

大型加速器を用いた 素粒子実験への機械学習適用

2022/11/18

大阪公立大学, 大阪公立大学NITEP, 大阪大学RCNP, 大阪大学IDS

岩崎 昌子



阪大RCNP 深層学習プロジェクト 阪大IDS 学際プロジェクト

FY2018 – FY2023

大型加速器を用いた素粒子・原子核物理実験に
機械学習を適用

素粒子・原子核実験と情報分野との共同研究を行い
加速器実験のアプローチに変革を生み出したい

素粒子
原子核物理



情報科学

学術変革領域研究(A) 学習物理学の創成

総括班：橋本幸士（領域代表）

B01：深層学習の数理と応用：田中章詞（理研AIP）

B02：高次元統計的機械学習：樺島祥介（東大理）

B03：機械学習と位相幾何学：福嶋健二（東大理）

A01：計算物理学：富谷昭夫（大阪国際工科専大）

A02：素粒子物理学：野尻美保子（KEK）

A03：物性物理学：大槻東巳（上智大）

A04：量子・重力物理学：橋本幸士（京大理）

学習物理学
新法則の発見、新物質の開拓

FY2022

—

FY2026

計画研究A02 「機械学習による素粒子物理の革新的発展」

野尻（代表、KEK）

田中（東大ICEPP） 長原（阪大IDS） 武村（九工大） 岩崎（阪公大）

大型加速器を用いた素粒子実験

LHC

エネルギー 14TeV
周長 = 27km

- ATLAS 実験
- CMS 実験
- LHCb 実験



ATLAS 実験 ~5000人

フランス-スイス

日本

SuperKEKB

エネルギー ~11GeV
周長 = 3km

- Belle II 実験



Belle II 実験 ~1100人

- 素粒子実験用の主な大型加速器は世界に2つ
- 素粒子や加速器の研究者・技術者・学生が多数集結

Belle II 実験の装置

SuperKEKB 加速器

Belle II 測定器



周長 3km

7.7m(W) x 7.2m(D) x 7.9m(H)

大量の素粒子反応を生成

大型加速器を用いた素粒子実験

7

- ▶ 大型実験施設（巨大加速器、測定器）を使用
→ 実験装置の制御点数は数千-数万点以上
- ▶ 膨大量の実験データ
→ BelleII実験では、年間数十ペタバイトの予定
- ▶ 膨大な背景事象から極微の信号事象を抽出

大量データ処理を
いかに、効率よく・精度よく行うか

機械学習の適用が有効


従来より**高性能**、**高速**なデータ処理が期待

強力なデータ処理ツール



大量データを処理を
いかに、効率よく・精度よく行うか

大型加速器実験 × 最先端情報学




ビーム衝突実験
データ取得

データ校正
粒子再構成

物理解析

大型加速器実験 × 最先端機械学習

機械学習の適用



ビーム衝突実験
データ取得

データ校正
粒子再構成

物理解析

大型加速器実験
大量データ 高額な運転経費

BelleII実験
生成データ量 年間~30ペタバイト
運転経費 年間数十億円

実験の効率化、大量データを効率的に学術的結果へ導くために、
最先端機械学習の適応が有効

例: 10%の向上 → 年間数億円の費用効果

機械学習

Supervised Learning

教師あり学習

Task driven

Classification

分類・識別

Regression

回帰

Unsupervised Learning

教師なし学習

Data driven

Dimensionality Reduction

次元削減

次元削減

Clustering

Reinforcement Learning

強化学習

Environment driven

Algorithm learns to react to the environment

Real-time decisions

Game AI

Learning Tasks

Robot Navigator

....

いろいろなタイプの機械学習があります

機械学習

Supervised Learning

教師あり学習

Task driven

Classification
分類・識別

Regression
回帰

加速器実験で行ってきた機械学習
特徴量(High-level data)を用いた
教師あり学習による分類・識別

Dimensionality
Reduction
次元削減

Clustering

to the environment

Real-time decisions
Game AI
Learning Tasks
Robot Navigator
....

いろいろなタイプの機械学習があります

機械学習

計算機技術・計算手法の進展により
様々なタイプの機械学習が可能になった
低特徴データ(生データ、low-level data)を用いた
機械学習も可能になった

Classification

分類・識別

Regression

回帰

Dimensionality

Reduction

次元削減

Clustering

Real-time decisions

Game AI

Learning Tasks


Robot Navigator

....

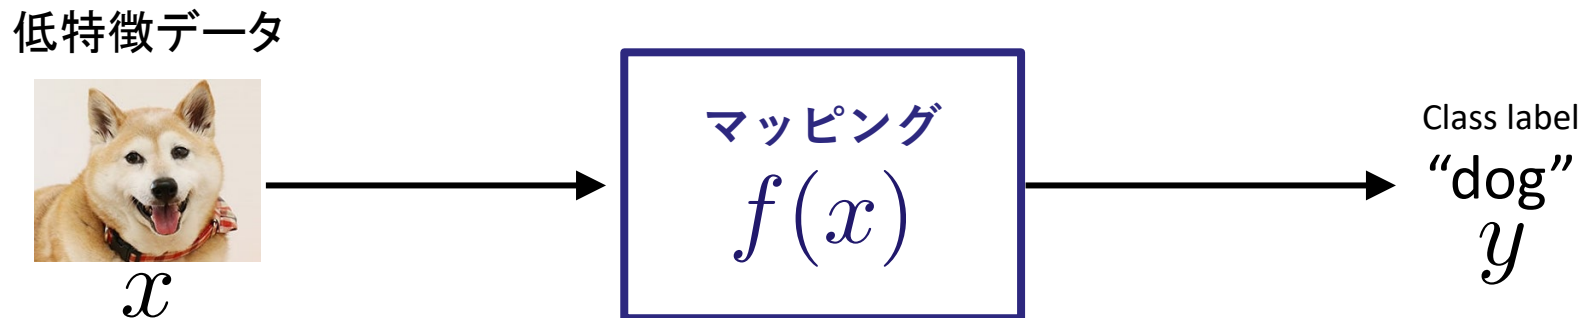
いろいろなタイプの機械学習があります

いままでの機械学習 vs 深層学習

- 今までの機械学習



- 深層学習



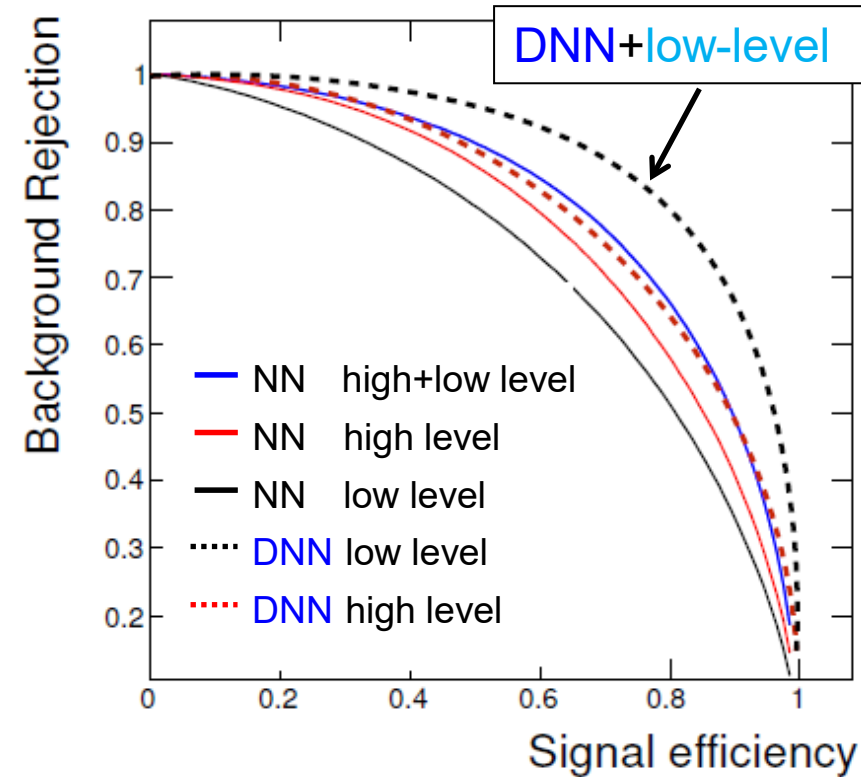
深層学習は、特徴抽出も含めて、データから **学習** している

入力 x から出力 y へのマッピングの作成

特徴量 vs 低特徴データ

LHCにおけるb-jet識別

低特徴データを用いた
深層学習を行うと
よい識別性能が得られる!!



D.Guest, K.Cranmer, D.Whiteson, Annu. Rev. Nucl. Part. Sci.68 1-22 (2018),
arXiv:1806.11484 [hep-ex].

加速器実験への 最先端機械学習の適用

【キーワード】

- 低特徴データ (Low-level data, 生データ)
- 様々なタイプの機械学習
回帰、次元削減、強化学習、
再帰型ネットワーク、畳み込み型ネットワーク ...

現在進めている以下の開発について紹介する

1. 低特徴データを用いた機械学習手法の開発
 - 1-1: 信号識別・フレーバー識別
 - 1-2: 測定器較正
2. スパースセンシングを用いたデータ圧縮
3. 機械学習を用いた加速器制御技術の開発

1. 生データを用いた機械学習


1-1: 信号号識別・フレーバー識別

情報分野では、高度な画像認識ツールが開発されている(CNN等)



戦略1: 素粒子実験データを画像データへ変換して適用

→ 多くの実験で適用されている

Particle Jet



Jet as Image data





D. Guest, K. Cranmer, D. Whiteson, Annu. Rev. Nucl. Part. Sci. **68** 1-22 (2018)

1. 生データを用いた機械学習

1-1: 信号号識別・フレーバー識別

問題点

- 実験で生成された粒子は、任意の運動量・エネルギーを持っている
→ 膨大量の学習データが必要
- データを画像に変換するときに、精度が落ちる可能性あり



D. Guest, K. Cranmer, D. Whiteson, Annu. Rev. Nucl. Part. Sci. **68** 1-22 (2018)


1. 生データを用いた機械学習

1-1: 信号号識別・フレーバー識別

Osaka-City U., IDS, RCNP

戦略2: low-level data(粒子の4元運動量、位置情報) + DNNを用いた
識別方法を開発

Particle Jet



Jet as low-level data

Part1 (E, P_x , P_y , P_z , x, y, z)

Part2 (E, P_x , P_y , P_z , x, y, z)

Part3 (E, P_x , P_y , P_z , x, y, z)

.....

