AI × 素粒子実験の最前線

田中純一
東京大学 素粒子物理国際研究センター

2026年5月29日

自己紹介

- 東大の素粒子実験の研究室（相原研の一期生）卒業
  - Belle実験（つくば、KEK）でD論を書きました。
  - 研究室の同期には横山先生（東大理学部物理）、樋口先生（東大IPMU）
    - 同期の東大大学院関係の先生: 濱口先生、福嶋先生、矢向先生　（結構います…）

物性にも…

- 2002年から素粒子センターでアトラス実験をやっています。
  - 計算機センターのお仕事：Grid
  - データ解析の準備（2010年まで待った）
  - 実際のデータ解析 → 2012年7月 ヒッグス発見
  - 2013年3月 EMカロリメータの読み出しデジタルトリガーのR&Dに正式に参加
    - FPGA Firmwareの開発
    - デジタルトリガーのオペレーション
  - 2018年4月 Tokyo Tier2, ビッグデータを使った計算機科学
    - 計算機センター（グリッド、クラウド、スパコン）
    - 深層学習、量子コンピュータ
    - Beyond AIなどにも参画していた
  - 将来実験に向けたR&D(新人さんに託したい)

ヒッグスでは終わりたくないですね。

田中研：アトラス+将来、人工知能、量子センサーなどに興味のある方、募集中

素粒子物理・素粒子実験

Understand our universe, the origin of everything
→ how to interact?, what is matter?, what is force?, …

Find ultimate equation(s) to explain our universe!

見えている物質で計算した速度
より早く動いている.

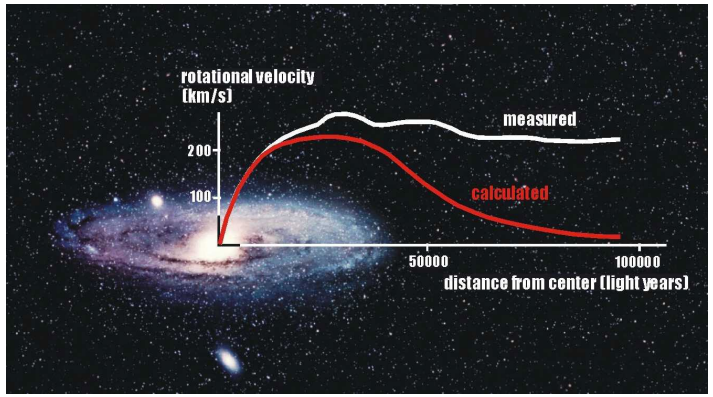

素粒子標準模型

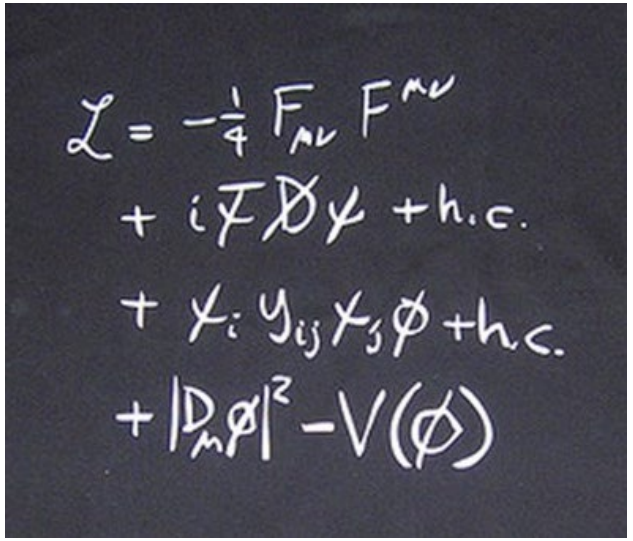

17個の素粒子

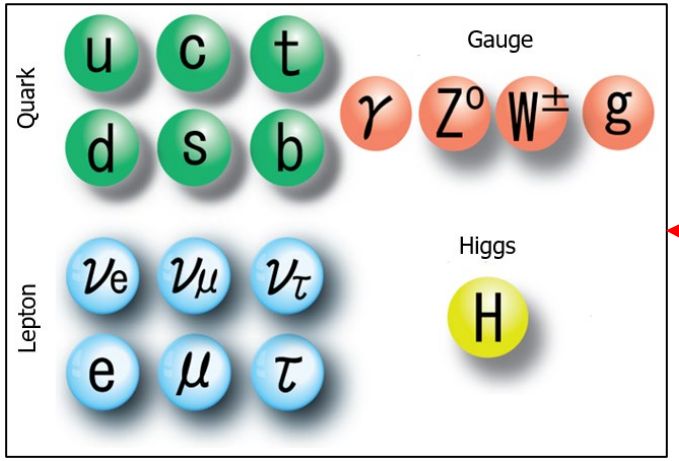

Matter
Fermion (Spin ½)

Force
Boson (Spin 0 or 1)

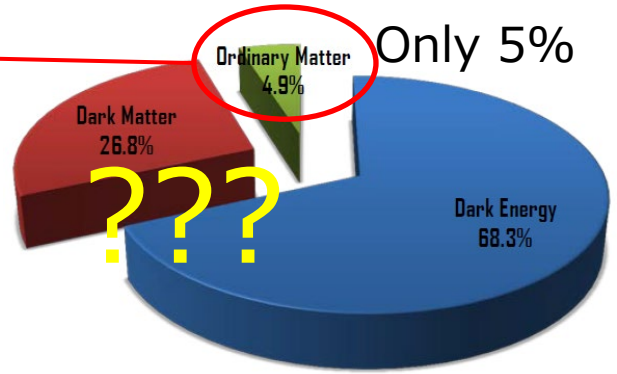

Only 5%

（個人的に）達成したいこと: 今の標準模型を超えたものを見つけたい. 暗黒物質候補とSUSYの証拠

世界最高エネルギーの**LHC加速器**は宇宙初期（ビッグバンの10^{-12}秒後の世界）の状態を人工的に作り出すことができる！

Swiss Geneva

CERN

ATLAS

CERN Meyrin

SUISSE

FRANCE

CMS

SPS 7 km

ALICE

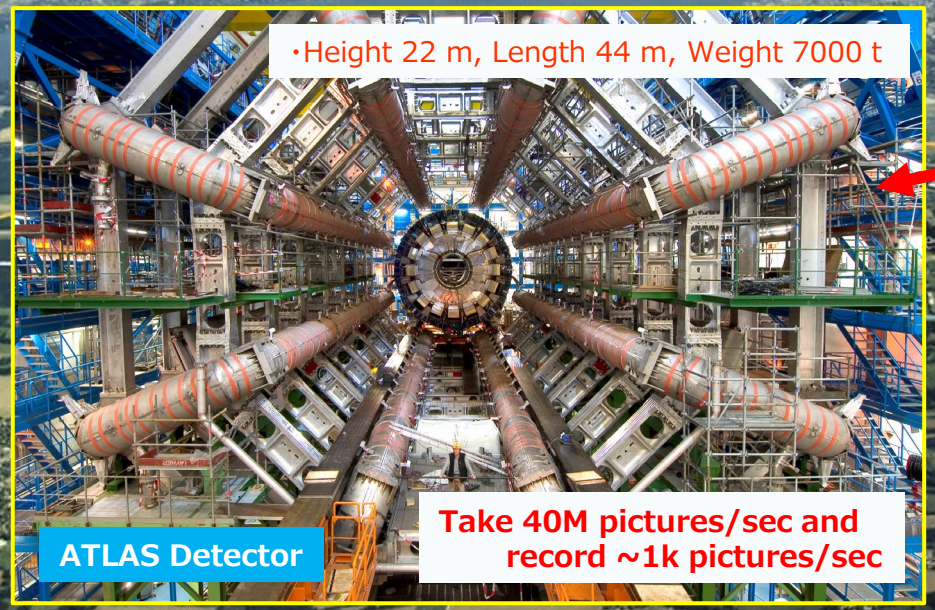

LHC tunnel 27km circumference
100m underground

Tokyo	Yamanote-line	34.5km
Nagoya	Meijo-line	26.4km
Osaka	Kanjo-line	21.7km

検出器のセンサー数 1億チャンネル

1秒間に最大1000枚の写真

Large Hadron Collider (LHC)

