

Reconstruction des événements à l'aide de Machine Learning en physique des particules

Journée thématique "activités Machine Learning à l'IPHC"

1/10/2020

Emery Nibigira

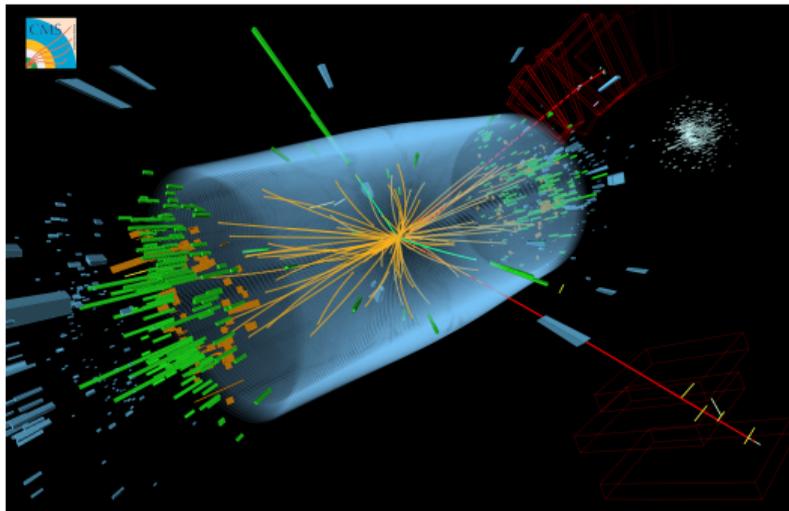


Sommaire

- Contexte
- Problème de classification
- Algorithmes de classification
- Applications
- Conclusion