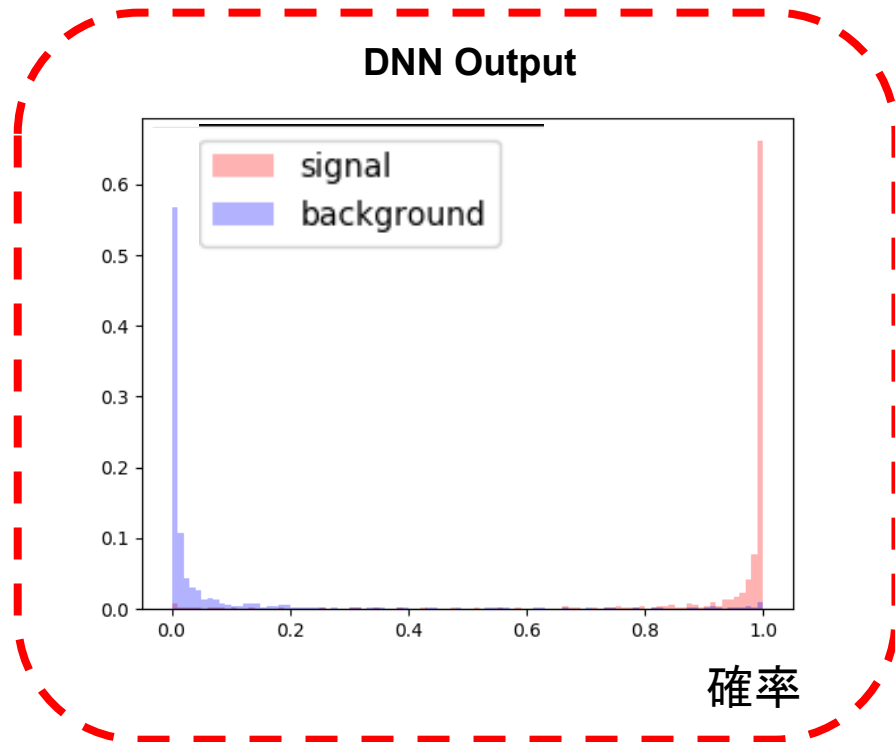
粒子の4元運動量と位置情報を
直接NNに入力

1-1: 信号号識別・フレーバー識別

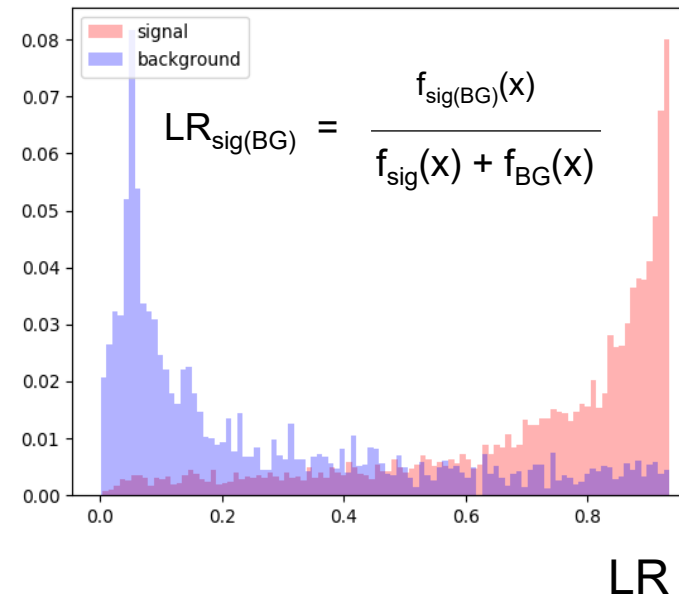
Belle実験での信号識別

信号識別性能向上!!

N.Kishida (Osaka City U.)



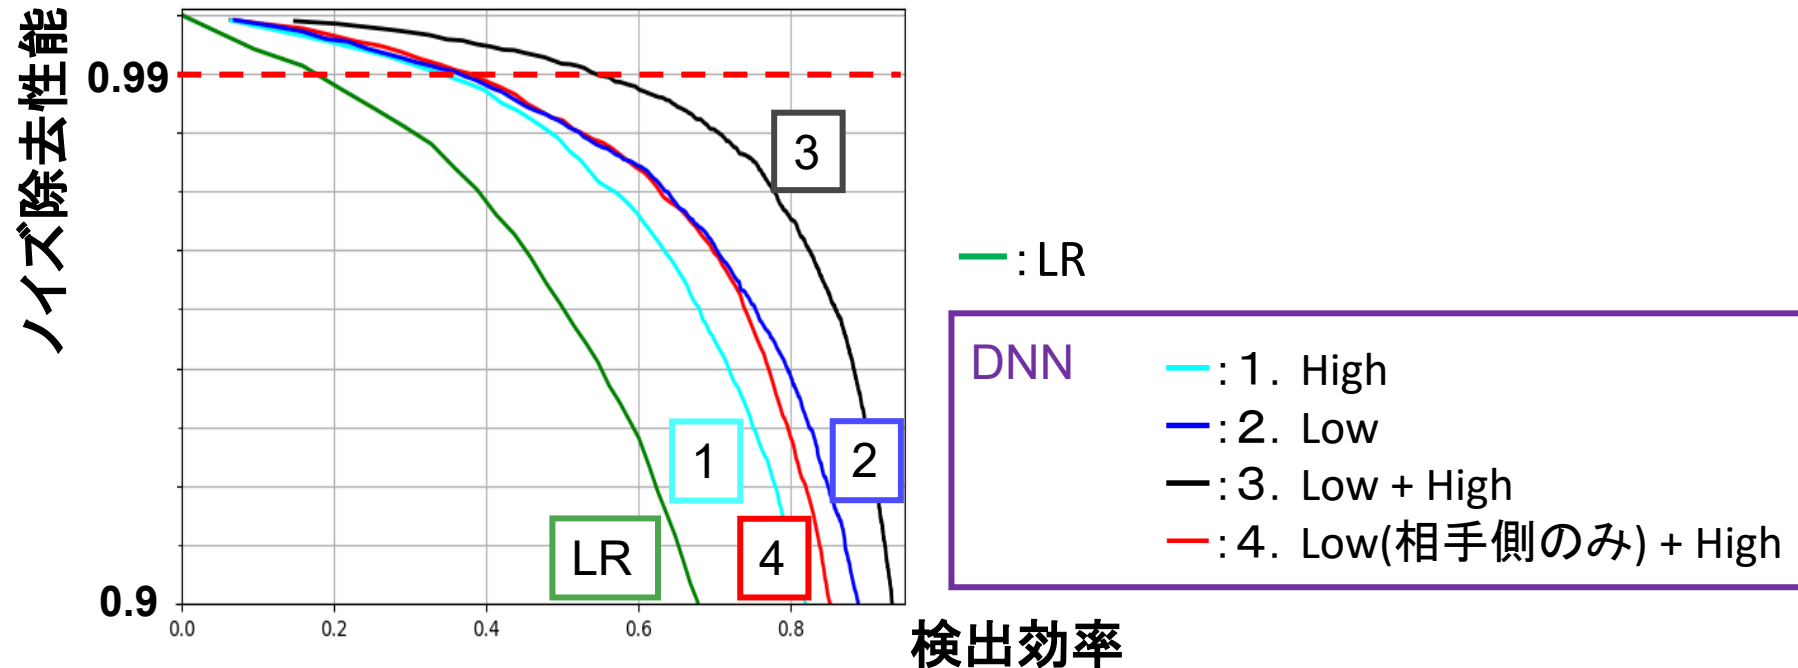
Likelihood Ratio (LR) using $\cos\theta$, KSFW



1-1: 信号号識別・フレーバー識別

Belle実験での信号識別

N.Kishida (Osaka City U.)



- Low-level dataを用いると識別能力が向上
- Low-level + High-level + DNN だと、識別能力が最も高い
- ノイズ除去性能0.99と比較すると、従来の方法に比べて**検出効率が2倍向上**


1-1: 信号号識別・フレーバー識別

ILC実験でのフレーバー識別

N.Kishida
(Osaka City U.)

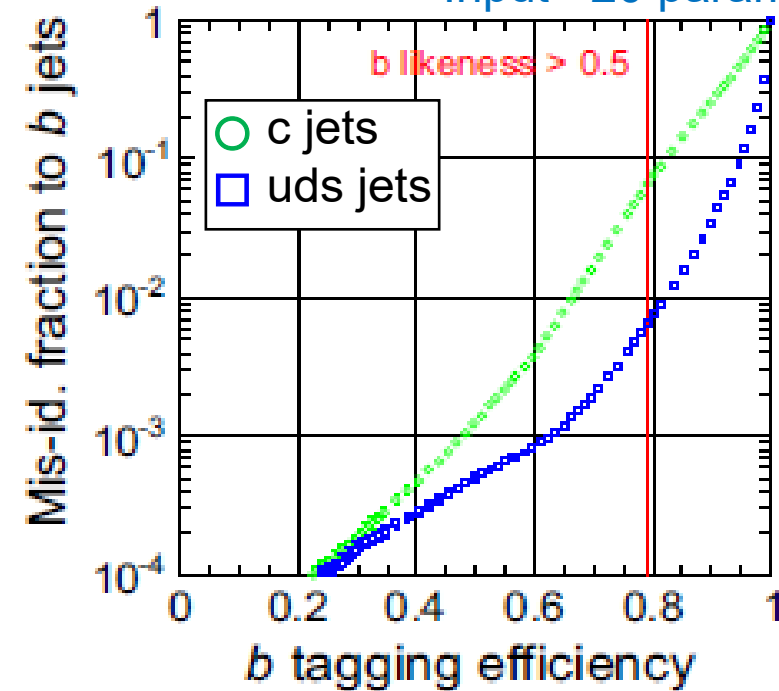
■ **b-jet** identification performance

DNN with Low + High level data



BDT with High-level data*

Input ~20 params



* : T.Suehara T. Tanabe
NIM A808(2016) 109

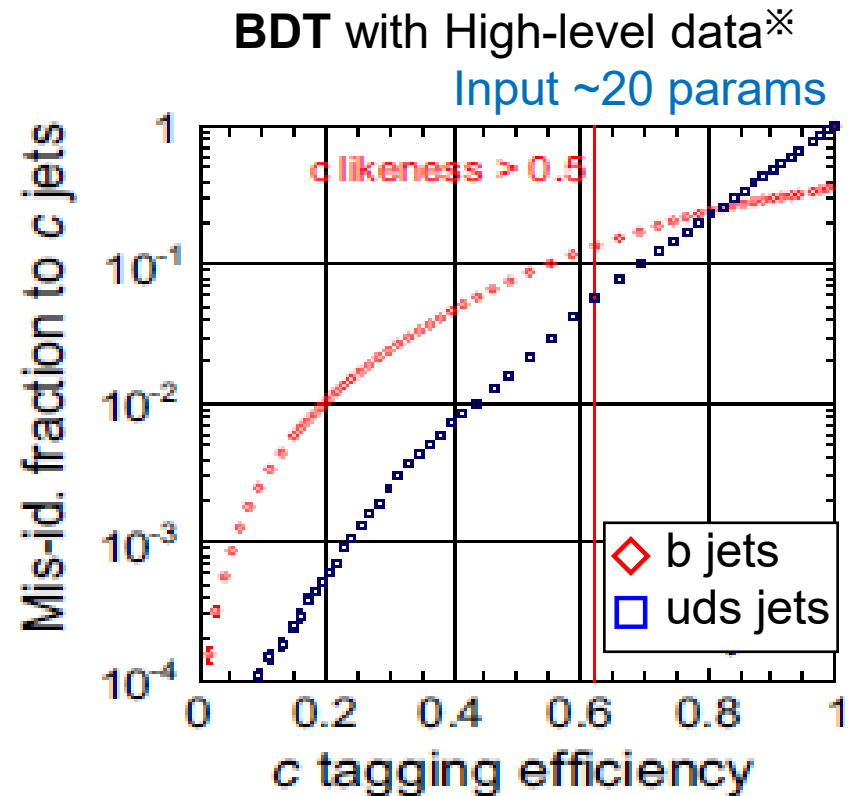
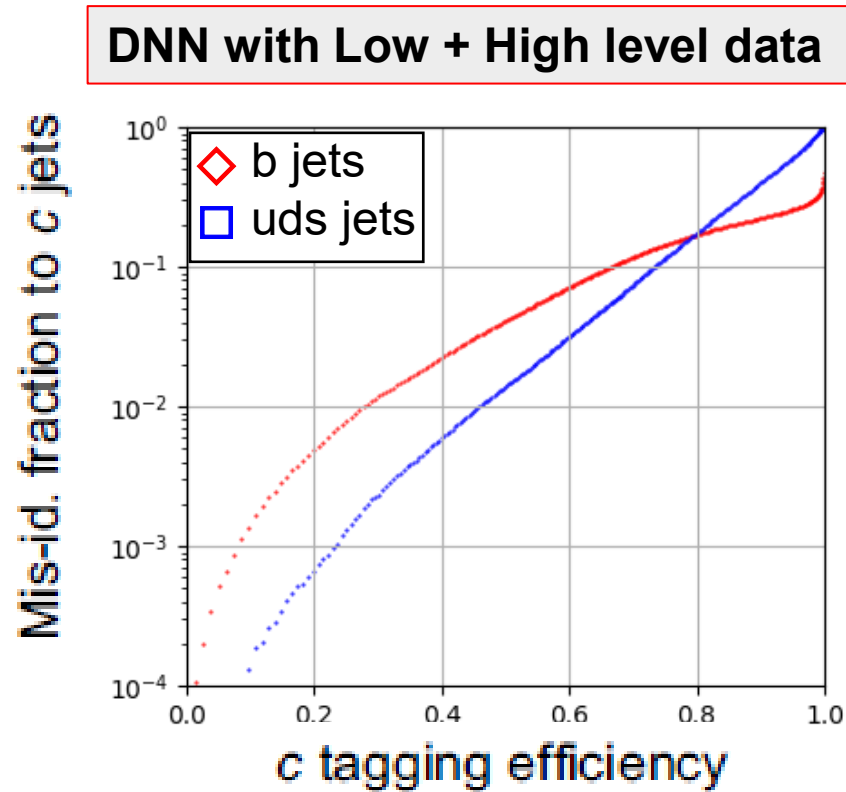
~1/3 mis-id fraction
with the same b-tagging efficiency