LHC 27 km

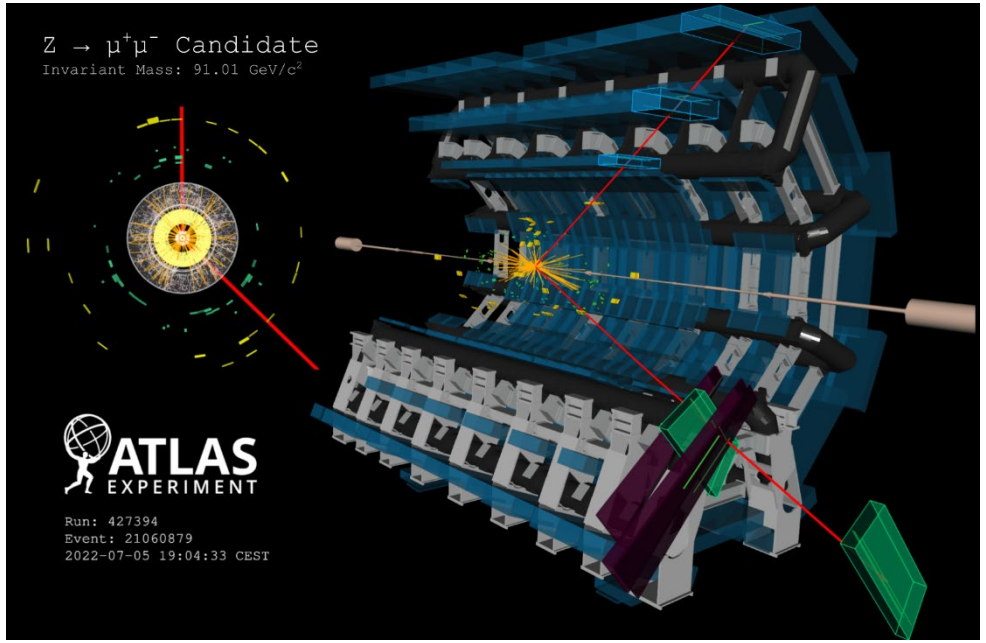

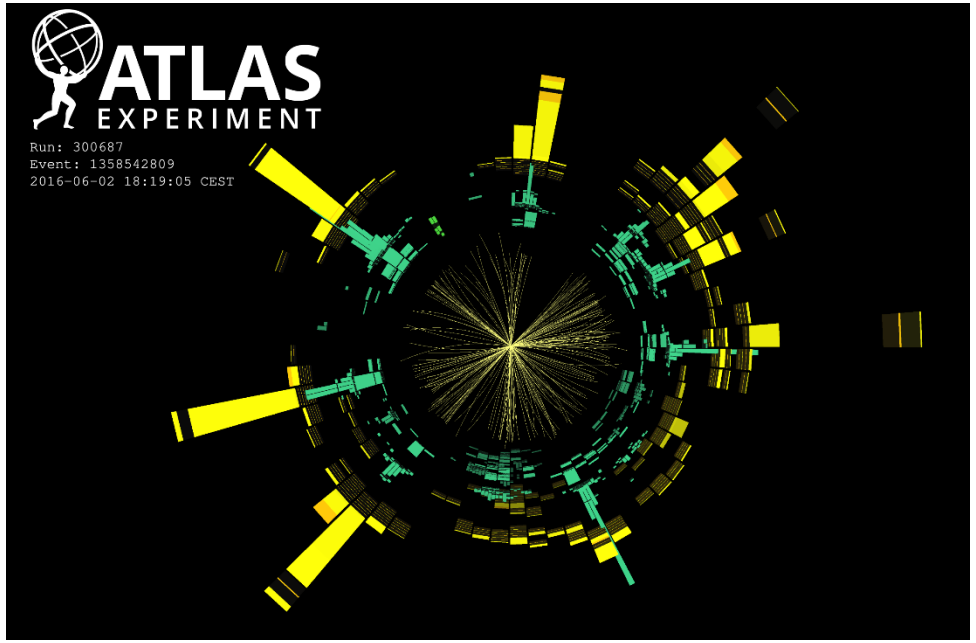

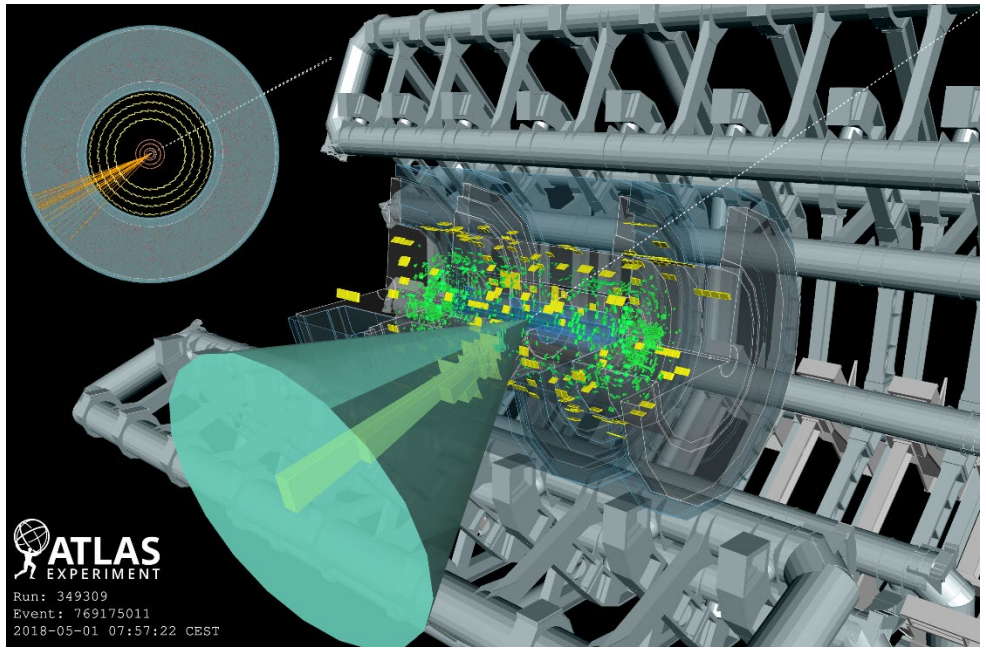

実験データの事象（写真！）の一例

2015-2018年 Run2実験
2022-2026年 Run3実験（進行中）
2030-2041ごろ HL-LHC実験

シミュレーションデータは数十倍

我々の研究：
実験データを再現したシミュレーションデータとの比較

膨大なデータと計算量

- 今は昔、計算機の発展に加速器実験は貢献していた。
- 今でも、加速器実験に計算機は必須。

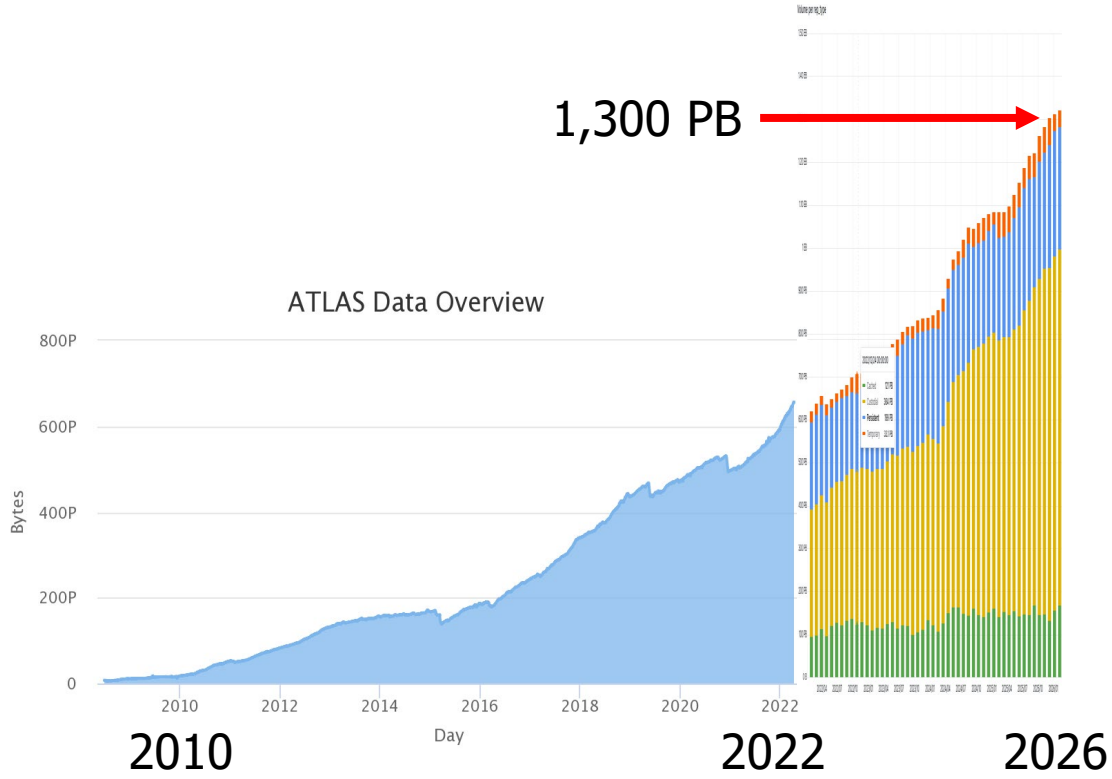

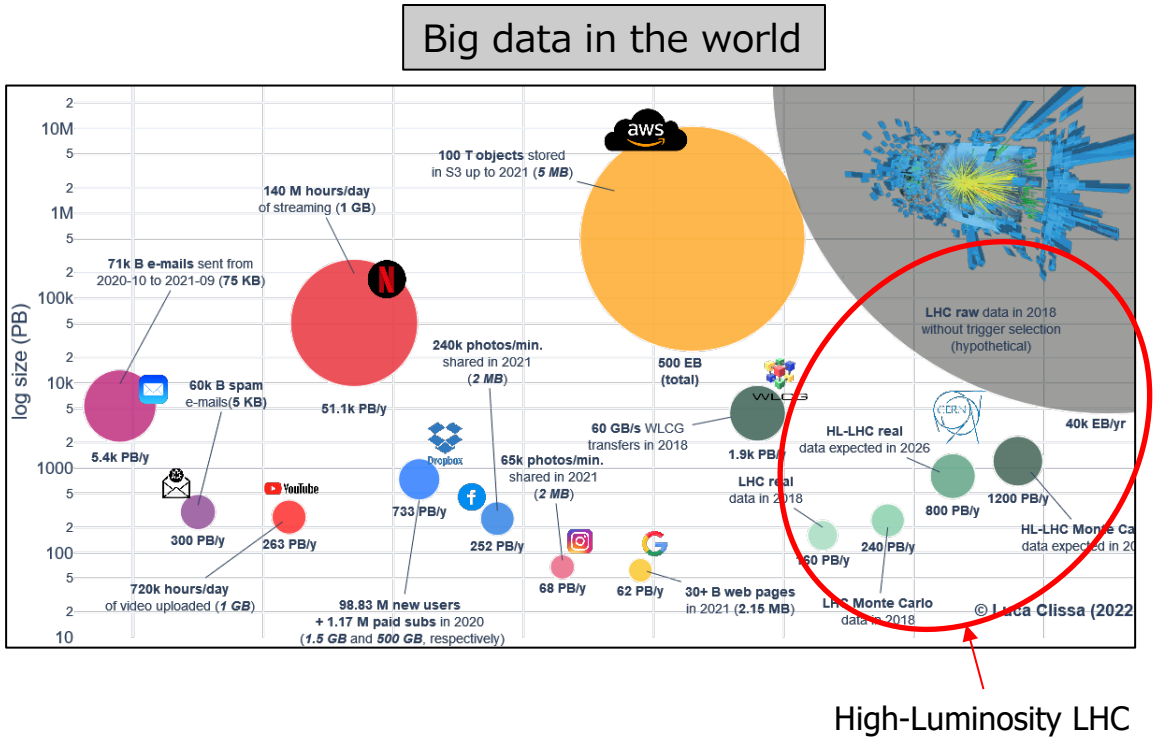

ATLAS実験のデータ（実験データ＋MCデータ） > 1,300 PB = 1,300,000 TB = 1,300,000,000 GB
ATLAS実験のRaw data = ~100PB, ~60x10^9 events = 約600億

グリッド技術により、世界中の計算機クラスターが
一元管理され、実験のデータ解析に利用されている

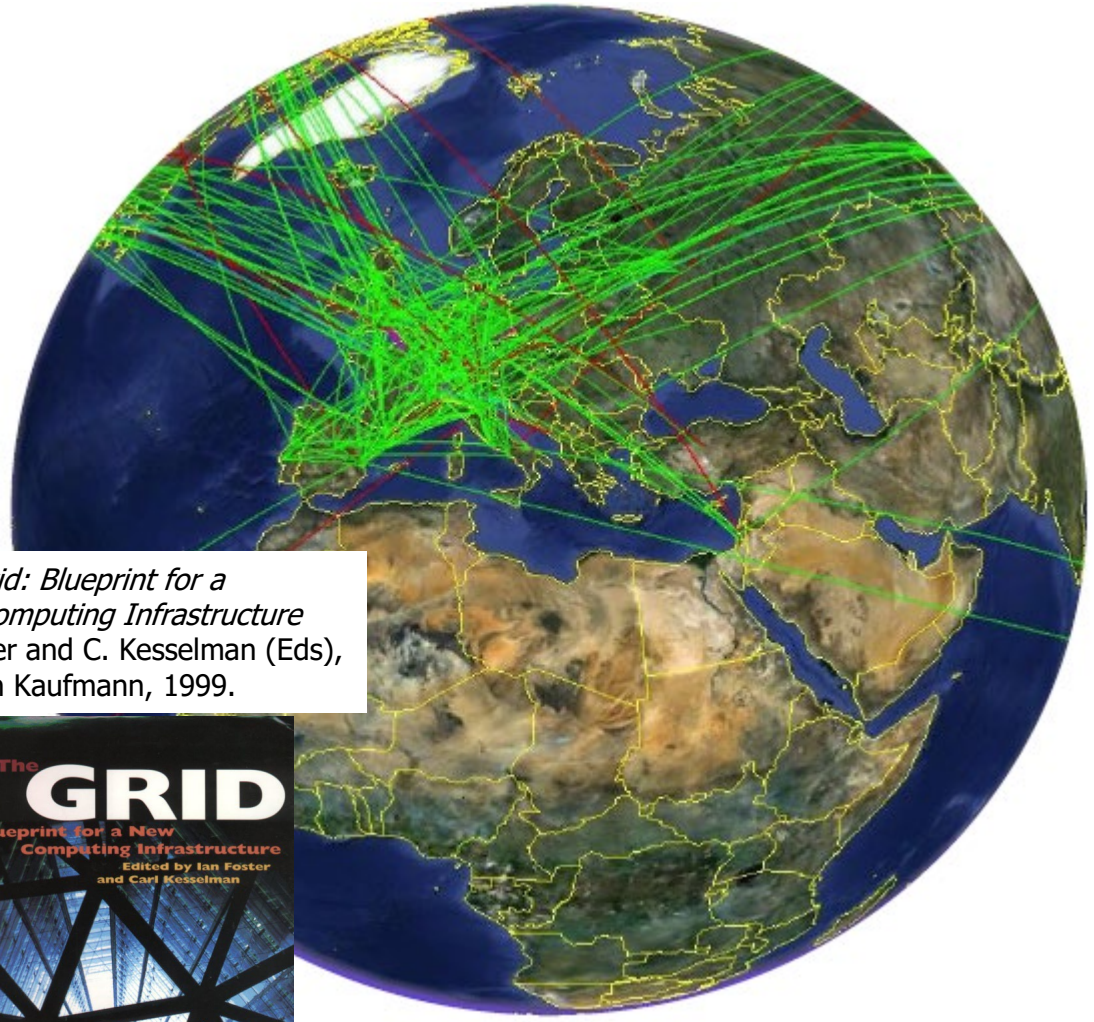

The Grid: Blueprint for a New Computing Infrastructure
I. Foster and C. Kesselman (Eds), Morgan Kaufmann, 1999.

