

加速器制御への 機械学習の適用

2022/10/18


岩崎昌子 (阪公大/NITEP, 阪大RCNP/IDS)



大型加速器制御

大型加速器実験における加速器制御

- 膨大な制御点数 数千-数万点以上
- 高度な要請 位置、エネルギー、輝度、、
- 高額な運転経費 例) 年間数十億円@SuperKEKB



**高精度・高効率で安定な加速器運転
の実現が重要**


例: 10%の向上 → 年間数億円の費用効果

情報分野で開発された

機械学習の適用が有効

従来より**高性能**、**高速**なデータ処理を期待

強力なデータ処理ツール




**高精度・高効率で安定な加速器運転
の実現が重要**

情報分野で開発された

機械学習の適用が有効

従来より**高性能**、**高速**なデータ処理を期待

強力なデータ処理ツール



従来より**高精度**・**高効率**で**安定な**
加速器制御が期待される

機械学習 (Machine Learning)

人工知能(AI, Artificial Intelligence)

Any technique that enables computers to mimic the intelligence or behavioral pattern of humans

機械学習(ML, Machine Learning)

A subset of AI. Techniques that enable computers to learn the best rules to solve tasks.

教師あり学習



教師なし学習

強化学習

機械学習 (Machine Learning)

- 人工知能 (AI) の手法の1つ
機械 (コンピュータ) に **学習** させて **認識・判断** を行わせる
- 「**学習処理**」と「**判定処理**」の二つの手順で行う
新人に、仕事の内容を教える (学習処理)、仕事をさせる (判定処理)

例: 加速器実験でのデータ解析 “信号事象選別処理”



学習

信号は、
Aの絶対値が小さい
Bの値が大きい


判定

$|A| < 0.6$
 $B > 0.5$
だったら、信号だと判断する
(信号事象選別)

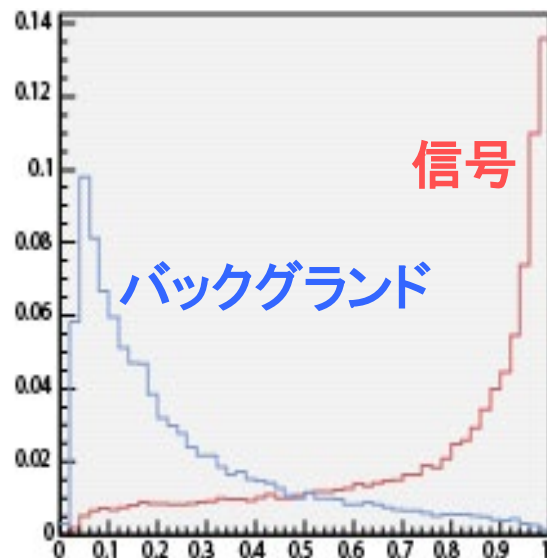
学習

- データを統計処理することで「モデル」を構築
- データの統計量が多いほどモデルの精度が向上
- データの統計量と信頼性が大切

パラメータA



パラメータB



学習

信号は、
Aの絶対値が小さい
Bの値が大きい

判定

$|A| < 0.6$
 $B > 0.5$
だったら、信号だと判断する
(信号事象選別)

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

**Unsupervised
Learning**

教師なし学習

Data driven

**Reinforcement
Learning**

強化学習

Environment driven

計算機技術・機械学習技術の進展により
様々なタイプの機械学習が可能になった

大量パラメータを直接用いる

機械学習も可能になった

加速器への適用

18pS06

ビーム物理領域
一般シンポジウム

13:30 ~ 16:20

加速器制御への適用

主題：機械学習を用いた加速器ビーム制御

座長：小島 完興 (QST)

- 1 趣旨説明 5分 KEK 加速器 大谷将士
- 2 加速器ビーム制御に向けた機械学習の基礎 25分
大阪大学データビリティフロンティア機構 中島悠太
- 3 機械学習を適用した KEK 電子陽電子入射器ビーム調整の開発
25分 大阪市立大学 大学院理学研究科 岩崎昌子
- 4 RCNP における機械学習手法を用いたイオン源制御 25分
大阪大学 核物理研究センター 森田泰之

休 憩 14:50 ~ 15:05

座長：大谷 将士 (KEK)

- 5 SACLA/SPring-8 における機械学習手法を用いた XFEL の自動調整
25分 高輝度光科学研究センター/
理化学研究所 放射光科学研究センター 岩井瑛人
- 6 理化学研究所におけるガウシアンプロセスを用いた一次重イオン
ビームトランスポートの自動調整の開発 25分
理化学研究所仁科加速器科学研究センター 西隆博
- 7 ML を使用した J-PARC リニアックオンラインモデリングの最初の
試行 25分 高エネルギー加速器研究機構加速器研究施設