1-1: 信号号識別・フレーバー識別

ILC実験でのフレーバー識別

N.Kishida
(Osaka City U.)

■ c-jet identification performance



~1/2 mis-id fraction

With the same c-tagging efficiency

※ : T.Suehara T. Tanabe
NIM A808(2016) 109



1. 生データを用いた機械学習

1-2: カロリメータのエネルギー較正

Osaka-City U., IDS, U. Oregon, SLAC

ILC SiD測定器電磁カロリメータのエネルギー較正を開発

- 30層Si + W サンプル型
- 物質質量(total) $\sim 26X_0$
- $\Delta E \sim (17/\sqrt{E} \oplus 1)\%$ (デザイン値)




問題点

1. 入射粒子のエネルギーと測定エネルギーが**非線形**
2. 電子と光子で、測定器の応答が異なる(**粒子依存性**)

1-2: カロリメータのエネルギー較正

機械学習の回帰(Regression)を用いてエネルギー較正を行う




1-2: カロリメータのエネルギー較正

機械学習の回帰(Regression)を用いてエネルギー較正を行う

エネルギー較正性能向上!!

Photon Energy Resolution $\Delta E(\%) \times \sqrt{E}$

Y.Naka (Osaka-City U.)



生データを用いた機械学習

2. スパースセンシングを用いた データ圧縮

- 加速器実験では膨大量のデータが生成される
- データ収集能力に限界があるのでFilteringが必須
(例： Belle2実験のデータ転送帯域 30GB/sec)

→物理事象を選別するFiltering(トリガー)を設定




トリガー条件をみたさない事象は捨てられる

機械学習を用いて

リアルタイムに事象のデータサイズを圧縮できないだろうか？

スパースサンプリング・復元による信号観測

元信号に対して**観測点が少ない**、劣決定問題を解く手法



通常サンプリング

スパースサンプリング

同じサンプリング数で、より広帯域に信号復元可能


…ブラックホールを「可視化」した手法として有名

- 空間・時間についてスパースに(疎に)計測
- 計測した**少数データ**から、信号のスパース性(時間や空間の近傍連続性)を仮定して元データ情報を**復元**

→多数ある観測点から本質的な観測点の選別も可能

スパースサンプリング・復元による信号観測

元信号に対して**観測点が少ない**、劣決定問題を解く手法



通常のサンプリング

スパースサンプリング

同じサンプリング数で、より広帯域に信号復元可能


…ブラックホールを「可視化」した手法として有名

- 空間・時間についてスパースに(疎に)計測
- 計測した**少数データ**から、信号のスパース性(時間や空間の近傍連続性)を仮定して元データ情報を**復元**

→多数ある観測点から本質的な観測点の選別も可能

スパースサンプリング・復元による信号観測

元信号に対して**観測点が少ない**、劣決定問題を解く手法



通常のサンプリング

スパースサンプリング

同じサンプリング数で、より広帯域に信号復元可能

…ブラックホールを「可視化」した手法として有名

- ・空間・時間についてスパースに(疎に)計測
- ・計測した**少数データ**から、信号のスパース性(時間や空間の近傍連続性)を仮定して


元データ情報を**復元**

→多数ある観測点から本質的な観測点の選別も可能

信号が持つ重要な情報を保つような
サンプリングパターンを機械学習で最適化する


素粒子実験へのスパースサンプリングの適用

素粒子実験に、スパースサンプリング・スパース復元を適用させることを目指す。



素粒子実験へのスパースサンプリングの適用


素粒子実験に、スパースサンプリング・スパース復元を適用させることを目指す。



DAQ時に必要な処理は「あらかじめ決められたパターンにしたがうサンプリング処理」
→ リアルタイムに事象のデータサイズを削減可能

素粒子実験へのスパースサンプリングの適用

素粒子実験に、スパースサンプリング・スパース復元を適用させることを目指す。



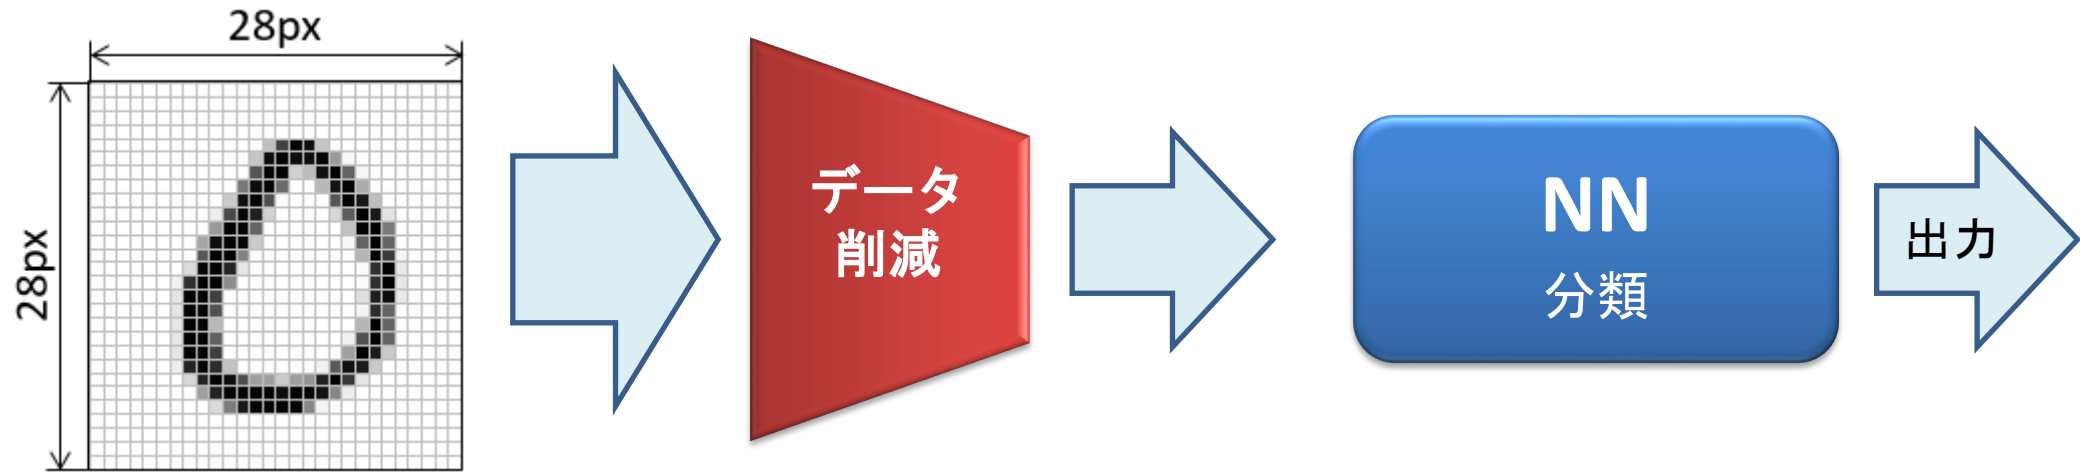
本研究では、ILC SiD 電磁カロリメータのエネルギー較正にスパースサンプリングを適用し、エネルギー較正性能について評価を行った

開発の指針

これまで行ってきた機械学習のタスク(本研究では、カロリメータのエネルギー較正)の前段に、データ削減・削減パターン最適化を挿入



予備実験：手書き文字の分類





入力データ

$28 \times 28 = 784$ 次元

- データ削減によって、文字分類性能がどの程度劣化するか評価する
- データ削減方法
 1. ランダム削減
 2. 機械学習(VAE)を用いた次元削減
 3. 機械学習で削減パターンを最適化して、データ削減

VAEを用いた次元削減


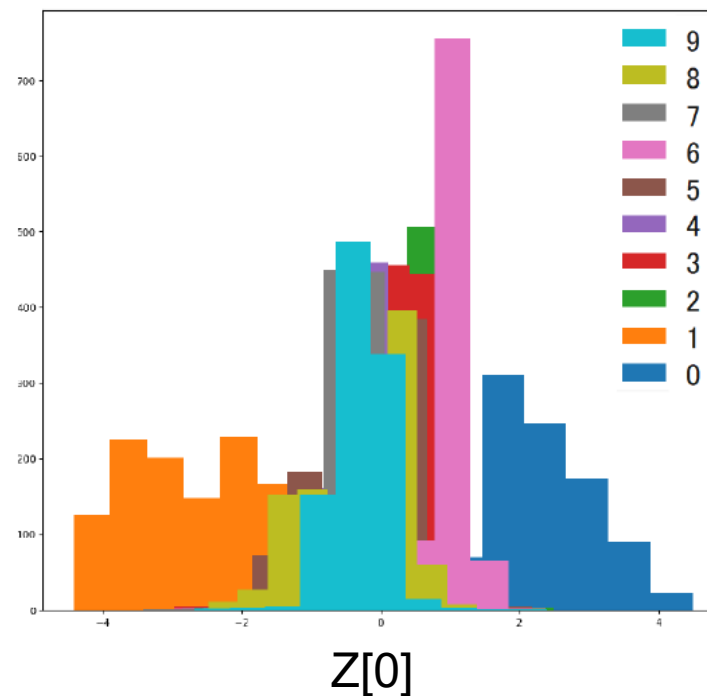



入力データ


28x28 = 784 次元

出力：潜在変数 Z

1 次元 (Z[0])