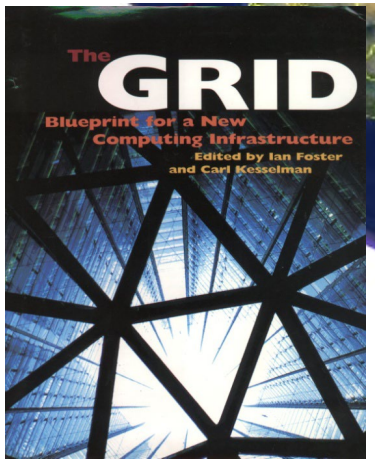

ATLAS実験だけで、
常時約70万CPUコアのジョブが走っている

素粒子「実験」の研究

みなさんにはたくさんの選択肢があります！

ハードウェア開発・オペレーションの仕事

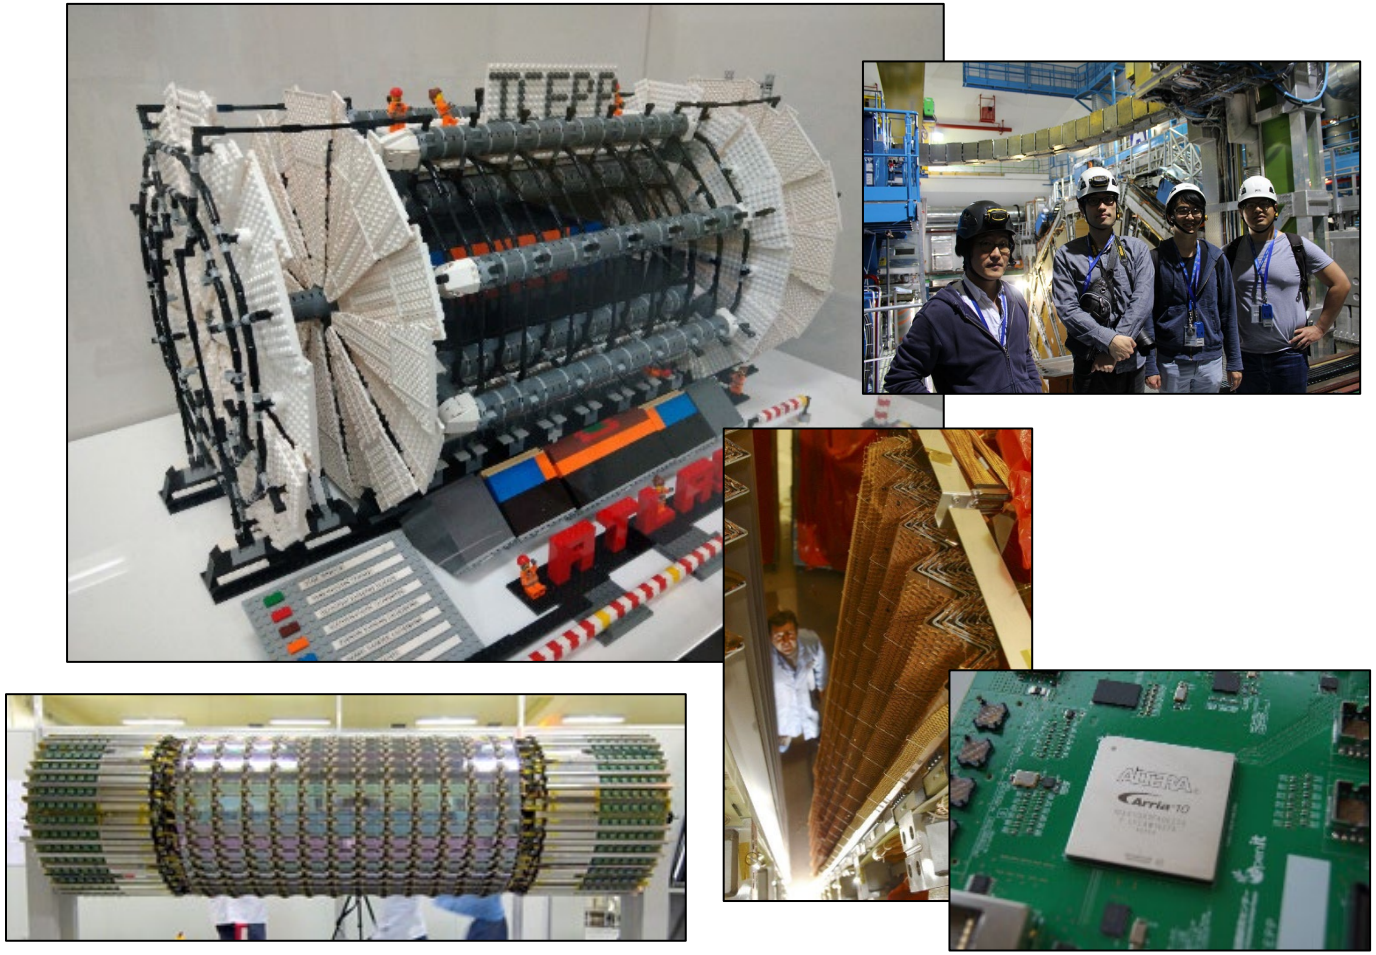

計算機上での仕事

検出器データ

↓ 再構成

再構成データ

↓ 粒子識別

解析データ

↓ 解析・検定

学術データ

今日は人工知能を使った研究の紹介！

（大型）実験での研究の鍵

$$N = \sigma \times BR \times \int L dt \times \sum \varepsilon$$

$$\text{発見感度} = \frac{S}{\sqrt{B}}$$

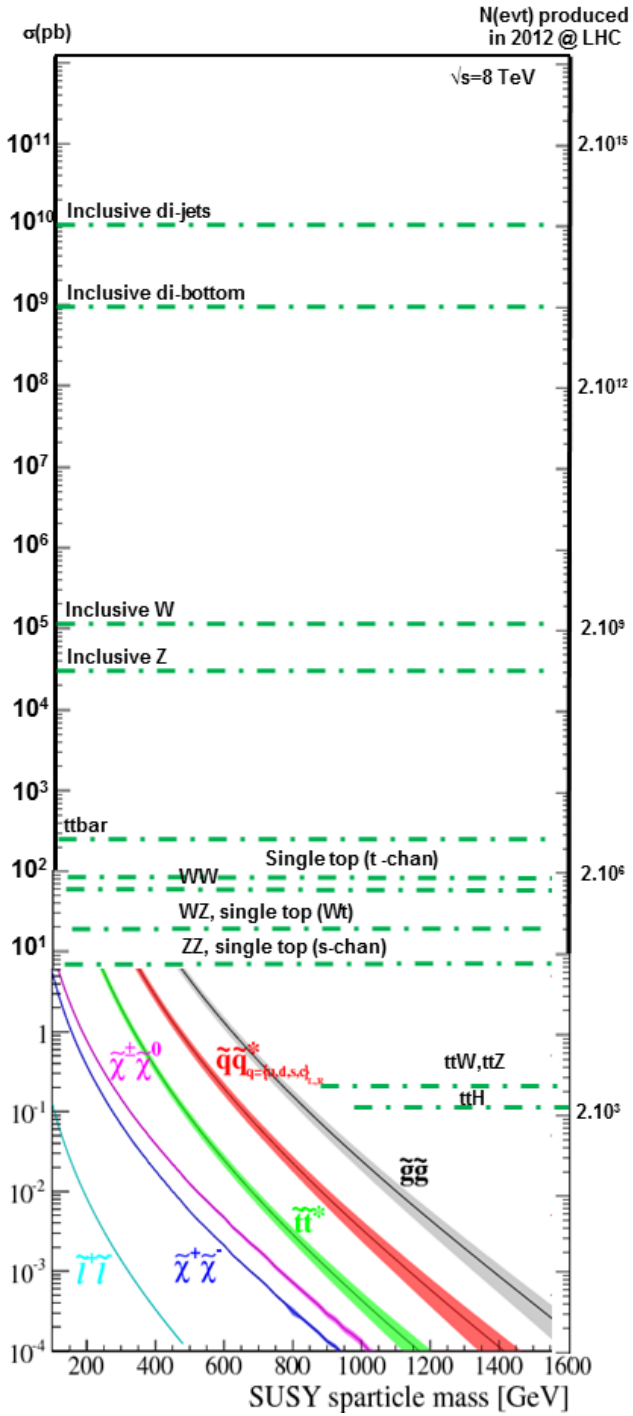

"N"(数)と"感度"が増える・良くなることが実験の鍵

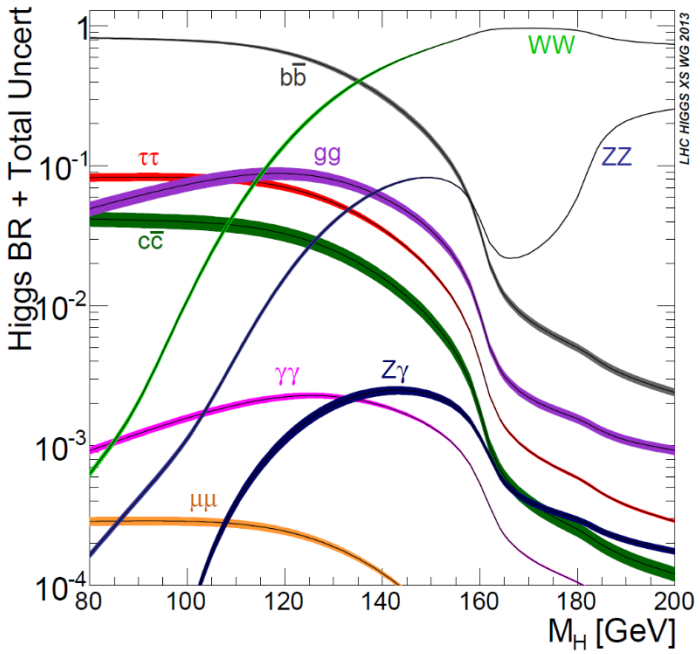

$\sum\varepsilon =$
アクセプタンス x
トリガー x
再構成 x
識別 x
解析

大雑把言えば、どこかで2倍改善できたら、データを2倍取得することと同じ。
Sだけ2倍に改善できたら、データを4倍取得すうことと同じ。

検出器データ

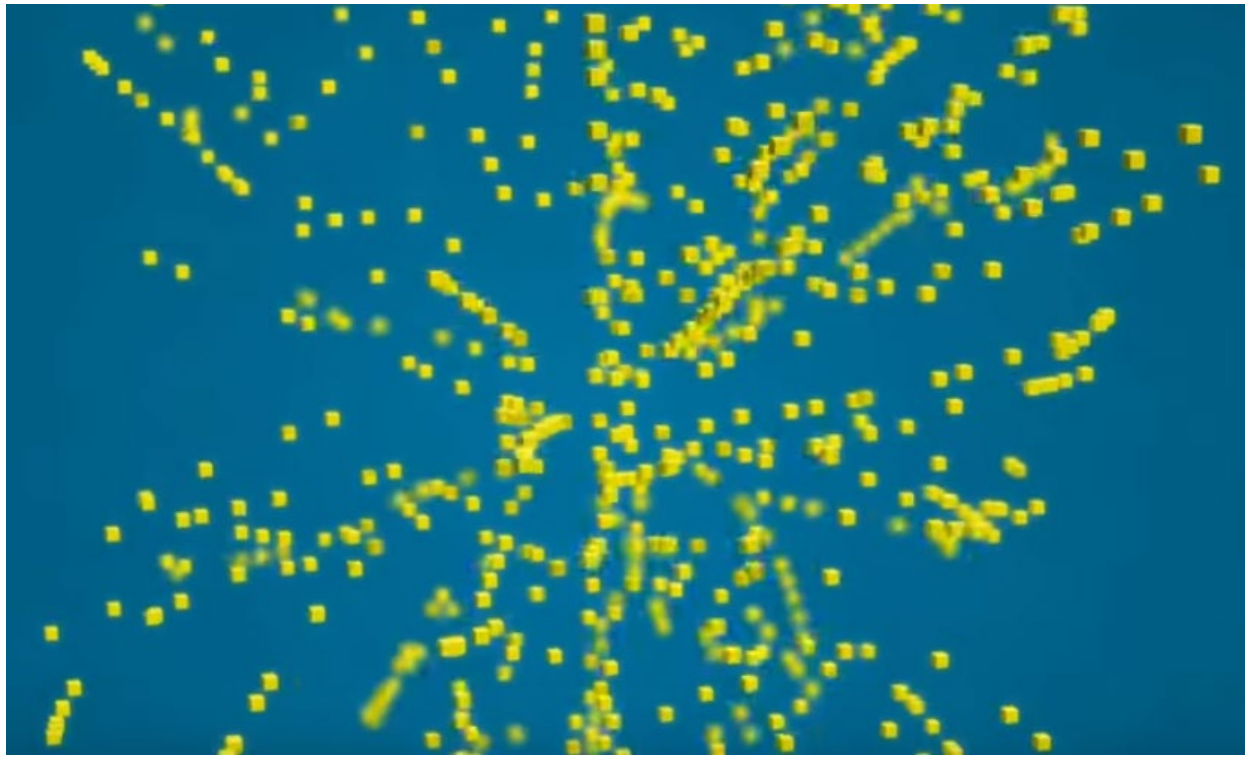

再構成データ

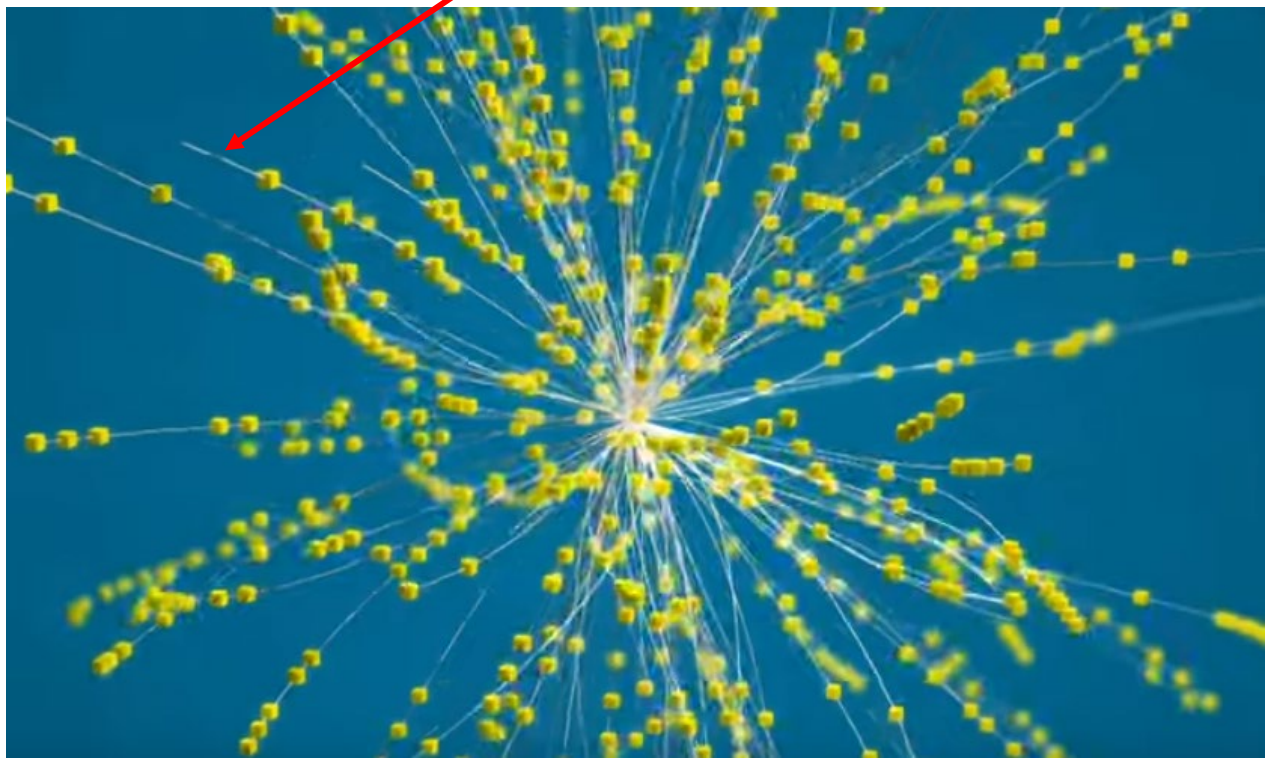

我々のデータ解析：1個1個の陽子・陽子事象がどの物理プロセスから生じたのか、判断する

検出器データは“点”情報 → 粒子（オブジェクト）に再構成

ソフトウェア開発は重要な研究

素粒子実験：データ解析ワークフロー

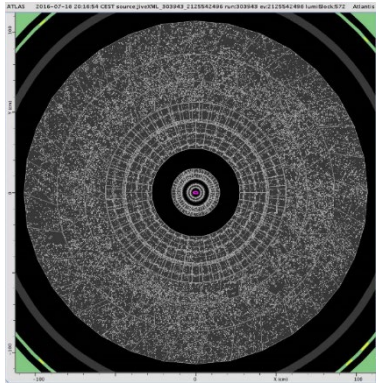

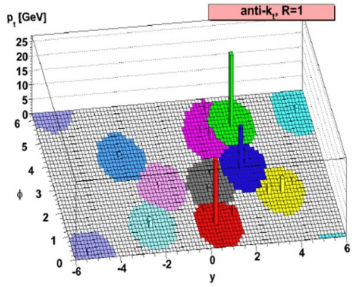

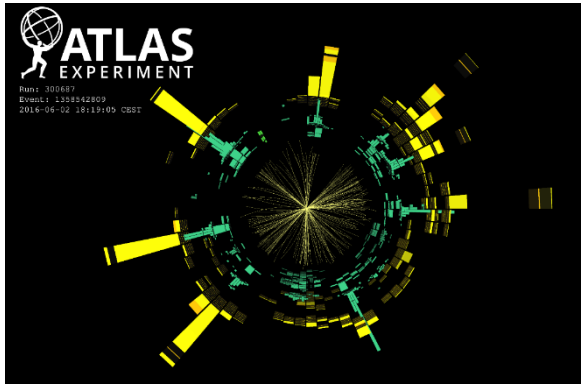

検出器データ → 「再構成」
- 飛跡検出器
- カロリメータ検出器
- ミュー粒子検出器

→ 再構成データ → 「粒子識別」
- 電子や光
- ミュー粒子
- ジェットの種類

→ 解析データ → 「データ解析」

学術論文

点
（位置）

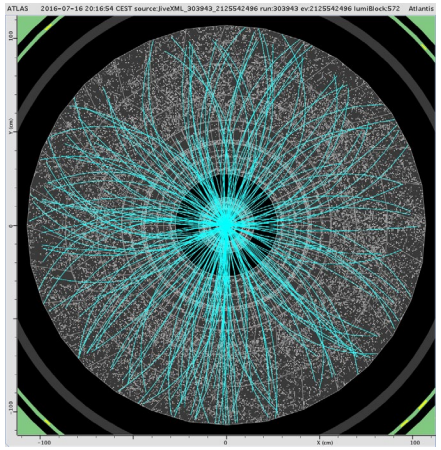

曲線や塊：
運動量やエネルギー

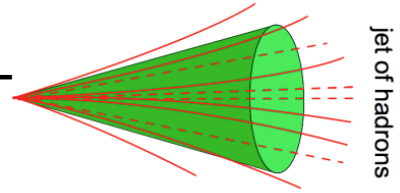

このジェット何？

粒子名が付いた
運動量やエネルギー

測定値(E,**p**)を持つ
電子や光子など

ここまでくれば
シグナルかバックグラウンドか
判断可能になる.

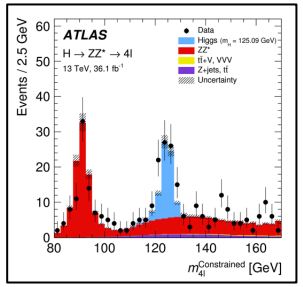

信号事象かどうか?
発見か?

素粒子実験と人工知能

- データ解析の改善
  - オーソドックスなアプローチ：Non-ML・DLからML・DLへ@データ解析ワークフロー
    → これが主流！
  - アグレッシブ：素粒子実験データの基盤モデル（Foundation model）＋エージェント etc.
    フレームワークの開発 → “データ解析する研究者”を作る

- アグレッシブ：より“intelligent”/“creative”な部分を
  - コード開発
  - データ解析：背景事象の見積もり方法の開発
  - 論文執筆
  - 実験計画・実験設計

  etc.

  } 世界の誰かがすでに取りかかっている

「人工知能」の分野では日々新しいアイデアが生まれている → 素粒子物理への応用

Multi-layer perceptron (MLP)

