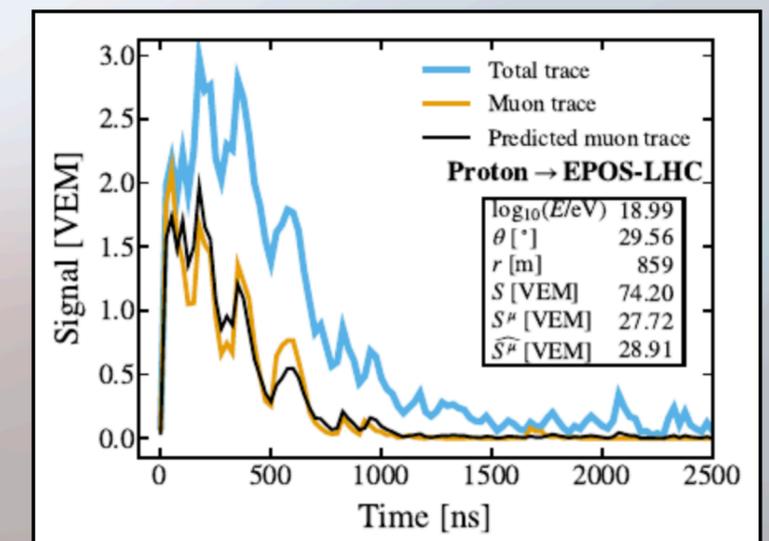
$$\mathcal{F}_{\mu} = \frac{1}{\lambda - \beta} \left(\lambda \frac{S_{\text{WCD}}}{\mathcal{A}_{\text{WCD}}} - \beta \frac{S_{\text{SSD}}}{\mathcal{A}_{\text{SSD}}} \right).$$



Supervised - DNN

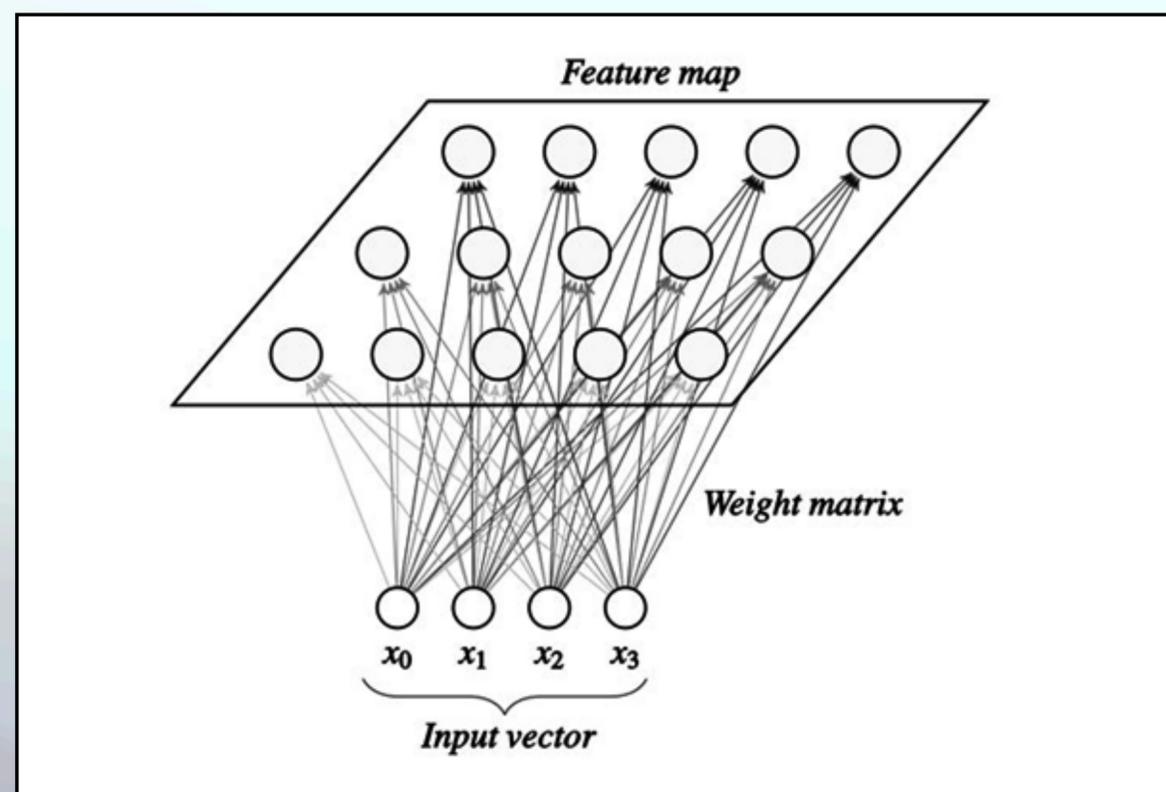


Supervised - RNN



Self Organizing Map

Una mappa auto-organizzante, o SOM, è un metodo di riduzione della dimensionalità dei dati. Si tratta di una rete neurale **non supervisionata** per costruire una rappresentazione discretizzata a bassa dimensione dallo spazio di input dei campioni di addestramento



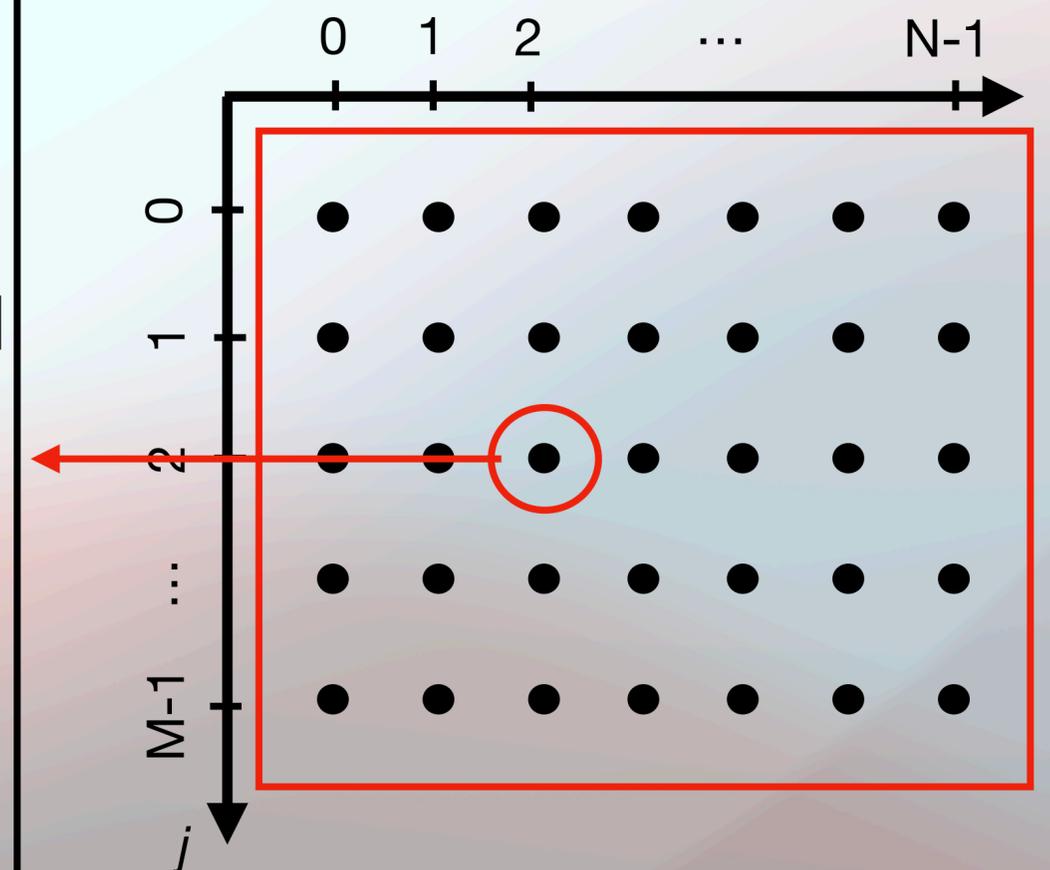
$Q = N \times M$ (neuroni)