VAEを用いた次元削減

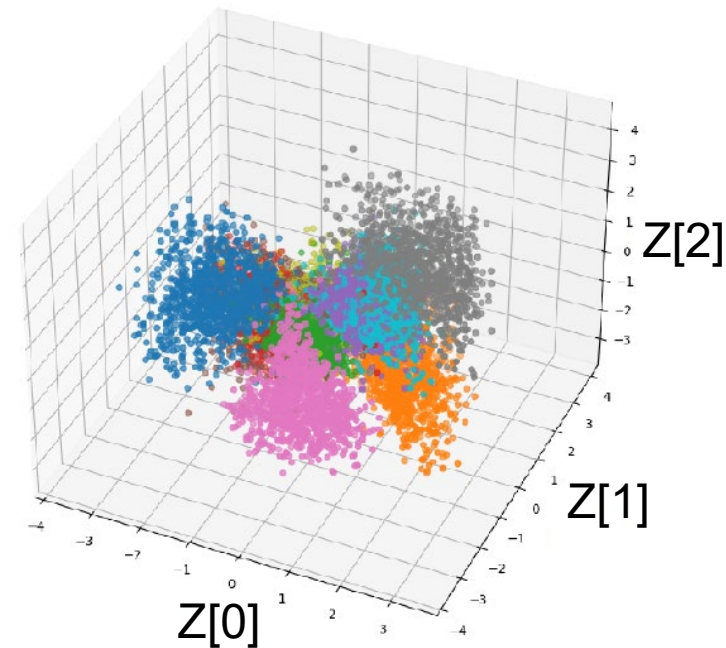


出力：潜在変数 Z

2次元 ($Z[0]$, $Z[1]$)






3次元 ($Z[0]$, $Z[1]$, $Z[2]$)



予備実験: 手書き文字の分類

C.Kato
(Osaka Metropolitan U.)

入力: 784パラメータ






データを
1/10(ランダム削減)
1/50(機械学習による次元削減)
に圧縮しても、
90%の分類性能を維持

予備実験: 手書き文字の分類

C.Kato

(Osaka Metropolitan U.)

入力: 784パラメータ






データを
1/10(ランダム削減)
1/50(機械学習による次元削減)
に圧縮しても、
90%の分類性能を維持

予備実験：手書き文字の分類

C.Kato

(Osaka Metropolitan U.)