Liu Youg

日本物理学会
ビーム物理領域
2022/3/18

加速器への適用

第19回日本加速器学会年会
2022/10/18-21

- TUOPA02 加速器制御への機械学習の適用
○岩崎 昌子(阪公大理学研究科・阪大RCNP)
- TUOA03 ベイズ最適化を用いた陽子線ビームサイズ・位置の自動調整システムの検討
○中島 秀, 天野 大三, 滝 和也, 福井 基文, 白澤 克年, 宮下 拓也, 橋 正則(住友重機械工業)
- TUOA04 SACLAにおける機械学習による故障予知・異常検知アプリケーションの試作
○佐藤 悠史(中央電子(株), 理研), 清水 俊吾, 上條 慎二(中央電子(株)), 岩井 瑛人(理研, 高輝度光科学研究センター), 前坂 比呂和(理研)
- TUP051 コンパクトERLにおける機械学習によるビーム光学の自動調整
○神尾 彬(HISOR), 加藤 政博(UVSOR), 島田 美帆, 宮内 洋司, 帯名 崇(KEK)
- WEP019 機械学習によるベータatron振動波形のリアルタイム解析
○藤井 将, 渡部 圭祐, 橋本 智(兵庫県大 高度研)
- WEP029 加速器分野への機械学習の応用を通じた人材育成の試み
大山 博史, 岩野 成, 小池 隆太, 原田 直幸, 丸山 太洋(広島商船高専), 笠井 聖二, 澤田 康輔(呉工業高専),
○加藤 政博, 神尾 彬, 浅井 佑哉(広島大), 広田 克也, 帯名 崇, 本田 融(KEK)
- THP033 機械学習を用いた空洞内面欠陥自動検出ソフトの開発
○荒木 隼人(KEK), 浅野 峰行(株式会社NAT), 早野 仁司(KEK), 飯竹 真之(S-works)
- THP055 ベイズ最適化を用いたイオン源制御手法の開発
○森田 泰之, 福田 光宏, 依田 哲彦, 神田 浩樹, 畑中 吉治, 斎藤 高嶺, 田村 仁志, 安田 祐介(阪大RCNP),
鷺尾 隆(阪大産研), 中島 悠太(阪大IDS), 岩崎 昌子(大阪公立大学), 武田 佳次郎, 原 隆文, 莊 浚謙,
Zhao Hang, 橋高 正樹, 松井 昇大朗(阪大RCNP)

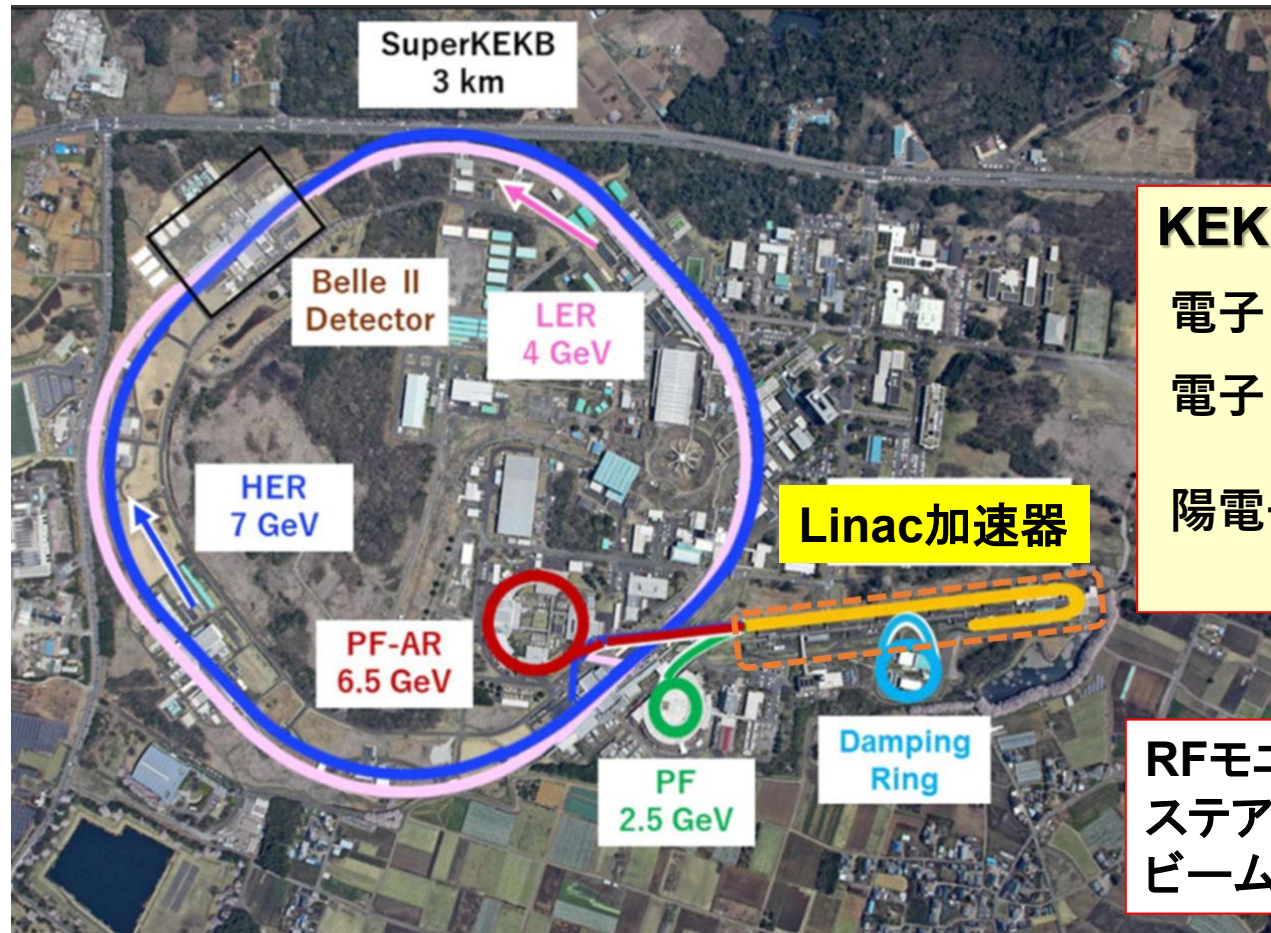


加速器制御への 機械学習の適用

1. KEK Linac 加速器への適用
2. 理研、SACLA、J-PARC

機械学習を用いた KEK Linac加速器制御の開発

阪公大、KEK
阪大IDS、阪大RCNP



KEK Linac加速器

電子・陽電子線形加速器 (600m)

電子 3つのリングへ入射
(PF, PF-AR, KEKB-HER)

陽電子 1つのリングへ入射
(KEKB-LER)

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



開発に用いた加速器データ

Linac加速器の実運転データを使用して開発をおこなった

使用した加速器データ


- Super KEKB入射用電子ビームデータ(2018/11~2021/06)