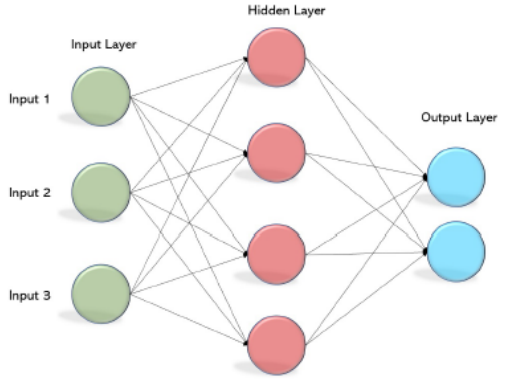

From: https://becominghuman.ai/multi-layer-perceptron-mlp-models-on-real-world-banking-data-f6dd3d7e998f

Graph neural networks (GNNs)

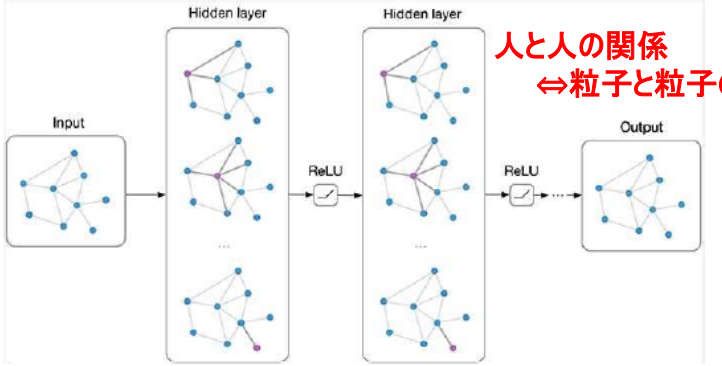

人と人の関係
⇔粒子と粒子の関係

From: https://theaisummer.com/Graph_Neural_Networks/

"Scaling law"に従う
(パラメータ数、データセットサイズ、予算に対してべき乗則)

Convolutional neural networks (CNNs)

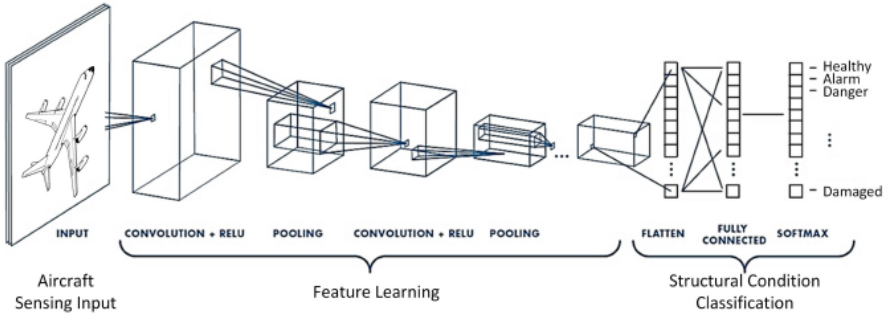

From: [Tabian et al., "A Convolutional Neural Network for Impact Detection and Characterization of Complex Composite Structures," Sensors 19(22), 2019]

AlexNet (2012) by Hinton's team

Transformers

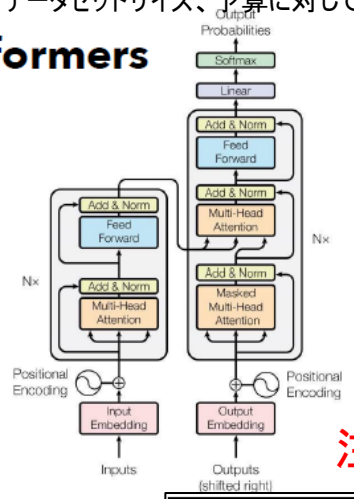

注意機構

From: https://pytorch.org/tutoria

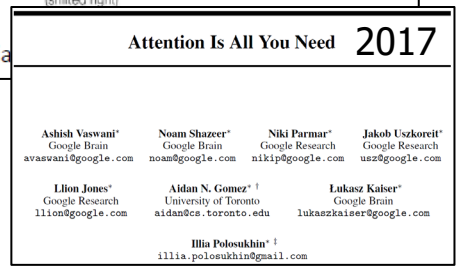
Attention Is All You Need 2017

Ashish Vaswani* Google Brain avaswani@google.com
Noam Shazeer* Google Brain noam@google.com
Niki Parmar* Google Research nikip@google.com
Jakob Uszkoreit* Google Research usz@google.com
Llion Jones* Google Research llion@google.com
Aidan N. Gomez* † University of Toronto aidan@cs.toronto.edu
Łukasz Kaiser* Google Brain lukaszkaiser@google.com
Illia Polosukhin* ‡ illia.polosukhin@gmail.com

トップクォークの識別性能

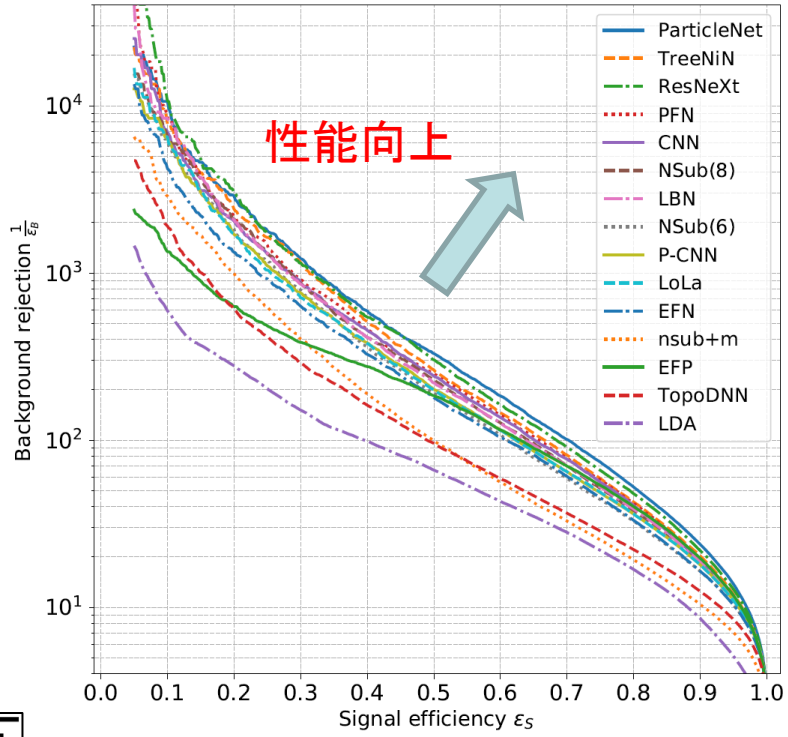

arXiv:1902.09914

阪大IDS：中島悠太先生のスライドから

2012年「ヒッグス発見」と「AIブーム再燃」
2023年「生成AI元年」
2025年「AIエージェント元年」

素粒子実験データとGraph Neural Network

荷電粒子の特徴：運動量と位置（インパクトパラメータ） クラスターの特徴：運動量（エネルギーとその場所） etc.	荷電粒子の数 クラスターの数
特徴量の数は固定	事象ごとに異なる

どうならべる？

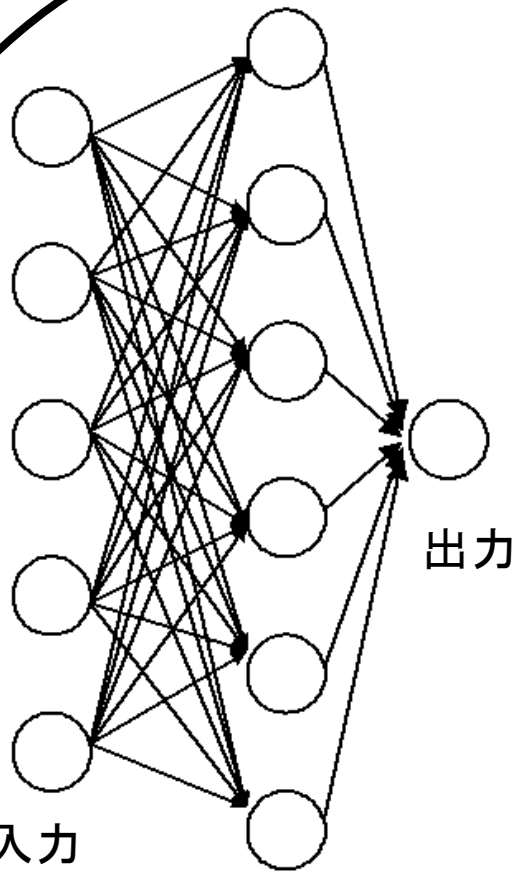

MLP = Multi layer perceptron（多層パーセプトロン）

グラフニューラルネットワーク (GNN)

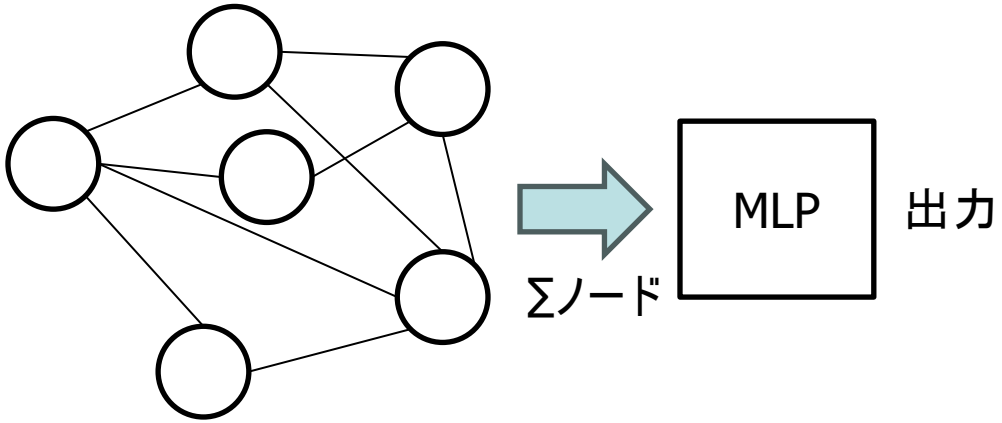

- 各ノードに荷電粒子やクラスター（の表現）を割り当てる。
- ノードやエッジがMLP

GNNは素粒子データと相性はいい

この人たちは単独では観測できない(QCD理論)!

