

シミュレーションを併用した重イオンビームトランスポートラインのベイズ最適化に関する研究

Study for Bayesian optimization of heavy ion beam transport using simulation

2023 11/27

理研仁科加速器科学研究センター 西 隆博

共同研究者

岩井 瑛人^{a,c}, 内山 暁仁^b, 清水 陽平^b, 杉本 崇^a, 炭竈 聡之^b,
福田 直樹^b, 藤井 洋樹^b, 前坂 比呂和^c

a. 公益財団法人高輝度光科学研究センター

b. 理研仁科加速器科学研究センター


c. 理研放射光科学研究センター



アウトライン

- ・ 理研 RIBF と機械学習を用いたビーム輸送最適化
- ・ ベイズ最適化のためのシミュレーションの概要
- ・ ベイズ最適化のハイパーパラメータ
(acquisition function / objective function / phase ellipse)
- ・ 各ハイパーパラメータでのシミュレーション結果の比較
- ・ 解析の現状まとめと今後の予定

理研 RIBF と機械学習を用いたビーム輸送最適化



将来的な目標: **> 1 pμA** ^{86+U beam}
 (×10 times upgrade)

⇔ 局所的なビームロス ~ **0.2%** で機器を壊しうる。

目標の高強度ウランビーム (> 1pμA / 100 kW) の達成には、

- 局所的なビームロスを **0.1 ~ 1%** に抑える
- 環境などの変化に追従する**常時最適化**

が必要となる

ビーム輸送パラメータの常時自動最適化

- 600 以上のコントロールパラメータ
- その他環境変数




- 非破壊ビーム検出器
- ビームロスモニター
- 下流検出器

パラメータの最適化手法: ガウス過程回帰を用いた逐次学習

SACLA@Spring-8 で実用化されている機械学習による自動調整
→ RIBF に応用し、将来的な高精度のビーム調整に繋がりたい

ガウス過程回帰




C. M. Bishop, Pattern Recognition and Machine Learning, Springer (2006)

- 誤差、不定性を持つ多次元データを取り扱える
- local min. にハマりにくい
- **比較的少ない試行回数で最適化が可能**

Gaussian Process を用いた逐次学習による自動調整
XFEL の強度を最適化した例 (~15 パラメータ同時最適化)