Reconstruction des événements en physique des particules

repose sur notre capacité à détecter les particules issues de chaque collision

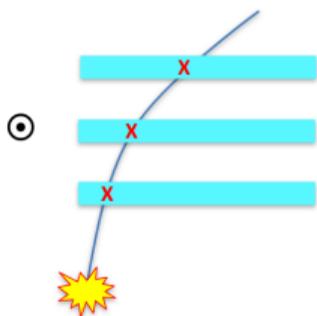


- **trajectographie**

points de passage

- **trace**

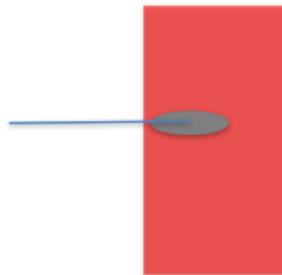
- **impulsion** $p = 0.3B \times r$



- **calorimétrie**

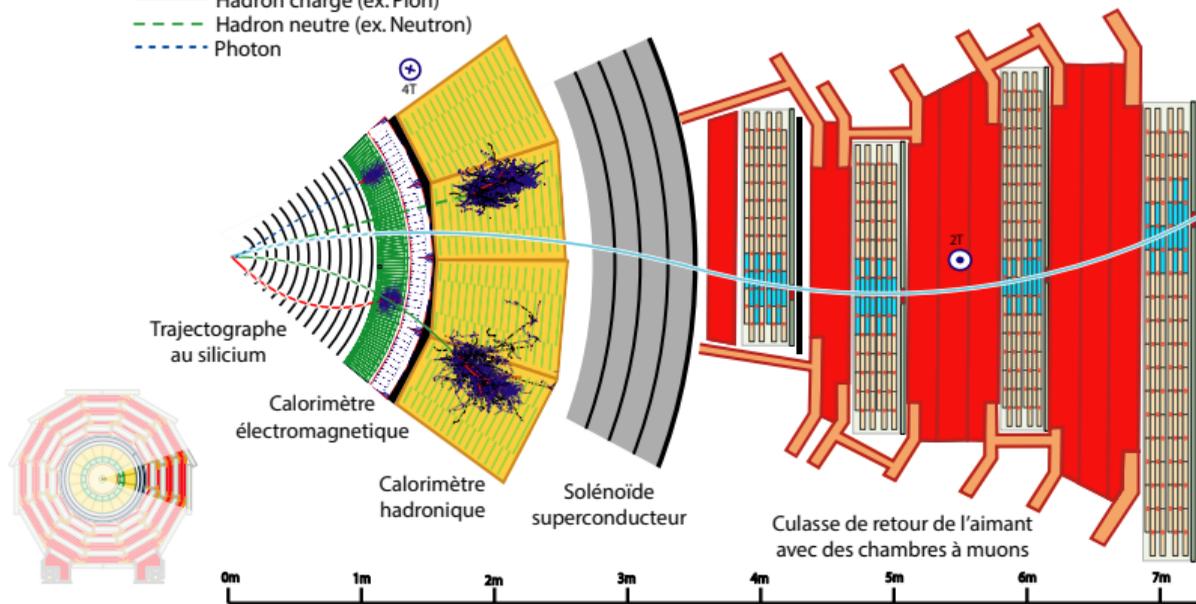
dépôts d'énergie

- **énergie**



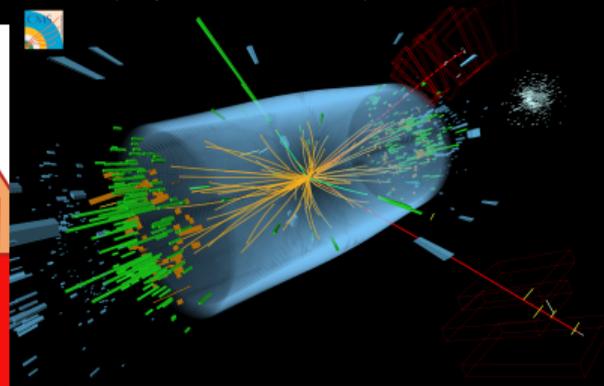
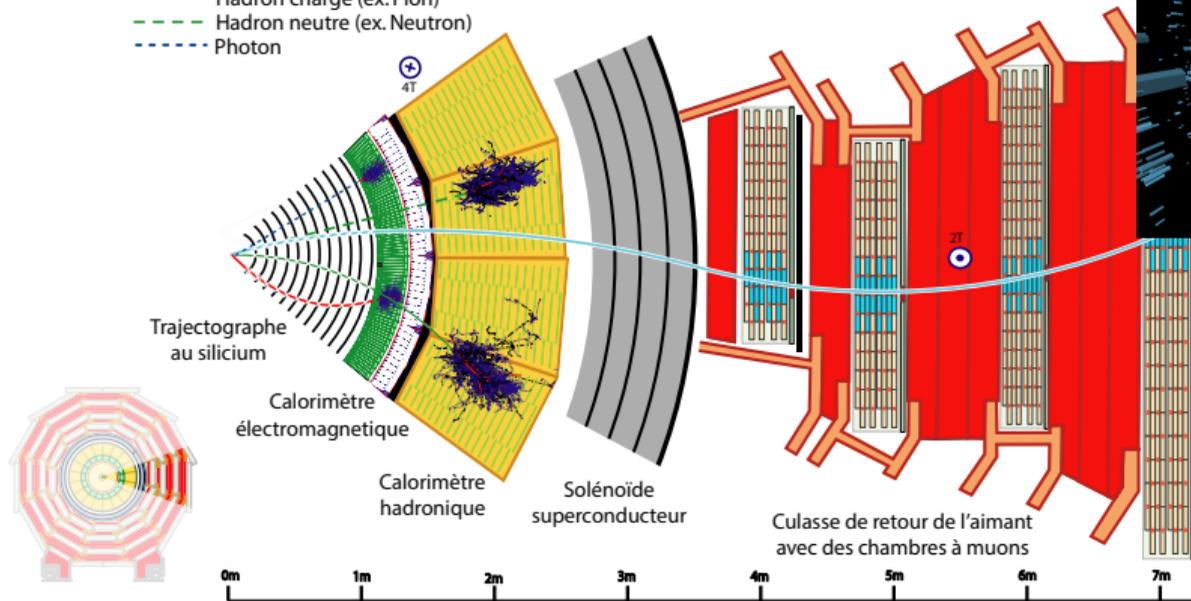
Légende:

- Muon
- Électron
- Hadron chargé (ex. Pion)
- - - Hadron neutre (ex. Neutron)
- - - Photon



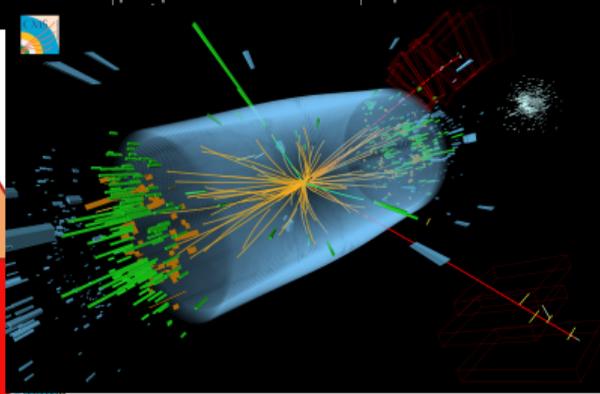
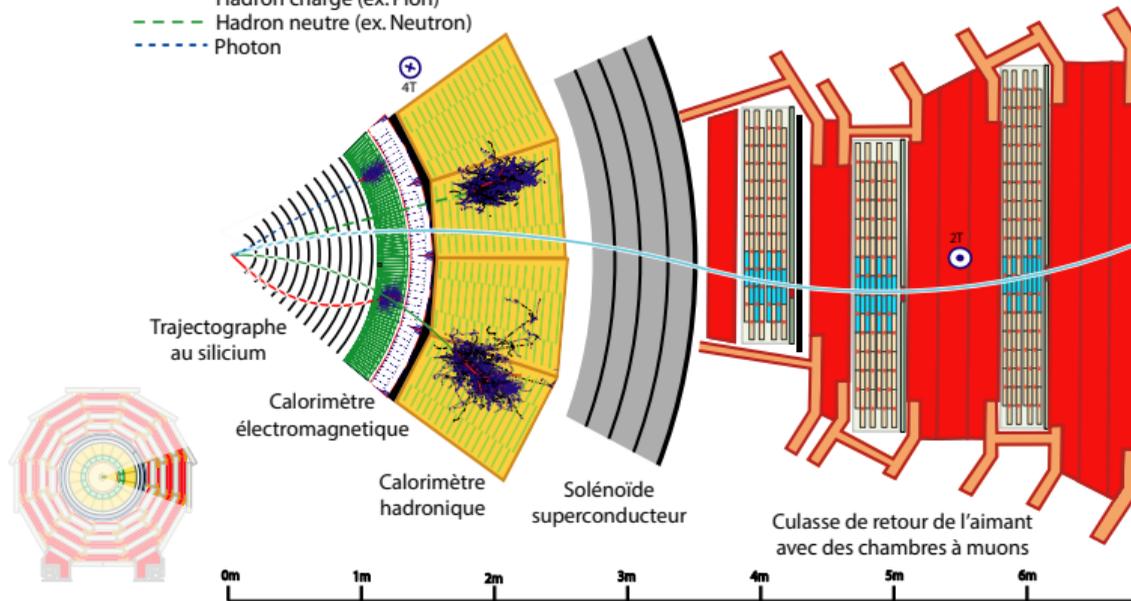
Légende:

- Muon
- Électron
- Hadron chargé (ex. Pion)
- - - Hadron neutre (ex. Neutron)
- - - Photon



[1] Identifier les particules électrons, muons, ...

