



大阪公立大学
Osaka Metropolitan University

グラフニューラルネットワークと説明可能AIを用いた KEK電子陽電子入射器のモデル構築と重要パラメータ推定

© Osaka Metropolitan University All Rights Reserved.

大阪公立大学 上村恒介

加速器・ビーム物理の機械学習ワークショップ2025

1. イントロダクション

KEK Linac加速器

長さ600mの電子・陽電子線形加速器

電子ビームを3つのリングへ入射 (PF,PF-AR,KEKB-HER)

陽電子ビームを1つのリングへ入射 (KEKB-LER)

ビームダンプ(BD)へ入射


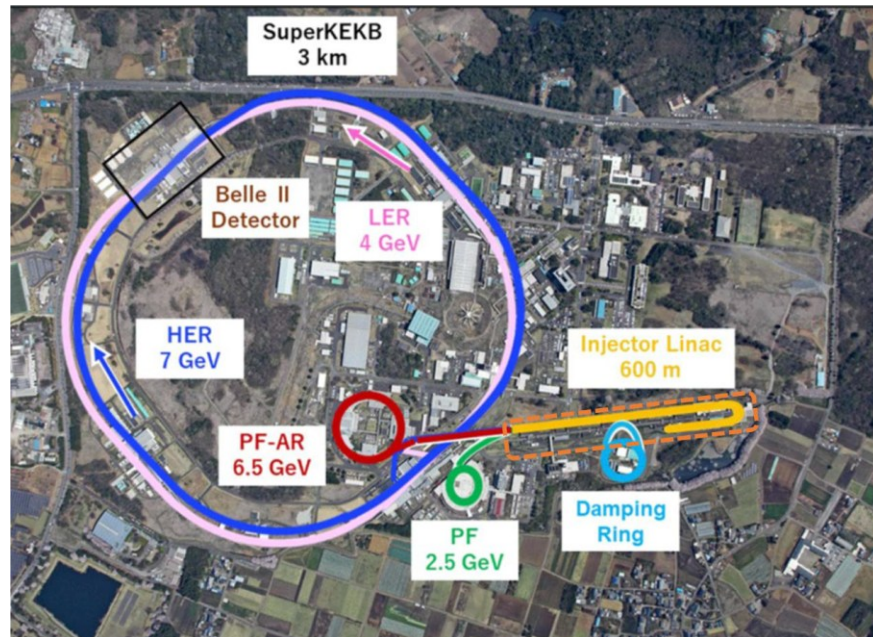
Linac加速器構成要素

RFモニター：約60台

ステアリング電磁石：約115台

ビーム位置モニター(BPM)：約100台

50台の加速器ユニットで構成(各ユニットにクライストロン 1台)