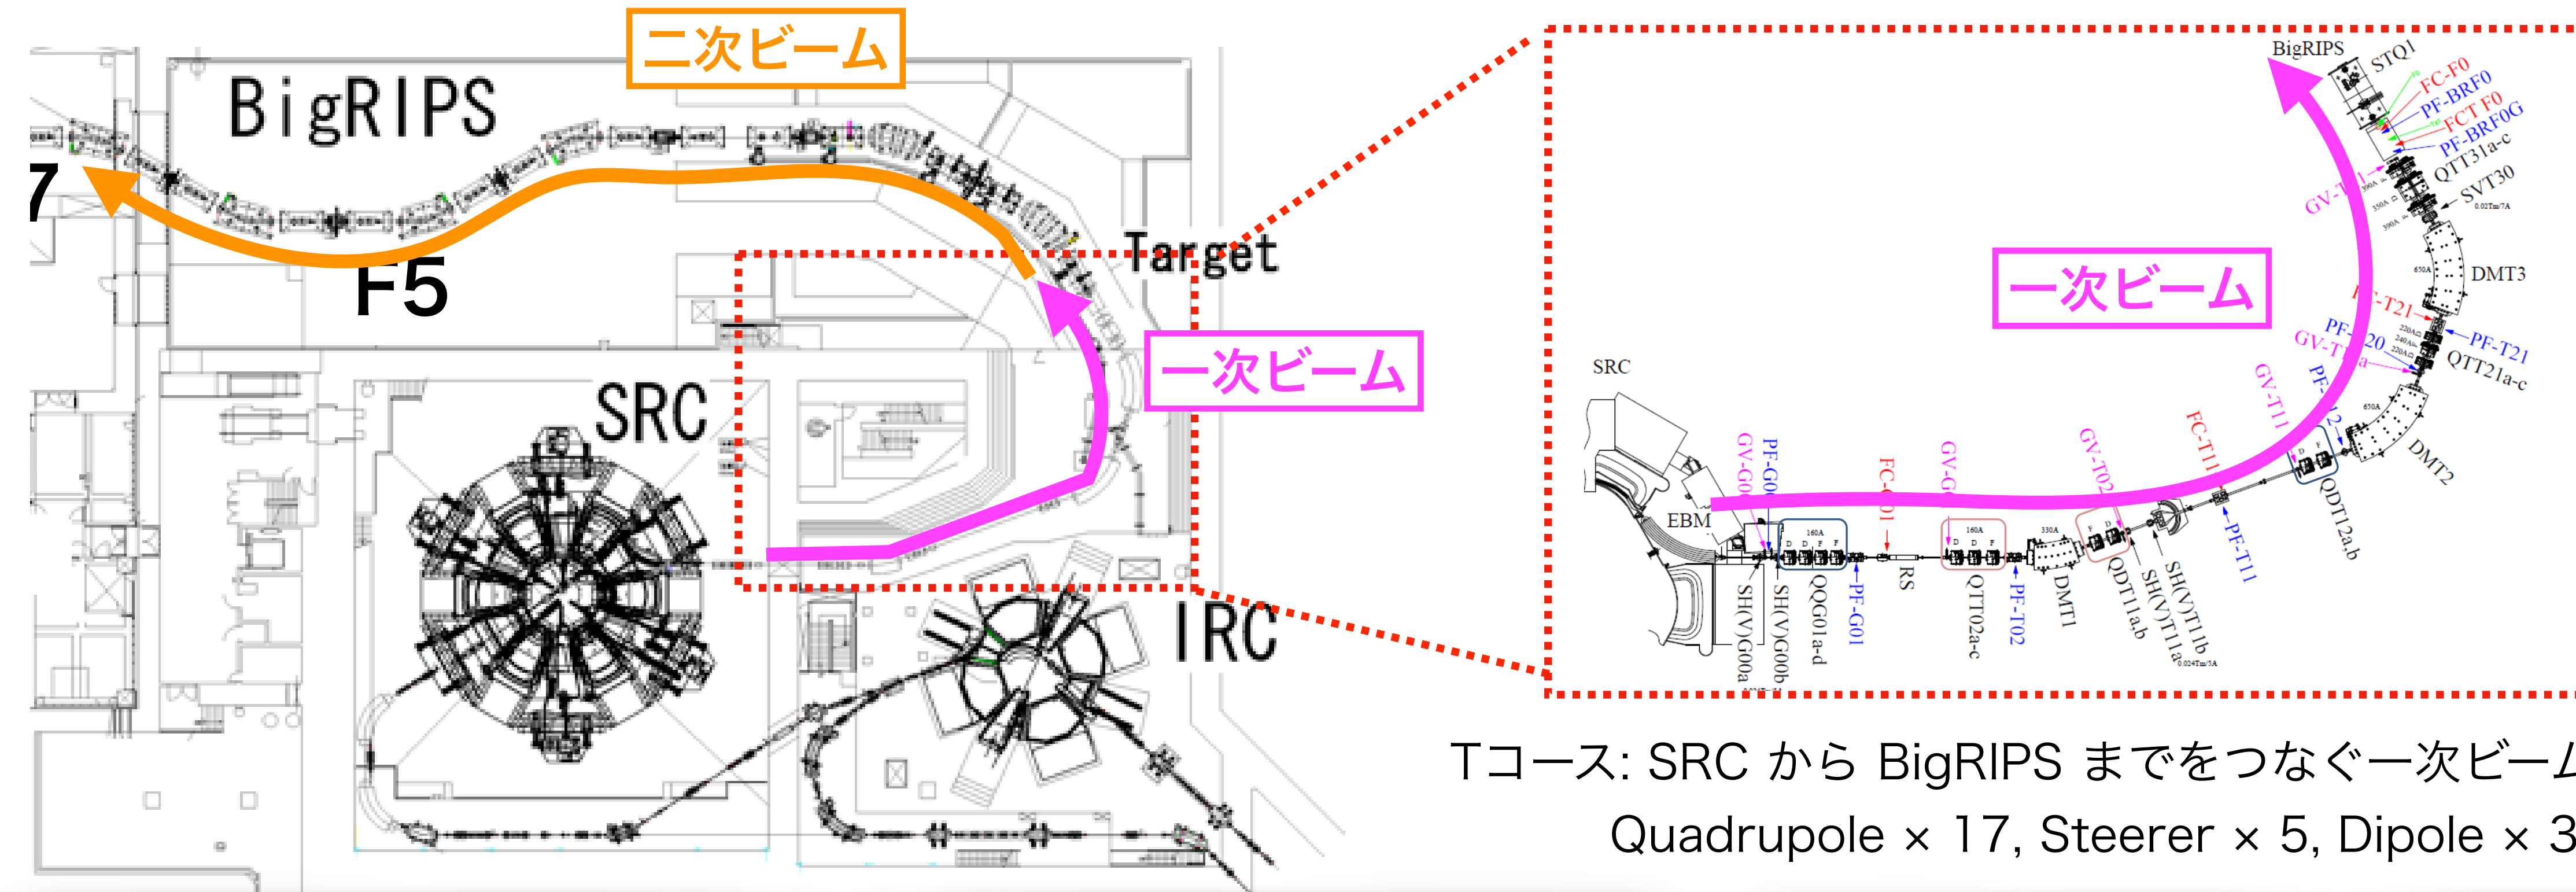
ビーム物理研究会2020、岩井氏資料より



→ JASRI 岩井さん


E. Iwai et al, Proc. of PASJ 2021 WE0B02

RIBF への機械学習の導入の第一歩: 一次ビーム最下流の光学系調整