- Légende:
- Muon
 - Électron
 - Hadron chargé (ex. Pion)
 - - - Hadron neutre (ex. Neutron)
 - - - Photon

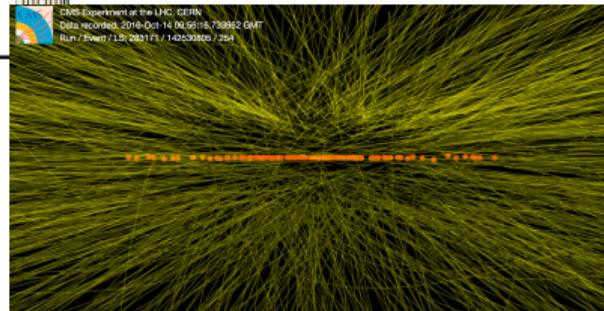


[1] Identifier les particules électrons, muons, ...


[2] Identifier le processus

$pp \rightarrow ? \rightarrow \text{électrons, muons, ...}$

Prediction: Modèle Standard, Autre modèle



Collision pp \implies croisement entre deux **paquets de protons** (10^{11} protons chacun au LHC)



⊙ Jusqu'à 10^9 collisions par seconde

★ **taux de collision élevé** \longrightarrow acquisition (électronique)

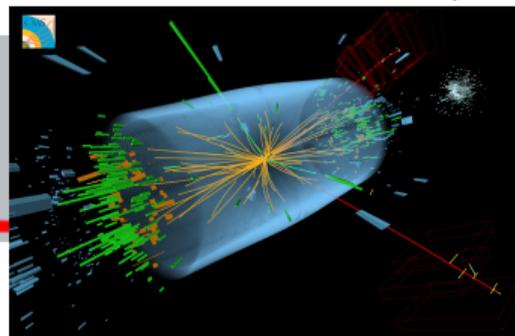
★ **grande quantité de données (Big data)** \longrightarrow computing, stockage

⊙ Nécessite un système de **filtrage**:

- on ne peut pas tout stocker

- sélectionner que les événements intéressants pour la physique

Collision pp \implies croisement entre deux **paquets de protons** (10^{11} protons chacun au LHC)



⊙ Jusqu'à 10^9 collisions par seconde

★ **taux de collision élevé** \longrightarrow acquisition (électronique)

★ **grande quantité de données (Big data)** \longrightarrow computing

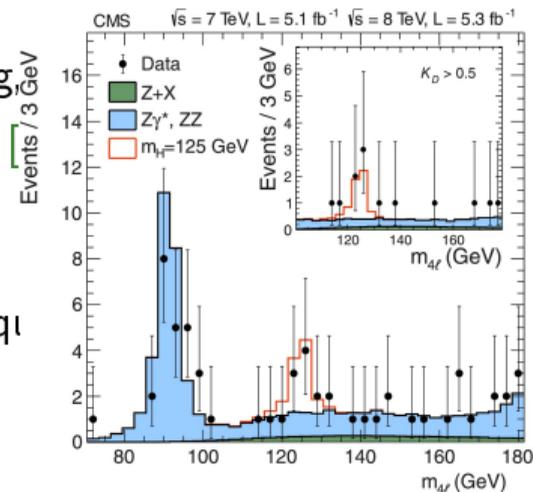
⊙ Nécessite un système de **filtrage**:

● on ne peut pas tout stocker

● sélectionner que les événements intéressants pour la physique

⊙ **Analyse physique** (signal vs bruit, mesure de précision)

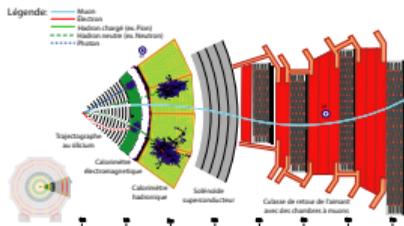
○ données simulées et observées



Utilisation de Machine Learning (ML)

- **Supervisé:** classification, regression
- **Non supervisé**
- ...