1. イントロダクション


素粒子実験（SuperKEKB/BelleII実験・ビームダンプ実験）の性能を向上するために、KEK Linac加速器には以下の点が求められる

①ビーム透過率の向上

- ・ビームの入射効率を上げる
- ・高統計

②ビームロスの低減

- ・ビームバックグラウンドの抑制
- ・低BG

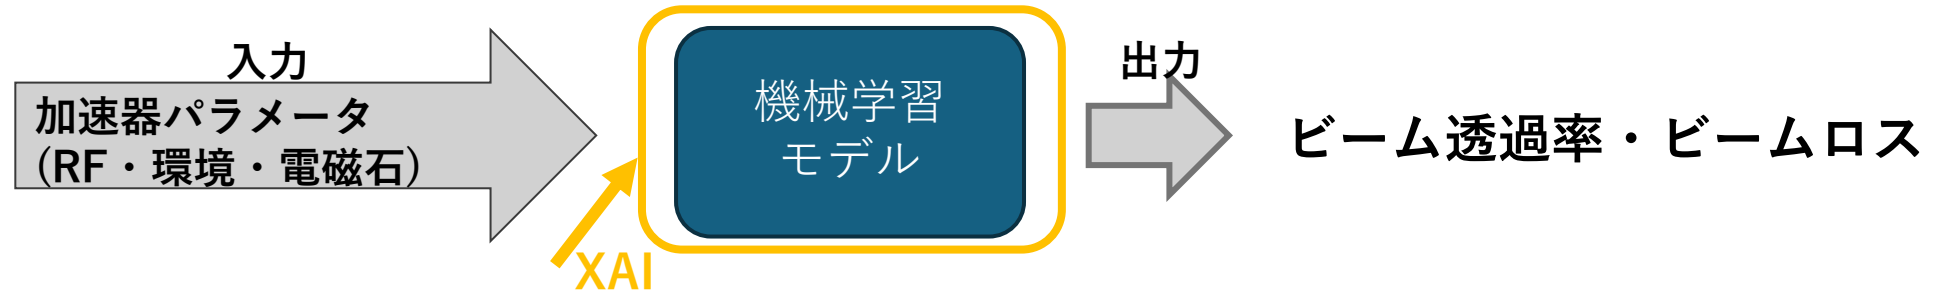


機械学習を用いて、加速器制御の性能を向上させて、
ビーム透過率向上・ビームロス低減を実現したい

1. イントロダクション

これまで我々は、

1. 機械学習で加速器のモデルを構築し、



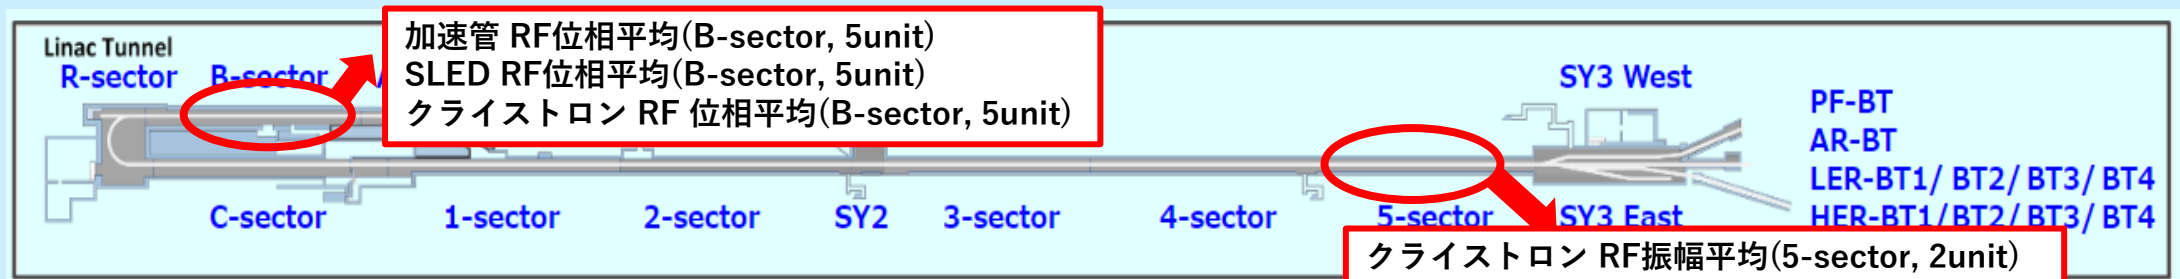
2. XAIを適用することで、加速器チューニング性能向上に重要なパラメータを推定した

XAI(説明可能AI, EXplainable AI) :

機械学習による出力やモデル全体の振る舞いを説明する技術
本研究では、SHAPを使用した



XAIから推定されたビーム透過率向上に重要なパラメータ(ビームダンプ実験)

K. Uemura (OMU) *et.al.*



1. イントロダクション

XAIで重要と予想されたパラメータと重要ではないと予想されたパラメータについて、加速器のテストビームを用いて実際にパラメータを変化させた

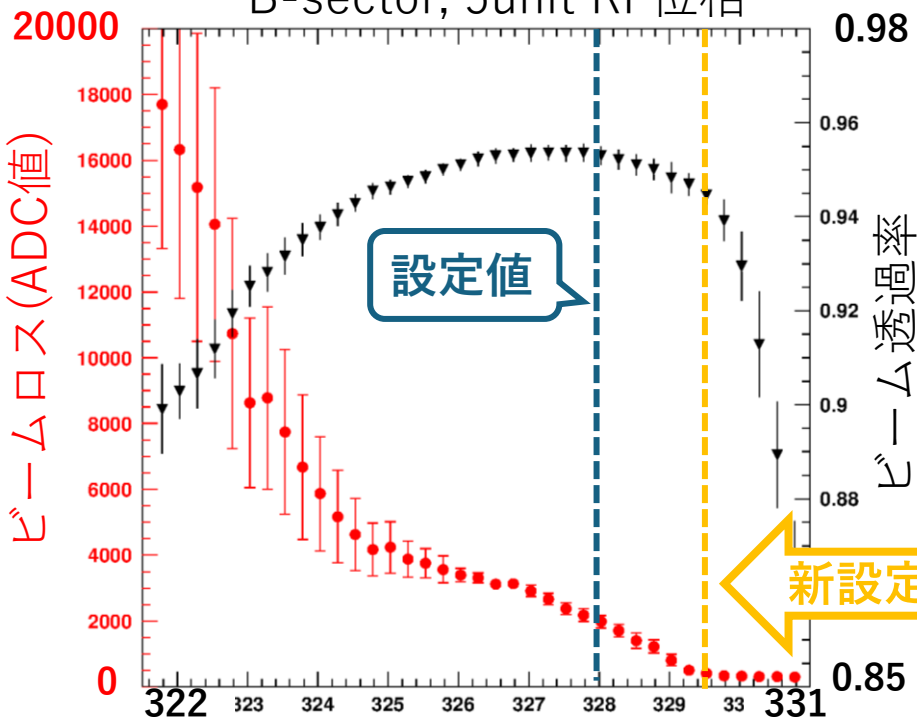


→XAIで予想したパラメータが実際に重要であることが分かった

1. イントロダクション

テストビームによる試験結果


B-sector, 5unit RF位相



B-sector, 5unit RF位相 [Deg]

F. Miyahara (KEK)


- XAIにより、B-sector RF位相がビーム透過率、ビームロスの両方に大きく寄与することが分かった
- テストビームで、RF位相を変化させた
- ビーム透過率・ビームロスがどちらも変化した(予想通り)
- ビーム透過率はほぼ同じ(1%↓)
ビームロスはペデスタル付近まで下げることが
できるパラメータ値を探すことができた



B-sector

大型加速器への適用

- ・ 大型加速器は構成要素が膨大量($O(1000) \sim O(10000)$)である
- ・ 大型加速器実験に適用させるためには、2000以上のパラメータを取り扱いたい



パラメータ数が膨大な機械学習では、
過学習の抑制が重要




グラフニューラルネットワーク
(Graph Neural Network, GNN)
を用いた機械学習手法を開発した

1. イントロダクション


GNNを用いた機械学習

全結合型(MLP)



- ・ 全パラメータ間の相関を直接見ている

グラフニューラルネットワーク(GNN)



- ・ グラフデータを扱う
 - ・ グラフはノードとエッジからなる
 - ・ グラフ中の「要素」に対して共通なWeightsを求める
- パラメータ数が少なくなることに相当

最適化するパラメータが少ないので、GNNで過学習抑制が期待できる

2. グラフデータの作成

作成したグラフデータを用いて、過学習なく、
機械学習でビーム透過率・ビームロスの予測ができるかを検証した

使用したデータ

- ・ SuperKEKB(SKB)入射用電子ビームデータ (2024/06/01 ~2024/06/31)
- ・ ビームダンプ(BD)電子ビームデータ (2023/11/01 ~2024/01/31)