環境パラメータ(環境温度、冷却水温等) 732個
運転パラメータ(電磁石励起電流読み値) 500個

入射効率の指標(Linac上流と下流の電荷量比) 1個

合計1233個

$$Q_{ratio} = \frac{\text{Linac 加速器下流のBPM(SP_58_0)での電荷量}}{\text{Linac 加速器上流のBPM(SP_A1_M)での電荷量}}$$




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

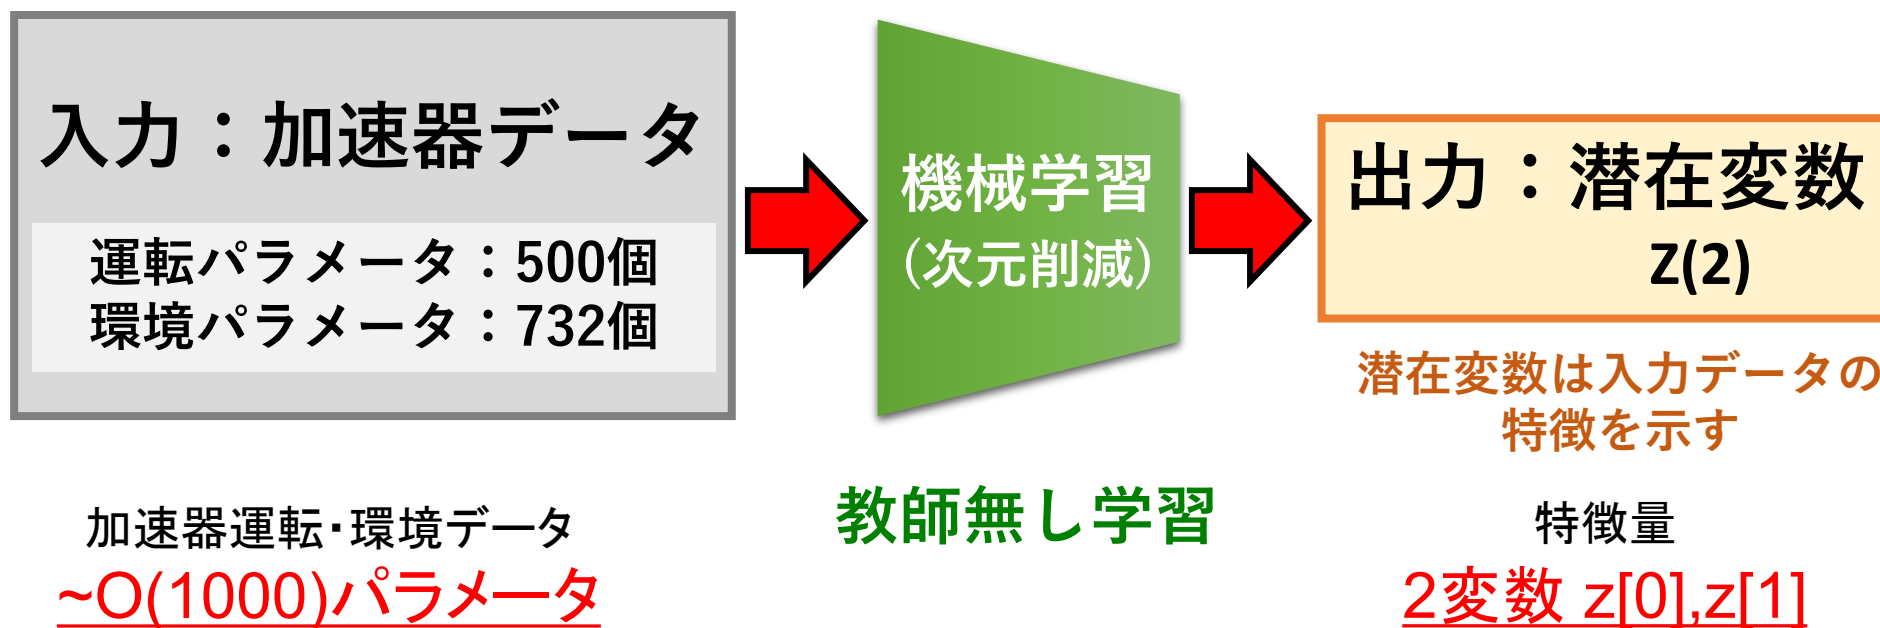


環境適応型機械学習(強化学習) を用いた加速器制御

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