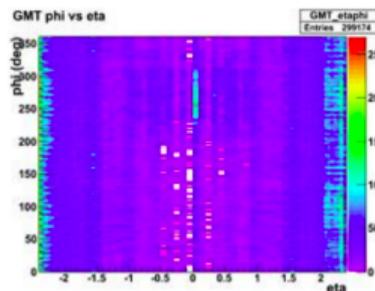
Identification, reconstruction



Computing



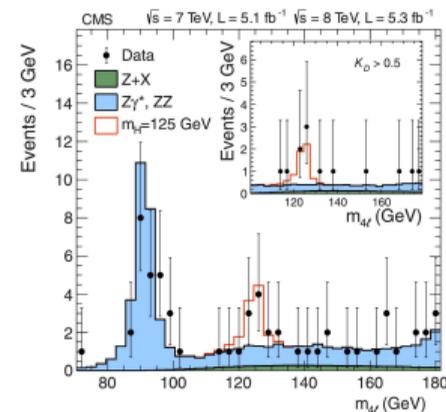
Monitoring



Électronique

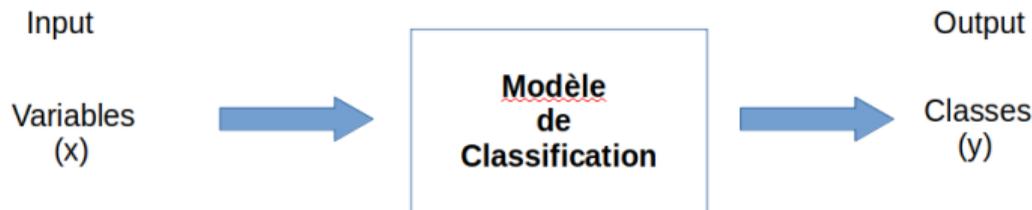


Analyse



Problème de classification

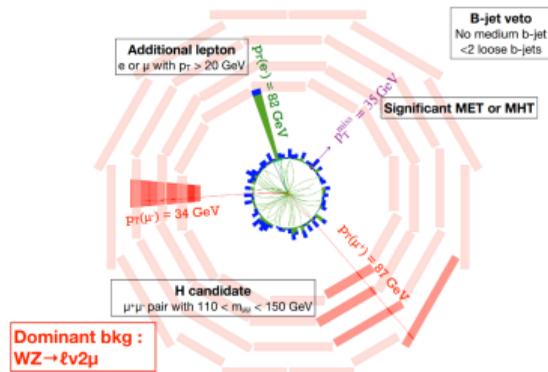
Rappel (Présentation de E. Chabert)



Prenons un exemple: Higgs

A chaque événement,
une série de variables dont on connaît les valeurs

- input: variables discriminantes (x_i)
- output: 2 classes \rightarrow oui (événement Higgs) ou non



Classification: construire à un modèle, basé sur des algorithmes
visant à prédire le groupe d'appartenance Y pour chaque valeur x_i

Problème de classification

Échantillon d'entraînement

Id	masse	impulsion	charge	classe
1	34	90	-1	Non
2	25	170	1	Non
3	84	90	1	Oui
4	50	100	-1	Non
5	22	80	-1	Oui
6	139	200	1	Non
7	75	80	1	Oui
8	43	12	-1	Non
9	40	90	1	Non
10	84	70	-1	Oui

Échantillon Test

Id	masse	impulsion	charge	classe
11	86	65	-1	?
12	115	170	1	?
13	32	11	1	?
14	45	99	-1	?
15	76	80	1	?

Principe:

1. Entraînement:

- l'algorithme apprend à généraliser
- construit un modèle prédictif

2. Test:

- à partir du modèle prédictif
- faire une déduction

Les algorithmes de classification

De nombreux algorithmes

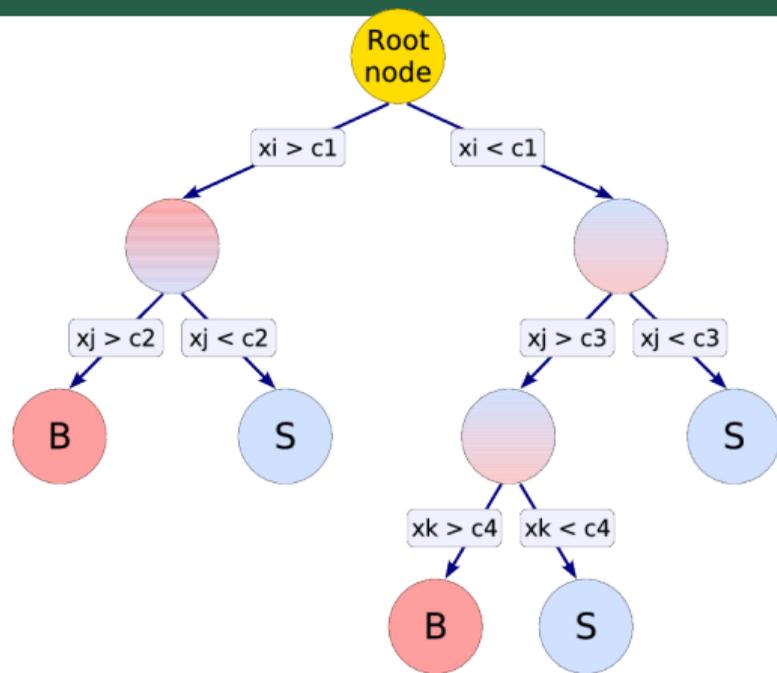
- ★ réseaux de neurones
- ★ arbres de décision
- ★ ...

Et de nombreux outils



Arbres de décision

10



Arbre de décision: succession de coupures séquentielles pour séparer au mieux signal et bruit

- à la **racine** → l'ensemble de l'échantillon
- critère de séparation (**nœuds**) → valeur seuil
- critère d'arrêt
- à chaque **feuille** → type de classe : S ou B

Paramètres ajustables (les plus utilisés)