Vettore di riferimento:

$$\vec{r}^{(i,j)} = [r_1^{(i,j)}, r_2^{(i,j)}, \dots, r_k^{(i,j)}]$$

- Neurone (i, j)
- Cardinalità k legata al vettore di input

$$\vec{x} = [x_0, x_1, \dots, x_k]$$



Addestramento

- I vettori di riferimento dei singoli neuroni vengono inizializzati con due possibili opzioni: **'pca'** o **'random'** initialization sui dati.
- Per ogni input $l \in [0, L - 1]$ viene determinato un neurone vincitore, come il neurone (i, j) che minimizza la distanza euclidea:
$$D_{min}^l = \min_{(i,j)} \sum_{k=0}^{K-1} (r_k^{(i,j)} - x_k^l)^2$$
- Definiamo una singola epoca t quando tutti gli input L sono stati elaborati dalla mappa
- Aggiornamento di tutti i vettori di riferimento: $\vec{r}^{(i,j)} \rightarrow \vec{r}'^{(i,j)}$ **IPER-PAR: $[\alpha(\frac{t}{N_e}), \sigma(\frac{t}{N_e})]$**
- Questo processo viene ripetuto per un numero selezionato di epoche (N_e) o opzionalmente fino al raggiungimento di una determinata condizione

Test preliminari sui MC per la caratterizzazione di f_μ

Sciami simulati con CORSIKA

- $\sim 5 \times 10^5$ segnali da eventi simulati
- Distribuiti uniformemente in logaritmo dell'energia (sopra $10^{18.5} eV$) direzione di arrivo e massa del primario (p, He, CNO, Fe)
- Ricostruzione con Offline

Test preliminari sui MC per la caratterizzazione di f_μ

Selezione Dataset 1 - Serie Temporali

- Media pesata dei segnali dei PMT nel WCD
- Cardinalità:
 $k = 300$ bin ($\approx 2.5\mu s$ time window) con la nuova e più veloce elettronica di acquisizione
- Normalizzazione dei segnali
- Cluster basati sulla forma del segnale

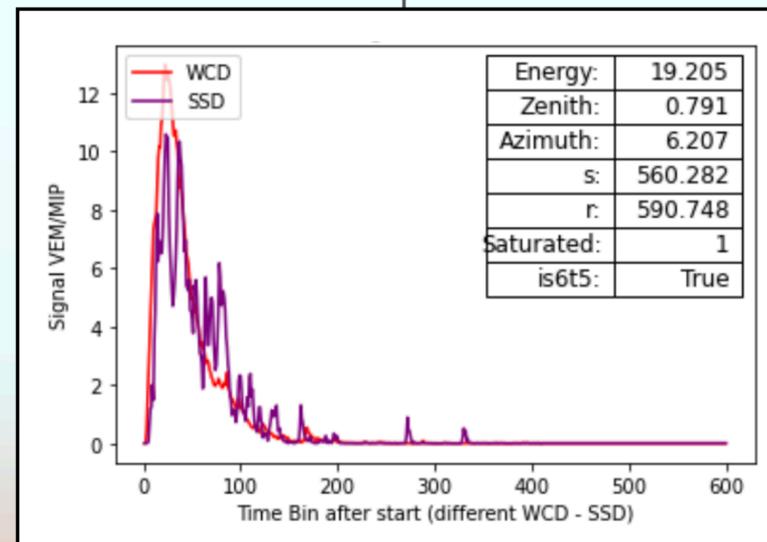
Selezione Dataset 2 - 'Meta'

Parametri ricostruiti dello sciame

- x_0 E : energia primario.
- x_1 r : distanza della stazione dall'asse dello sciame
- x_2 θ : zenith
- x_3 ψ : azimuth

Informazioni dai segnali della stazione

- x_4 S_{WCD} : segnale rilasciato in acqua [VEM].
- x_5 S_{SSD} : segnale rilasciato nello scintillatore [MIP]
- x_6 t_r : tempo di salita
- x_7 t_f : tempo di discesa.
- x_8 t_{50} : tempo al 50% del segnale totale
- x_9 A/peak : rapporto area-picco



Test preliminari sui MC per la caratterizzazione di f_μ

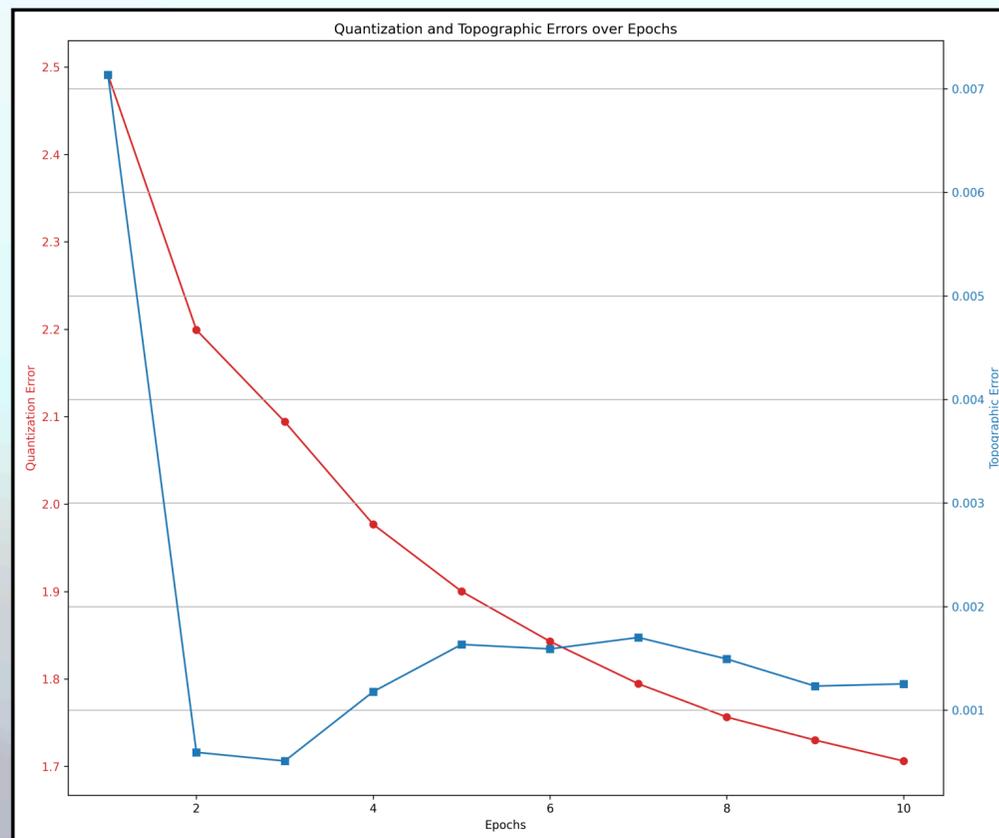
Dataset 1 - Serie Temporali

- Errori di **quantizzazione** e **topografico** in funzione del numero di epoche

- $L \simeq 3.7 \times 10^5$, $Q = \text{int}(5\sqrt{L}) = 3024$

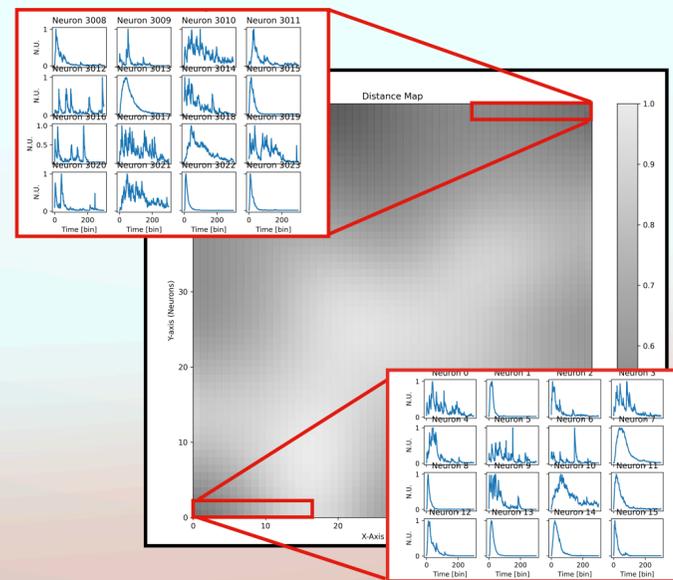
- $\alpha_0 = 0.5$, $\sigma_0 = 10$, $N_e = 10$