ジェットの識別

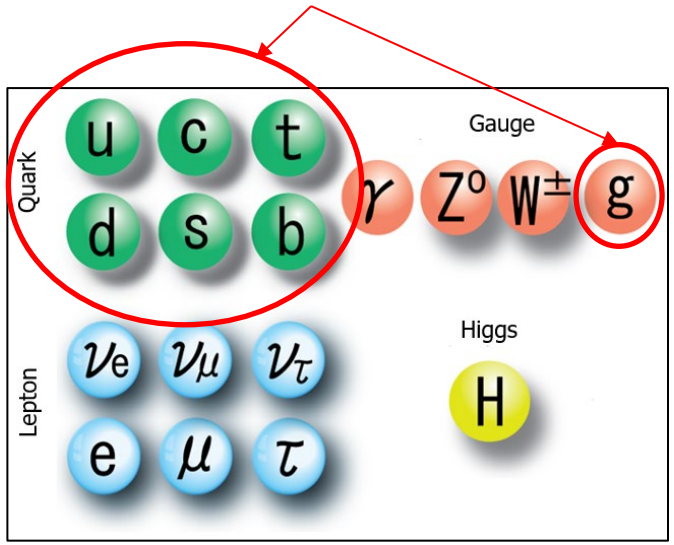

(生成時)

quark or gluon

QCD

(検出器では)

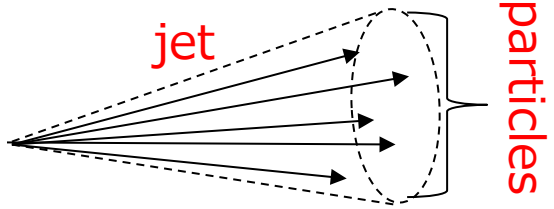

ジェット＝粒子の束

粒子をよーく観ると

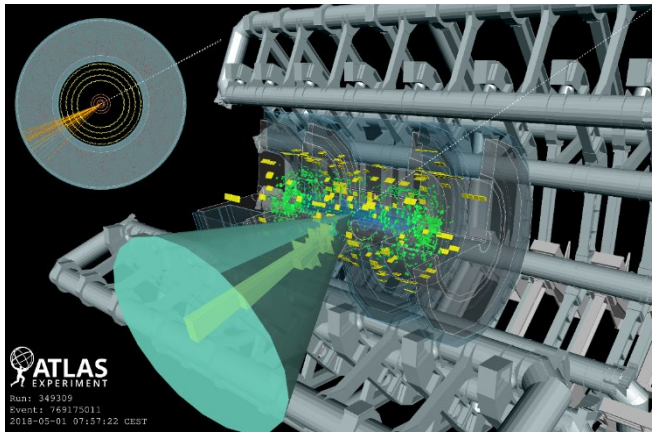

歴史的にはCNNから

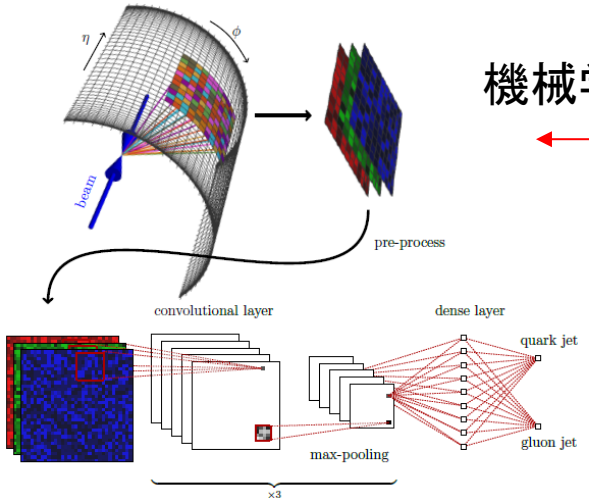

arXiv:1612.01551

機械学習化

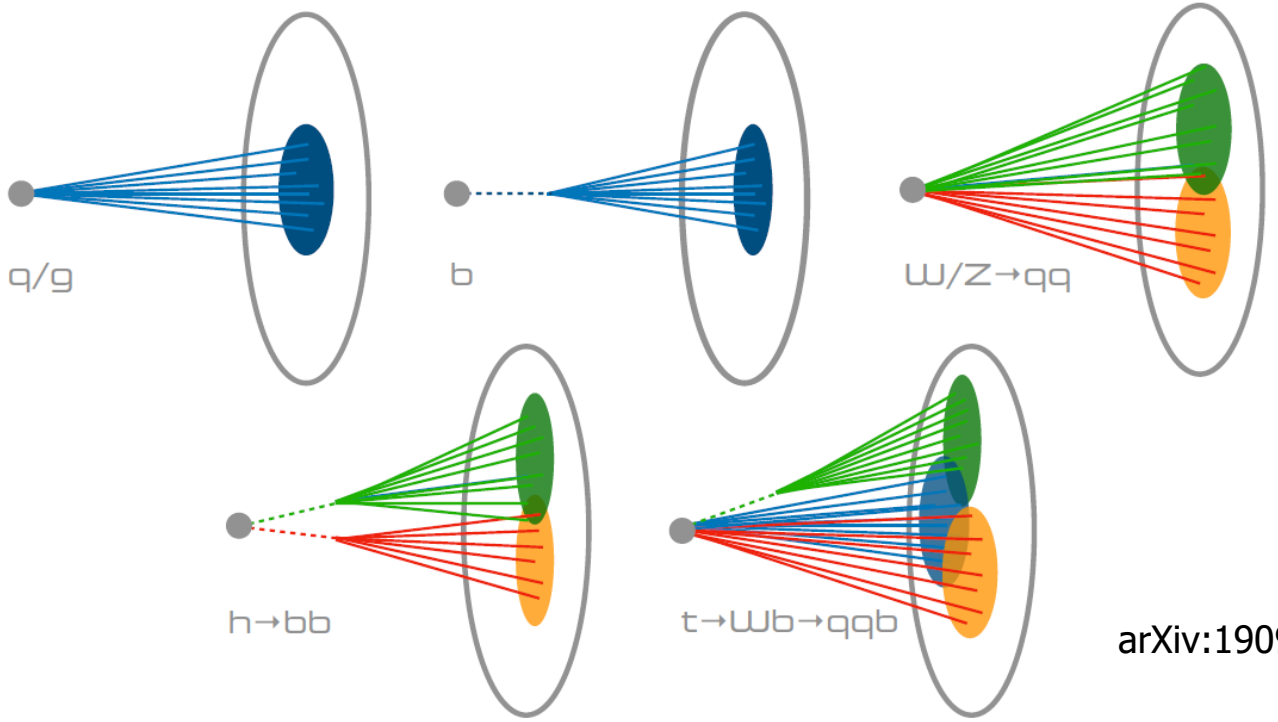

arXiv:1909.12285

Graph Neural Networkを用いたb-tagging

ATL-PHYS-PUB-2022-027

H→bb（ヒッグス粒子の崩壊）のような研究：b-jetの識別が鍵

u,d,s
Light quark jet
Gluon jet

b-jet

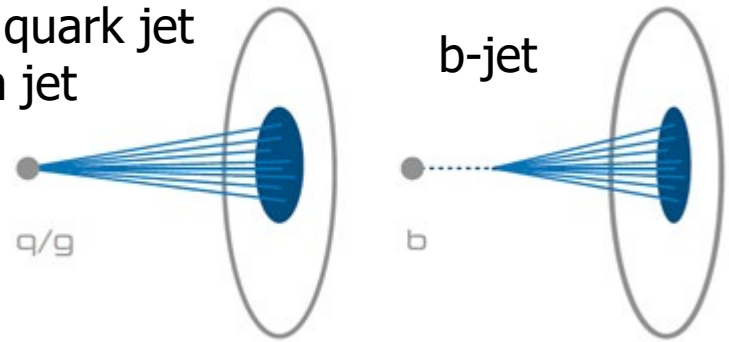

b-jet: Bハドロンの崩壊 B→Dlν, D→Klν

BやDは比較的長寿命→検出器で識別可能

従来の方法：長寿命という性質を抽出する複数のアルゴリズムの開発
それらの出力を機械学習のインプットに。

最新の方法：粒子(track)を「ノード」として表現したグラフを使った深層学習
入力変数は多いが、どちらかといえば、かなり生データに近い.

Jet Input	Description
p_T	Jet transverse momentum
η	Signed jet pseudorapidity
Track Input	**Description**
q/p	Track charge divided by momentum (measure of curvature)
$d\eta$	Pseudorapidity of the track, relative to the jet η
$d\phi$	Azimuthal angle of the track, relative to the jet ϕ
d_0	Closest distance from the track to the PV in the longitudinal plane
$z_0 \sin\theta$	Closest distance from the track to the PV in the transverse plane
$\sigma(q/p)$	Uncertainty on q/p
$\sigma(\theta)$	Uncertainty on track polar angle θ
$\sigma(\phi)$	Uncertainty on track azimuthal angle ϕ
$s(d_0)$	Lifetime signed transverse IP significance
$s(z_0)$	Lifetime signed longitudinal IP significance
nPixHits	Number of pixel hits
nSCTHits	Number of SCT hits
nIBLHits	Number of IBL hits
nBLHits	Number of B-layer hits
nIBLShared	Number of shared IBL hits
nIBLSplit	Number of split IBL hits
nPixShared	Number of shared pixel hits
nPixSplit	Number of split pixel hits
nSCTShared	Number of shared SCT hits
nPixHoles	Number of pixel holes
nSCTHoles	Number of SCT holes
leptonID	Indicates if track was used in the reconstruction of an electron or muon (only for GN1 Lep)

これがjetの識別機

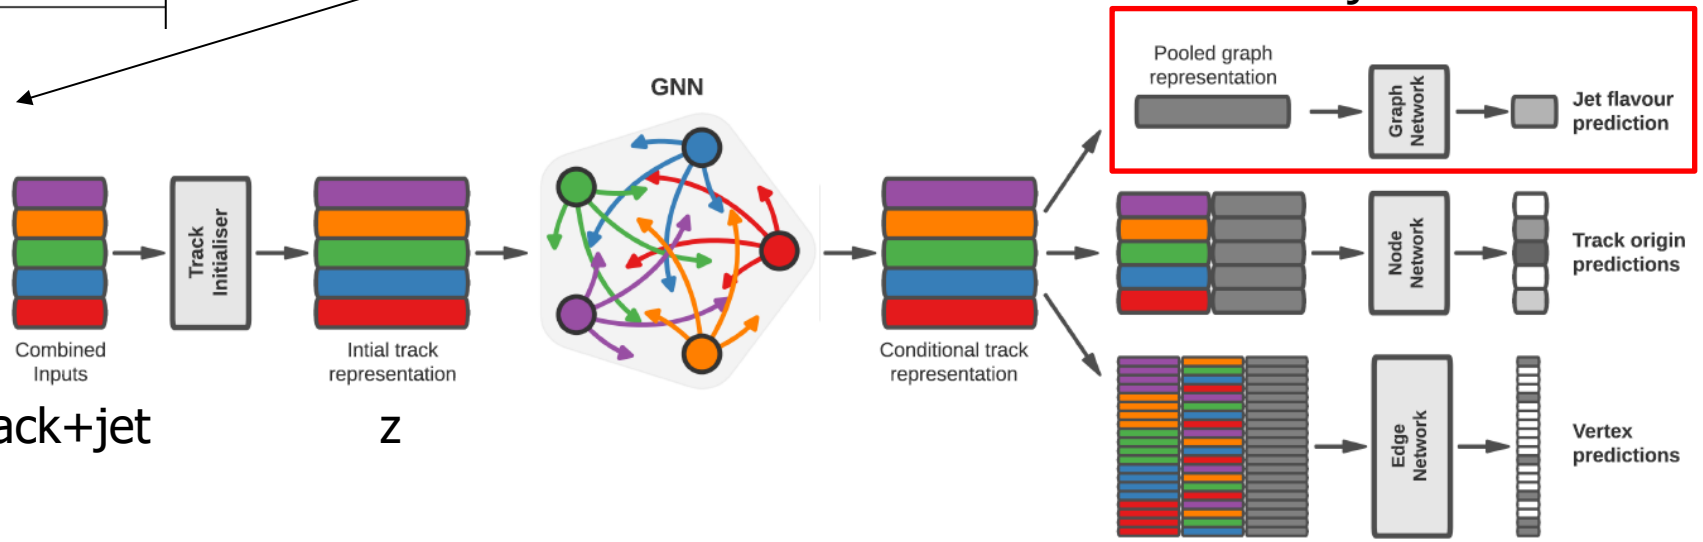

track+jet

z

これがjetの識別機

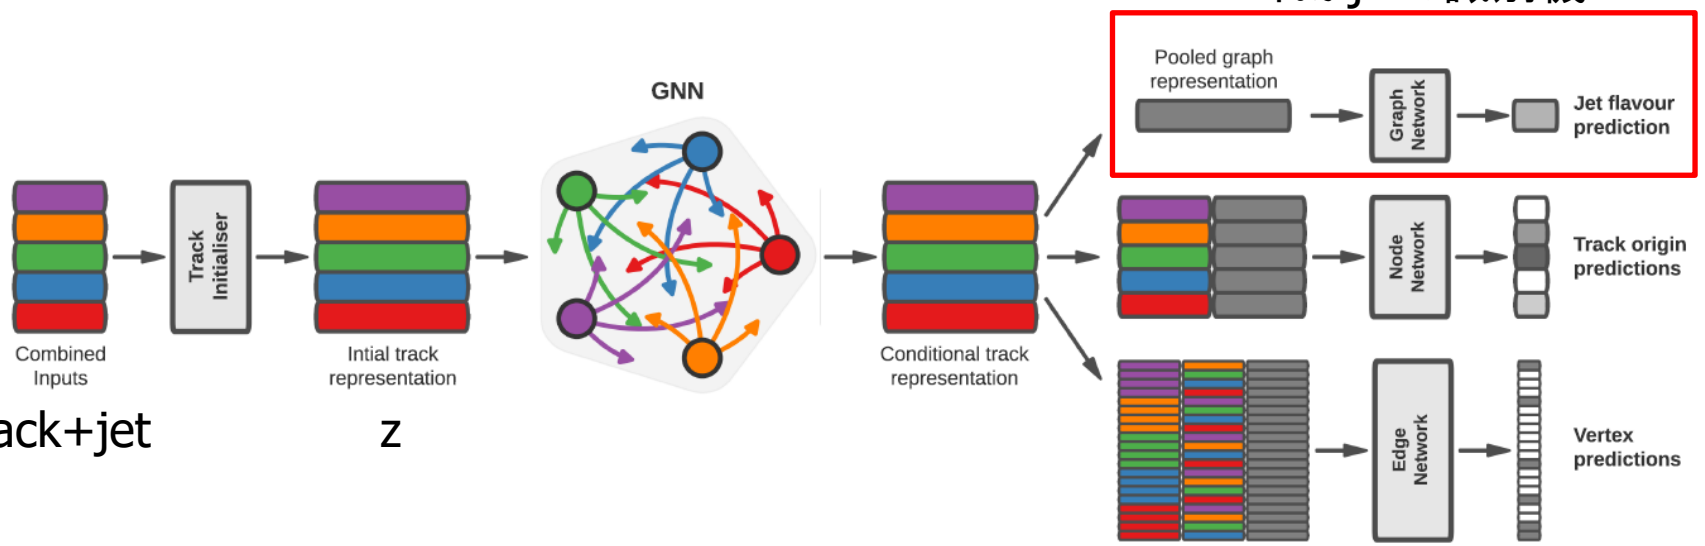

グローバル

ノード

エッジ

track+jet

z

工夫：グラフのノードとエッジ情報も学習に使う!