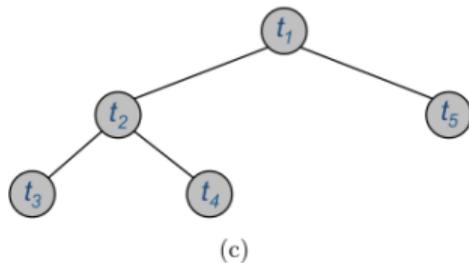
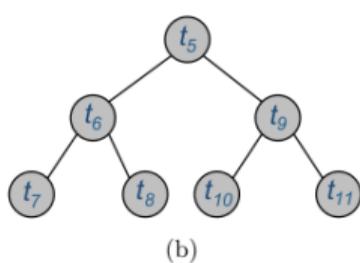
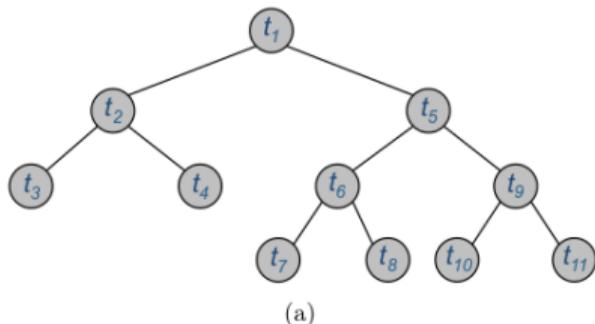
profondeur maximale

nombre minimal d'événements dans les nœuds

Les arbres de décision: simple, peu de préparation des données,...
sensible au **sur-apprentissage (overfitting)**
→ éviter le sur-apprentissage: paramètres ajustables, **pruning**

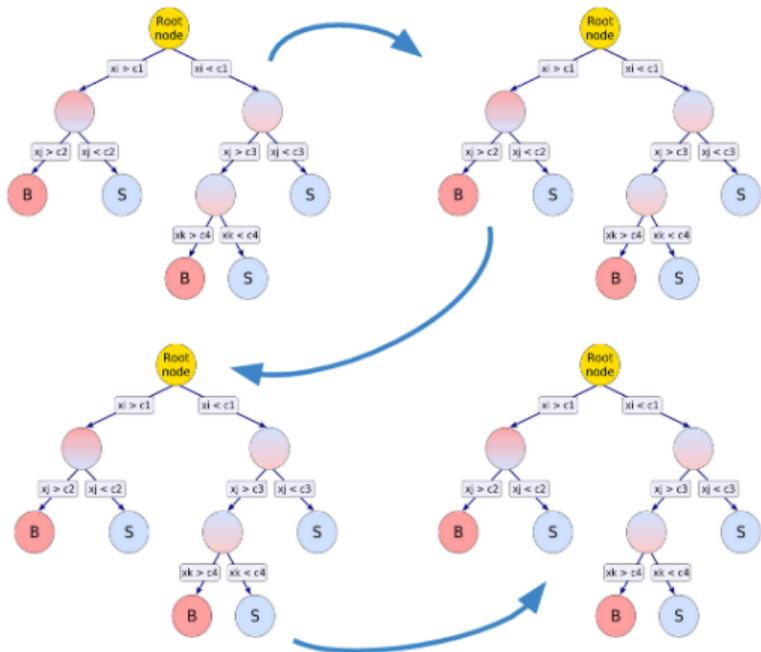
Arbres de décision - pruning

- l'arbre de décision maximal (a) est simplifié en un de ses sous-arbres (b), (c)
- en supprimant une ou plusieurs de ses branches de l'arbre non pertinentes
- et en les remplaçant par des feuilles



Arbres de décision - Boosting (BDT)

12



boosting: construire itérativement de nouveaux arbres

Les événements mal classés (taux d'erreur) sont boostés

Différents algorithmes

- **AdaBoost** (Adaptive Boosting)
- **Gradient Boosting**
 - **XGBoost** (eXtreme Gradient Boosting)

Paramètres ajustables (les plus utilisés)

nombre d'arbres

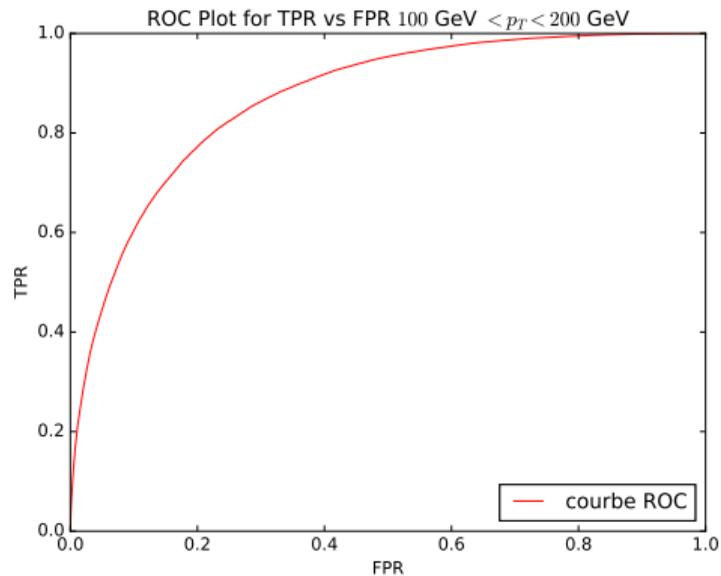
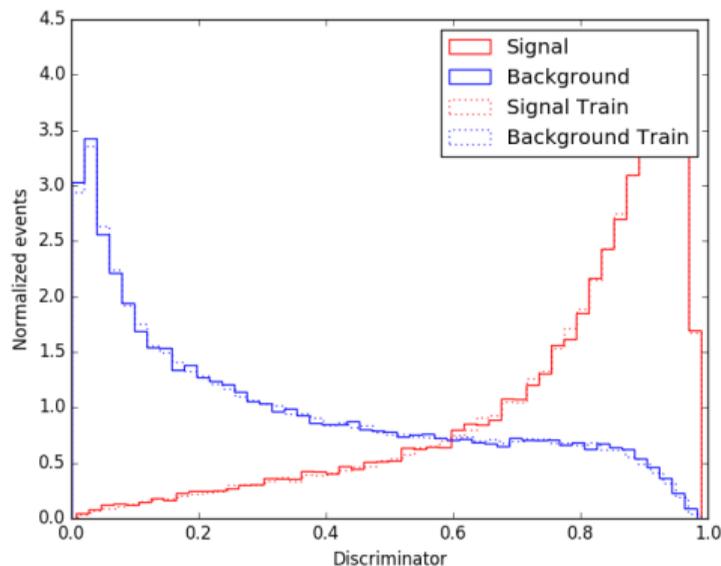
paramètres de boost selon l'algorithme