- Neuron Distance Map (grid: 55×55)



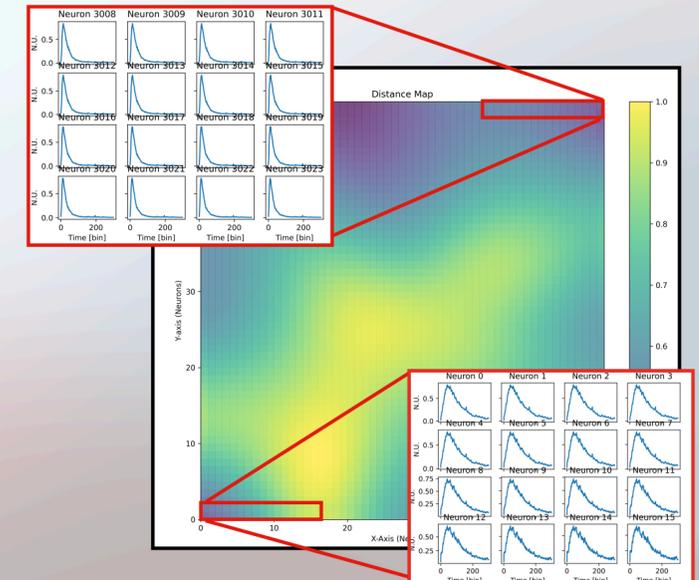
PRIMA DELL'ADDESTRAMENTO

Inizializzazione 'random'



DOPO L'ADDESTRAMENTO

Clustering di segnali simili in diverse zone della mappa

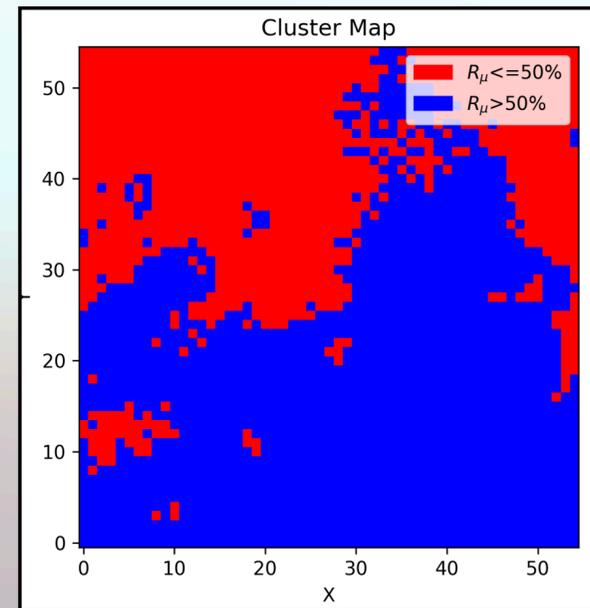
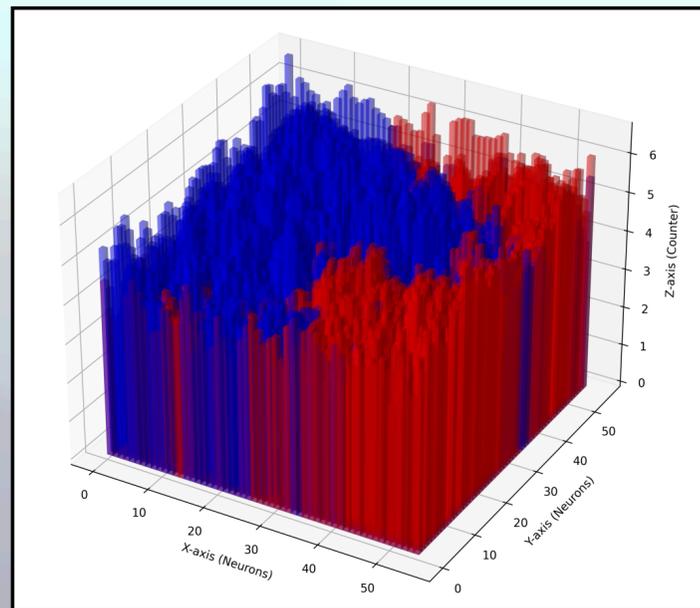
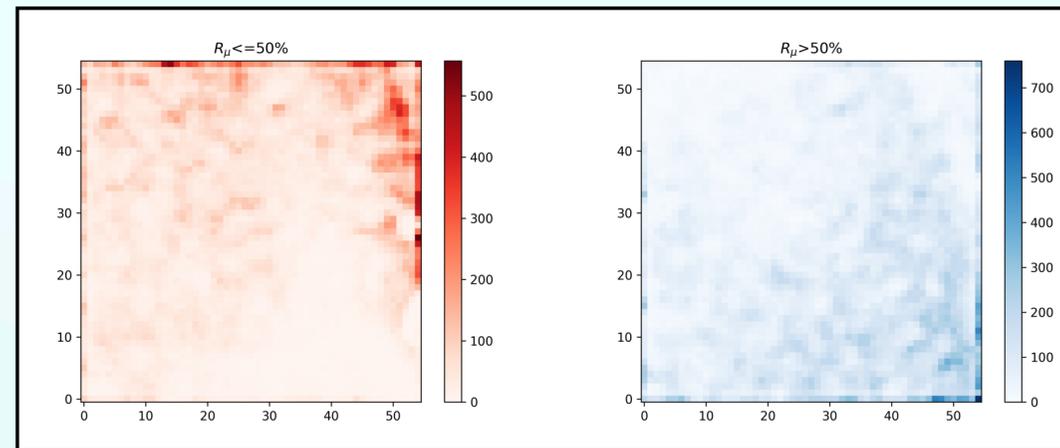


Test preliminari sui MC per la caratterizzazione di f_μ

Dataset 1 - Serie Temporali

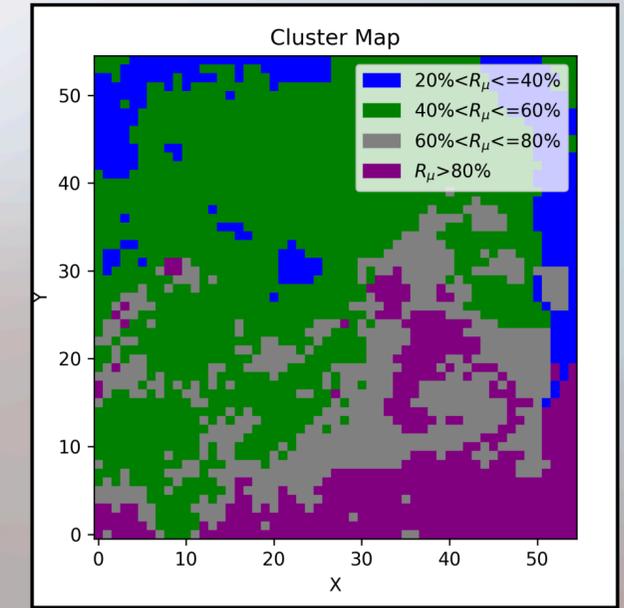
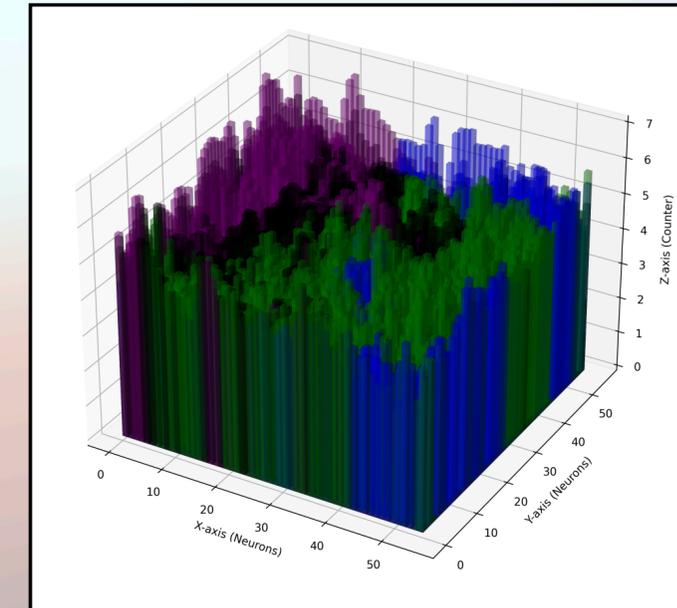
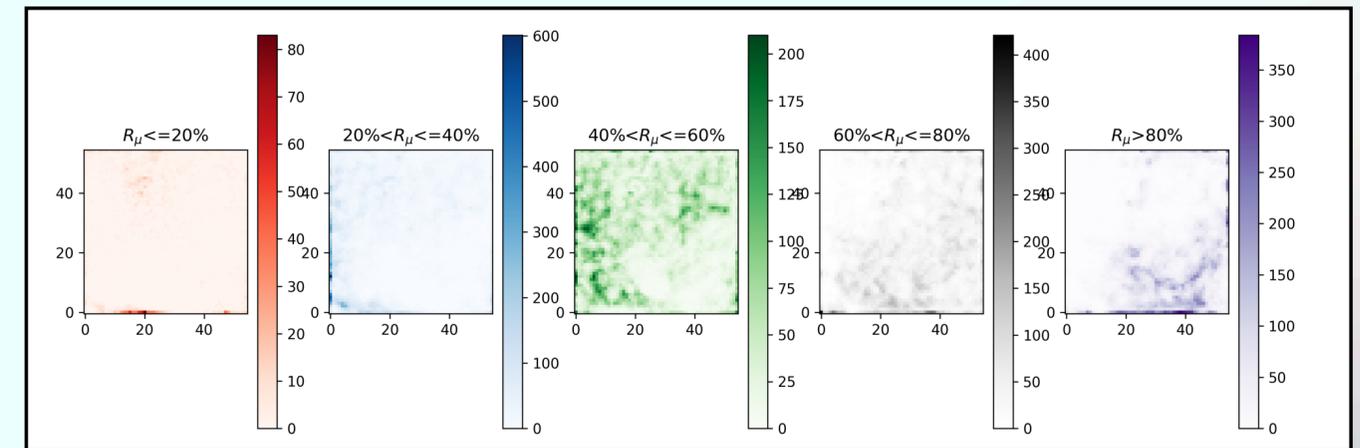
Clustering Binario