- 赤と青のトラックがb-jet由来
- 緑のトラックは別の陽子・陽子の相互作用（パイルアップ）

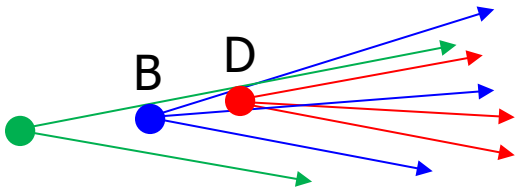

ノード識別：生成点分類（例：赤丸、青丸、緑丸 et

エッジ識別：同じ生成点由来かどうか？

$$L_{\text{total}} = L_{\text{jet}} + \alpha L_{\text{vertex}} + \beta L_{\text{track}}$$

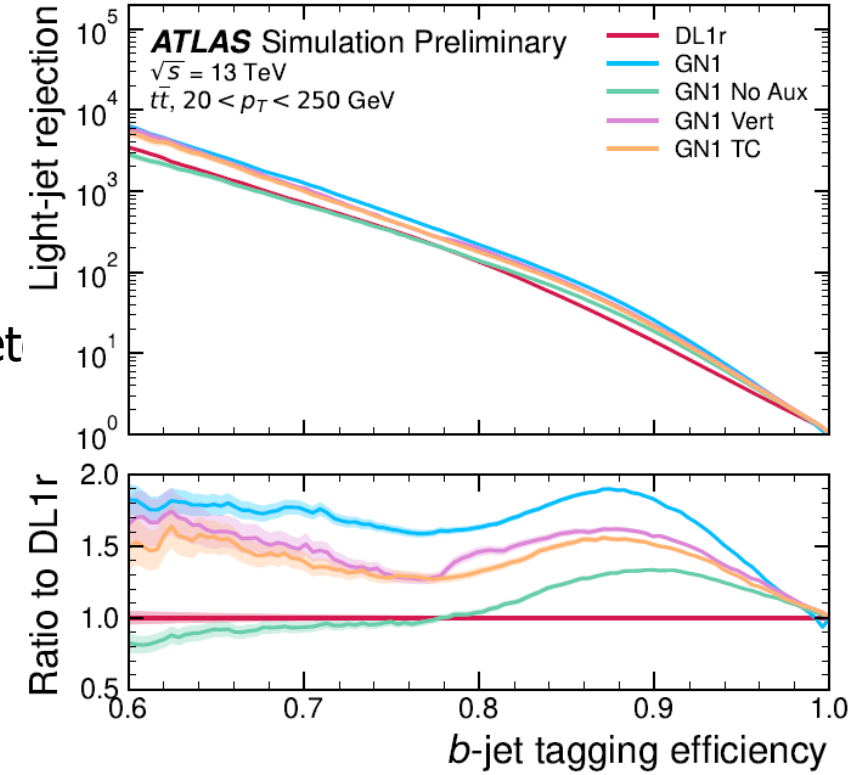

事前知識を機械学習へ

信号事象

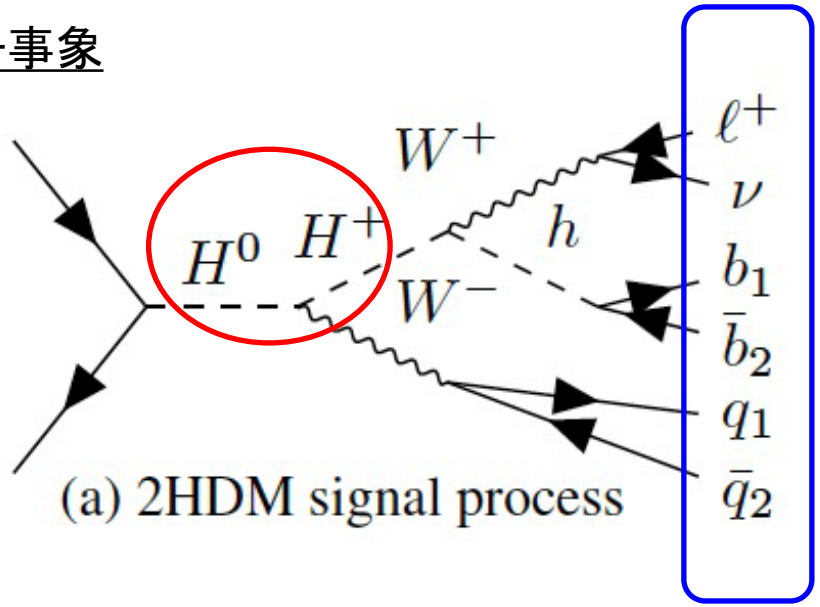

(a) 2HDM signal process

背景事象

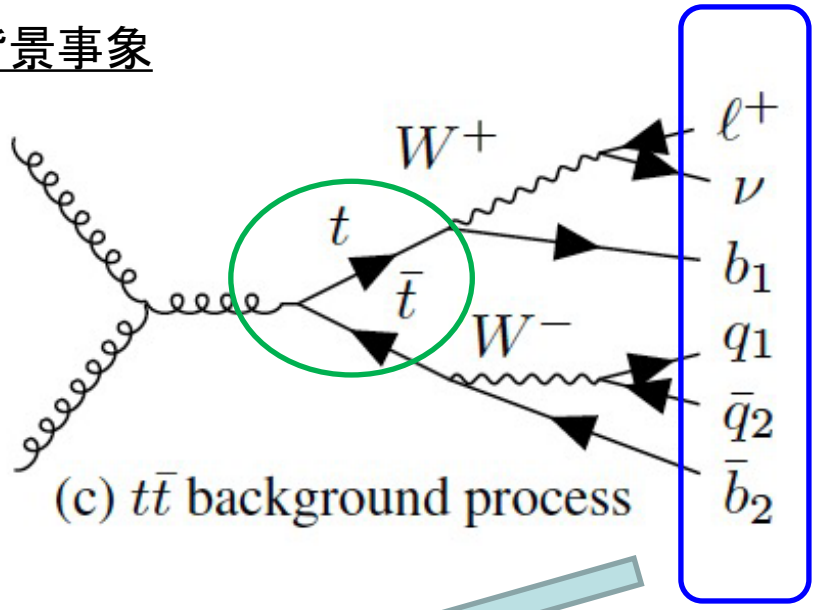

(c) $t\bar{t}$ background process

解析データ（検出器データ）でみえるものは全く同じ

しかし、信号事象と背景事象の生成過程は異なることは知っている！
→ 信号事象には途中でHiggsが存在、背景事象では途中でtopが存在などという情報

異なるファインマン図

(arXiv:2212.08759, Accepted by the "NeurIPS 2022 ML4PS Workshop")

Decay-aware neural network

異なるファインマン図 → 異なるホップ数（Vertex数）

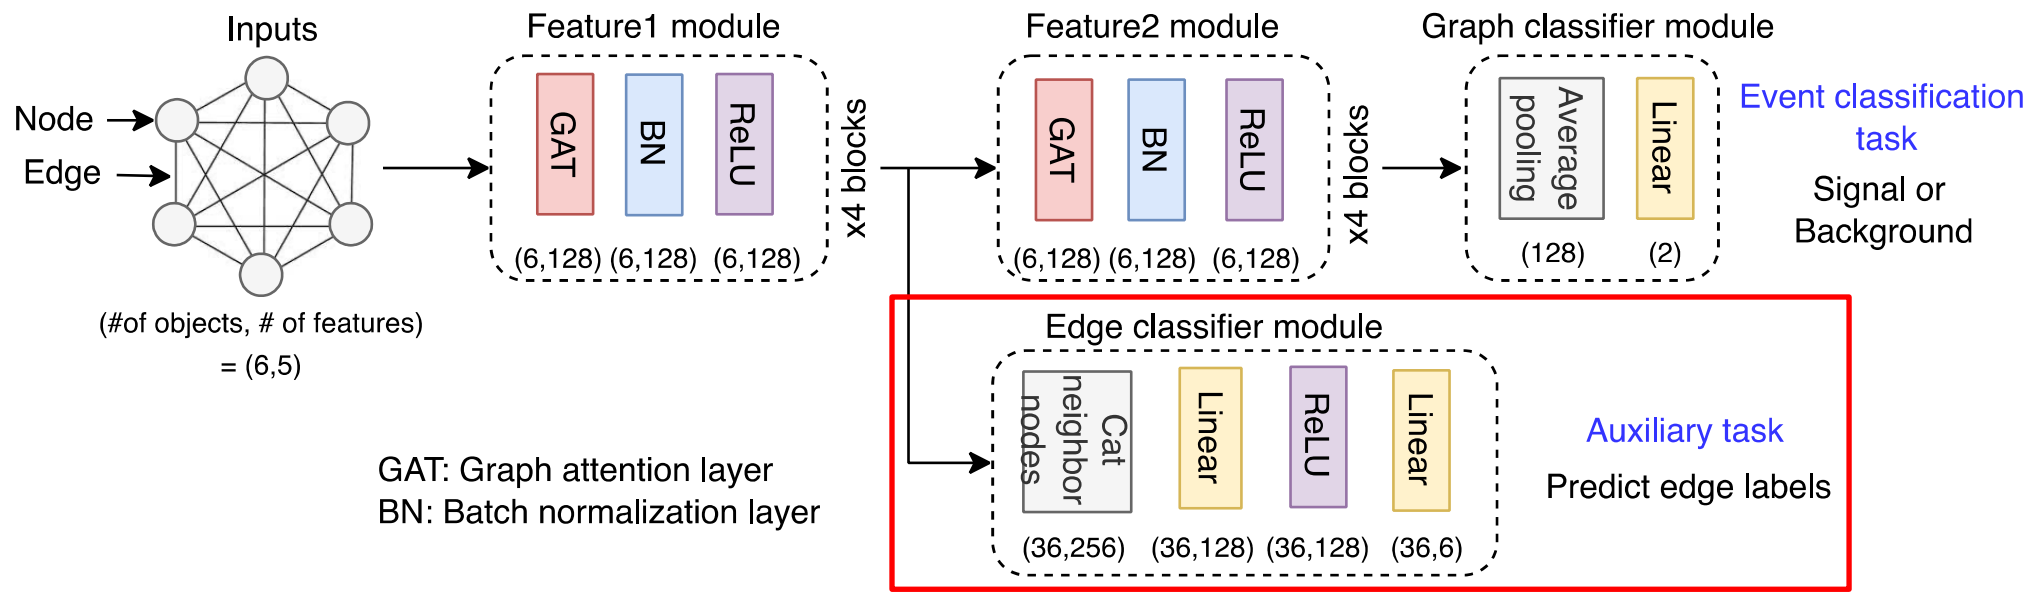

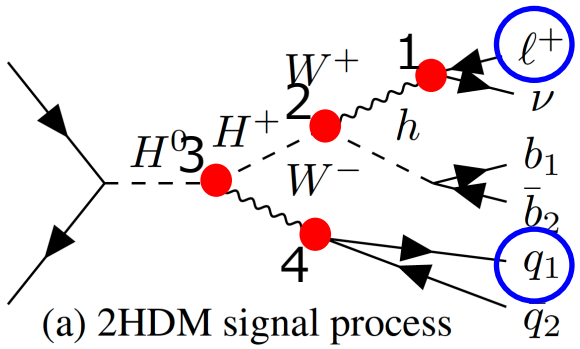

(a) 2HDM signal process

	l	v	b_1	b_2	q_1	q_2
l	0	1	3	3	4	4
v	1	0	3	3	4	4
b_1	3	3	0	1	4	4
b_2	3	3	1	0	4	4
q_1	4	4	4	4	0	1
q_2	4	4	4	4	1	0

Label matrix based on decay chains

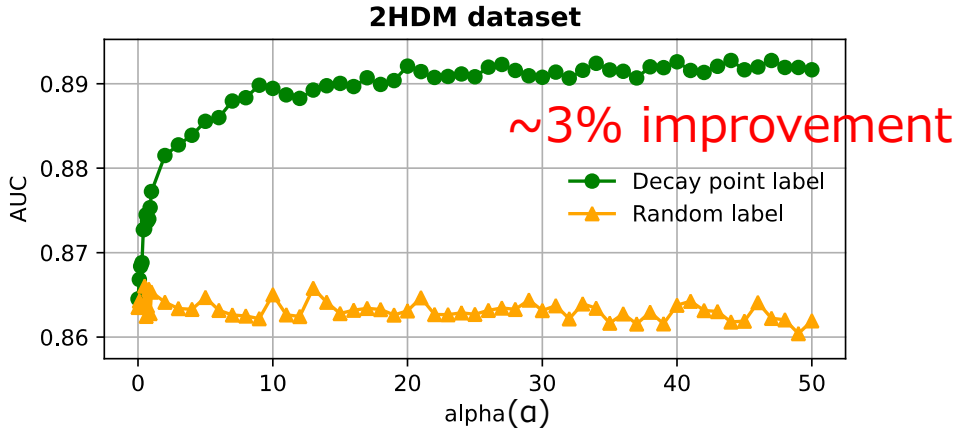

Loss = L (event classification)
+ α* L (auxiliary task)