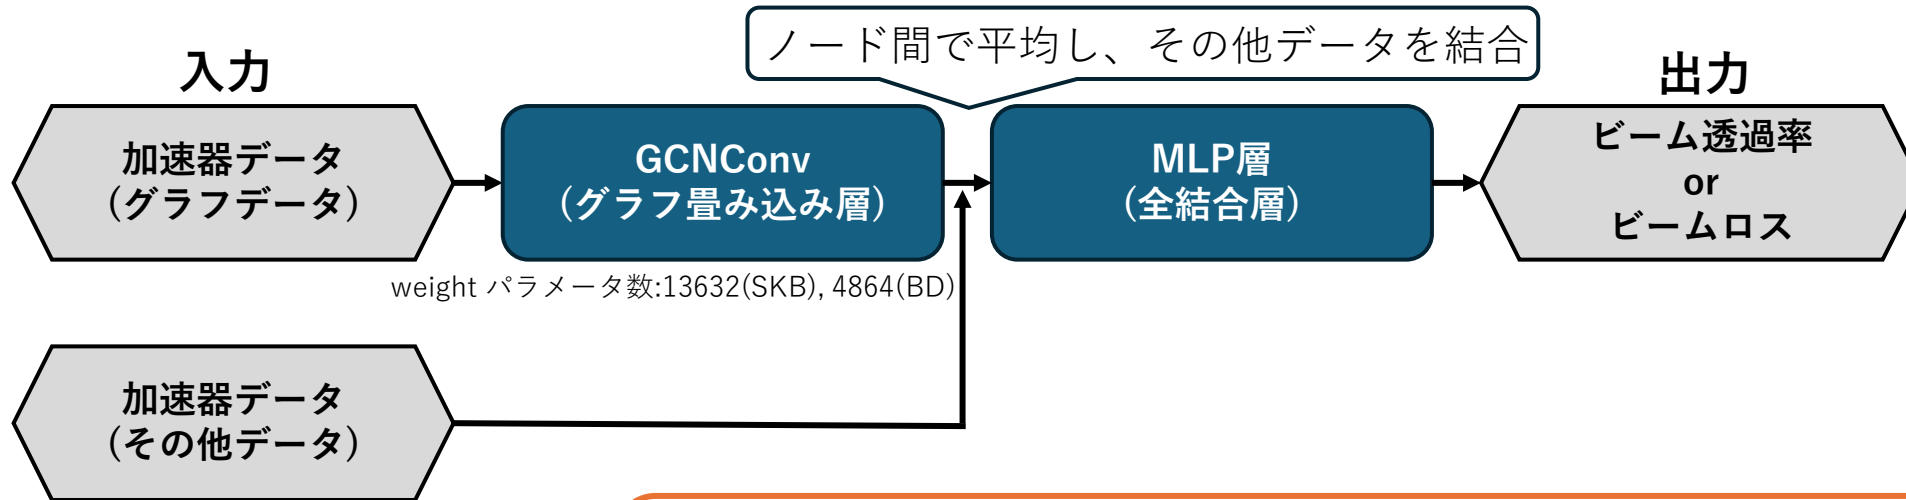
		SKB	BD
加速器 パラメータ	RFパラメータ (RF振幅・RF波長など)	: 682個,	648個
	環境パラメータ (環境温度・冷却水温等)	: 822個,	819個
	電磁石パラメータ (電磁石励磁電流読み値)	: 563個,	661個
	BPMパラメータ (ビーム位置モニター)	: 194個,	192個
合計		2261個, 2320個	