入力:784パラメータ




データを
1/10(ランダム削減)
1/50(機械学習による次元削減)
に圧縮しても、
90%の分類性能を維持



ECLのエネルギー較正でも
機械学習を用いたデータ削減を目指す

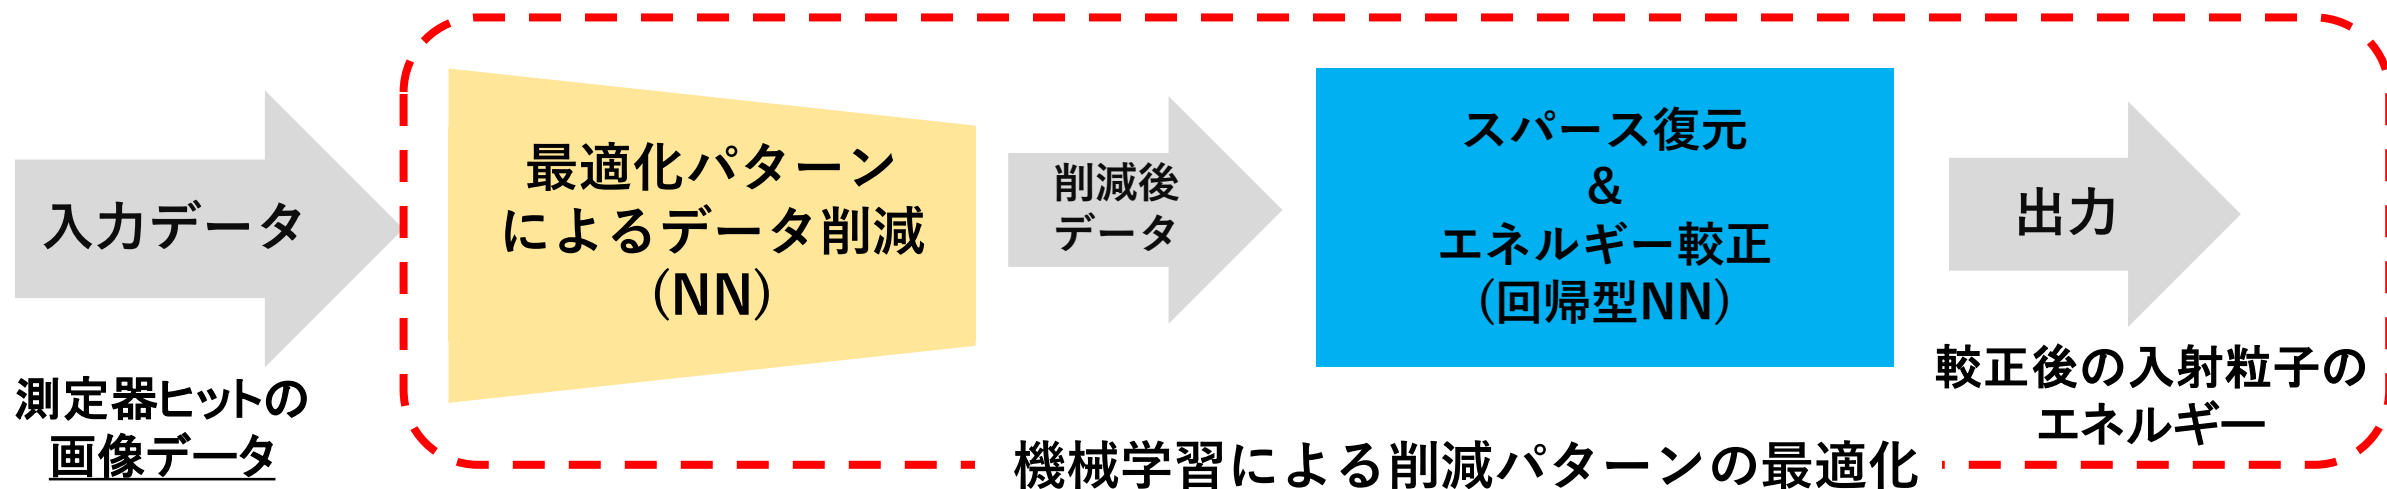
ILC SiD電磁カロリメータ(ECL)におけるデータ削減



測定器ヒットデータを使用し、エネルギー較正における削減パターンの最適化を行った。

削減パターンの最適化のための機械学習

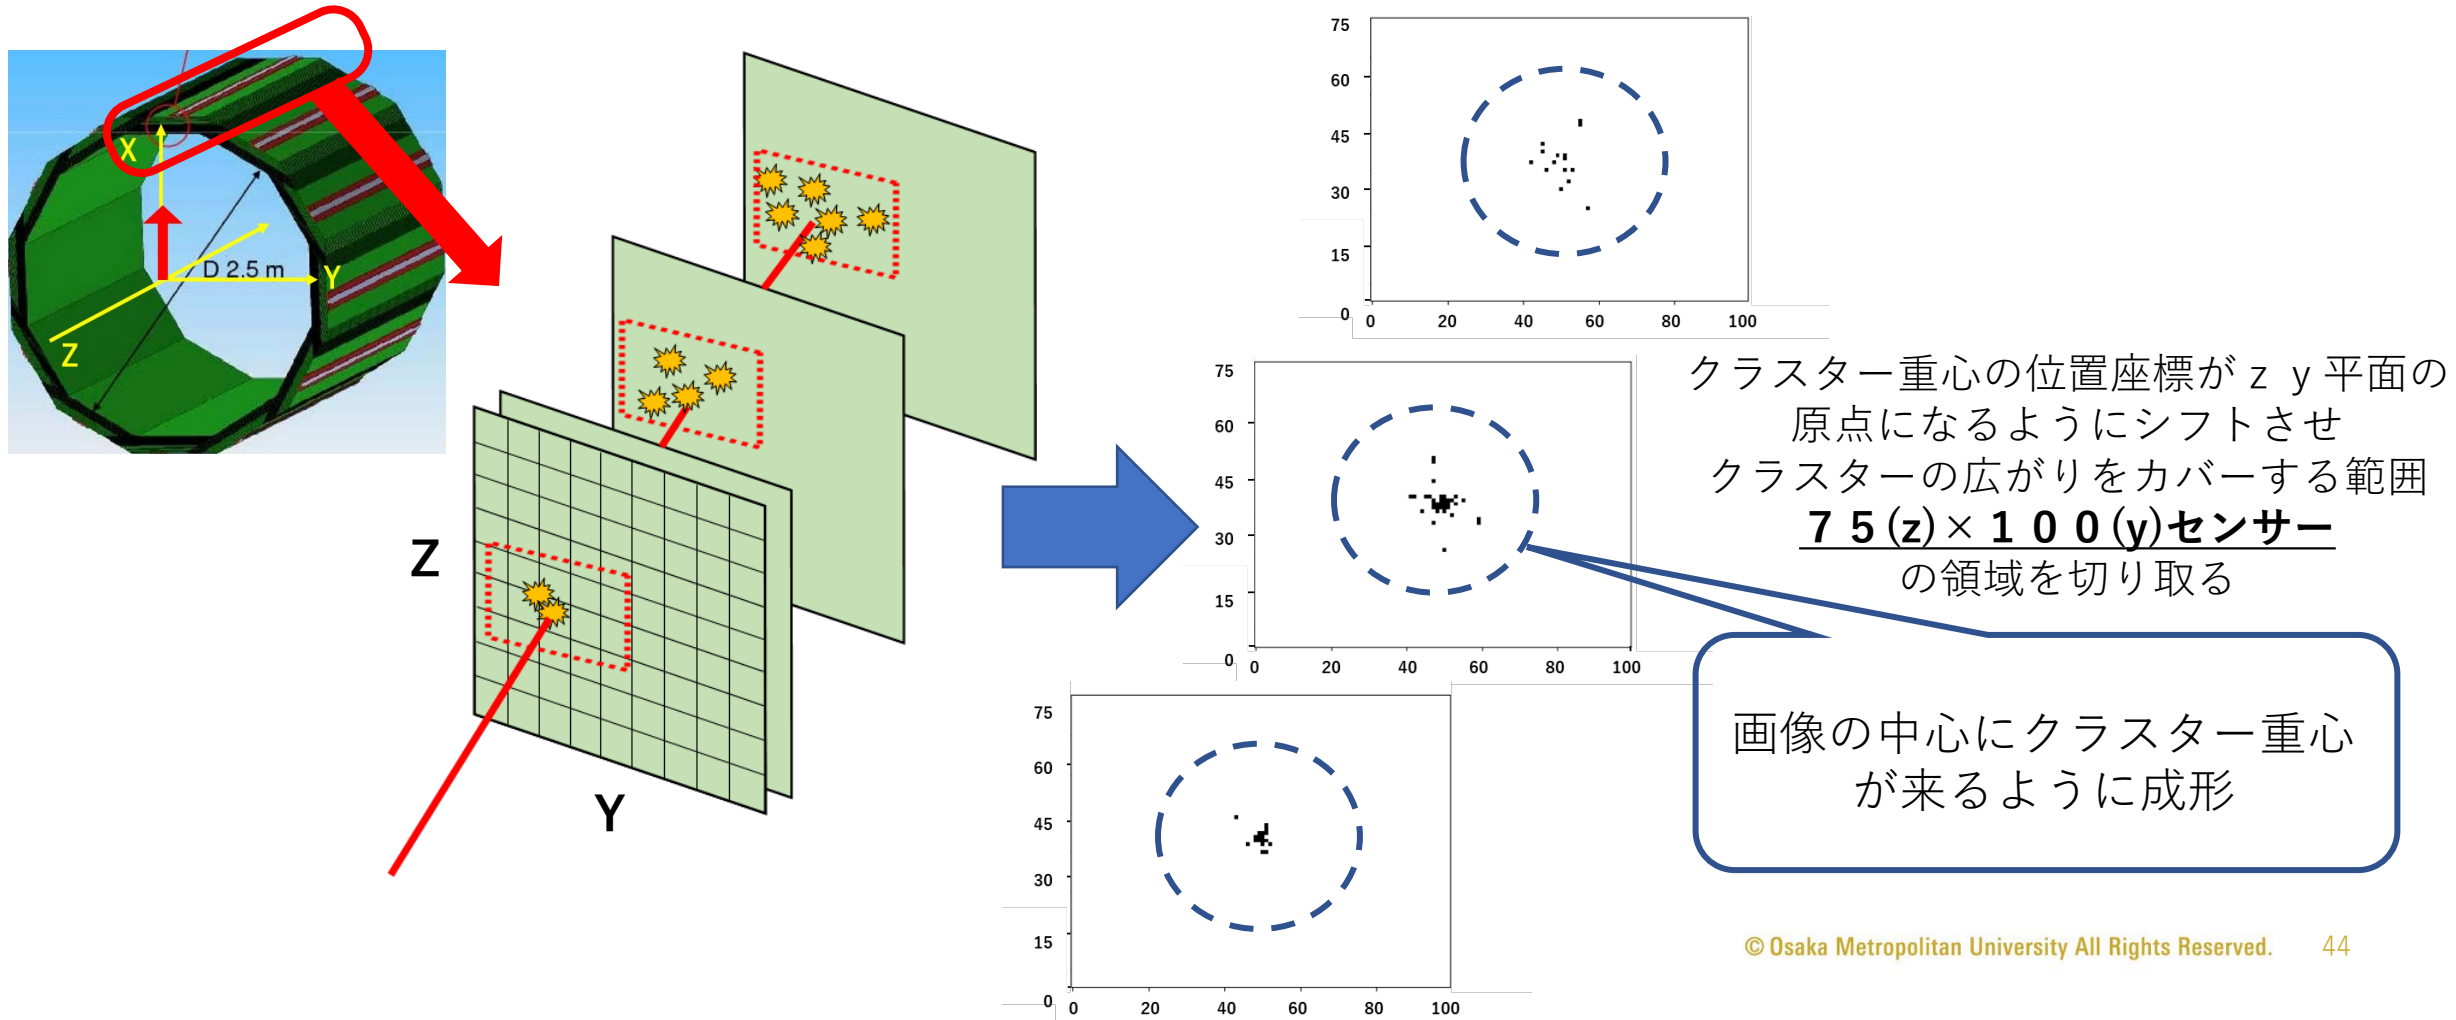
削減パターン最適化機械学習(*)を使用して、パターンの最適化を行う。



※ : M.Yoshida, H. Nagahara, et.al.,
"Joint optimization for compressive video sensing and reconstruction under hardware constraints",
The European Conference on Computer Vision (ECCV2018), 2018,

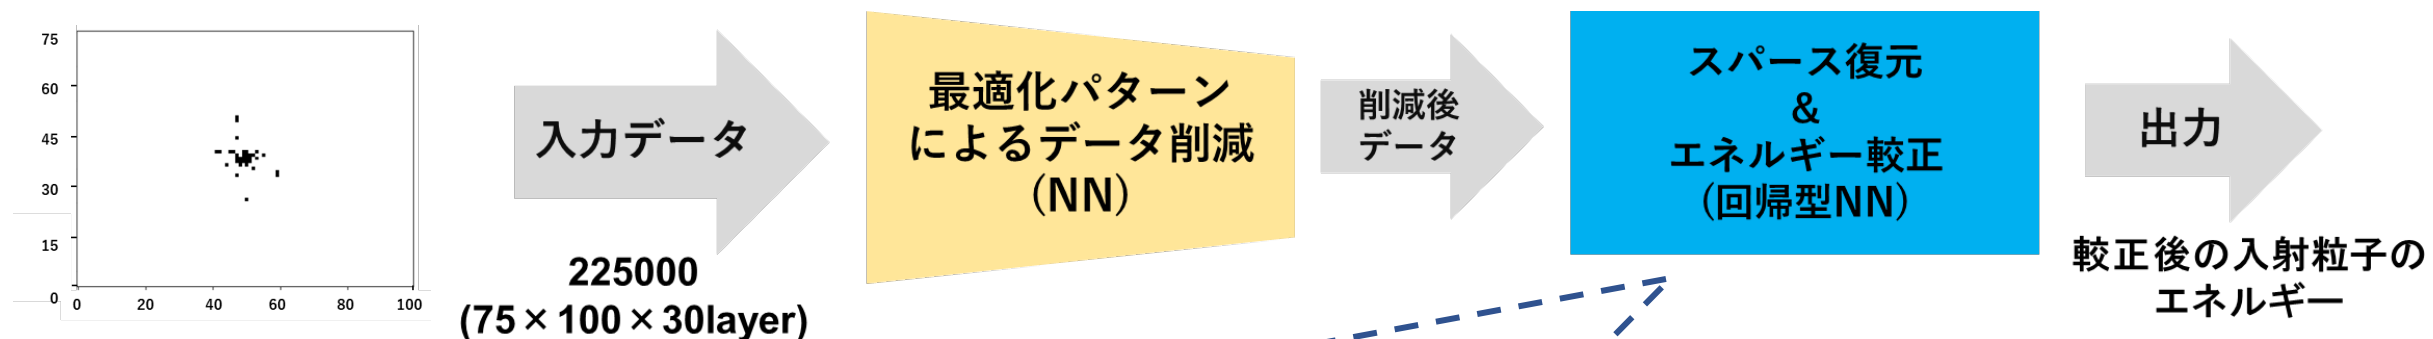
機械学習による削減パターン最適化

機械学習による削減パターン最適化を行うため、測定器ヒットデータを画像に変換した



機械学習による削減パターン最適化

削減パターン最適化機械学習(*)を使用して、パターンを最適化した



使用データ

電子の2~6.5GeVのデータを使用

学習用データ	~7万クラスター
評価用データ	~2万クラスター
テストデータ	~1万クラスター

中間層	4層
ノード数	100
入力パラメータ	225000
エポック数	10
オプティマイザー	Adam
活性化関数	ReLU

使用した計算機 CPUメモリ 512GB
GPU NVIDIA A100 (GPUメモリ 80GB)