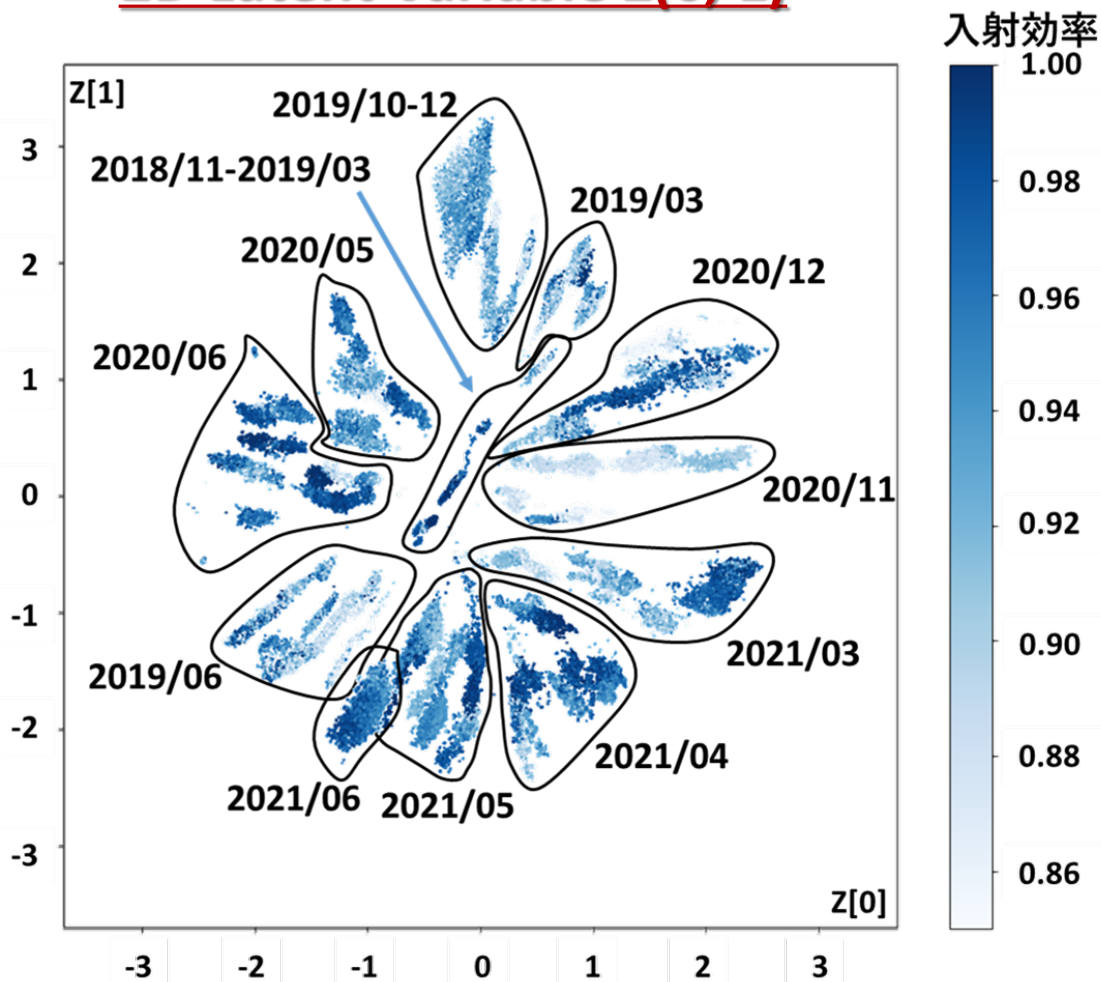


1. 機械学習による加速器状況の可視化

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**

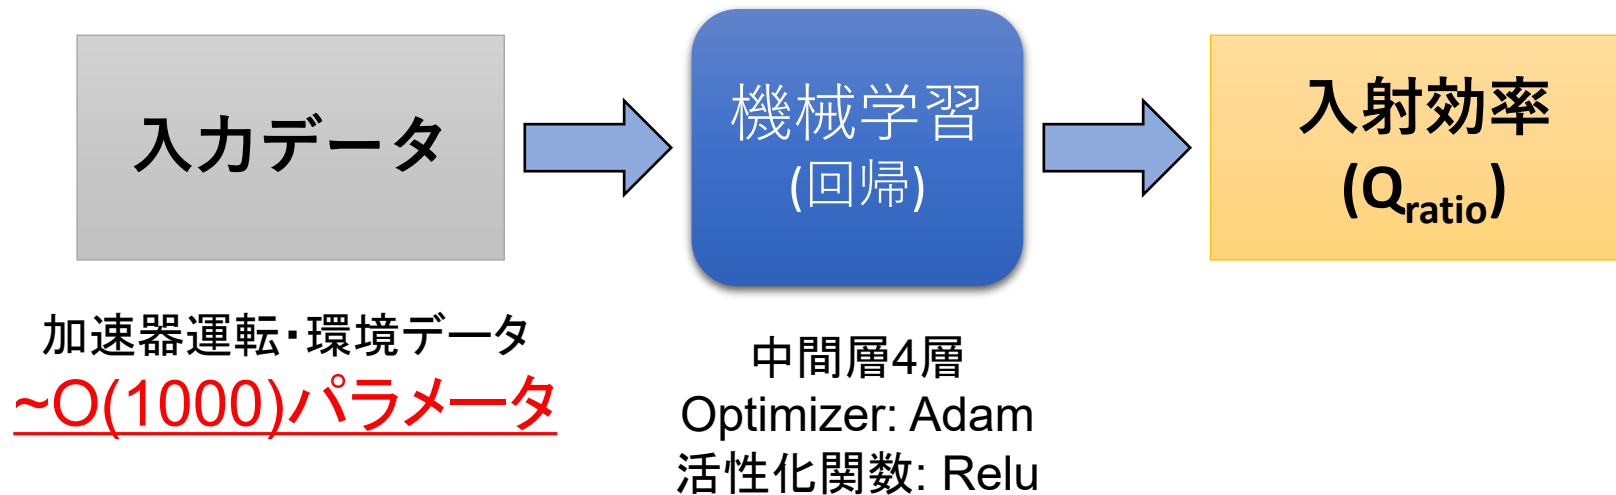
Pre-trainingのために、加速器シミュレーターが必要

↑
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

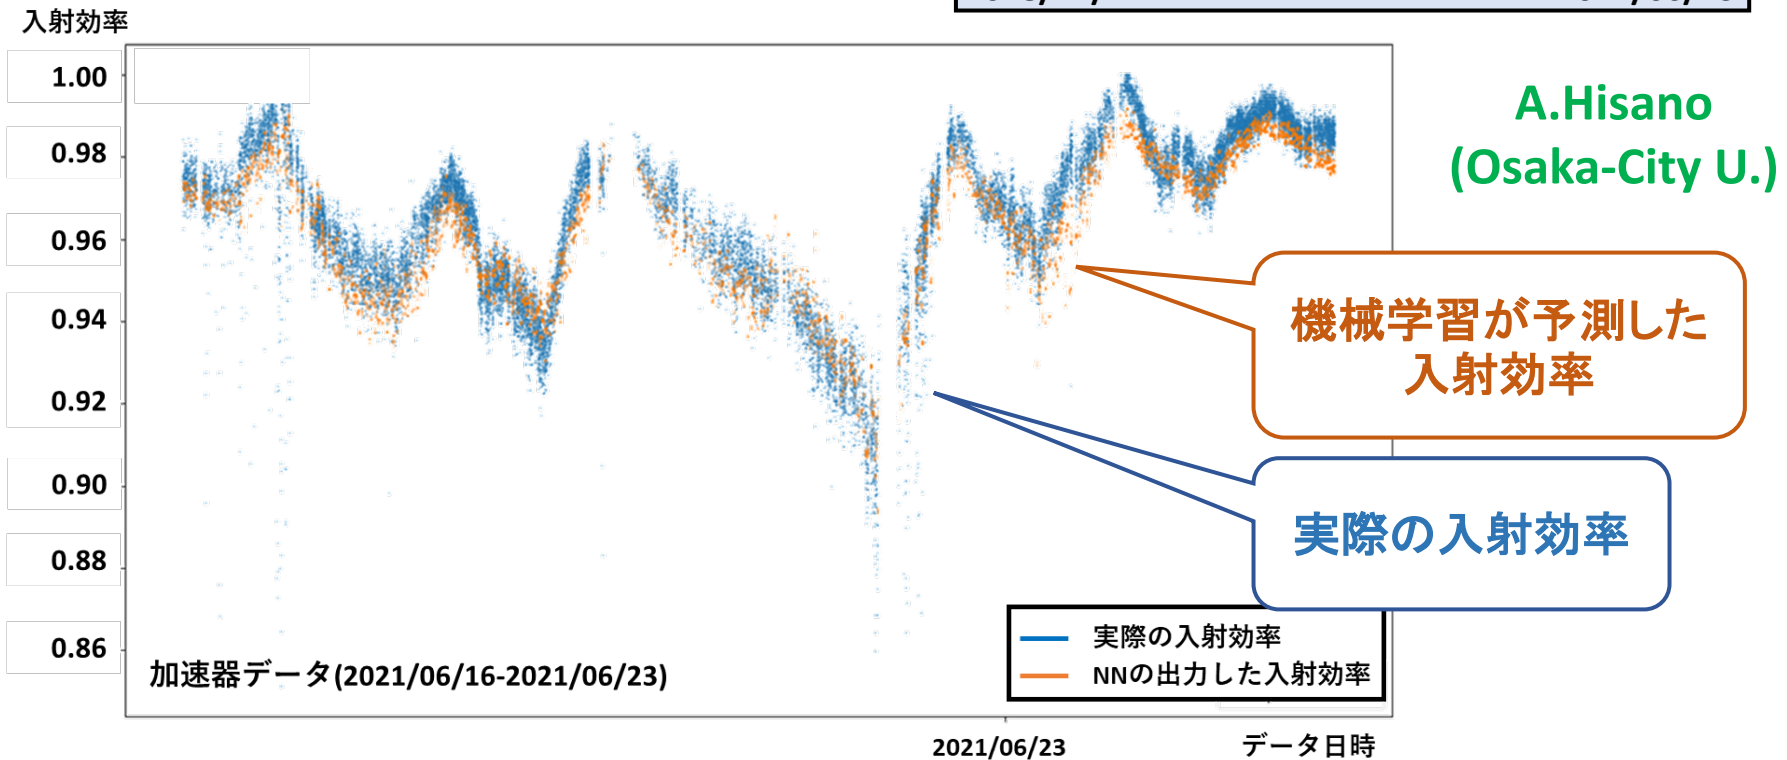
2-1: 機械学習を用いた入射効率の予測

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