GNNにより **ビーム透過率** \equiv 加速器上流と下流のBPMでの電荷比
ビームロス

の予想をした

3.GNNの導入

加速器データ(約2000パラメータ)を取り扱うGNNを構築した



その他データ

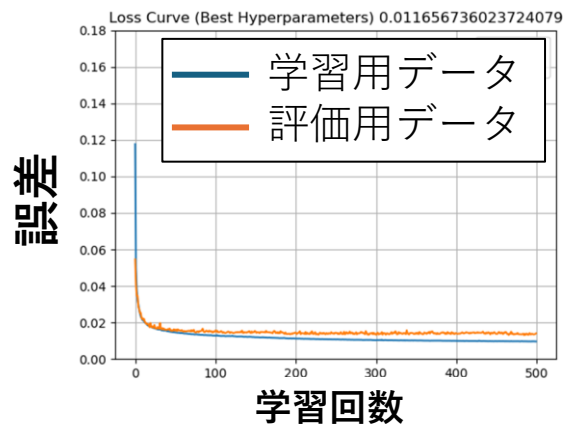
グラフデータに含まれないデータ(外気温・偏向電磁石など)は後で結合する

- ・構築したGNNを使って予測を行った
- ・比較のため、MLPでも予測を行った

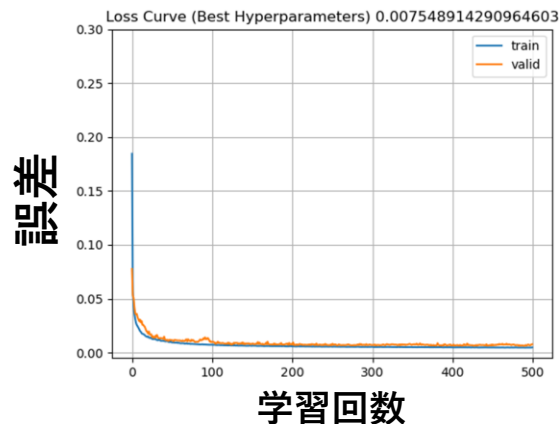
4.MLPでの予測

MLPを用いた機械学習で、ビーム透過率・ビームロス进行予測した


SKBビーム透過率学習曲線



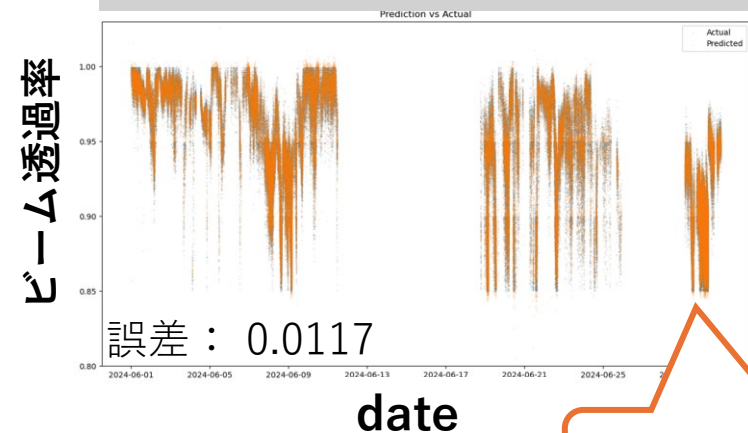
BDビーム透過率学習曲線



BDビームロス学習曲線

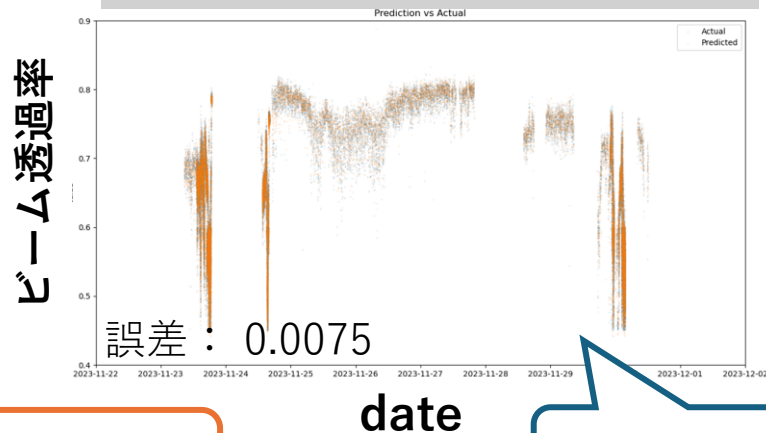


SKBビーム透過率予測




MLPで予想した値

BDビーム透過率予測



実際の値


BDビームロス予測




5.GNNでの予測

GNNを用いた機械学習で、ビーム透過率・ビームロス进行予測した

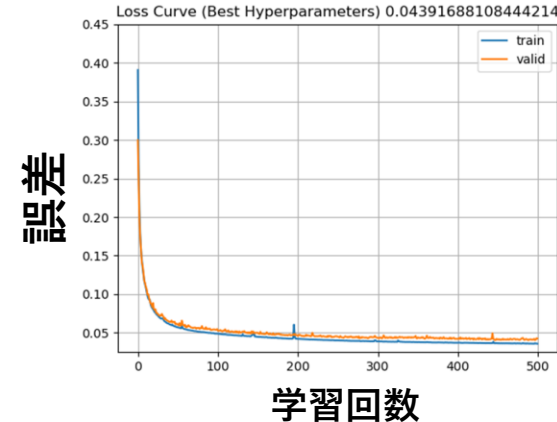
SKBビーム透過率学习曲线



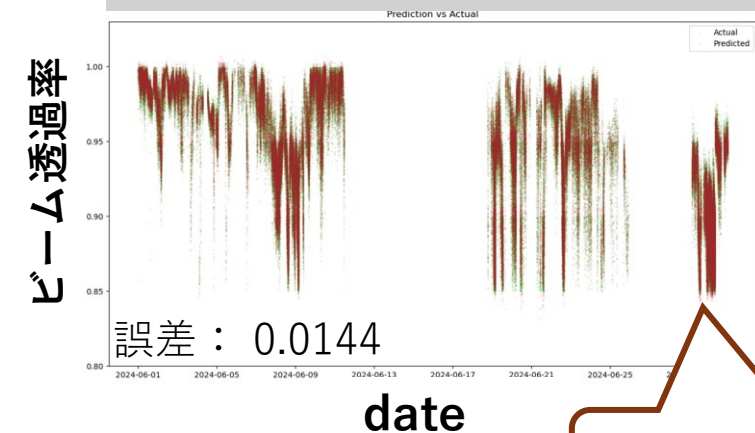
BDビーム透過率学习曲线



BDビームロス学习曲线

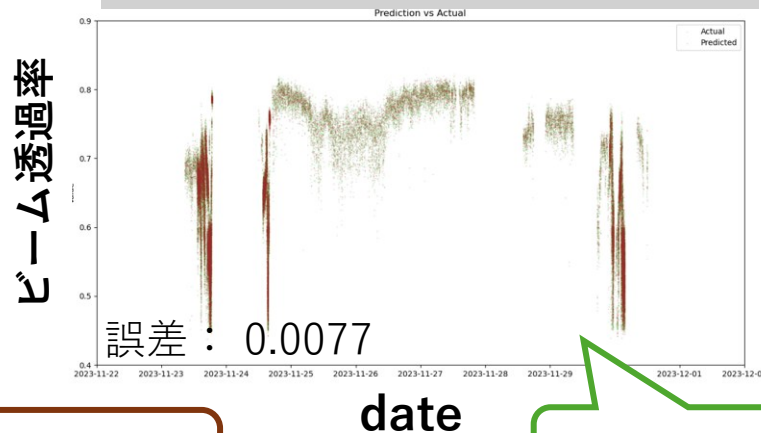


SKBビーム透過率予測



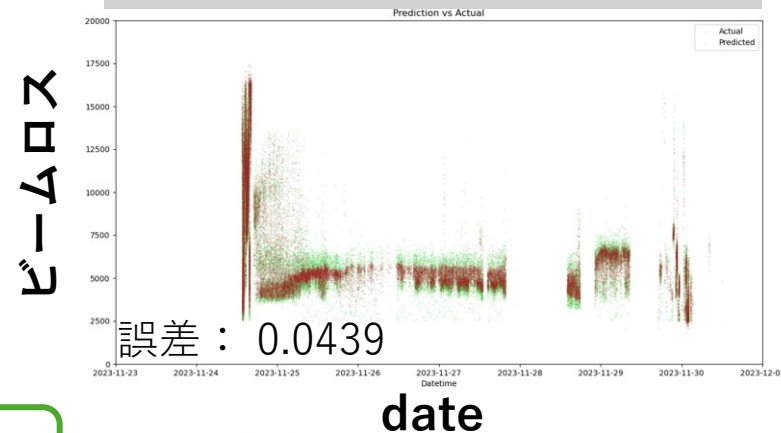