機械学習による削減パターン最適化

最適化パターンにしたがって削減した場合の電磁カロリメータのエネルギー較正

使用データ 2~6.5GeVの電子のデータを使用
下のような削減パターンを30枚(層)得た。

1層



2層



3層

。 。 。 。

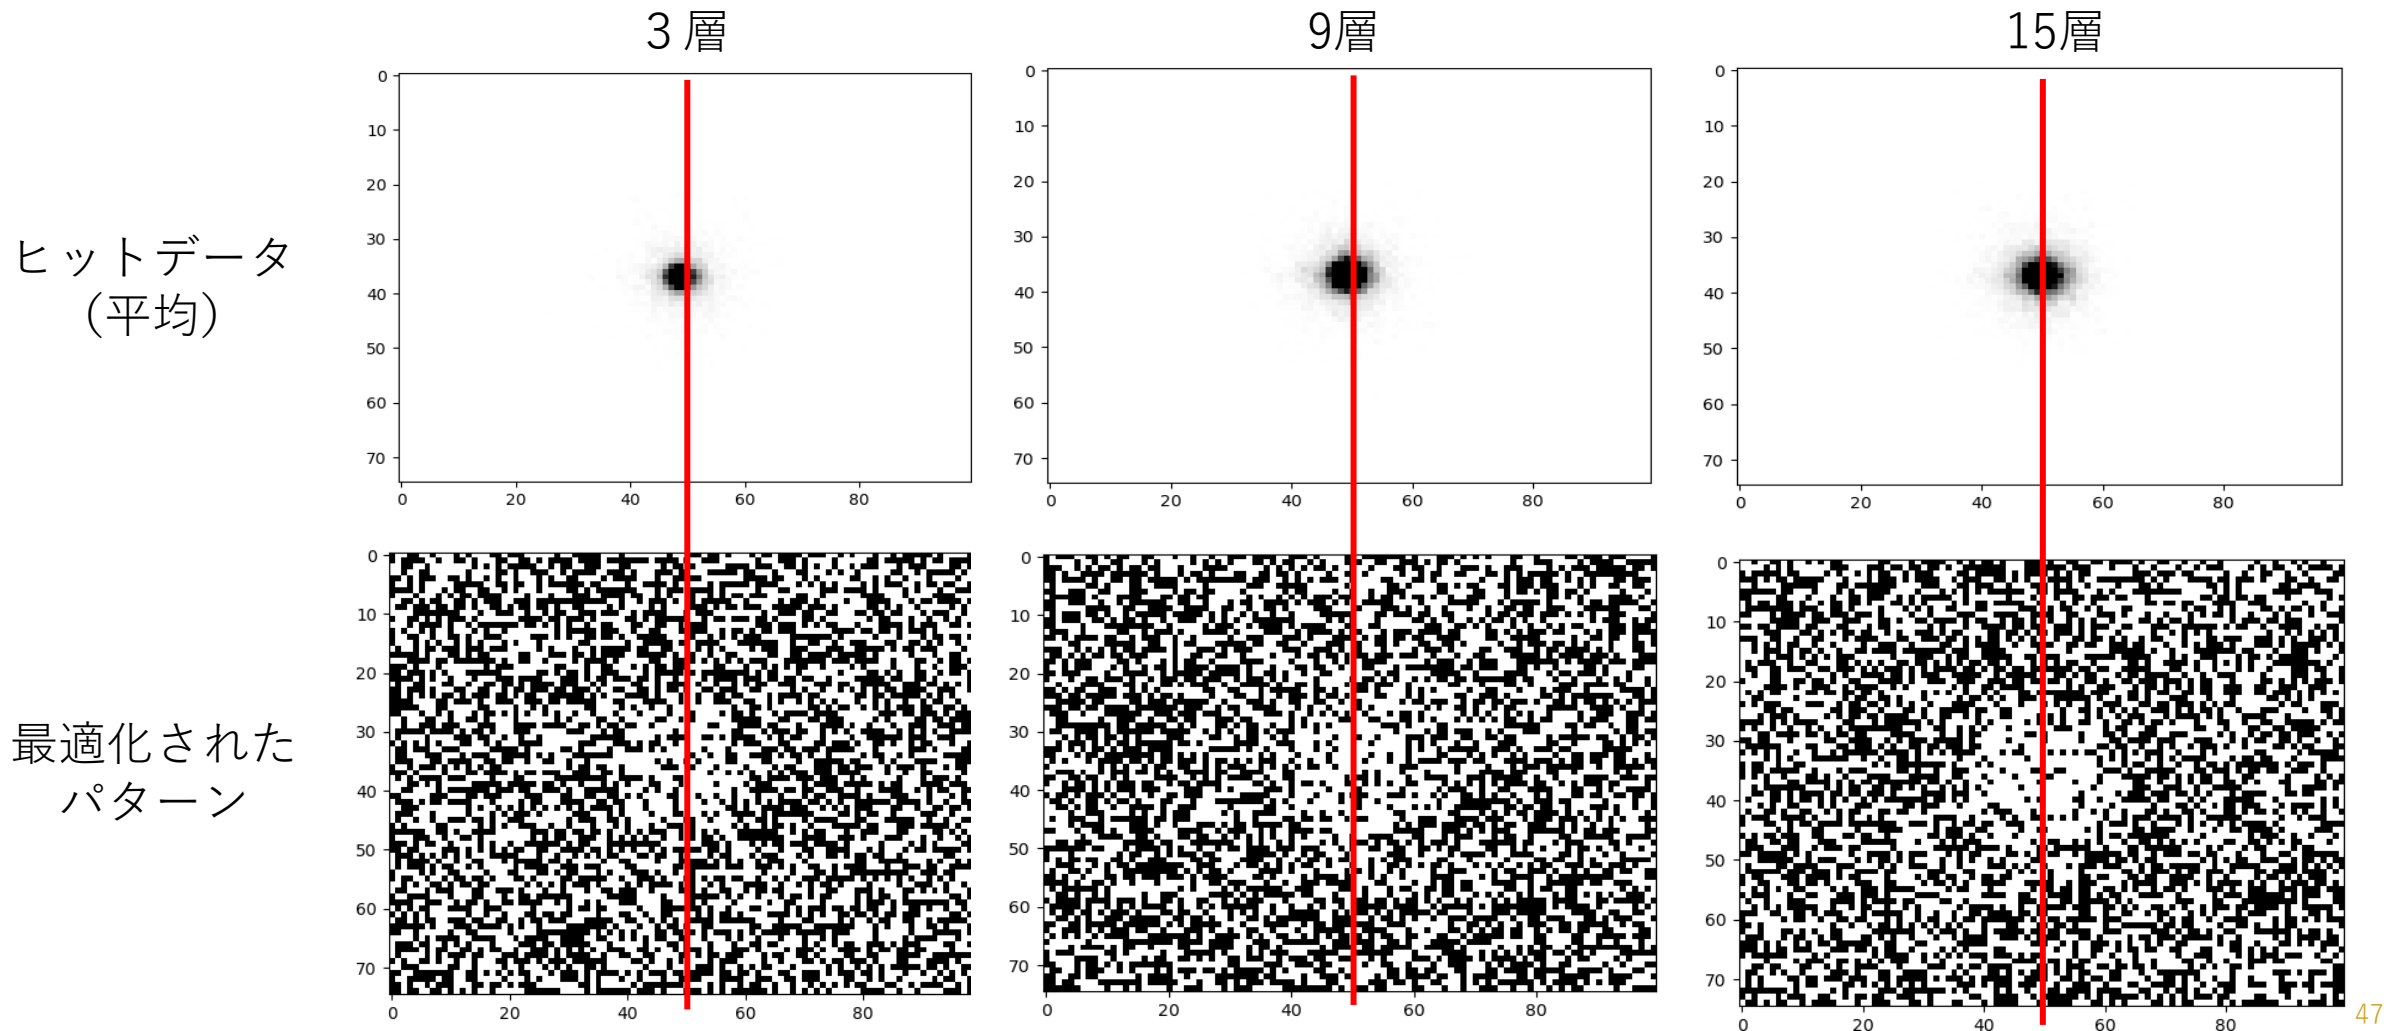


□ : データを保持
■ : データを削除

C.Kato
(Osaka Metropolitan U.)

機械学習による削減パターン最適化

最適化パターンにしたがって削減した場合の電磁カロリメータのエネルギー較正



機械学習による削減パターン最適化




最適化パターンにしたがって削減した場合の電磁カロリメータのエネルギー較正

3層

9層




15層

ヒットデータ
(平均)



ヒットのある箇所
を保持するように
最適化されている

最適化された
パターン



機械学習による削減パターン最適化

最適化パターンにしたがって削減した場合の電磁カロリメータのエネルギー較正

3層

9層

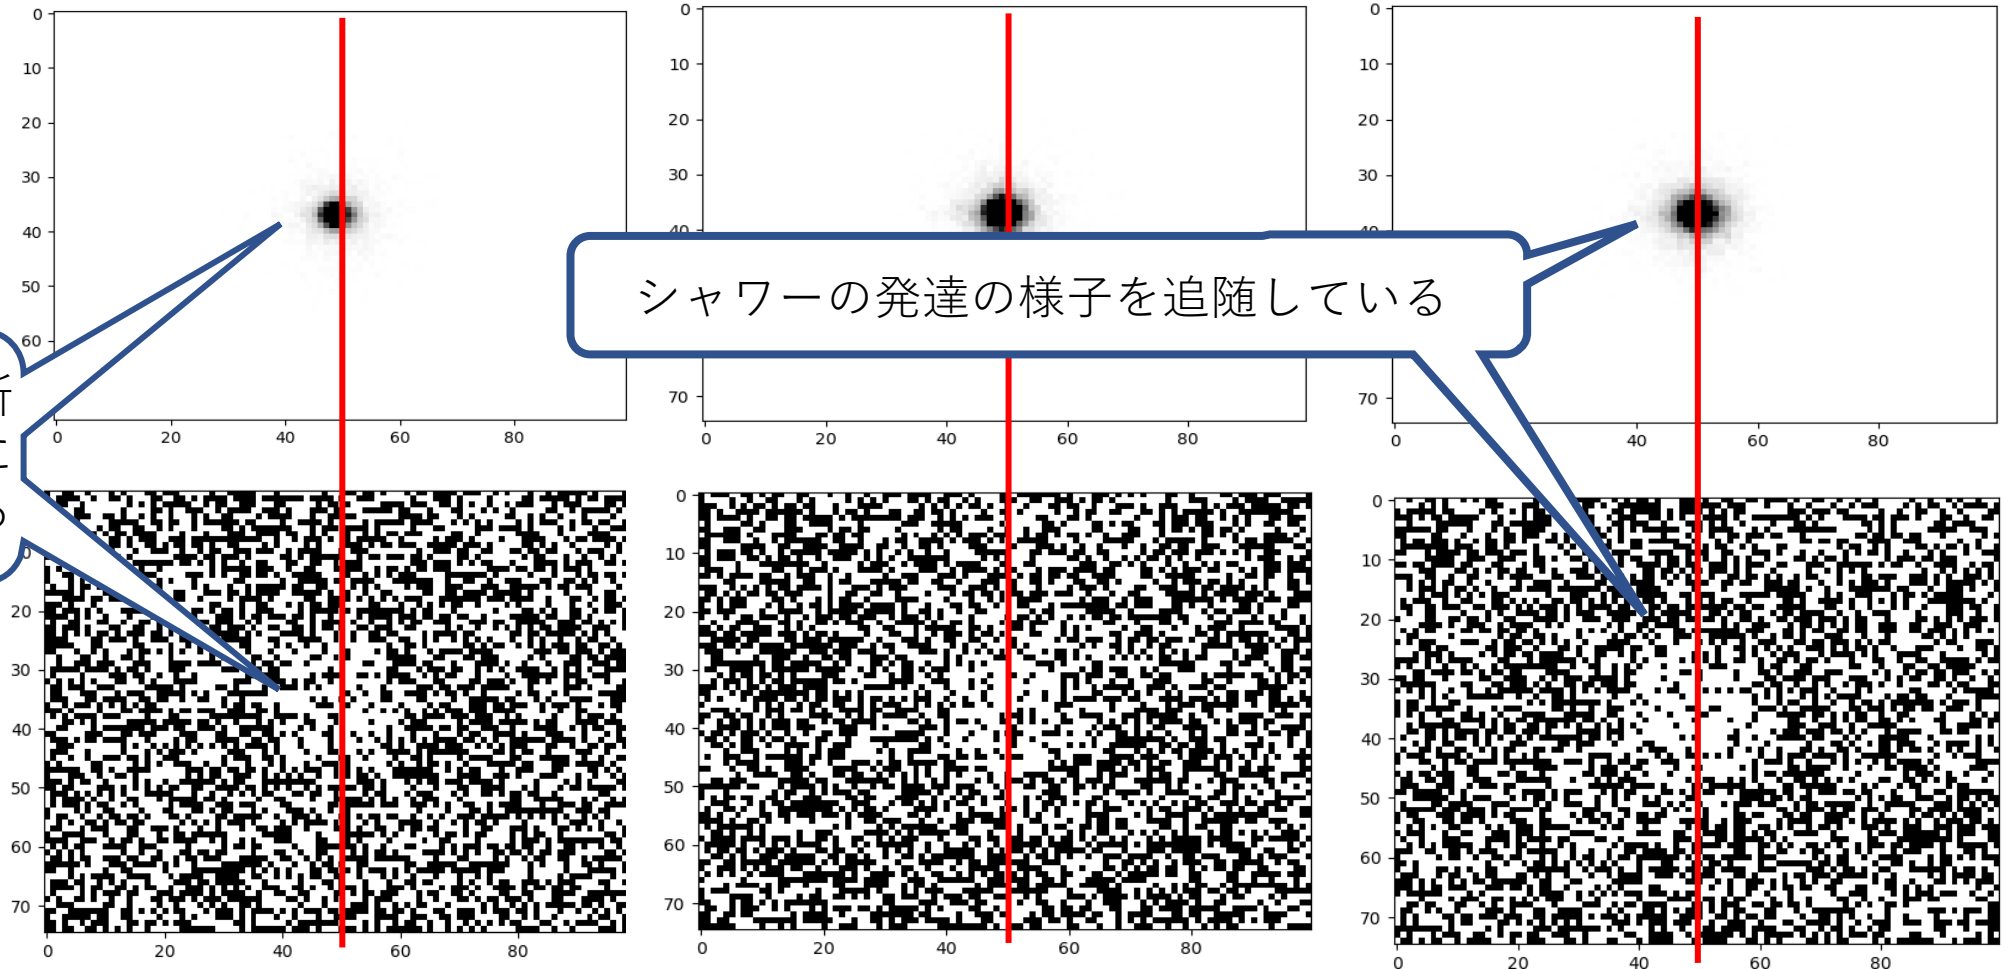
15層

ヒットデータ
(平均)

シャワーの発達の様子を追従している

ヒットのある箇所
を保持するように
最適化されている

最適化された
パターン




機械学習による削減パターン最適化

最適化パターンにしたがって削減した場合の電磁カロリメータのエネルギー較正
測定器ヒットに対する削減率

入射粒子のエネルギー2~6.5GeV

C.Kato
(Osaka Metropolitan U.)



削減率25%



機械学習による削減パターン最適化

最適化パターンにしたがって削減した場合の電磁カロリメータのエネルギー較正
測定器ヒットに対する保持率

C.Kato

(Osaka Metropolitan U.)

入射粒子のエネルギー2~6.5GeV



機械学習による削減パターン最適化


最適化パターンにしたがって削減した場合の電磁カロリメータのエネルギー較正

C.Kato

(Osaka Metropolitan U.)