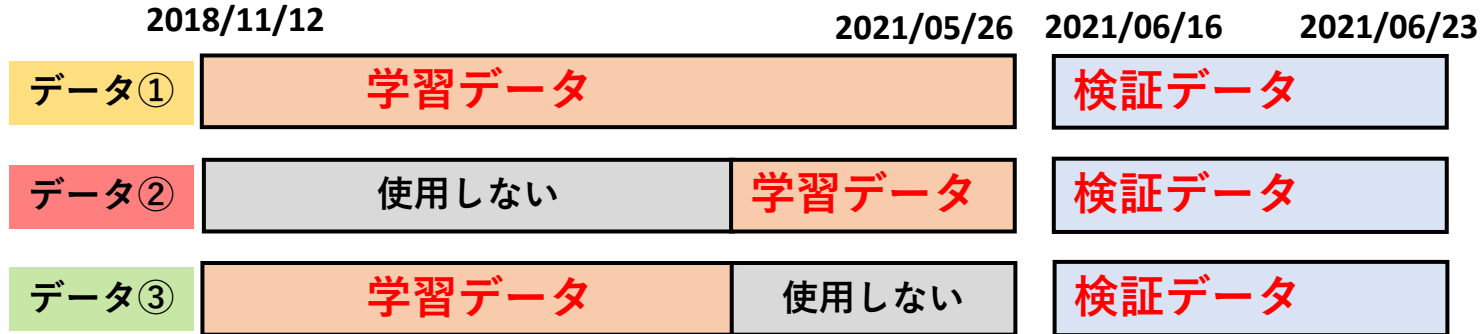


非常に良く一致 → 加速器パラメータと入射効率の関係を学習可能


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)



2021/04/28



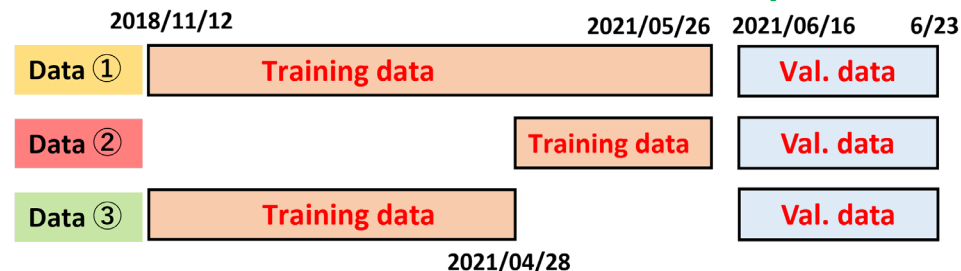
2021年6月の加速器パラメータの状態は、
 2021年5月の加速器パラメータの状態と類似
 → 2021年5月のデータで学習すると、
 2021年6月の入射効率が予測可能？！

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.)