$\{f_\mu \leq 50\%, f_\mu > 50\%\}$



Clustering Multiclasse

$\{f_\mu \leq 20\%, 20\% < f_\mu \leq 40\%, 40\% < f_\mu \leq 60\%, 60\% < f_\mu \leq 80\%, f_\mu > 80\%\}$

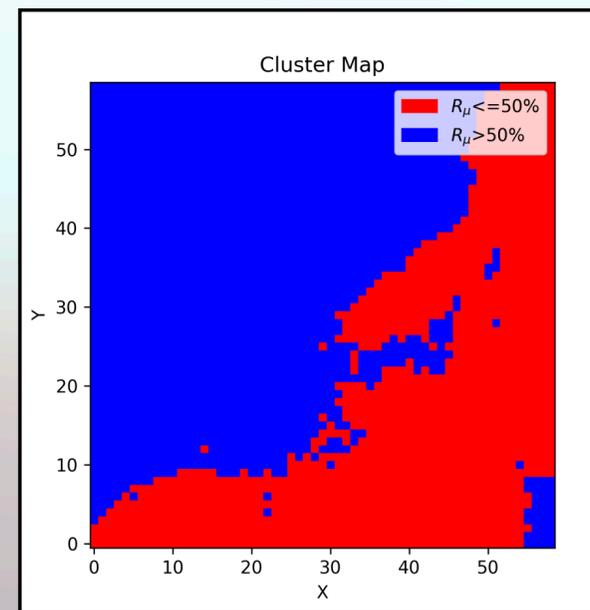
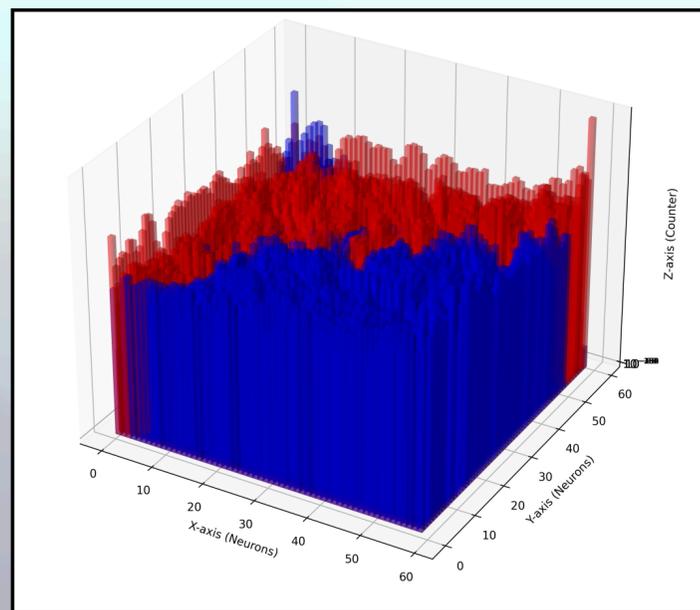
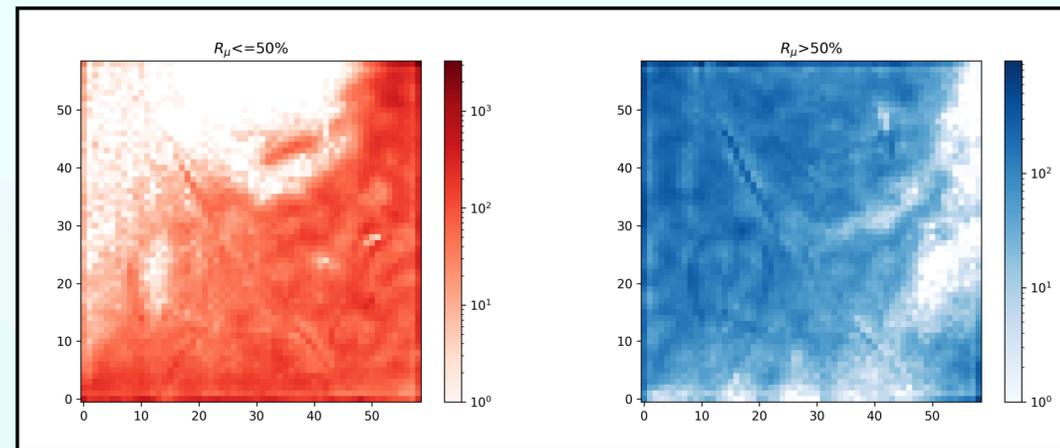


Test preliminari sui MC per la caratterizzazione di f_μ

Dataset 2 - 'Meta'