ECLエネルギー較正精度の比較

電子のエネルギー分解能 $\Delta E(\%) \times \sqrt{E}$



使用データ

- ・電子の2~6.5GeVのデータを使用
- ・データ数 10万クラスター

- ①データ削減なし
- ②最適化した削減パターンによるデータ削減 (25%の情報を削除)
- ③ランダムに25%データを削除

エネルギー分解能

	2.5GeV	5.0GeV	
削減なし	17.74%	20.44%	↓ 7~9%
パターンによる削減	18.97%	22.55%	
ランダム削減	20.25%	26.71%	↓ 14~24%

機械学習による削減パターン最適化


最適化パターンにしたがって削減した場合の電磁カロリメータのエネルギー較正

C.Kato

(Osaka Metropolitan U.)

ECLエネルギー較正精度の比較

電子のエネルギー分解能 $\Delta E(\%) \times \sqrt{E}$



使用データ

- ・電子の2~6.5GeVのデータを使用
- ・データ数 10万クラスター

- ①データ削減なし
- ②最適化した削減パターンによるデータ削減
(25%の情報を削除)
- ③ランダムに25%データを削除

- ・機械学習で最適化したパターンによるデータ削減で削減なしの場合とほぼ同等(~8%劣化)の較正結果が得られた。
- ・ランダムにデータ削減を行うと精度が~20%劣化した。

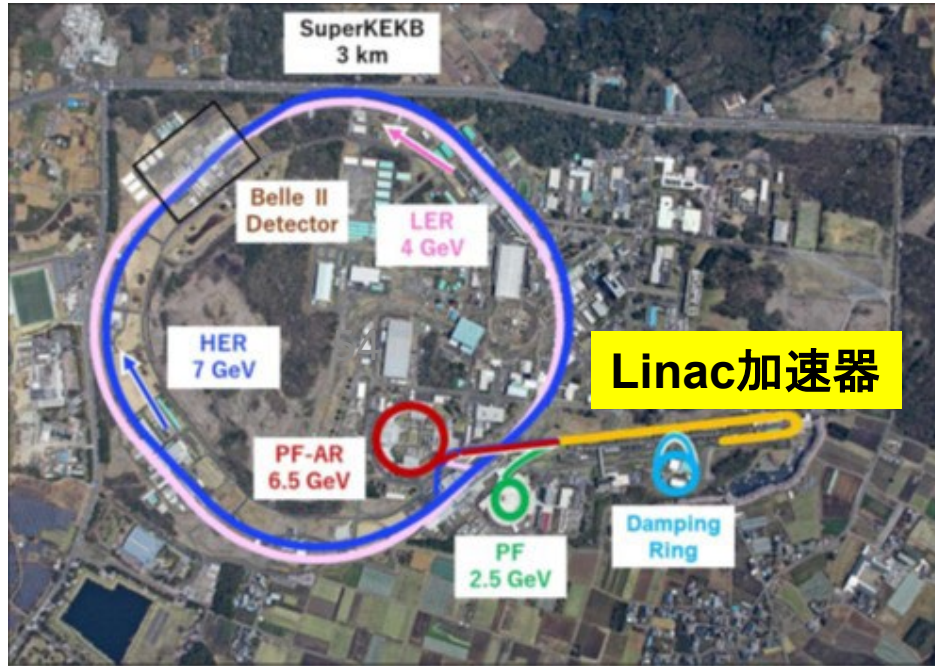


機械学習を使用することで
較正精度の劣化を抑えてデータ削減できた

3. 機械学習を用いた加速器調整

機械学習を用いたKEK Linac加速器調整の開発

KEK Linac、大阪市大、阪大IDS



RFモニター: 60台 ステアリング電磁石: 200台
ビーム位置モニター(BPM): 100台

数百パラメータの調整が必要

- 加速器周囲の環境変化により
運転調整が常時必要
- 複雑な調整システム
→調整する人によって最適化
のスピードや精度が変わる

**入射効率を高めるために
効率のよい加速器調整が重要**



加速器制御の問題点

問題点① 制御システムが複雑

構成要素が多い **~O(1000)**

→ 参照するパラメータが多数で複雑

→ 調整速度が個人の技量に依存

問題点② 運転状況が変化する

温度変化や振動、潮汐力等

周囲の環境が変化する

→ 常時調整が必要


加速器制御の問題点

問題点① 制御システムが複雑

構成要素が多い $\sim O(1000)$

→ 参照するパラメータが多数で複雑

→ 調整速度が個人の技量に依存



機械学習を用いた加速器の可視化

教師なし学習を用いた次元削減(特徴抽出)

問題点② 運転状況が変化する

温度変化や振動、潮汐力等

周囲の環境が変化する

→ 常時調整が必要

加速器制御の問題点


57

問題点① 制御システムが複雑

構成要素が多い $\sim O(1000)$

→ 参照するパラメータが多数で複雑

→ 調整速度が個人の技量に依存



機械学習を用いた加速器の可視化


教師なし学習を用いた次元削減(特徴抽出)

問題点② 運転状況が変化する

温度変化や振動、潮汐力等

周囲の環境が変化する

→ 常時調整が必要

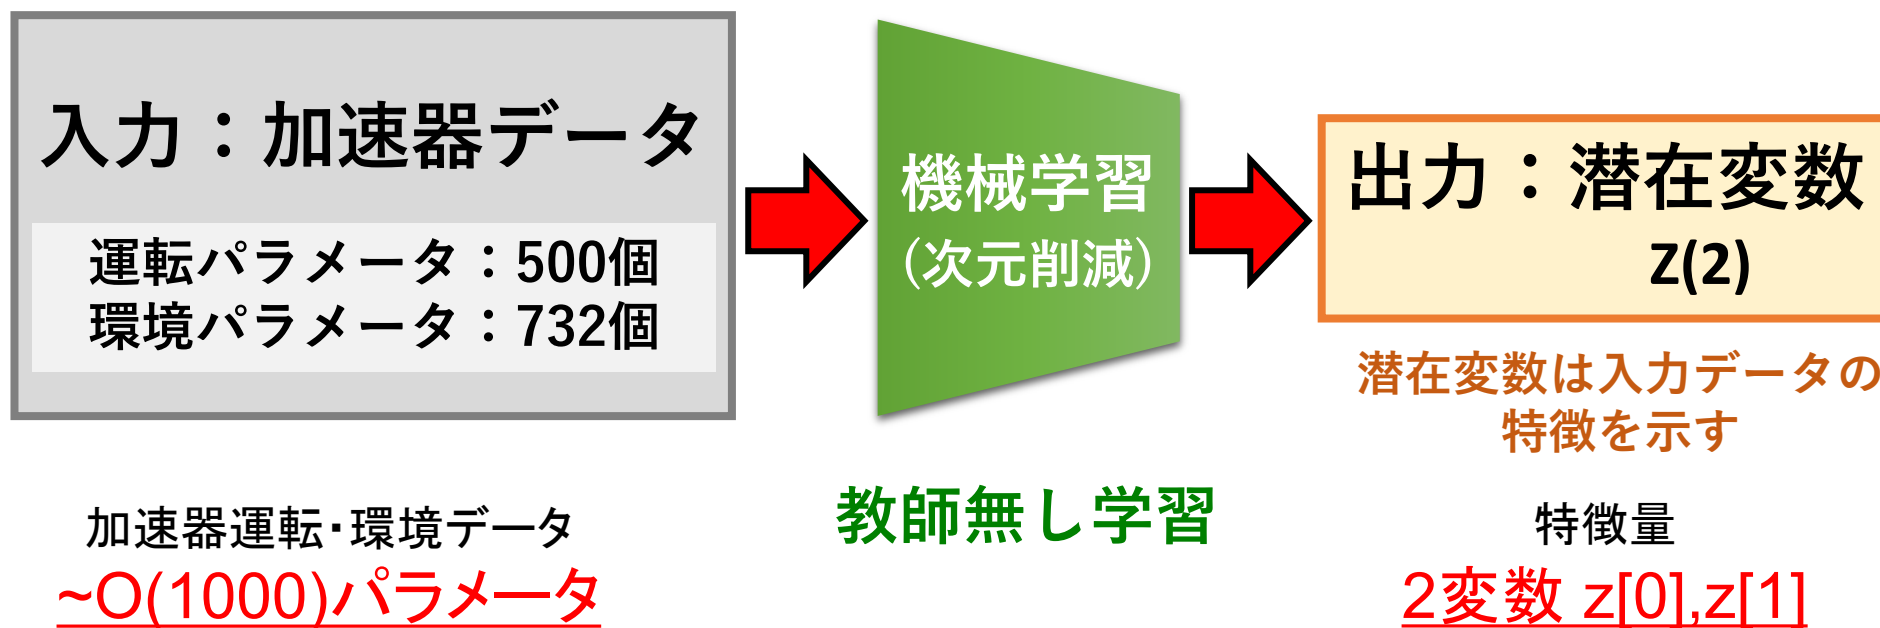


環境適応型機械学習(強化学習)
を用いた加速器制御

1. 機械学習による加速器状況の可視化

教師なし学習による次元削減（特徴抽出）で
加速器の可視化を行った

機械学習 (VAE, Variational Auto Encoder) を用いて行った

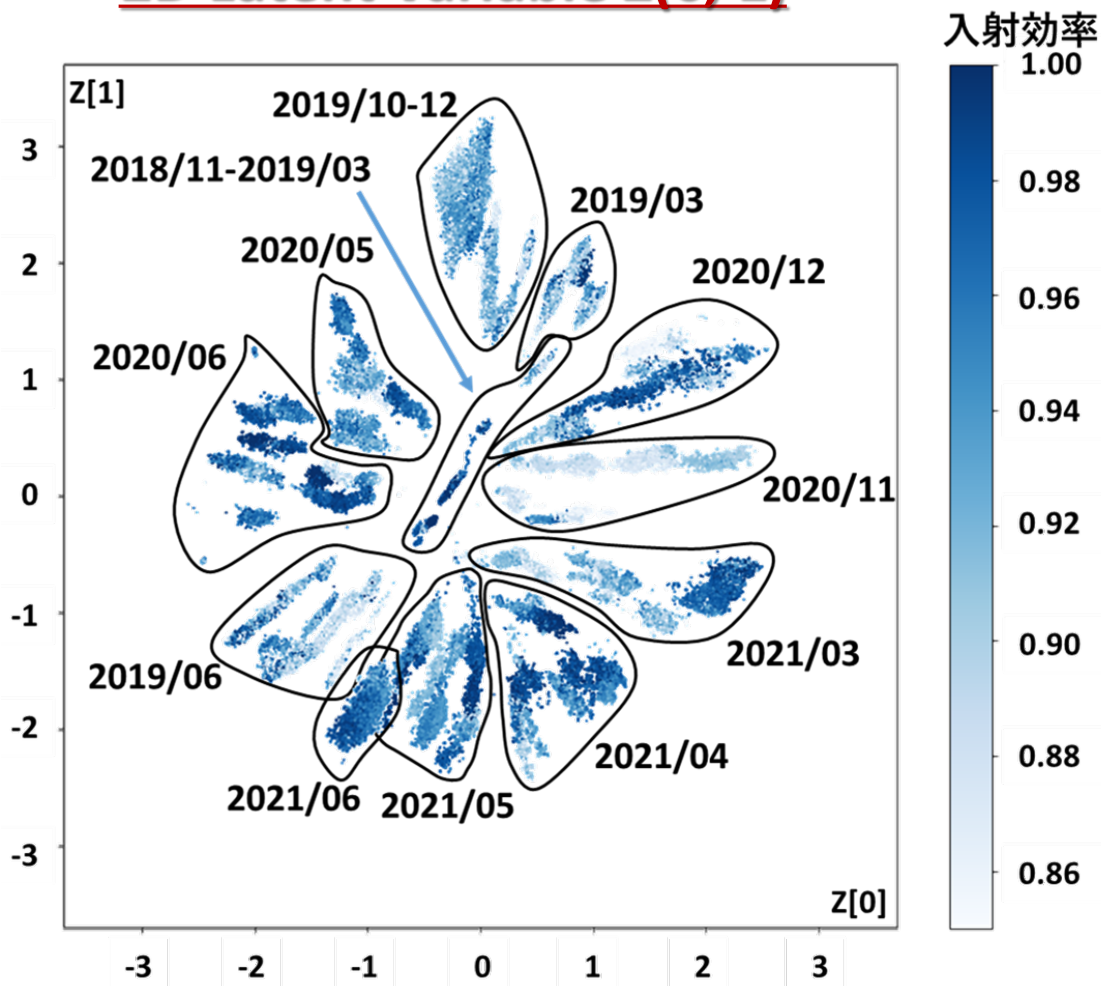


1. 機械学習による加速器状況の可視化

機械学習による次元削減（特徴抽出）で
1232パラメータの加速器データを2次元で表現 → **可視化!**

2D Latent Variable $Z(0, 1)$

A.Hisano (Osaka-City U.)