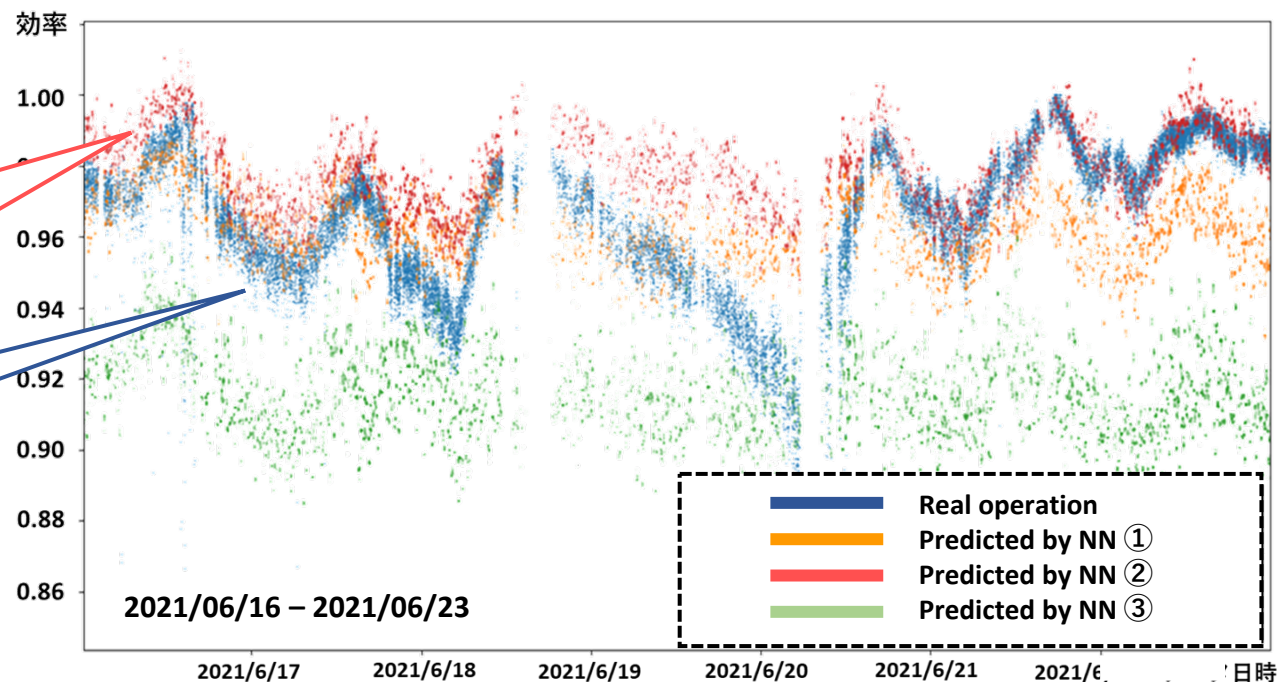
入射効率予測結果 その2



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?!

理化学研究所におけるガウシアンプロセスを用いた光学系調整

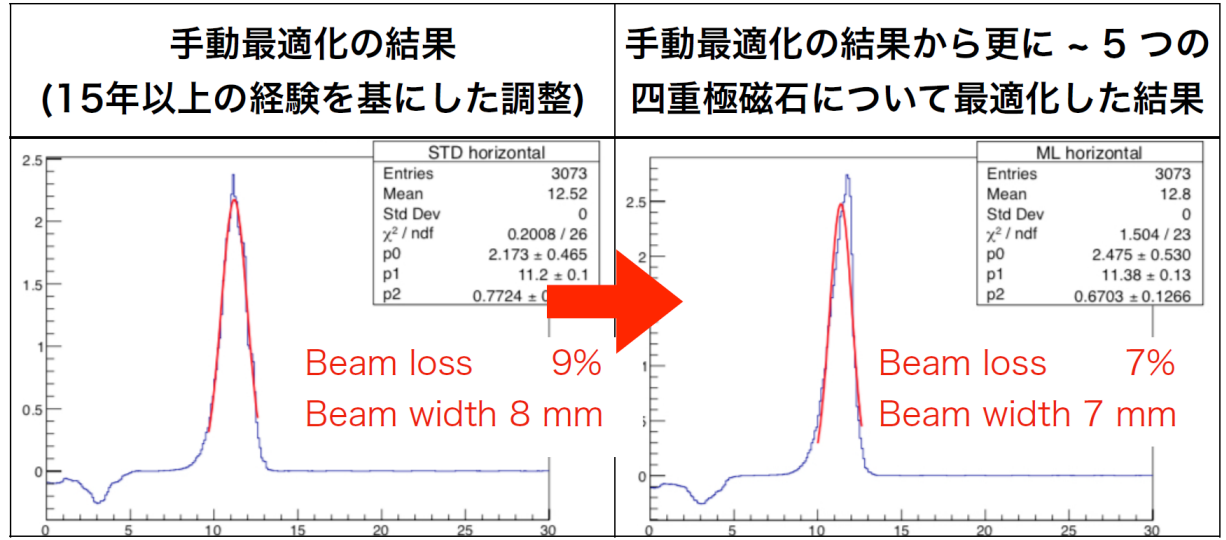


Transport line
from SRC to target
(~ 300 MeV/u 重イオン)