Performances

ROC curve (receiver operating characteristic curve):

graphique montrant les performances de l'algorithme de classification

- **TPR** (True Positive Rate) vs **FPR** (False Positive Rate)



choix du modèle (paramètres), variables, échantillon (représentatif)

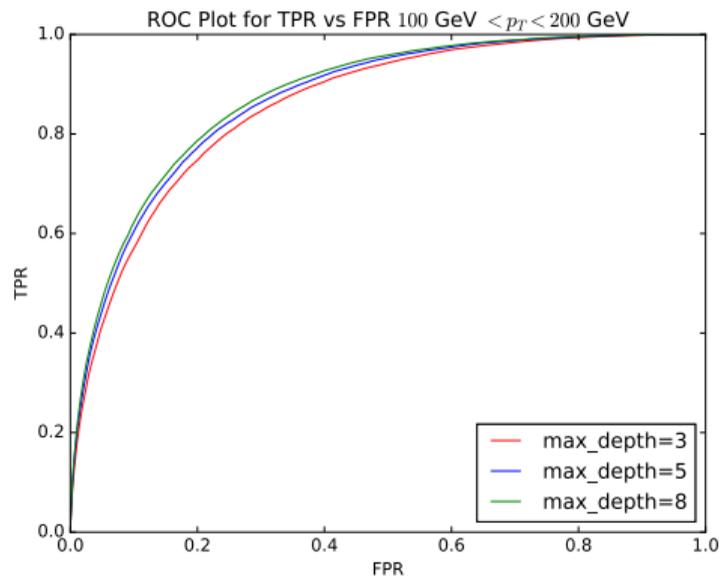
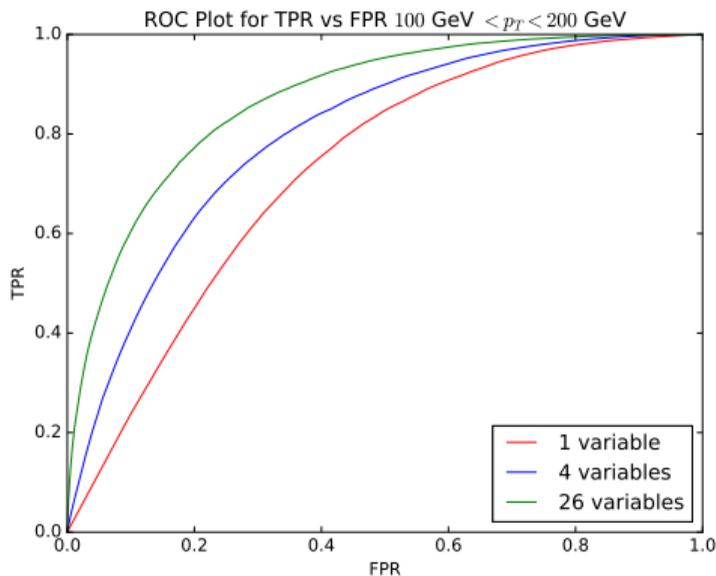
Performances

14

ROC curve (receiver operating characteristic curve):

graphique montrant les performances de l'algorithme de classification

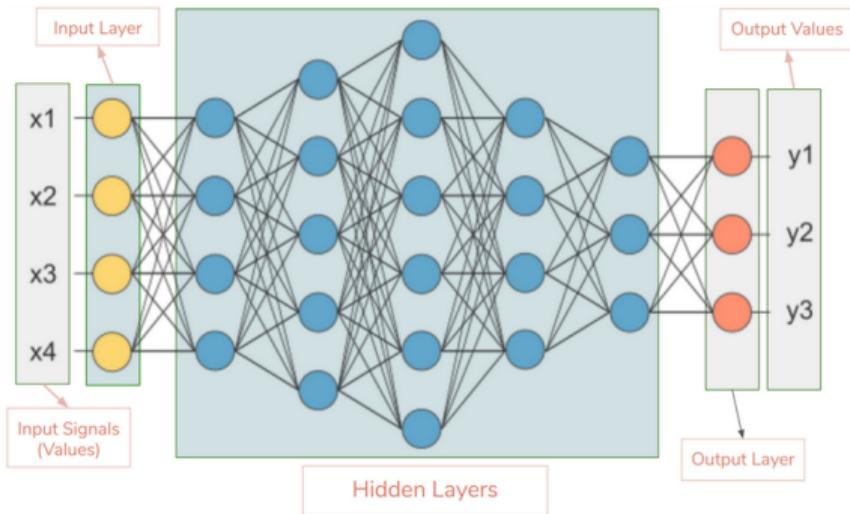
- **TPR** (True Positive Rate) vs **FPR** (False Positive Rate)



choix du modèle (XGBoost), variables, échantillon (représentatif)