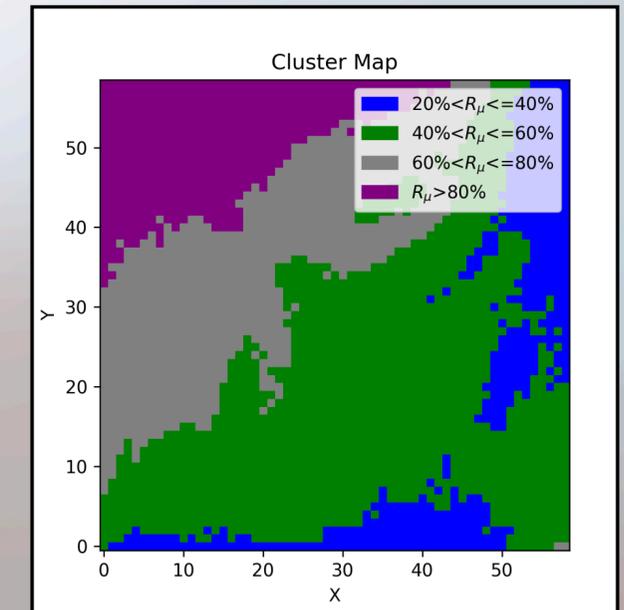
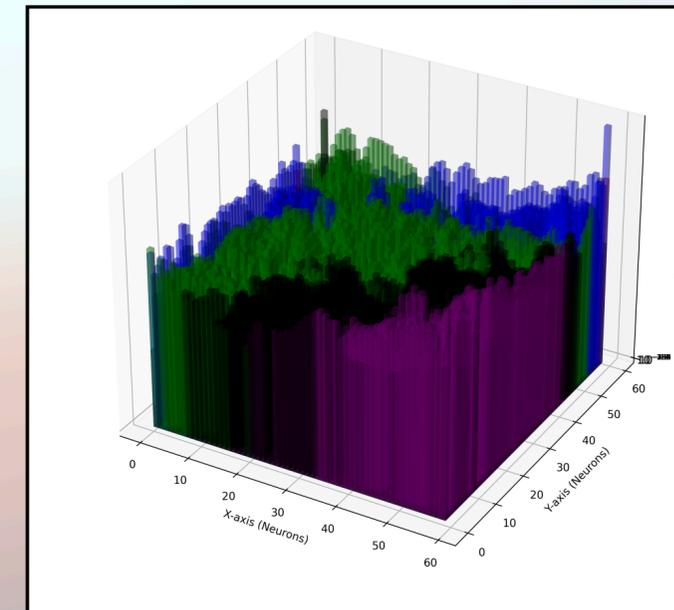
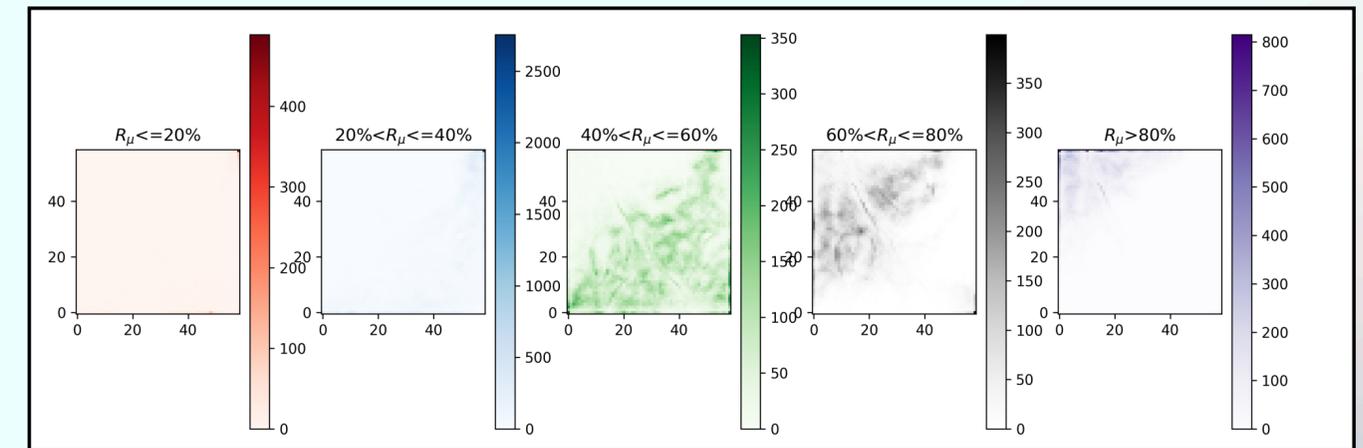
Clustering Binario

$\{f_\mu \leq 50\%, f_\mu > 50\%\}$



Clustering Multiclasse

$\{f_\mu \leq 20\%, 20\% < f_\mu \leq 40\%, 40\% < f_\mu \leq 60\%, 60\% < f_\mu \leq 80\%, f_\mu > 80\%\}$



Conclusioni

- Test preliminari dimostrano una maggiore efficacia per cluster di input ad alta dimensionalità rispetto ad algoritmi più semplici
- Risultati sui soli segnali WCD mancano delle informazioni aggiuntive legate ai parametri di ricostruzione dello sciame

Step Successivi

- Studio di input più adatti al clustering finalizzato allo studio della muon fraction
- Ricerca di strutture direttamente sui dati (simulations unbiased)
- Applicazione per classificazione 'sciame per sciame' della composizione di massa

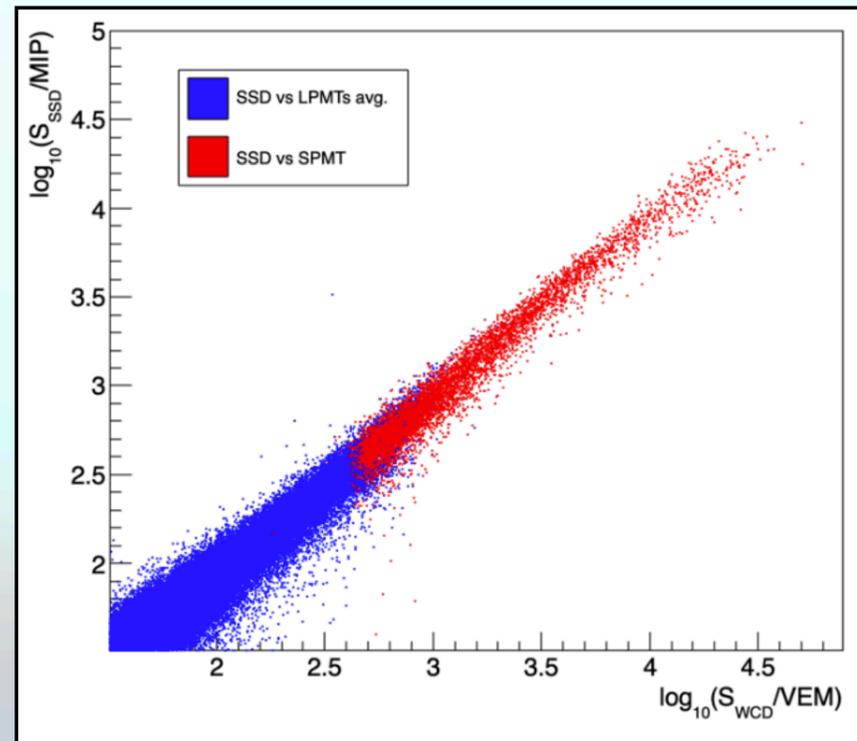
GRAZIE DELL'ATTENZIONE

BACKUP

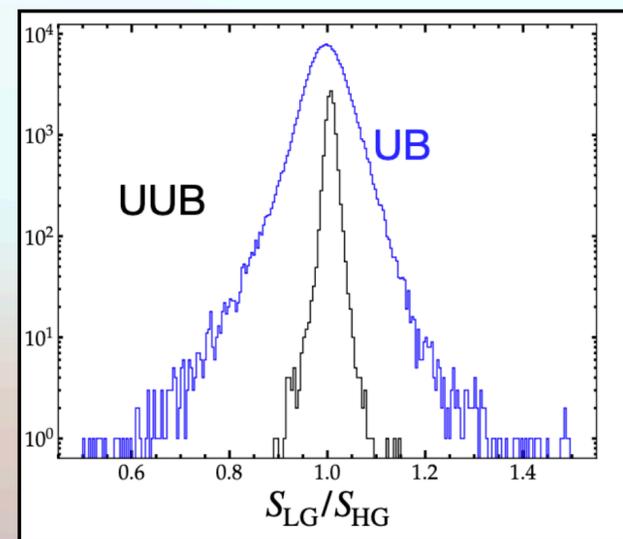
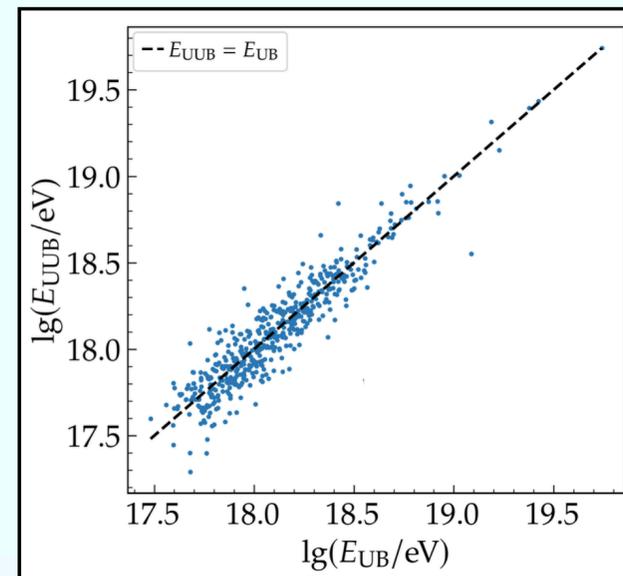
AugerPrime (Phase II)