四重極磁石 ~ 17個

低強度ビームに対するViewer (蛍光物質) を用いた
ビームスポットと通過効率の同時最適化テスト




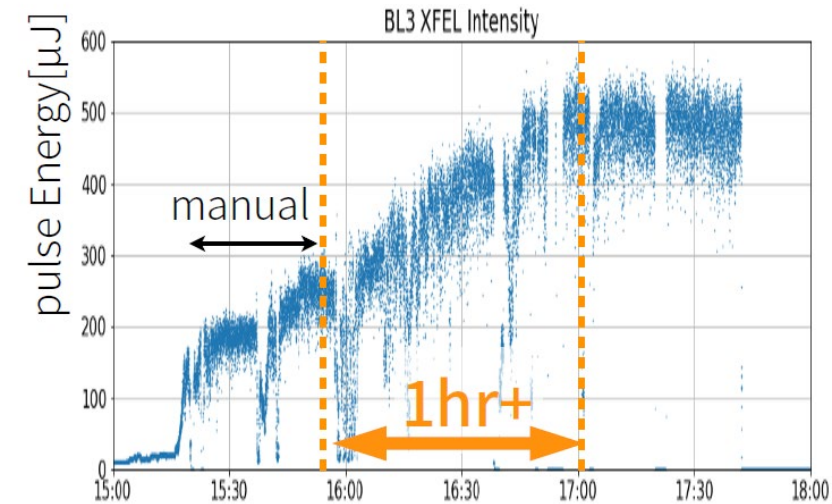
現在、

- Viewer → 二次ビームの軌跡から像と通過効率を同時計測する手法 (大強度ビームに対応)
- より効率的に最適化する手法 (事前学習など)
- 安全性の担保

などに重点を置いて開発中

SACLA での機械学習の取り組み

- **X線自由電子レーザー (XFEL) の自動最適化**
 - ガウス過程回帰によるXFEL 強度やスペクトル輝度の最適化。
 - 参考: 岩井ほか、「機械学習手法を用いた XFEL の自動調整」、第18回年会 WEOB02、令和3年8月。
- **加速器構成機器の異常検知、故障予測**
 - 中央電子(株) との共同研究
 - サイラトロン余命予測
 - 加速器停止時の復帰時間予測
 - 画像認識による計器読み取り
 - 参考: 佐藤ほか、「SACLAにおける機械学習による故障予知・異常検知アプリケーションの試作」、本年会 TUOA04。



J-PARC Linac Momentum Fluctuation Issue

Status

From ion-source: 60mA
Output: >50mA

J-PARC linac is a “scientific” accelerator with good stability and reproducibility in general. We try to avoid “Monkey Tuning”. However, we have challenges such as **higher stability requirement** from downstream against output center momentum fluctuations.



Sources and features of Li output center momentum fluctuations

| Source | Effected RF stations | $\Delta p/p _{RCSinj}$ | Temporal features |
|---------------------------------------|------------------------------|-------------------------|------------------------|
| Fluctuation with temperature/humidity | Esp. RF frequency transition | $N \times 0.01\%$ | Days, seasons |
| RF jitter | all | $0.015 \sim 0.025\%$ | 50Hz |
| imperfect RF FB&FF | all | $N \times 0.01\%$ | within 200~500 μ s |


- 現案：DB2調整案
- 現案の改進黨案：ACS21-DB1-DB2合同調整案、全幅校正・広い範囲調整できる
- 最終的な校正案：

人工知能/機械学習でエラ箇所を検出、全局的な校正


RCS off-momentum injection scheme (longitudinal painting) requires Li momentum offset within $\pm 0.01\%$.

RCSでは縦方向ベント入射の際、offset入射を行っている。


offset = -0.1% (現在の設定値)



offset値がずれた場合(ベーム試験で分かっている事実)



RCSのBLMでMPS発報
運動量広がり大→ビームロス大




3-50BTのBLMでMPS発報
空間電荷効果大→ビームハロー大


Input layer:
 $\{\Delta A_i, \Delta \phi_i\} * 46$
Amplitude and phase errors
@46 RF cavities

Output layer:
 $\{\Delta \phi_j, \Delta W_j\} * 87$
Beam phase and energy offset
@87 FCTs

Deep Neural Network



逆伝達モデル結果と誤差検出・補償




誤差検出OK・補償正確度OK

空洞位相: <0.1deg
出射運動量: <0.001%

ただ: 逆伝達方法はFCT冗長度条件が必要(各空洞2つ以上のFCT)
ACS部は現在FCT冗長度条件が満たされていない(ロス低減ため一部撤去)→もっと一般的に方法

もっと一般的に：正伝達モデルで補償

正伝達モデルで補償例



- 訓練したML正伝達モデルはシミュレーションの代理(surrogate)
 - MLモデルの正確度は+分!
 - 約300万倍早い
- シミュレーション: 1/数分間
MLモデルで予測: 10k/s

補償案は数秒間できる

誤差検出: 一部不可(改造が必要)
空洞位相誤差の検出:
FCT冗長度条件が満たされてセクション付近: <0.1deg
FCT冗長度条件が満たされていないセクションの大部分は検出できない: 誤差 >0.1deg
→将来モニター増設・移動対応策は検討中

冗長 非冗長 冗長 非冗長 冗長

出射補償正確度: OK
出射運動量: <0.001%

J-PARC Linac Momentum Fluctuation Issue

Status

From ion-source: 60mA
Output: >50mA


J-PARC linac is a "scientific" accelerator with good stability and reproducibility in general. We try to avoid "Monkey Tuning". However, we have challenges such as **higher stability requirement** from downstream against output center momentum fluctuations.