「加速器の状態」の
可視化に成功

短期間では、加速器の状態
はあまり変化しない

長期間(数か月以上)では
加速器の状態が変化する

2. 強化学習による加速器制御

環境変化に適応した運転調整 → **強化学習**が有効だと思われる

強化学習：周囲の環境変化に応じ、最適な行動を選択する
(報酬を最大化する行動を選択)

→ 入射効率を報酬とした強化学習を導入したい

強化学習を導入するために、以下の準備開発を進めている

1. 機械学習を用いた **入射効率の予測**

加速器パラメータと入射効率の相関を学習可能か評価

2. 機械学習を用いた **加速器シミュレーターの作成**

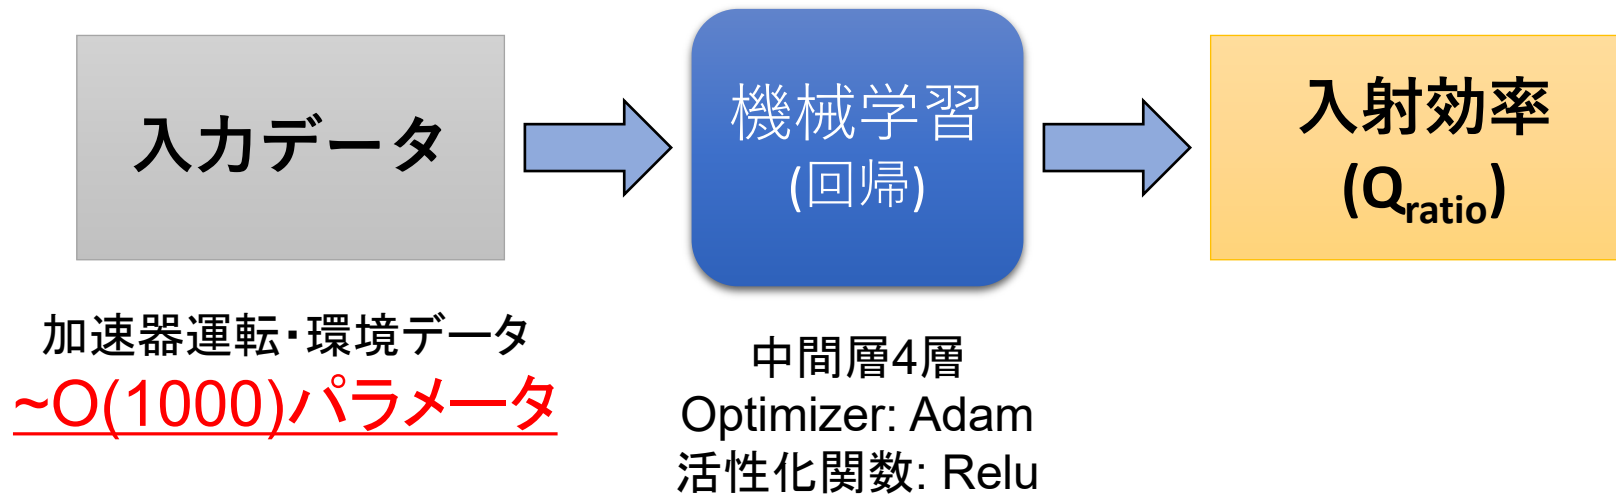
Pre-trainingのために、加速器シミュレーターが必要

↑
入射効率を最大化するために、実際に加速器で調整することは危険
(車の運転で、ハンドルを左右に切ってから進む方向を決めるのは危険)

2. 強化学習による加速器制御: 準備研究

2-1: 機械学習を用いた入射効率の予測

加速器パラメータを入力すれば
入射効率を予測する機械学習（回帰）で、入射効率を予測した



2. 強化学習による加速器制御: 準備研究


2-1: 機械学習を用いた入射効率の予測

入射効率予測結果 その1

学習・検証データ 同期間 (2018年11月～2021年6月)

2018/11/12	学習データ	2021/06/23
------------	-------	------------

2018/11/12	検証データ	2021/06/23
------------	-------	------------




非常に良く一致 → 加速器パラメータと入射効率の関係を学習可能

2-1: 機械学習を用いた入射効率の予測

入射効率予測結果 その2

検証データは、2021年6月
 学習用データは、以下の3パターンを使用 (学習用データは、それぞれ15万イベント)

	2018/11/12	2021/05/26	2021/06/16	2021/06/23
データ①	学習データ			検証データ
データ②	使用しない	学習データ		検証データ
データ③	学習データ	使用しない		検証データ



2021/04/28

2021年6月の加速器パラメータの状態は、
 2021年5月の加速器パラメータの状態と類似

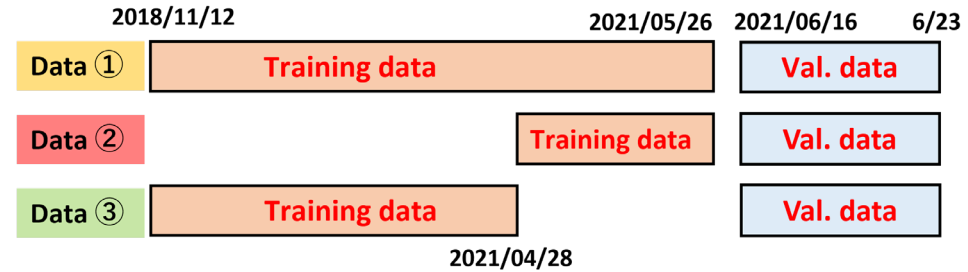
→ 2021年5月のデータで学習すると、
 2021年6月の入射効率が予測可能？！

A.Hisano
 (Osaka-City U.)


機械学習を用いた加速器運転調整：入射効率の予測

A.Hisano (Osaka-City U.)

入射効率予測結果 その2



入射効率



機械学習が予測した
入射効率

実際の入射効率

2021年5月を含むデータ(①②)で学習すると
2021年6月の入射効率をほぼ予測可能

直近データによる学習が重要

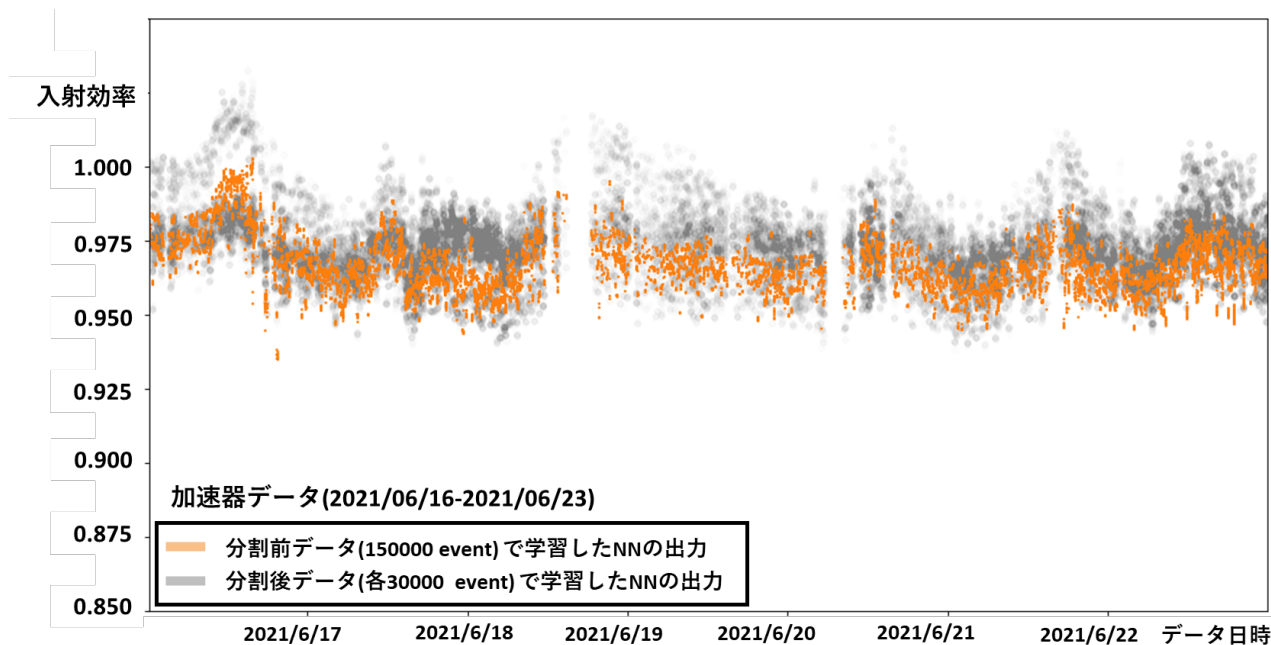
機械学習を用いた加速器運転調整：入射効率の予測

KEK Linac、大阪市大、阪大IDS

入射効率予測結果 その3

検証データは、2021年6月
学習用データは、学習データ①を5分割
(それぞれ3万イベント)

2018/11/12	2021/05/23	2021/06/16	2021/06/23
学習データ 150000 event	30000 event 30000 event 30000 event 30000 event 30000 event	検証データ	



A.Hisano
(Osaka-City U.)

DNN が予測した入射効率と実際の
入射効率の平均二乗誤差

分割前(150000 event) Ave 0.00036

分割後(30000 event) Ave 0.00043

Ave 0.00036

Ave 0.00045

Ave 0.00067

Ave 0.00038

学習用データの統計が高い方が入射効率の予測精度が高くなる

→ 加速器シミュレータで学習用データの統計量を確保することが有効?!

2. 強化学習による加速器制御: 準備研究

2-2: 機械学習を用いた加速器シミュレータの作成

強化学習を導入するためには 学習用加速器シミュレーターが必要




GANを用いた加速器シミュレーターの開発を進めている

GAN : **G**enerative **A**dversarial **N**etwork 敵対的生成ネットワーク

入力データを模倣して
疑似データを生成

互いに競合する
2つのネットワーク
で構成



<https://dzone.com/articles/working-principles-of-generative-adversarial-netwo>

まとめ

機械学習→大型加速器実験の
ビッグデータに対する強力なデータ処理ツール

最先端機械学習を適用することで
より高性能なデータ処理が可能



大型加速器実験の
新たな基盤技術への発展が期待