Réseaux de neurones - DNN

15

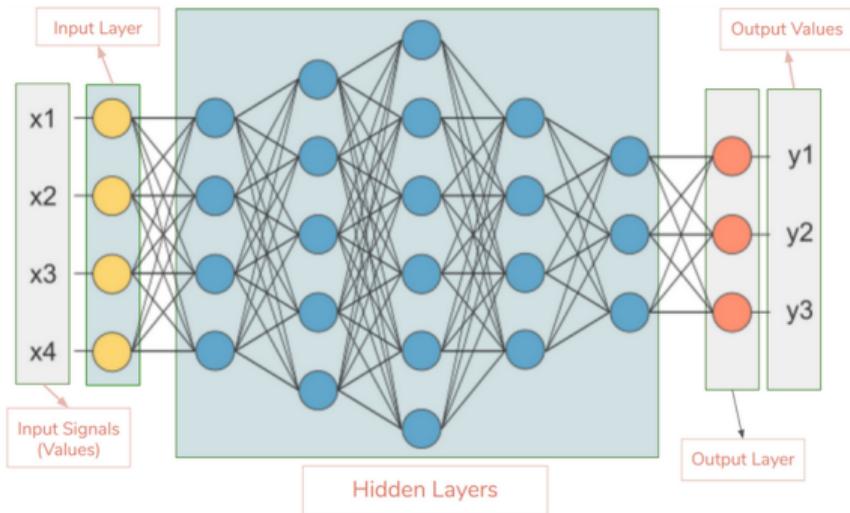


de plus en plus populaire

L'entraînement peut être parallélisé

CPU ou GPU

Réseaux de neurones - DNN



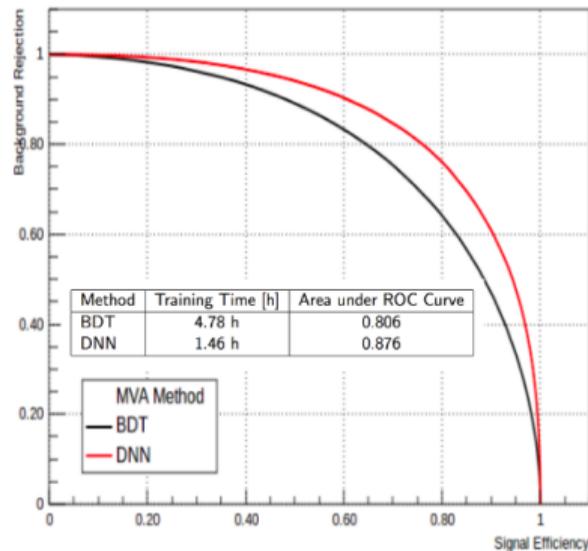
de plus en plus populaire

L'entraînement peut être parallélisé

CPU ou GPU

La performance dépend aussi de la paramétrisation du modèle (optimisation)

Background Rejection vs. Signal Efficiency



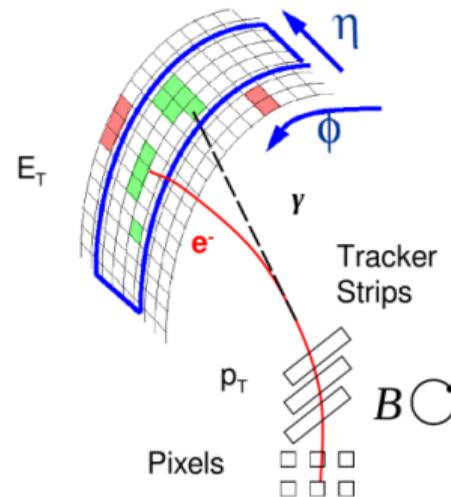
indico.cern.ch/event/798721

Gain en temps d'entraînement

Applications – Identification des électrons

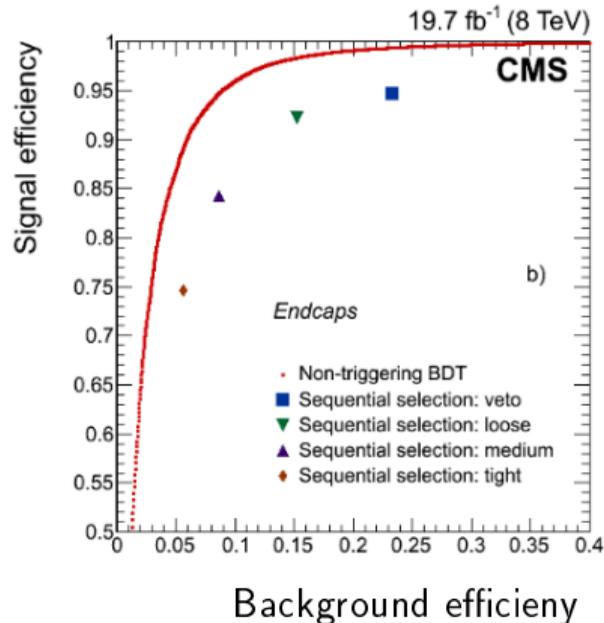
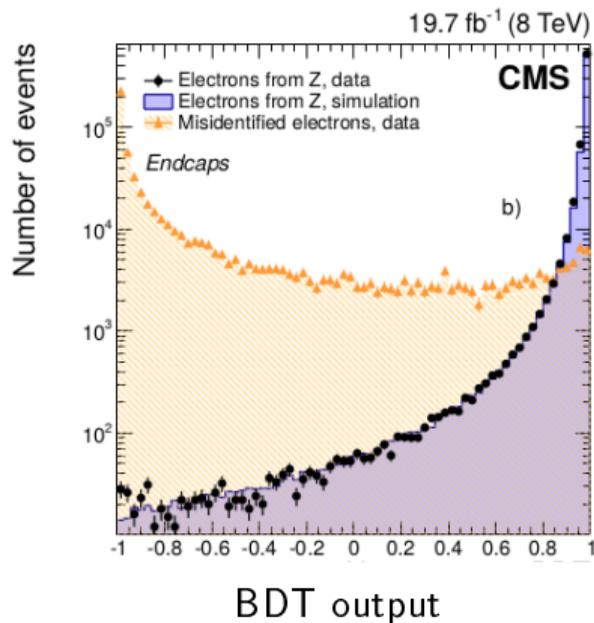
16