Sources and features of Li output center momentum fluctuations

| Source | Effected RF stations | $\Delta p/p _{RCSinj}$ | Temporal features |
|---------------------------------------|------------------------------|-------------------------|------------------------|
| Fluctuation with temperature/humidity | Esp. RF frequency transition | $N \times 0.01\%$ | Days, seasons |
| RF jitter | all | $0.015 \sim 0.025\%$ | 50Hz |
| imperfect RF FB&FF | all | $N \times 0.01\%$ | within 200~500 μs |

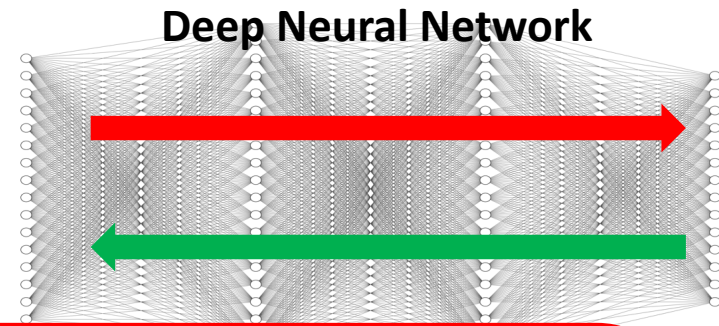
RCS off-momentum injection scheme (longitudinal painting) requires Li momentum offset within $\pm 0.01\%$.



Input layer:
 $\{\Delta A_i, \Delta \phi_i\} * 46$
Amplitude and phase errors
@46 RF cavities


Yong Liu (KEK)

Output layer:
@87 FCTs
energy offset




- 現案：DB2調
 - 現案の改進
 - 最終的な
- 人工知能/機

逆伝達



条件が必要 (各空洞2つ以上のFCT)
ACS部は現在FCT 冗長度条件が満たされていない(ロス低減ため一部撤去) → もっと一般的に方法

J-PARCで機械学習適用開発が進行中



出射補償正確度: OK
出射運動量: <0.001%

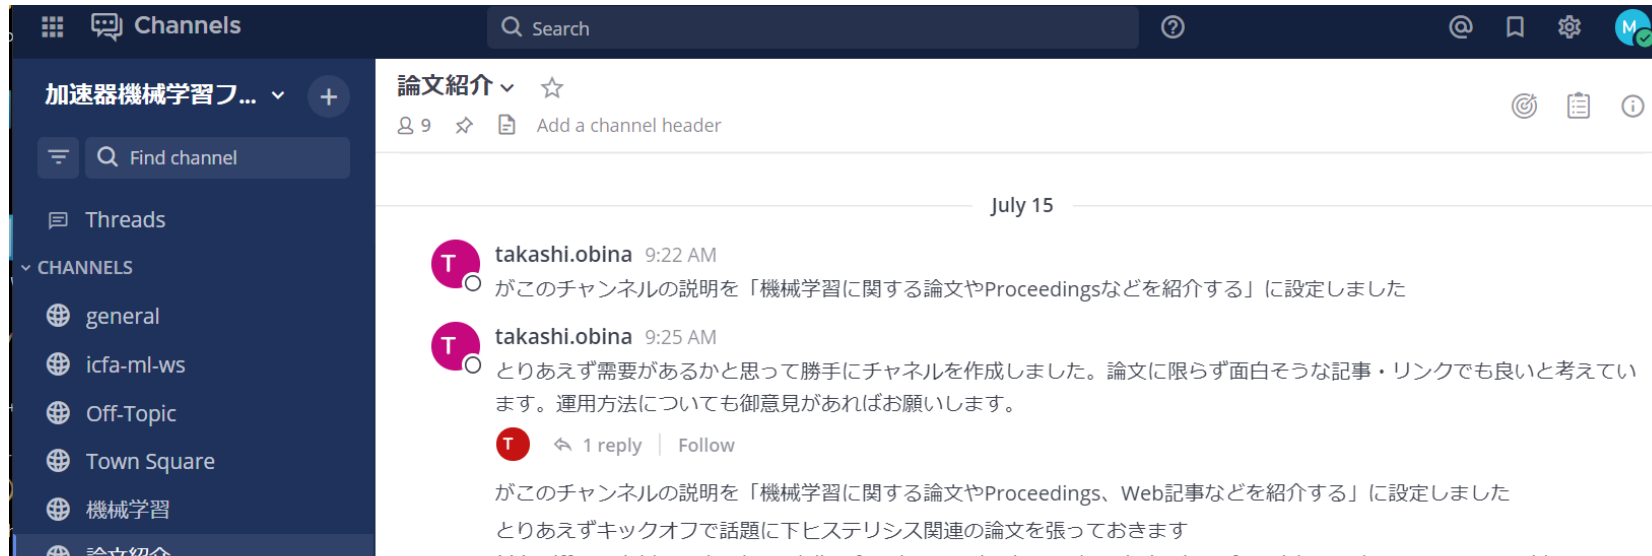
補償

はシミュ

!

お知らせ: 加速器機械学習フォーラム

加速器への機械学習適用についての情報交換を目的としています。
Mattermost を使用しています。
参加を希望される方は、世話人か、お近くの賛同メンバーまで御連絡ください。



世話人

依田 哲彦、大田 晋輔 (阪大RCNP)

賛同メンバー

岩井 瑛人 (理研, 高輝度光科学研究センター), 岩崎 昌子 (阪公大, 阪大RCNP)
帯名 崇 (KEK)、西 隆博 (理研)、野村 昌弘 (原子力機構)、前坂 比呂和 (理研)

まとめ

機械学習を用いた加速器制御の開発が進められている

様々な、機械学習技術の適用が始まっている
機械学習を用いた回帰、次元削減、強化学習、等

**従来よりも高精度、高効率で安定な
加速器制御の実現が期待される**

ありがとう
ございました