GNNで予想した値

BDビーム透過率予測



実際の値

BDビームロス予測



5.GNNでの予測

GNNを用いた機械学習で、ビーム透過率・ビームロスを予測した

SKBビーム透過率学習曲線

BDビーム透過率学習曲線

BDビームロス学習曲線

Loss Curve (Best Hyperparameters) 0.014439068734645844


Loss Curve (Best Hyperparameters) 0.007691132370382547

Loss Curve (Best Hyperparameters) 0.04391688108444214

GNNを使って、2000パラメータの入力に対して、
過学習なく、ビーム透過率・ビームロスを
予測するモデルを作成することができた

作成したモデルにXAIを適用し、重要なパラメータを推測する

ビーム透過率



date

GNNで予想した値


ビーム透



date

実際の値

ビームロ



date

XAIによる重要なパラメータの予測結果

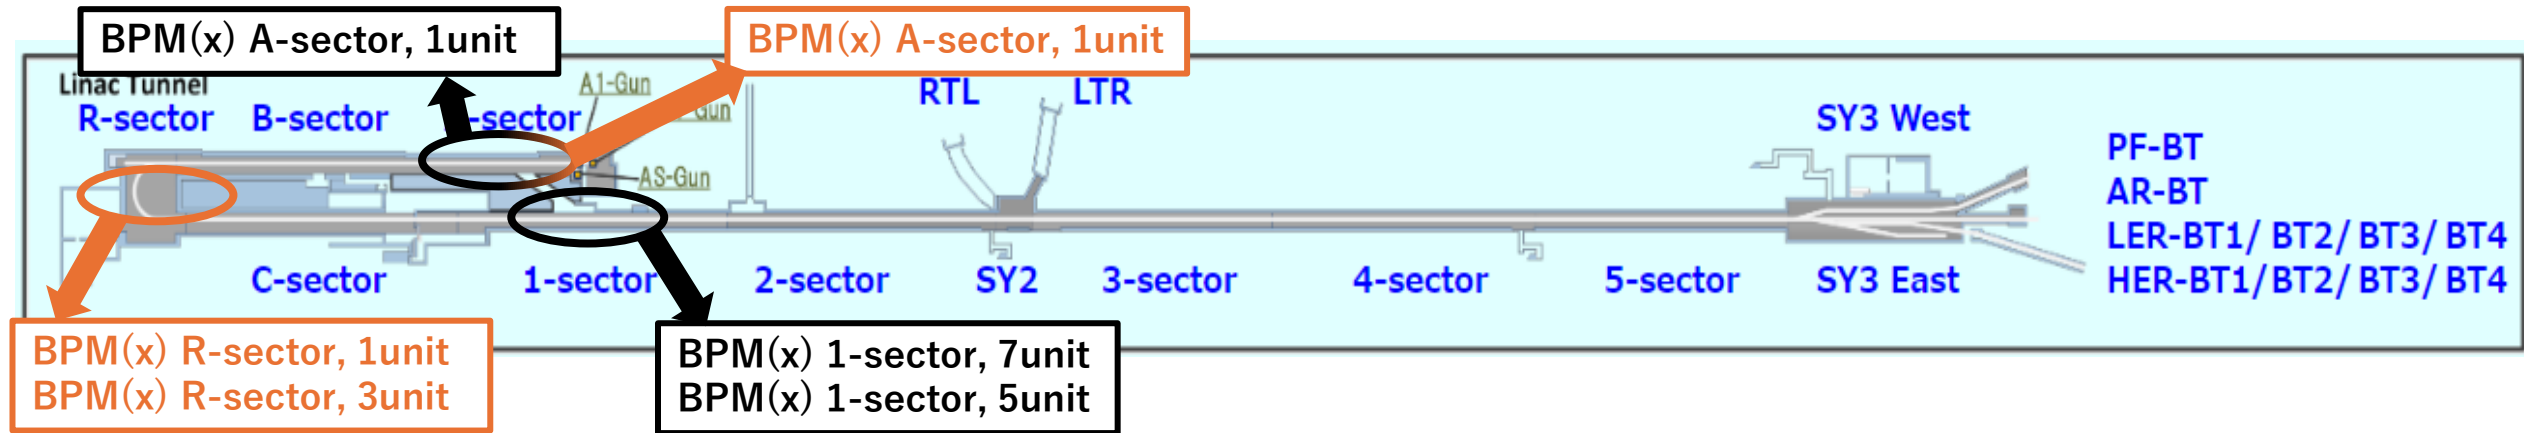
SKB入射ビーム(電子)(Belle2実験)

- ・ ビーム透過率

6.重要なパラメータの位置と種類(SKBビーム透過率/Belle2実験)

・SKBビーム透過率重要パラメータ

構築した**MLP**と**GNN**でそれぞれ重要と推測されたパラメータの位置と種類を示す



MLPでの重要なパラメータ

順位	パラメータ種類	場所
1	BPM(x)	1-sector, 7unit
2	BPM(x)	1-sector, 5unit
3	BPM(x)	A-sector, 1unit