Scaling Laws

（ちょっと大きな話？）

arXiv:2001.08361

Scaling Laws for Neural Language Models

Jared Kaplan *
Johns Hopkins University, OpenAI
jaredk@jhu.edu

Sam McCandlish*
OpenAI
sam@openai.com

Tom Henighan
OpenAI
henighan@openai.com

Tom B. Brown
OpenAI
tom@openai.com

Benjamin Chess
OpenAI
bchess@openai.com

Rewon Child
OpenAI
rewon@openai.com

Scott Gray
OpenAI
scott@openai.com

Alec Radford
OpenAI
alec@openai.com

Jeffrey Wu
OpenAI
jeffwu@openai.com

Dario Amodei
OpenAI
damodei@openai.com

Transformerの凄さ（？）

経験則であるが、スケーリング則とは
- ネットワークモデルのパラメータ数
- データ数
- 計算量

が上がれば上がるほど、性能が向上する

「金持ちの勝ち」の法則…？

ChatGPTなど

それを覆した(?) by DeepSeek (R1 2024年11月)

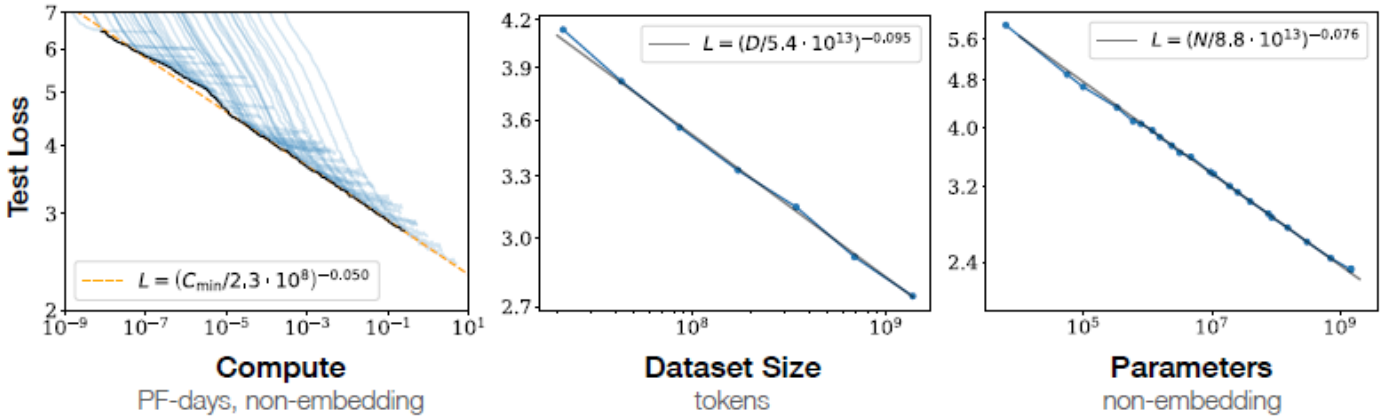

Transformer

学習データが膨大なら、Transformerでなんとかなるのでは?

arXiv:1706.03762

Transformer

$$\mathrm{Attention}(Q,K,V) = \mathrm{softmax}(\frac{QK^T}{\sqrt{d_k}})V$$

Q: Query
K: Key
V: Value

KeyとValueが「メモリー」的な働き　(K=Vは多い)

Queryは「問い合わせ」

QK^Tで「問い合わせ」と「メモリー」を
照らし合わせて、関係性、つまり、
「どこに注目すべきか」を抽出。(Attention weight)

Self-attentionの場合、Q=K=V

素粒子データでは
左側(エンコーダー)だけをよく使う

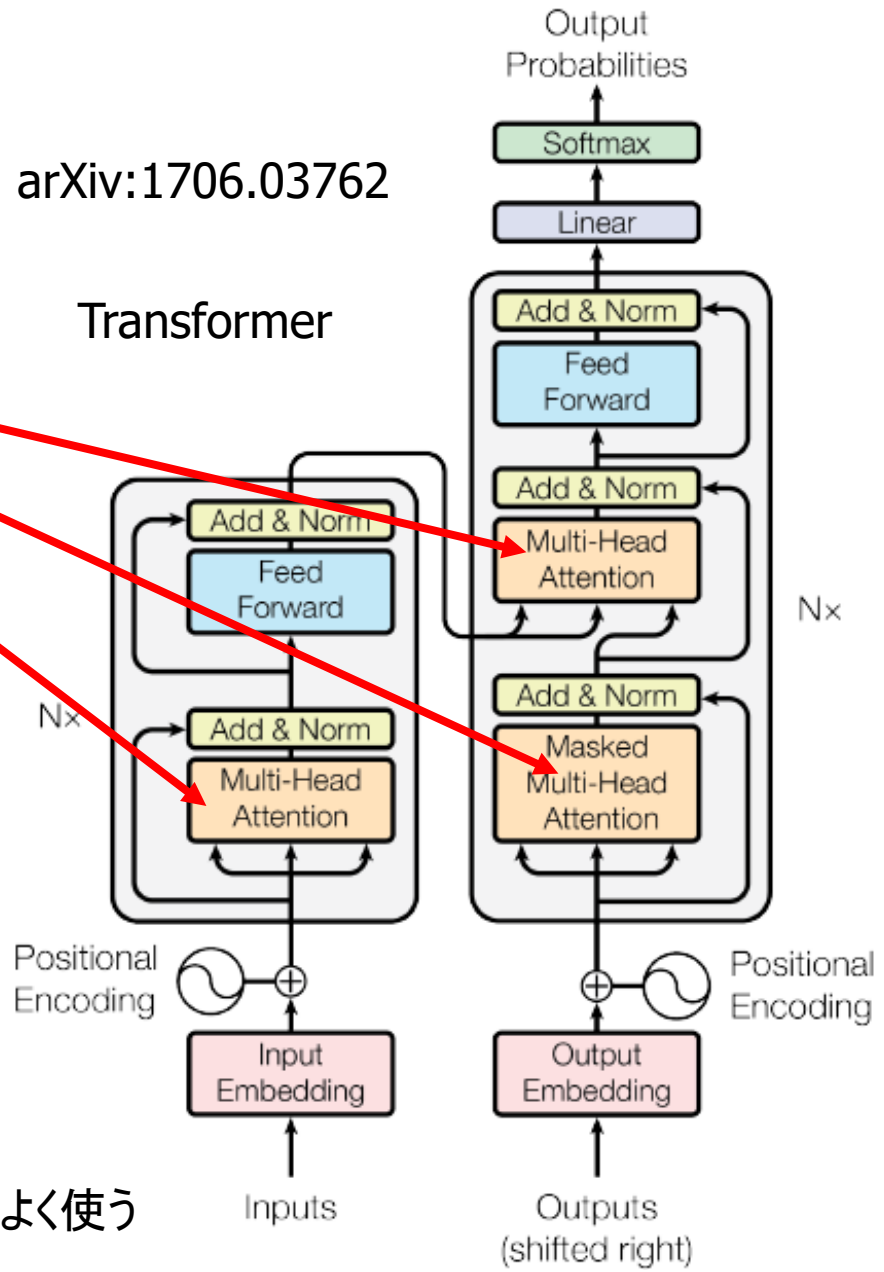

「基盤モデル」：ジェット汎用識別

「基盤モデル」

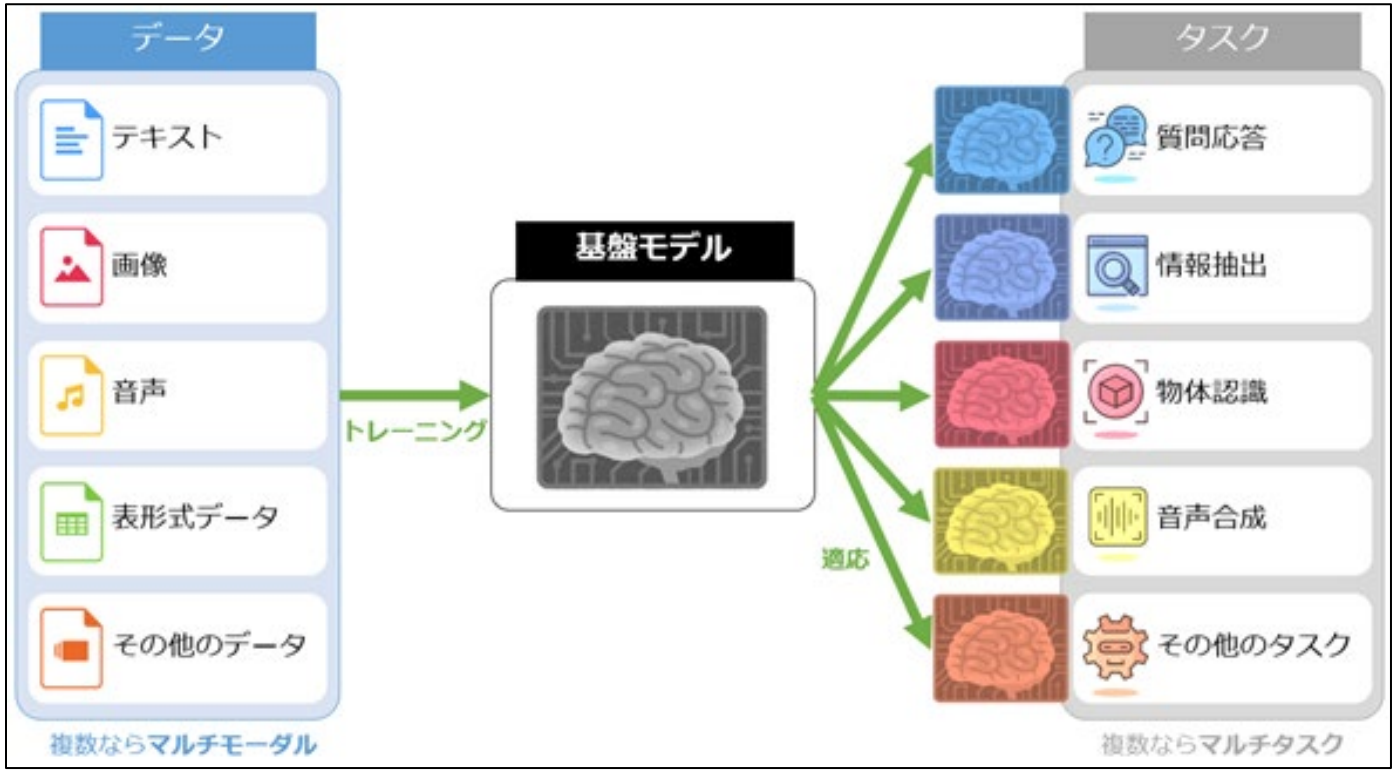

ジェットもいろいろ：q,g,b,W,Z,H,top etc.

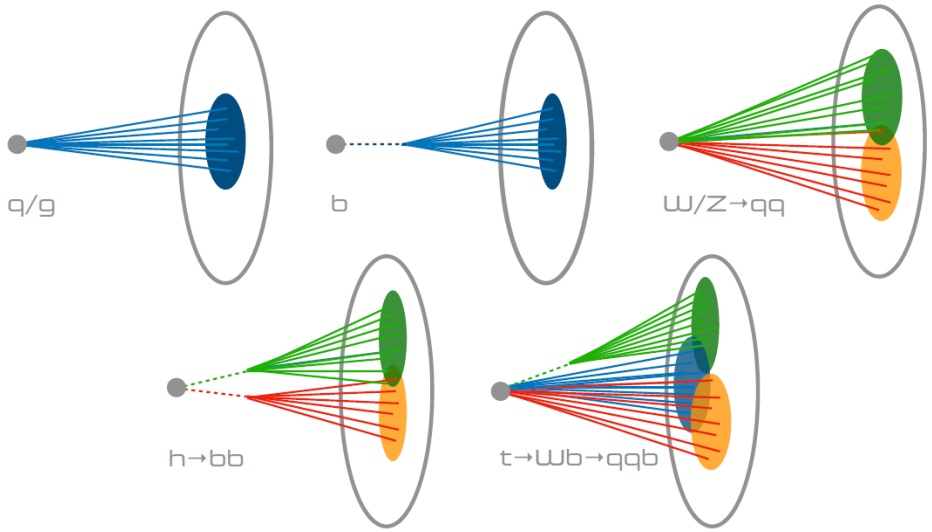

ちょっとテーマが小さいと思うかもしれないが、
素粒子データでも「基盤モデル」使えそう

https://atmarkit.itmedia.co.jp/ait/articles/2302/27/news014.html

ざっくり言うと「基盤モデル」とは「汎用的で賢いモデル」のこと。
実際に使うには、それをベースに目的に合わせてファインチューニング（再トレーニング、転移学習）をする。