Performances

WCD dynamic range extension

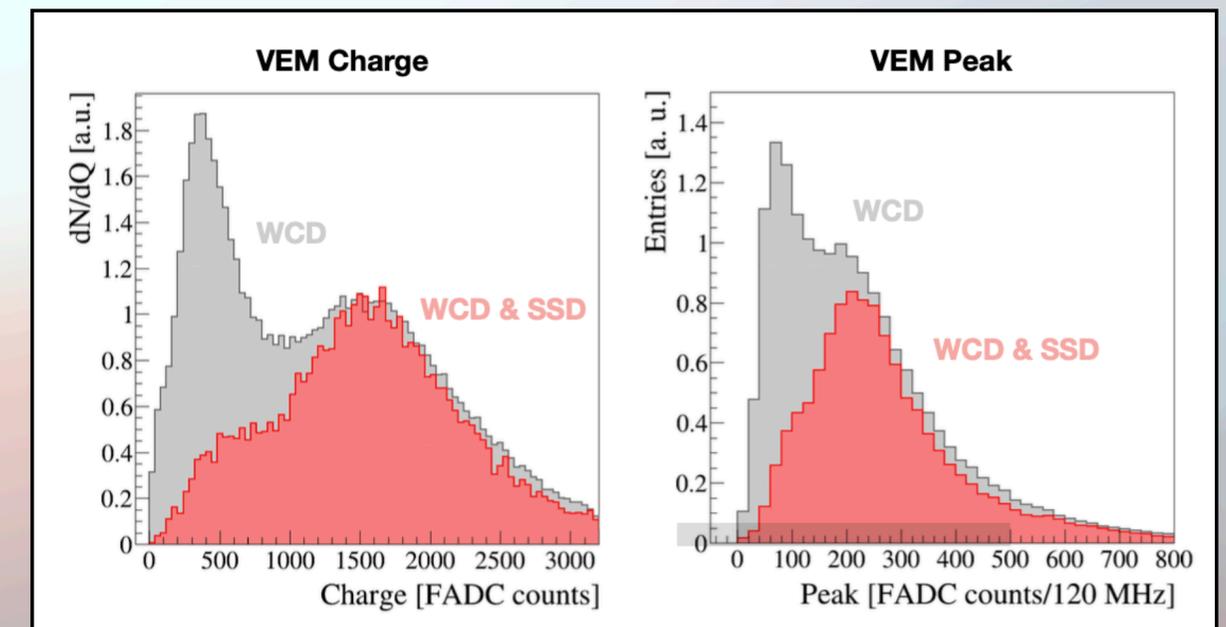
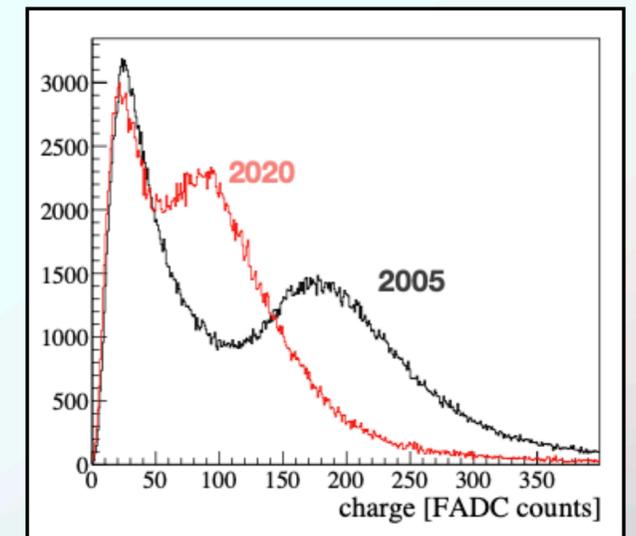


UB - UUB comparison



Calibration

L'aging del Water Cherenkov detector influisce sull'istogramma di calibrazione



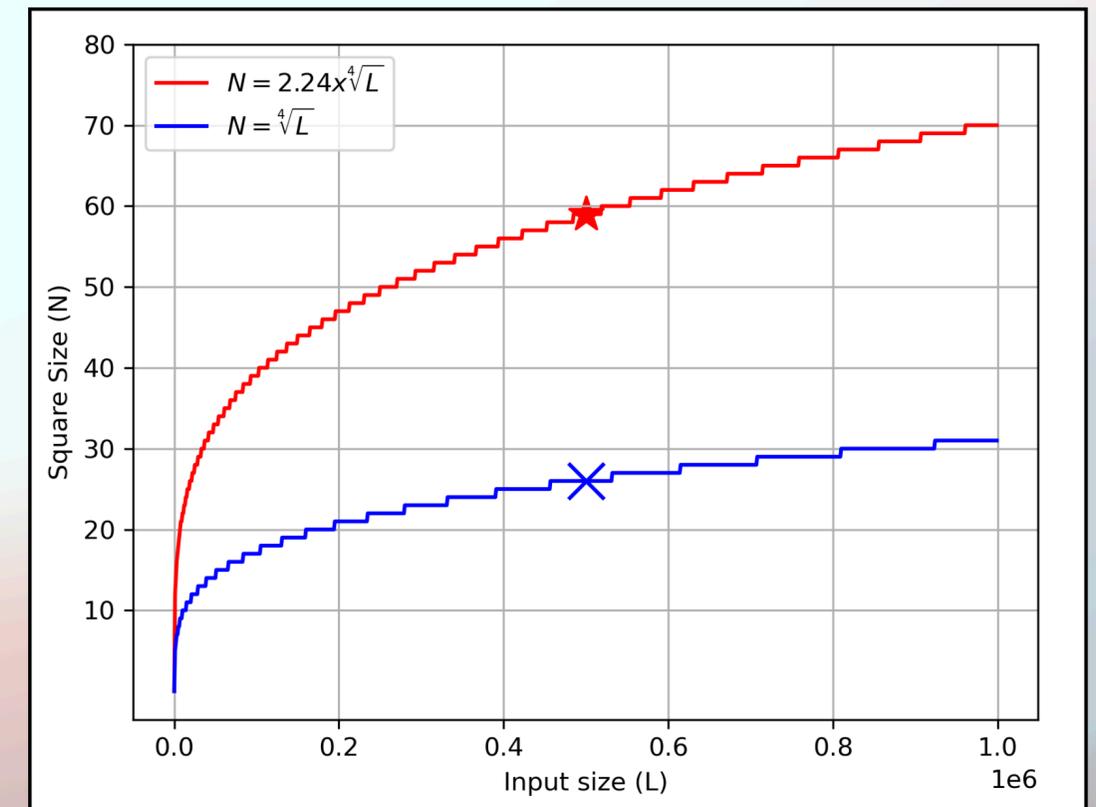
Numero di neuroni

- **Q** non deve essere troppo grande, altrimenti la mappa risultante avrebbe un singolo neurone adattato per ogni dato di input
- **Q** non deve essere troppo piccolo, poiché una mappa troppo povera non riesce a cogliere un'adeguata organizzazione dei dati in classi separate

In genere: $Q = 5\sqrt{\text{len}(\text{dataset})} = 5\sqrt{L}$

Per cui se si sceglie una griglia quadrata $N = M$

$$N = \sqrt{5\sqrt{L}} \simeq 2.24\sqrt[4]{L}$$



Aggiornamento pesi

Quando si definisce un neurone vincitore, tutti i pesi sono aggiornati come:

$$r_k'^{(i,j)} = r_k^{(i,j)} + \alpha \left(\frac{t}{N_e} \right) H \left(\frac{t}{N_e}, \vec{d}_{min} - \vec{d}_{(i,j)} \right) (x_k^l - r_k^{(i,j)})$$

peso (i,j)

Aggiornato all'input ***l***-esimo

peso (i,j)