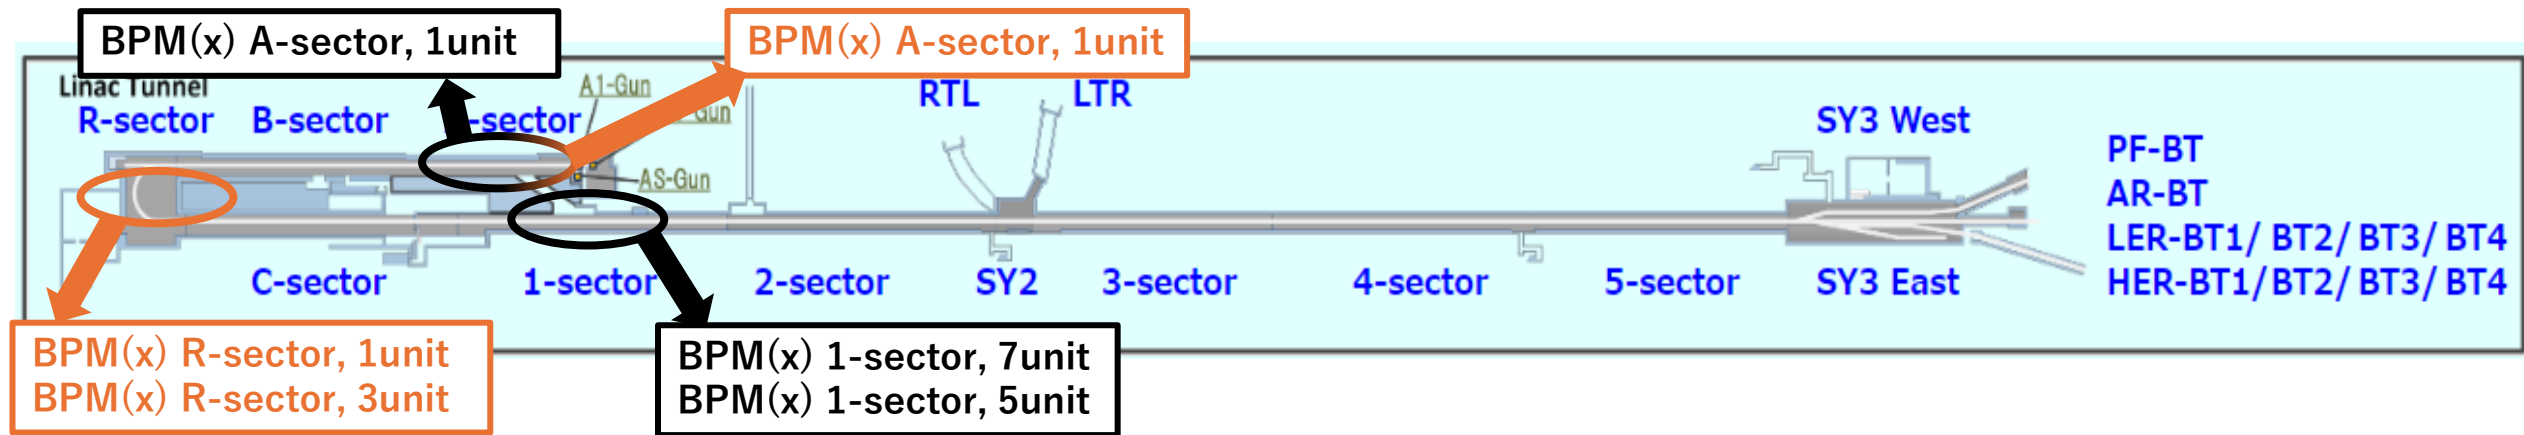
GNNでの重要なパラメータ

順位	パラメータ種類	場所
1	BPM(x)	R-sector, 1unit
2	BPM(x)	A-sector, 1unit
3	BPM(x)	R-sector, 3unit

6.重要なパラメータの位置と種類(SK Bビーム透過率/Belle2実験)

・ SK Bビーム透過率重要パラメータ

構築した**MLP**と**GNN**でそれぞれ重要と推測されたパラメータの位置と種類を示す



MLPでは、
A-sectorと1-sectorのビーム位置が重要であると予想された

GNNでは、
A-sectorとR-sectorのビーム位置が重要であると予想された

XAIによる重要なパラメータの予測結果

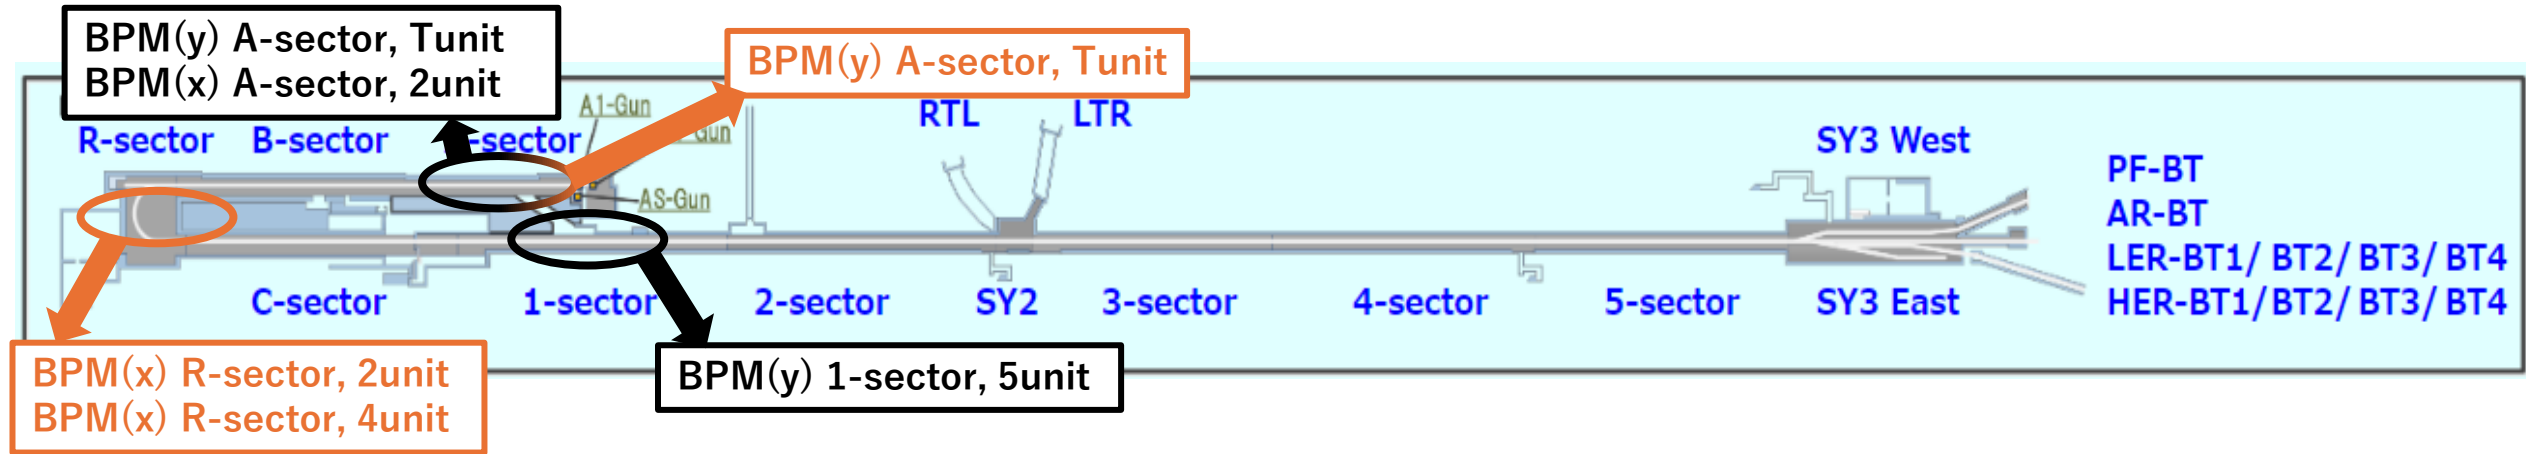
BD入射ビーム(EBES実験)