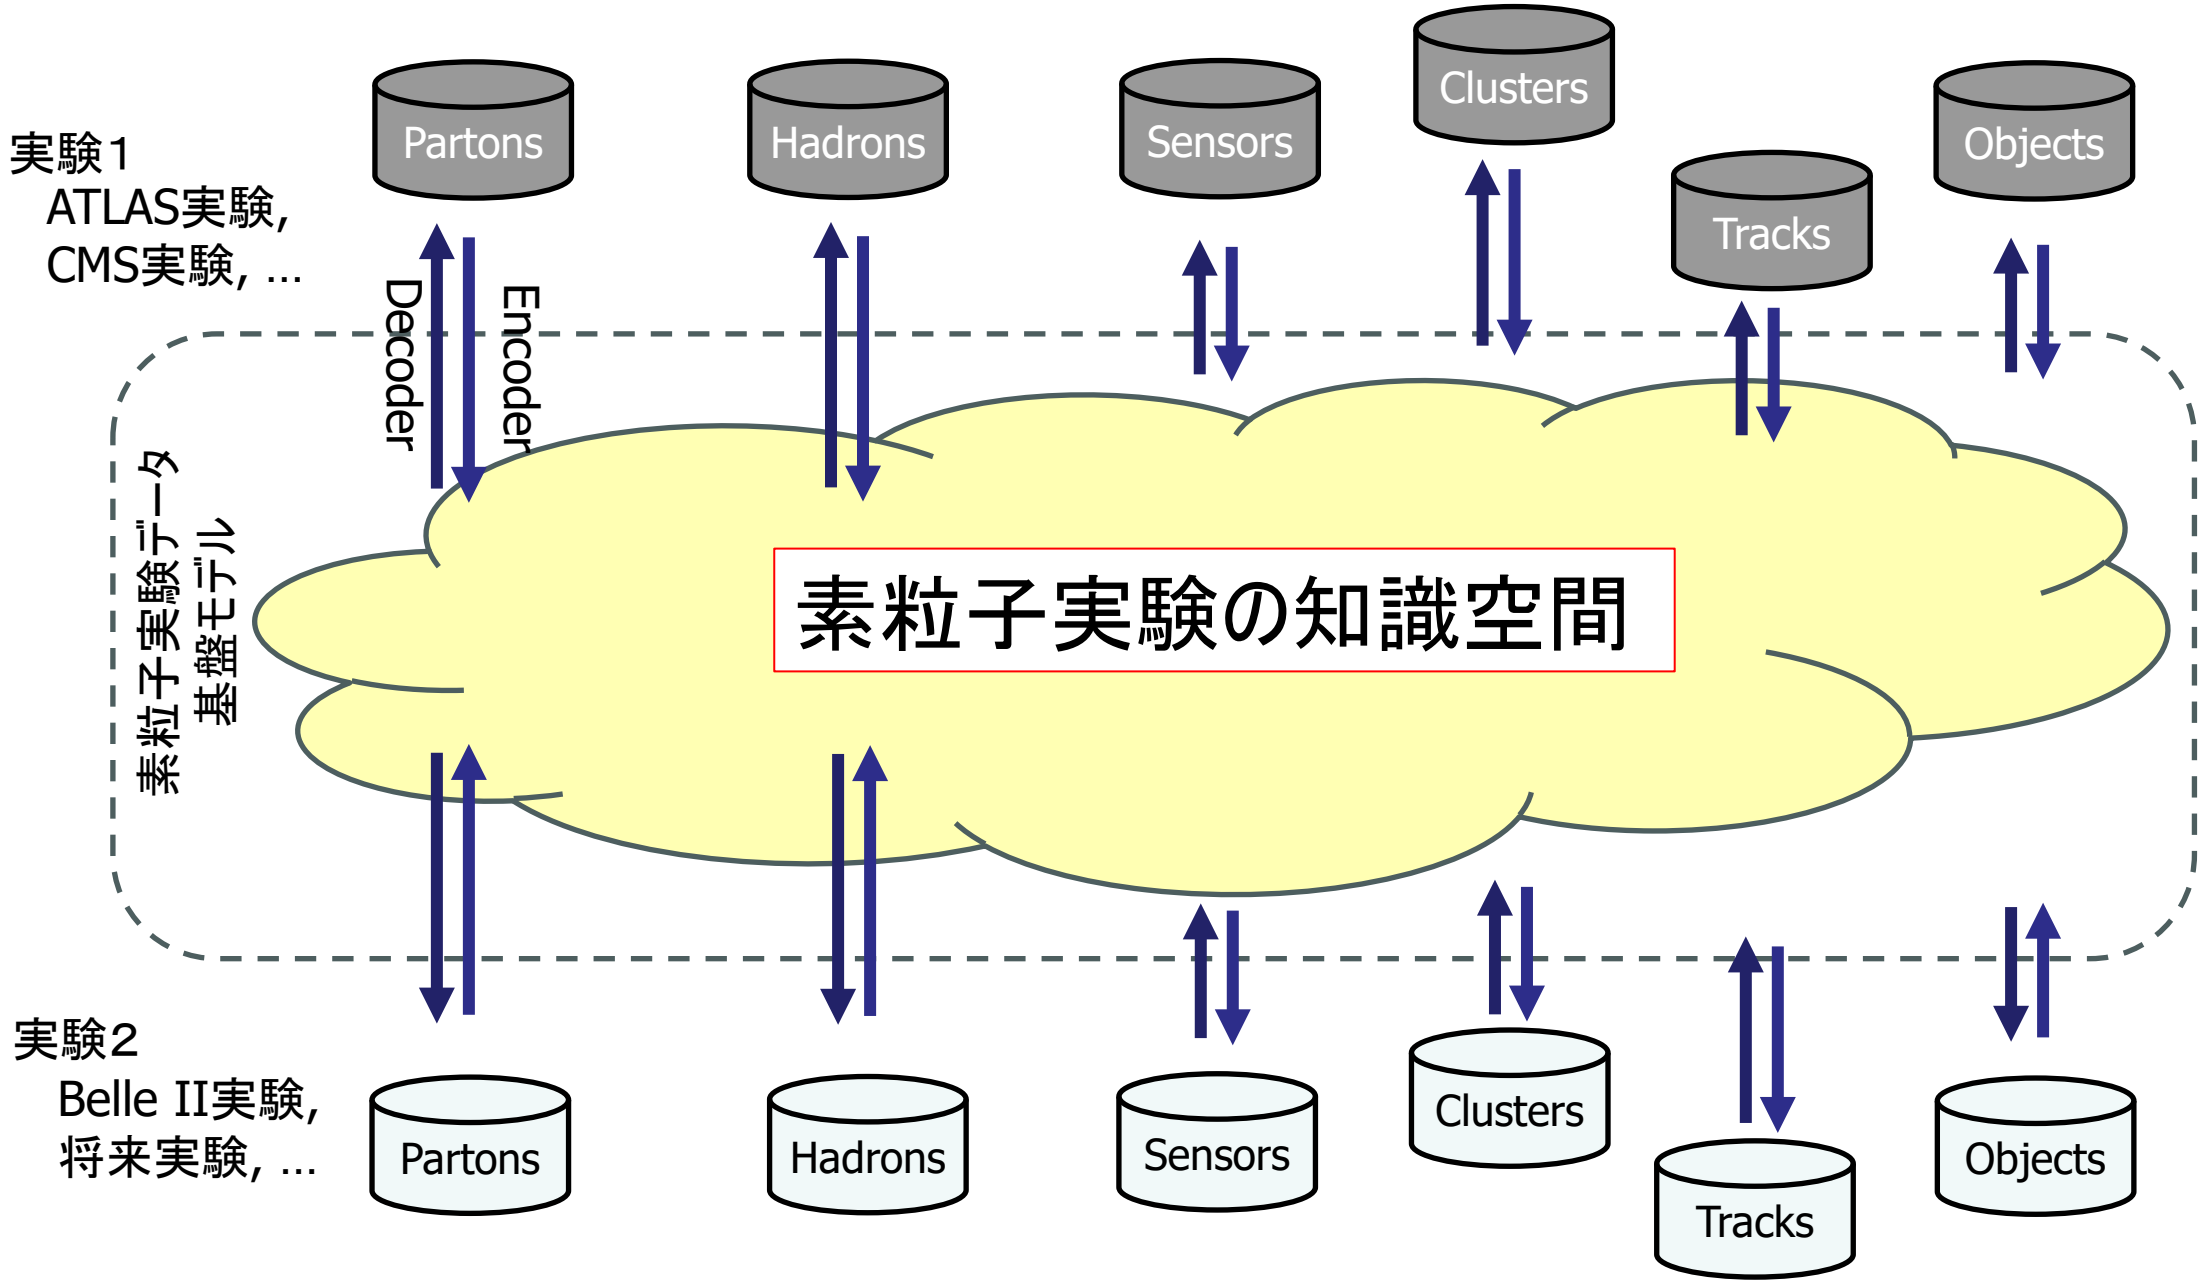
実験1
ATLAS実験,
CMS実験, …
Partons
Hadrons
Sensors
Clusters
Tracks
Objects
Decoder
Encoder
素粒子実験データ
基盤モデル
素粒子実験の知識空間
実験2
Belle II実験,
将来実験, …
Partons
Hadrons
Sensors
Clusters
Tracks
Objects

粒子識別等の性能改善（識別問題）

- b-tagging, c-tagging, tau-ID, q/g tagger
- W/Z, Top, Higgs tagger
- (Low p_T) electron, (low p_T) muon etc.
- 信号事象と背景事象の分類
- Particle flow

シミュレーション（生成AI）

- 検出器シミュレータ (Geant4の代替→高速化)
- 物理現象のシミュレータ：ジェット生成

ビッグデータから新粒子を発見できるのか？

- 異常検知

科学するAI・オートメーション化（自動運転）・研究者 etc.

- 説明責任（Explainable AI），解釈可能（Interpretability）
- 物理法則、対称性などの抽出
- 素粒子実験の一連の流れを（半）自動化するようなシステム
- データ解析するAI arXiv:2603.20179

"ChatGPT 3.5"の出現 (2022年11月)

Foundation model

LLM (Large Language Model) 生成AI元年 2023

AI-agents AIエージェント元年 2025

新しい研究スタイルの創造

素粒子物理も人工知能（データサイエンス）も研究したい方、大歓迎！

まとめ

- 素粒子実験
  - BigData → 人工知能の応用（情報理工的な理論寄りでなく実践的なツール）

[現実路線]

- 既存のツールを**機械学習を取り入れたツール**に置き換える
  - 個人的な感覚的では、5年ぐらい前まではかなり懐疑的（特にATLAS実験グループでは）
  - 今は積極的
    - **圧倒的な改善がときどきある（少々の改善は確実）**
    - 実験データの理解と十分に使えるだけの研究実績・経験
  - 素粒子実験データ
    - グラフネットワークやトランスフォーマは相性がいい

[将来投資]（誰かがやり遂げるはず。その”誰”を自分へ）

- 素粒子実験のデータ解析用の
  基盤モデル（Foundation Model）の可能性
- データを解析するAI（～“今”の研究者・大学院生）の可能性

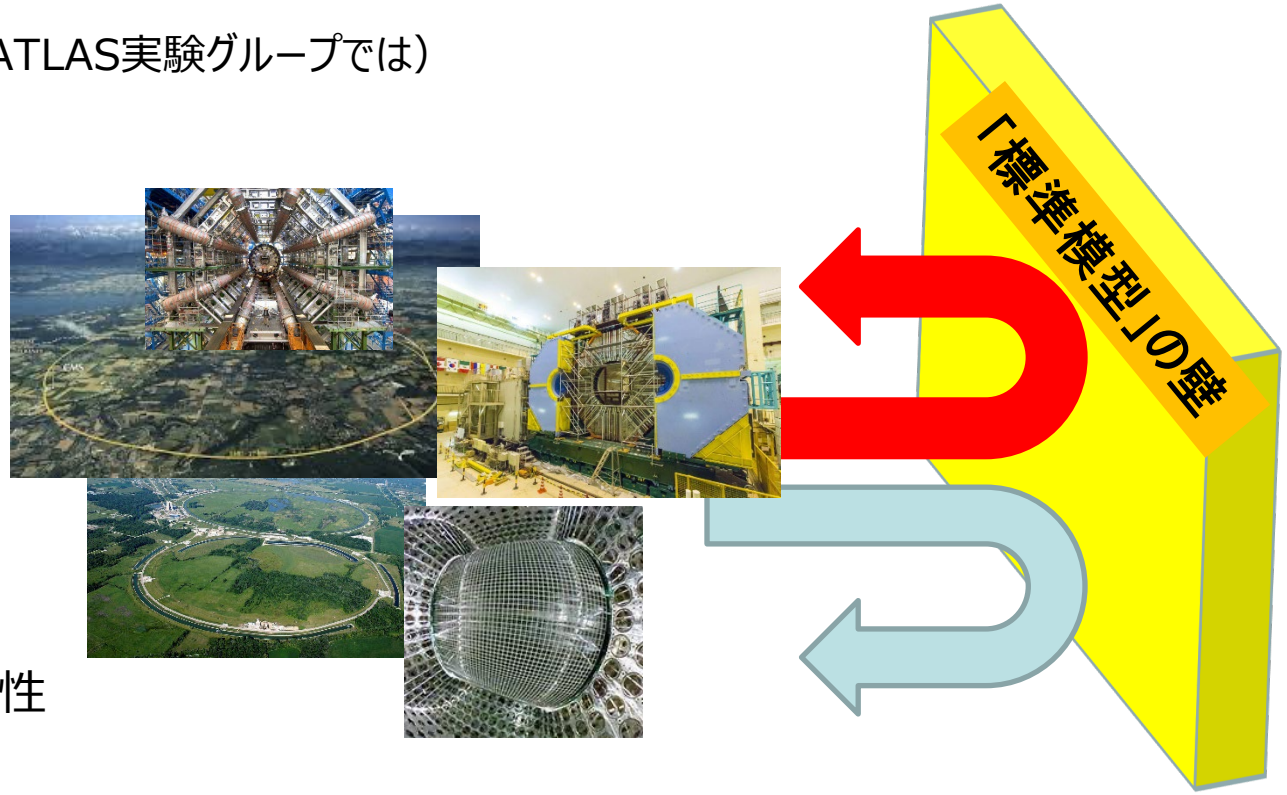

素粒子屋さんとしては　**「素粒子標準模型」の牙城を崩す！**