Aggiornato all'input ***(l-1)***-esimo

Differenza tra input ***l***-esimo e
peso

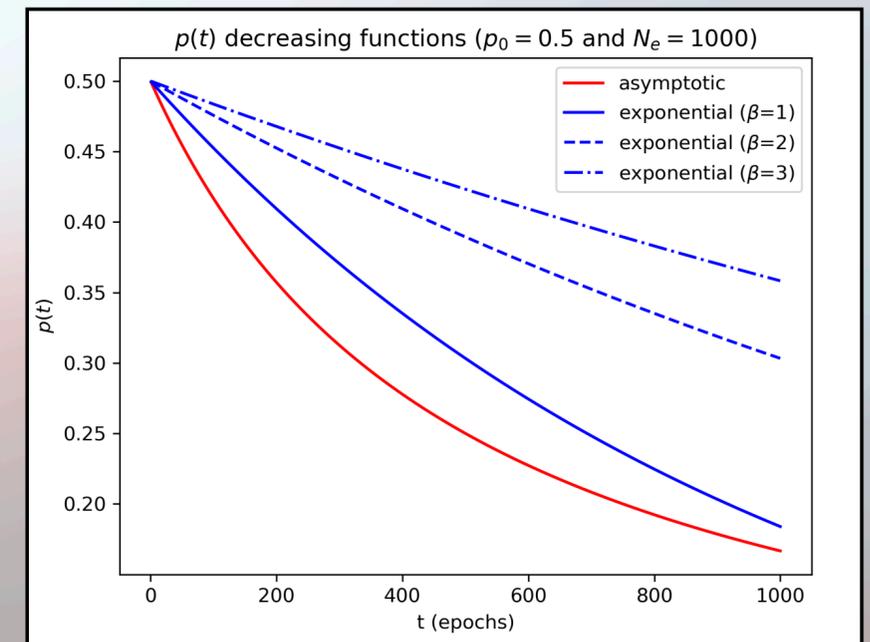
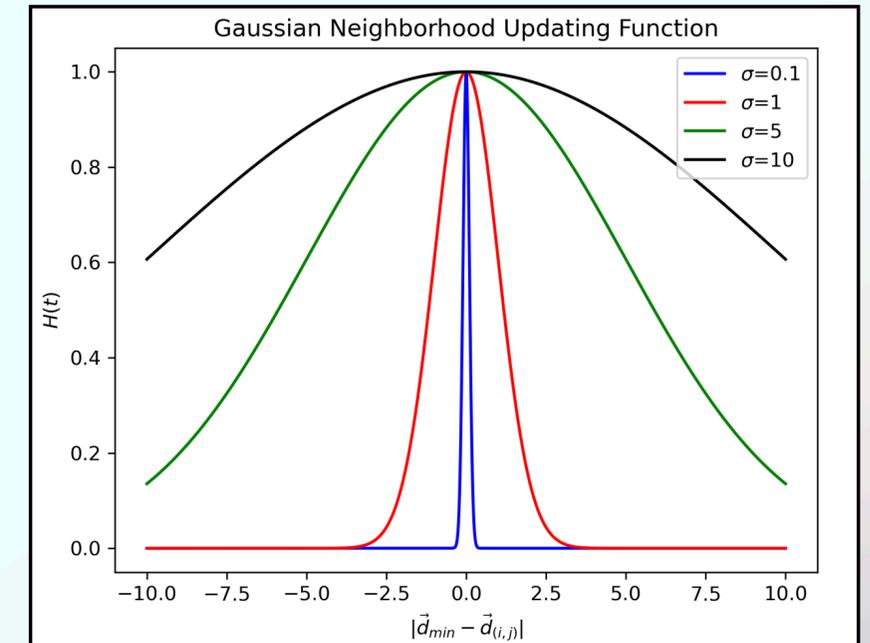
Aggiornamento pesi

Quando si definisce un neurone vincitore, tutti i pesi sono aggiornati come:

$$r_k^{(i,j)} = r_k^{(i,j)} + \alpha \left(\frac{t}{N_e} \right) H \left(\frac{t}{N_e}, \vec{d}_{min} - \vec{d}_{(i,j)} \right) (x_k^l - r_k^{(i,j)})$$

- **Learning Rate** α : iperparametro, funzione di N_e
- **Funzione di aggiornamento di vicinanza:**

$$H \left(\frac{t}{N_e}, \vec{d}_{min} - \vec{d}_{(i,j)} \right) \text{ in genere una Gaussiana: } \exp \left[- \frac{(\vec{d}_{min} - \vec{d}_{(i,j)})^2}{2\sigma^2 \left(\frac{t}{N_e} \right)} \right]$$



Monitoraggio del training

Errori di quantizzazione e topografico

- A differenza dei modelli supervisionati, in cui possiamo minimizzare una funzione di perdita, qui possiamo monitorare il processo di “addestramento” tramite ***l'errore di quantizzazione*** definito come:

$$QE = \frac{\sum_{l=0}^{L-1} D_{min}^l}{L}$$

- Possiamo controllare anche ***l'errore topografico*** che definisce quanto è buona la topografia della mappa, per preservare la vicinanza tra neuroni simili:

$$TE = \frac{\text{N. casi in cui i primi due BMU non sono vicini}}{\text{N. casi totali}} \times 100 \%$$

Implementazione di una libreria ottimizzata per lavoro su GPU

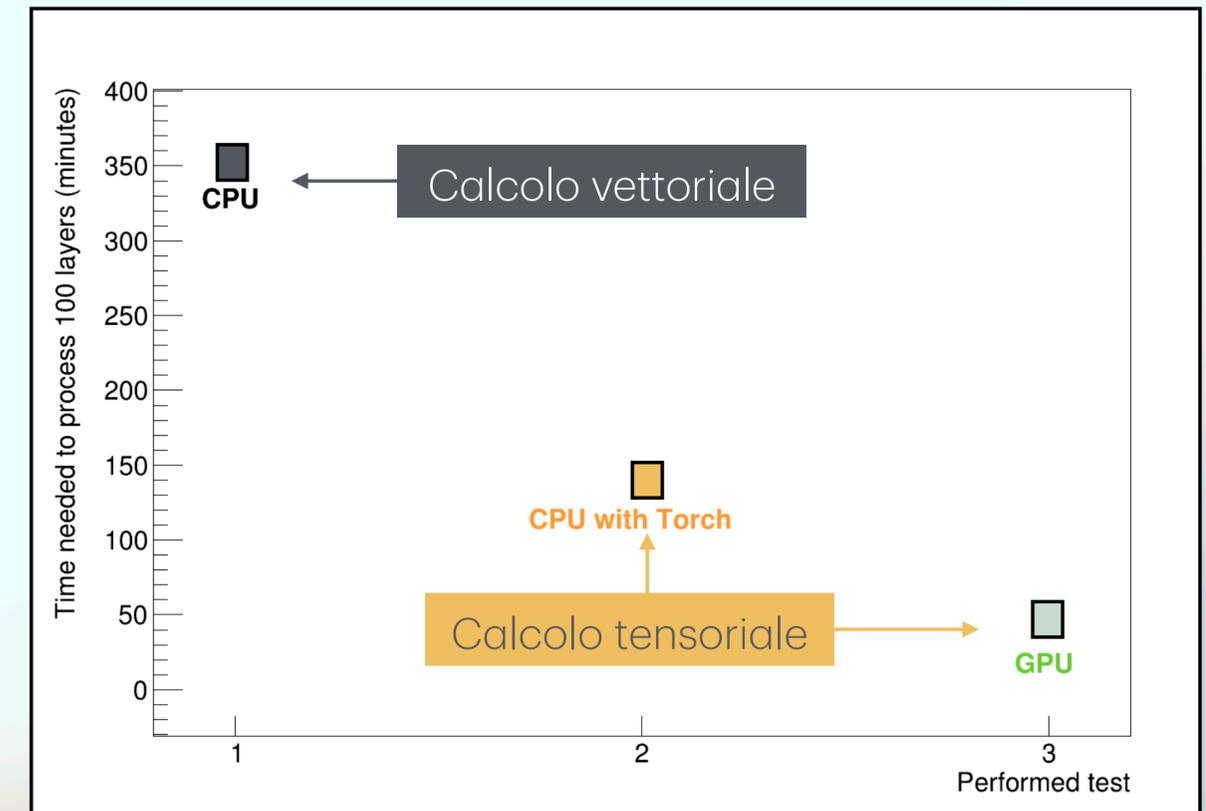
- Disponibili librerie basate su Numpy (calcolo vettoriale) delle Self Organizing Maps (SOM).