- ・ ビーム透過率
- ・ ビームロス

7.重要なパラメータの位置と種類(BDビーム透過率/EBES実験)

・BDビーム透過率重要パラメータ

構築した**MLP**と**GNN**でそれぞれ重要と推測されたパラメータの位置と種類を示す



MLPでの重要なパラメータ

順位	パラメータ種類	場所
1	BPM(y)	1-sector, 5unit
2	BPM(y)	A-sector, Tunit
3	BPM(x)	A-sector, 2unit

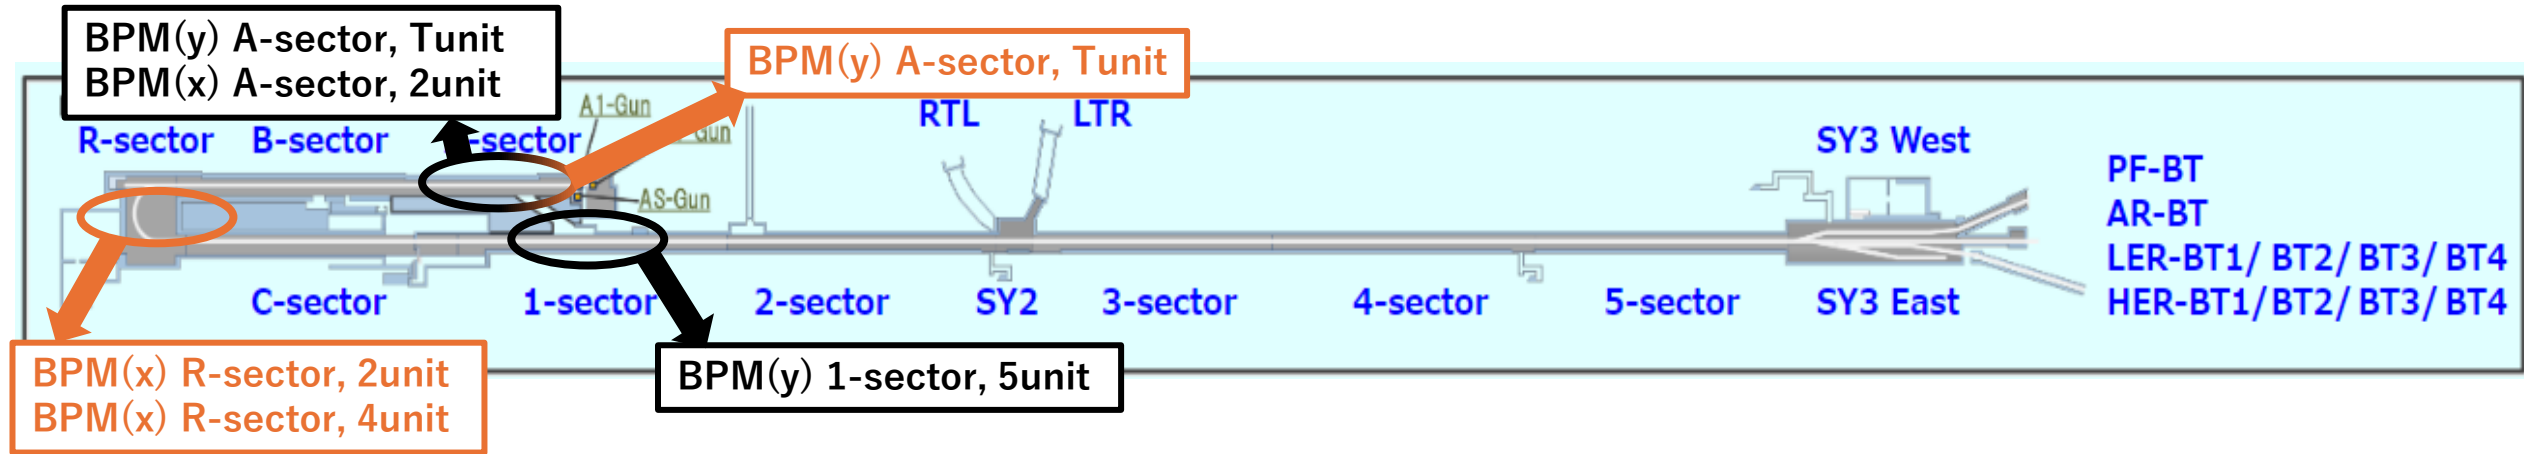
GNNでの重要なパラメータ

順位	パラメータ種類	場所
1	BPM(y)	A-sector, Tunit
2	BPM(x)	R-sector, 2unit
3	BPM(x)	R-sector, 4unit