- Un électron est défini à partir de sa **trace**
- ses **dépôts d'énergie** dans différentes cellules du calorimètre électromagnétique



séparer les électrons provenant de sources primaires des autres (bruit de fond)

Applications – Identification des électrons

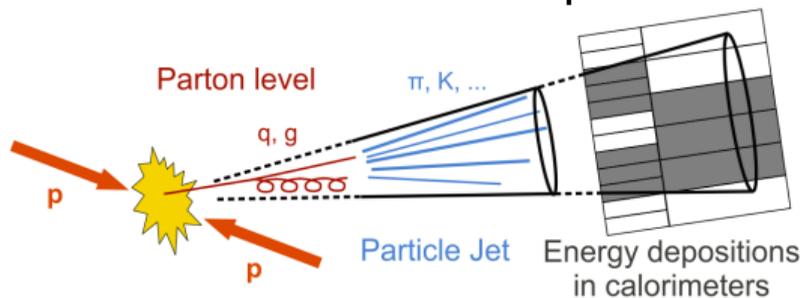


Amélioration de l'identification avec l'utilisation du BDT.

Applications – Identification des jets

18

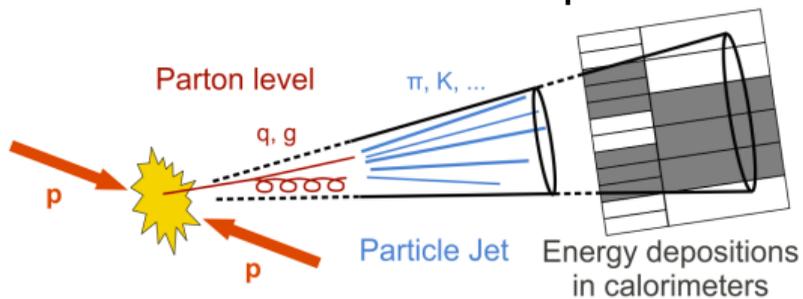
- signature expérimentale laissée par **quarks** (quark-b, quark-c, ...) et **gluons**
- ★ **traces**
- ★ dépôts d'énergie
calorimètres **EM** et **hadronique**



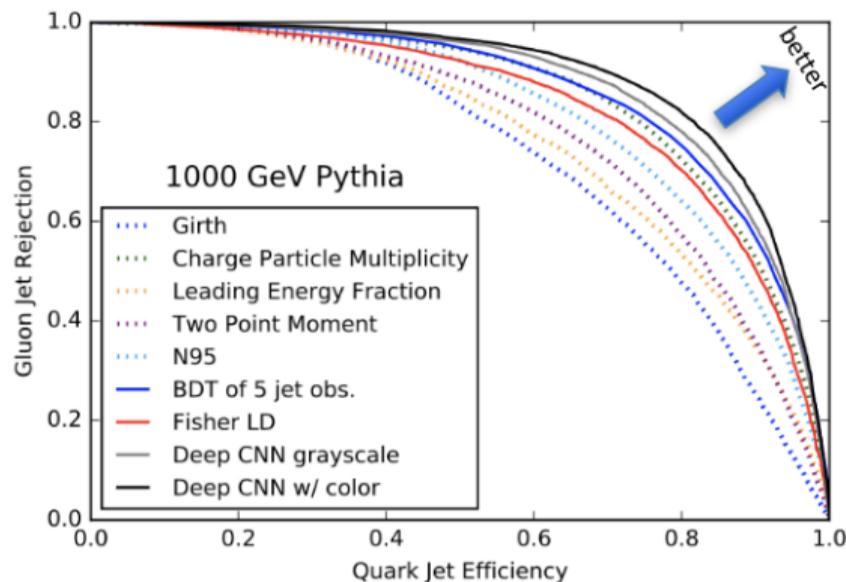
Applications – Identification des jets

18

- signature expérimentale laissée par **quarks** (quark-b, quark-c, ...) et **gluons**
- ★ **traces**
- ★ dépôts d'énergie
calorimètres **EM** et **hadronique**



Discriminating Quark and Gluon jets

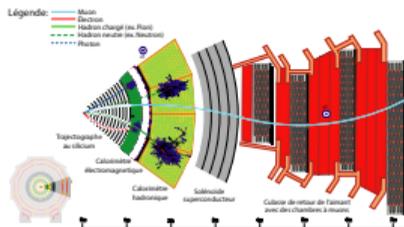


[arxiv:1612.01551](https://arxiv.org/abs/1612.01551)

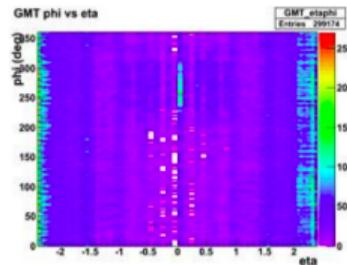
Conclusion

- ML peut intervenir dans plusieurs étapes de reconstruction (Physique des Particules)
- utilisation croissante de ML, surtout amélioration les performances

Identification, reconstruction, analyse



Monitoring



Computing



Électronique