<https://github.com/JustGlowing/minisom.git>

- Sviluppo di una libreria ottimizzata e più versatile per l'utilizzo di SOM in diversi contesti (fisici e non), basato sull'utilizzo di **pyTorch** per il calcolo tensoriale su GPU

A disposizione:

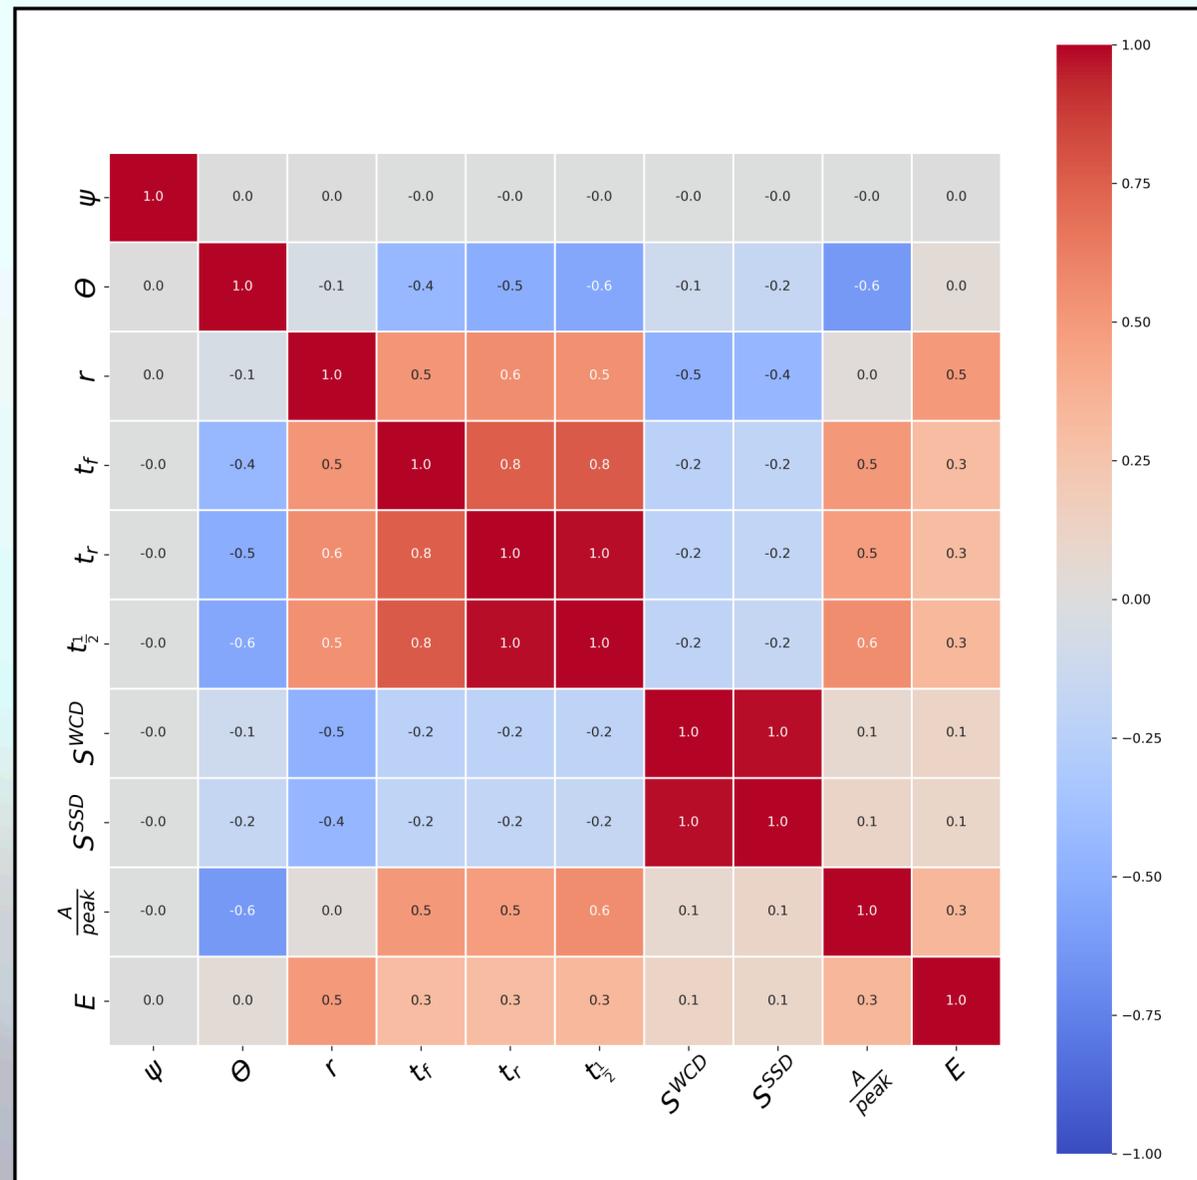
2 GPU's TESLA v100 - 32 GB



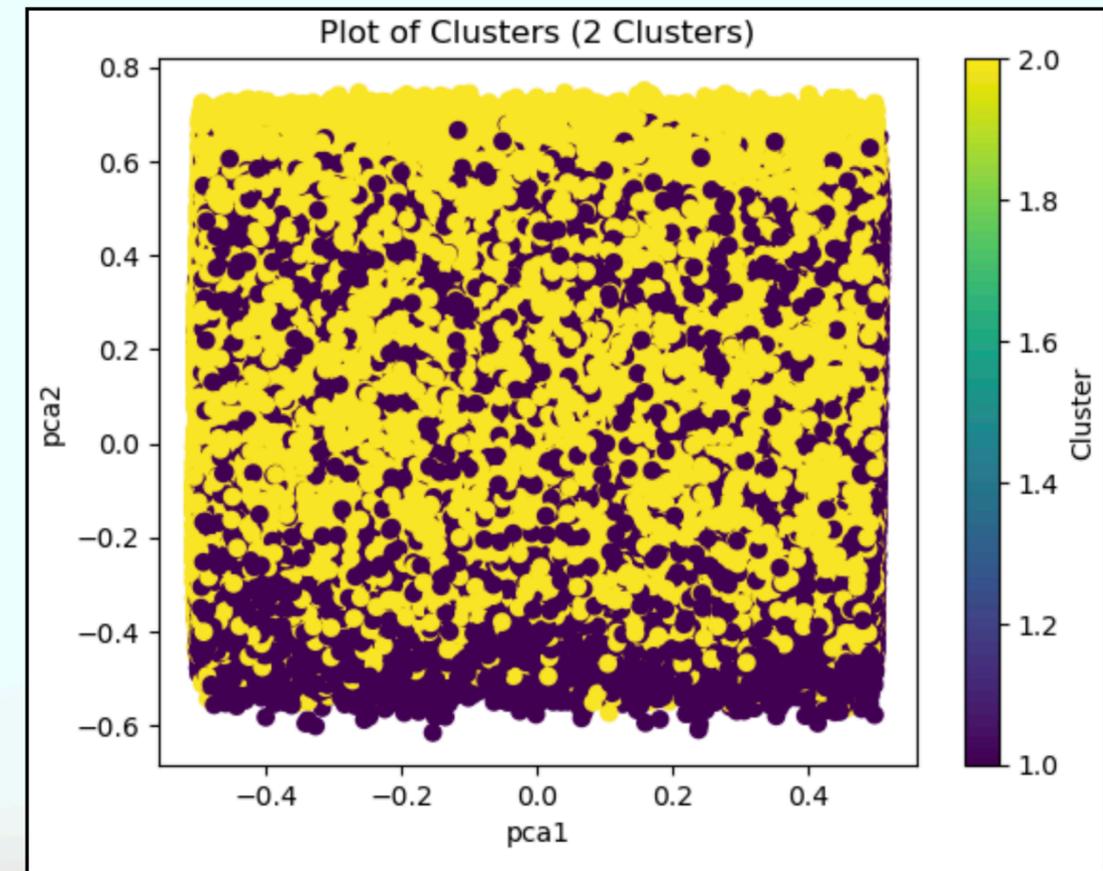
Fino a $\times 10$ volte più veloce con la nuova libreria su GPU

K-Means algorithm

Selezione dataset 2 - 'Meta'



K=2 , 2 PCA Components



Score

Accuracy Score (Train): 0.19581108931292882
 Accuracy Score (Test): 0.19556767714094825