7.重要なパラメータの位置と種類(BDビーム透過率/EBES実験)

・ BDビーム透過率重要パラメータ

構築した**MLP**と**GNN**でそれぞれ重要と推測されたパラメータの位置と種類を示す




MLPでは、
A-sectorと1-sectorのビーム位置が重要であると予想された

GNNでは、
A-sectorとR-sectorのビーム位置が重要であると予想された

8.重要なパラメータの位置と種類(BDビームロス/EBSE実験)

・BDビームロス重要パラメータ

構築した**MLP**と**GNN**でそれぞれ重要と推測されたパラメータの位置と種類を示す



MLPでの重要なパラメータ

順位	パラメータ種類	場所
1	BPM(x)	6-sector, 1unit
2	BPM(y)	6-sector, 1unit
3	BPM(x)	6-sector, 1unit

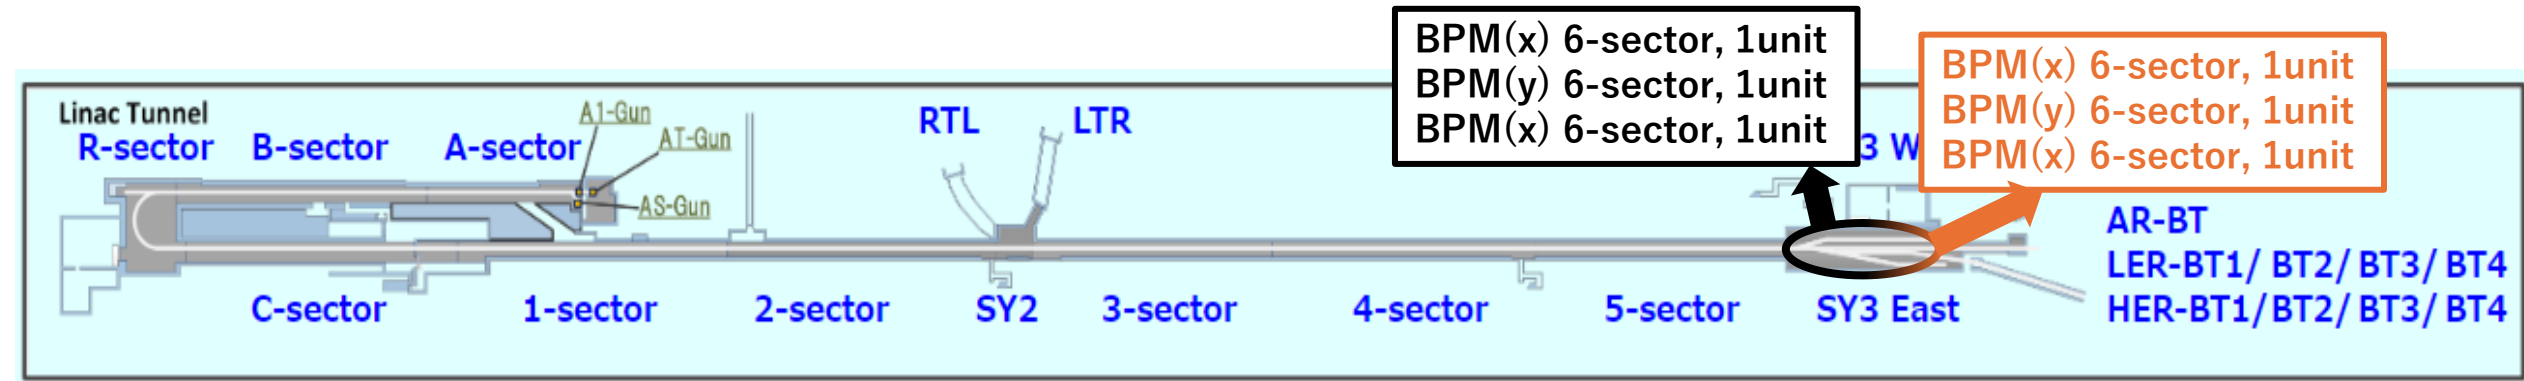
GNNでの重要なパラメータ

順位	パラメータ種類	場所
1	BPM(x)	6-sector, 1unit
2	BPM(y)	6-sector, 1unit
3	BPM(x)	6-sector, 1unit

8.重要なパラメータの位置と種類(BDビームロス/EBSE実験)

・ BDビームロス重要パラメータ

構築した**MLP**と**GNN**でそれぞれ重要と推測されたパラメータの位置と種類を示す



MLPと**GNN**で共通して、
6-sectorのビーム位置が重要であると予想された

**大規模加速器への機械学習適用を行うために、
GNNを用いた機械学習手法を構築し、
重要なパラメータを予想した**

1. 多パラメータ(2000以上)の入力に適用させるため、GNNを用いた機械学習手法を開発した
 - ・ ビーム透過率・ビームロスを予測することができた
2. 構築したGNNに対して、XAIを適用し重要なパラメータを求めた
 - ・ ビーム透過率：A, R, 1-sector(上流部)のパラメータが重要であると予想された
 - ・ ビームロス：6-sector(最下流部)のパラメータが重要であると予想された

大規模加速器への機械学習適用を行うために、
GNNを用いた機械学習手法を構築し、
重要なパラメータを予想した

今後、

- MLPとGNNの予測結果の違いについて詳しく調べる
- GNNでさらに大きなパラメータ数でも予測可能か検証する

本研究で確立した手法を用いて大規模加速器への機械学習適用を進める