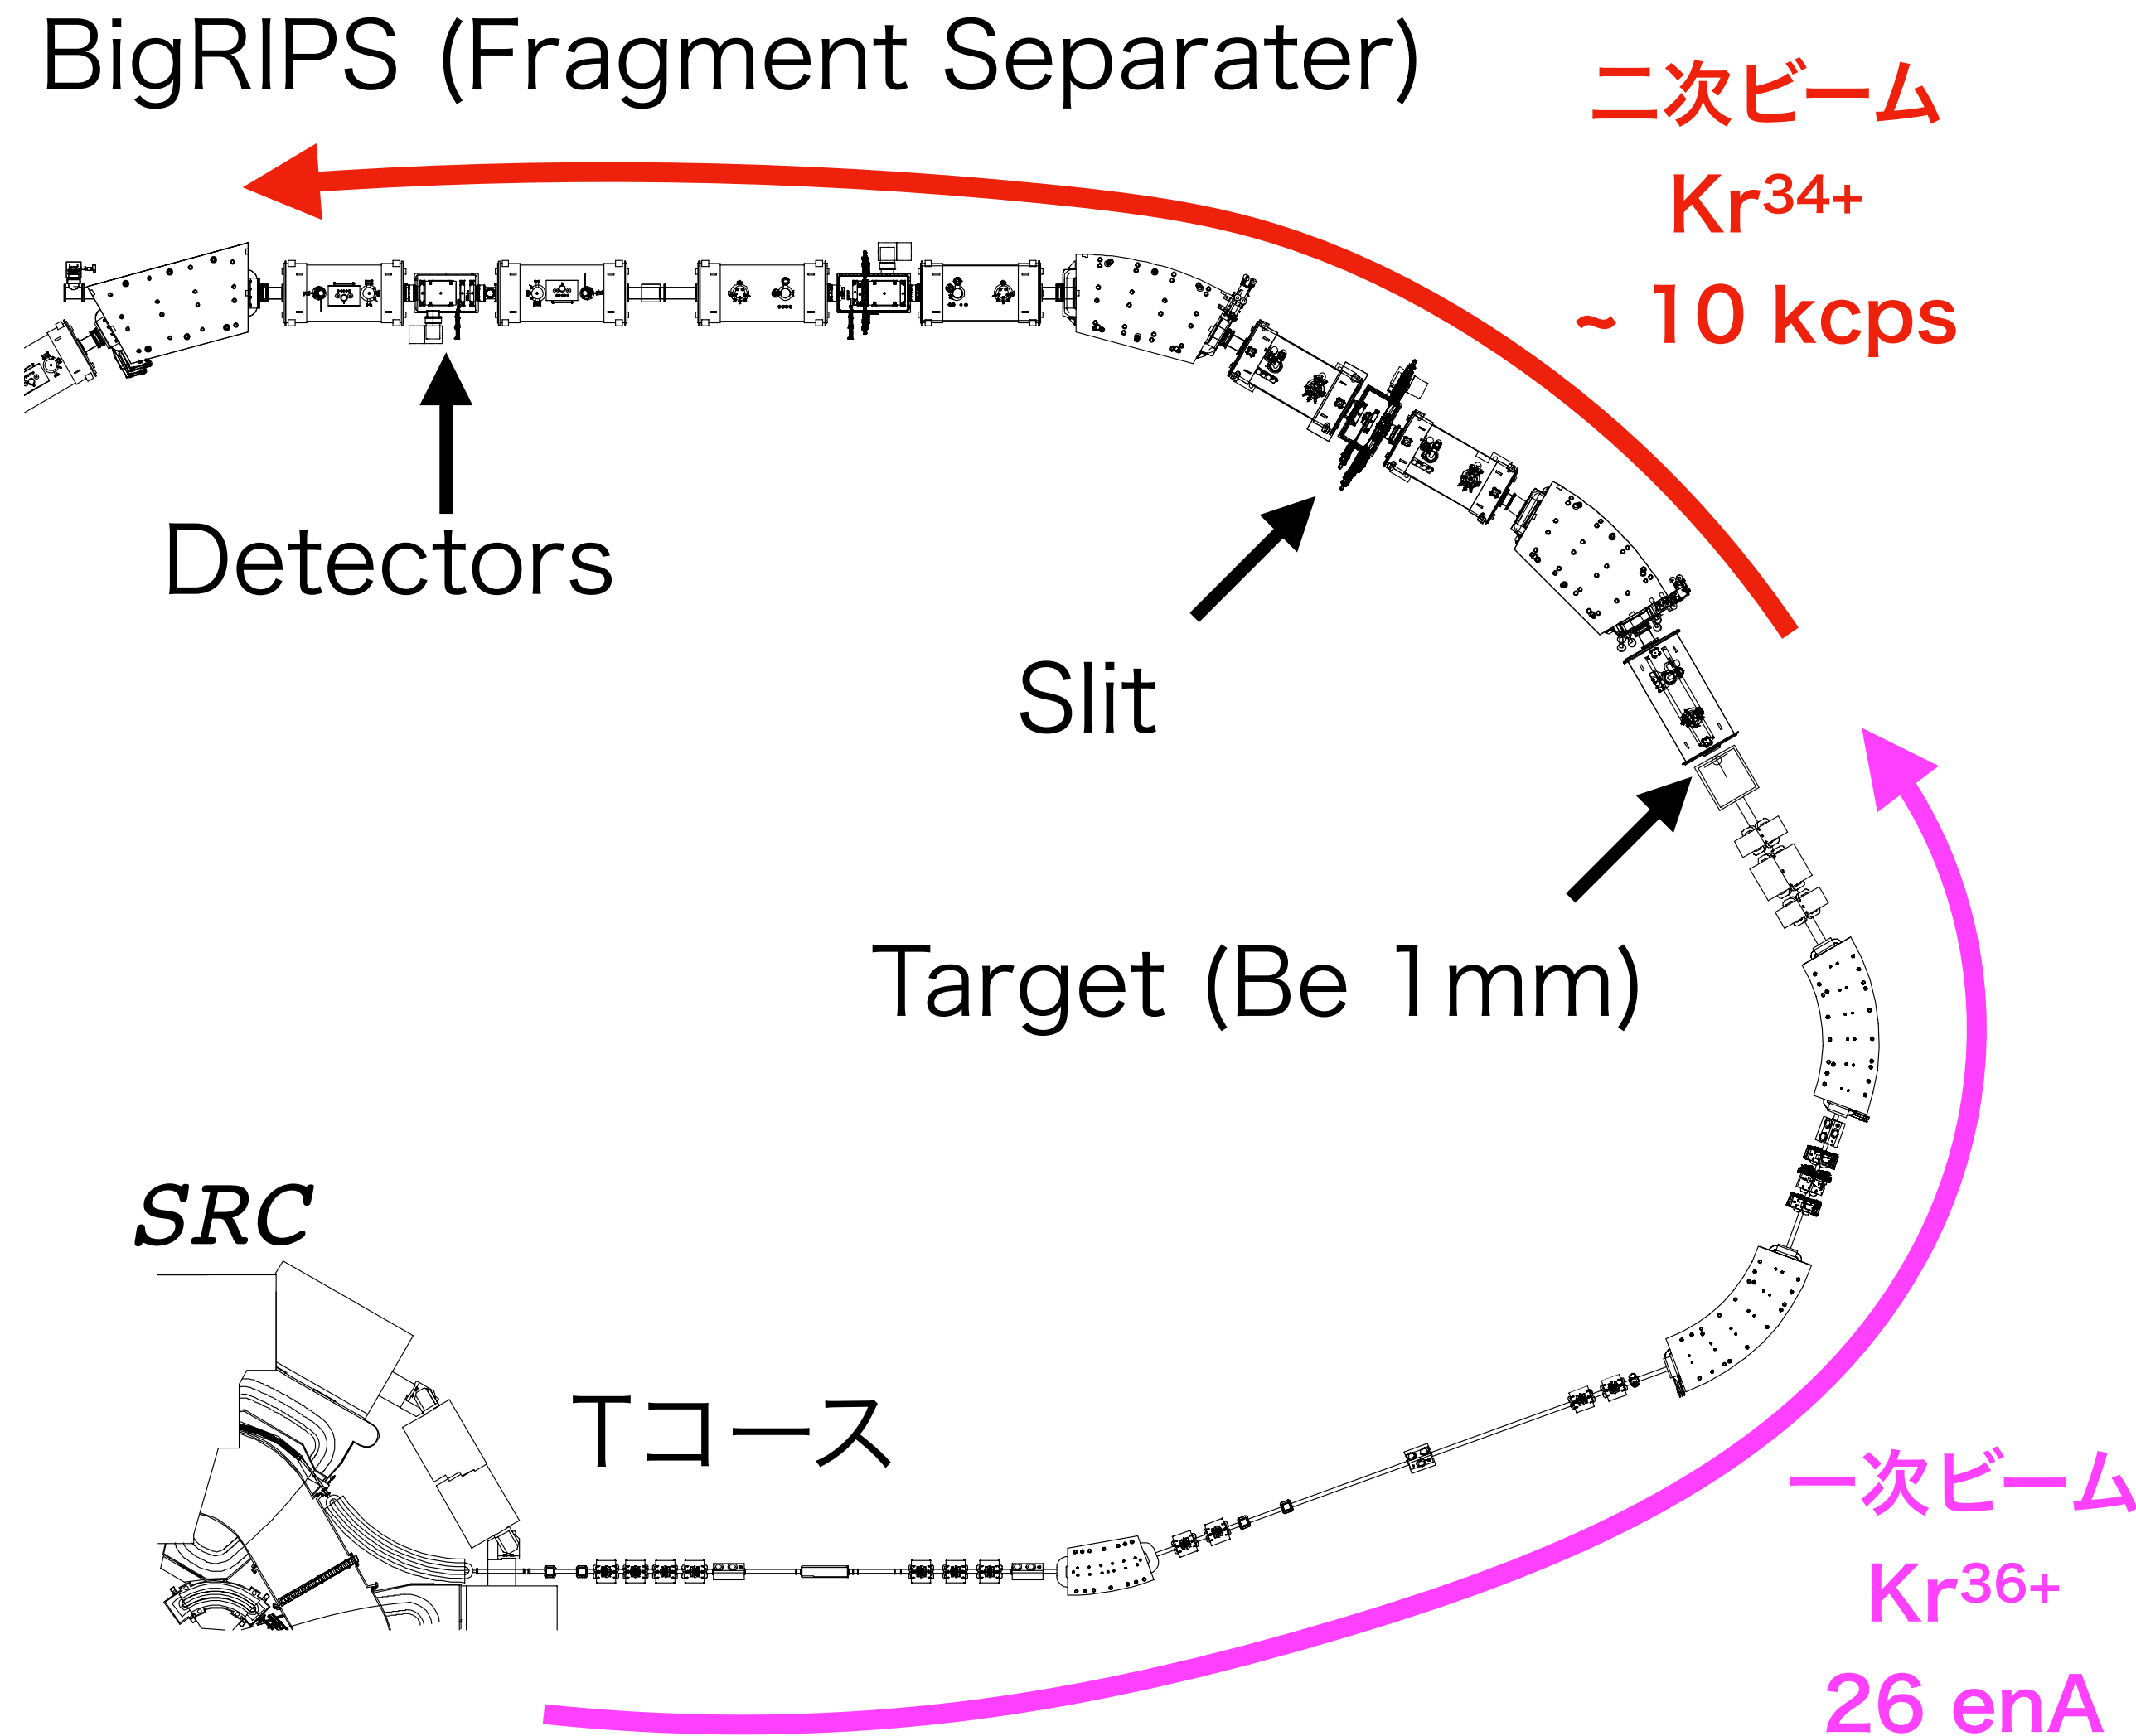
Tコース: SRC から BigRIPS までをつなぐ一次ビームライン
 Quadrupole × 17, Steerer × 5, Dipole × 3

- ・ 下流に Fragment Separator である BigRIPS 豊富な検出器などの情報からデータを集めやすい
- ・ 通常オペレーションの場合、最もロスの大い ウランビームでは通過効率 ~ 90% 程度と見積られる
- ・ 通過効率と小さいスポットを同時に実現することを目指す



- 将来的な目標である **1 pμA** のウランビーム実現には、
- ・ **ビームロスを 1 ~ 0.1 % 程度に抑える**
- ・ **像は小さく ($\sigma_h \sim < 1 \text{ mm}$) 保つ** ことが必要になる。


“高強度”一次ビームで荷電変換粒子の測定による光学系最適化




“高強度”一次ビームで荷電変換粒子の測定による光学系最適化

- 4 変数 (四重極電磁石)
 - 1 epoch ~ 25 s
 - 一度の最適化 ~ 30 分程度
 - 一次ビーム ~ 26 enA
- で最適化

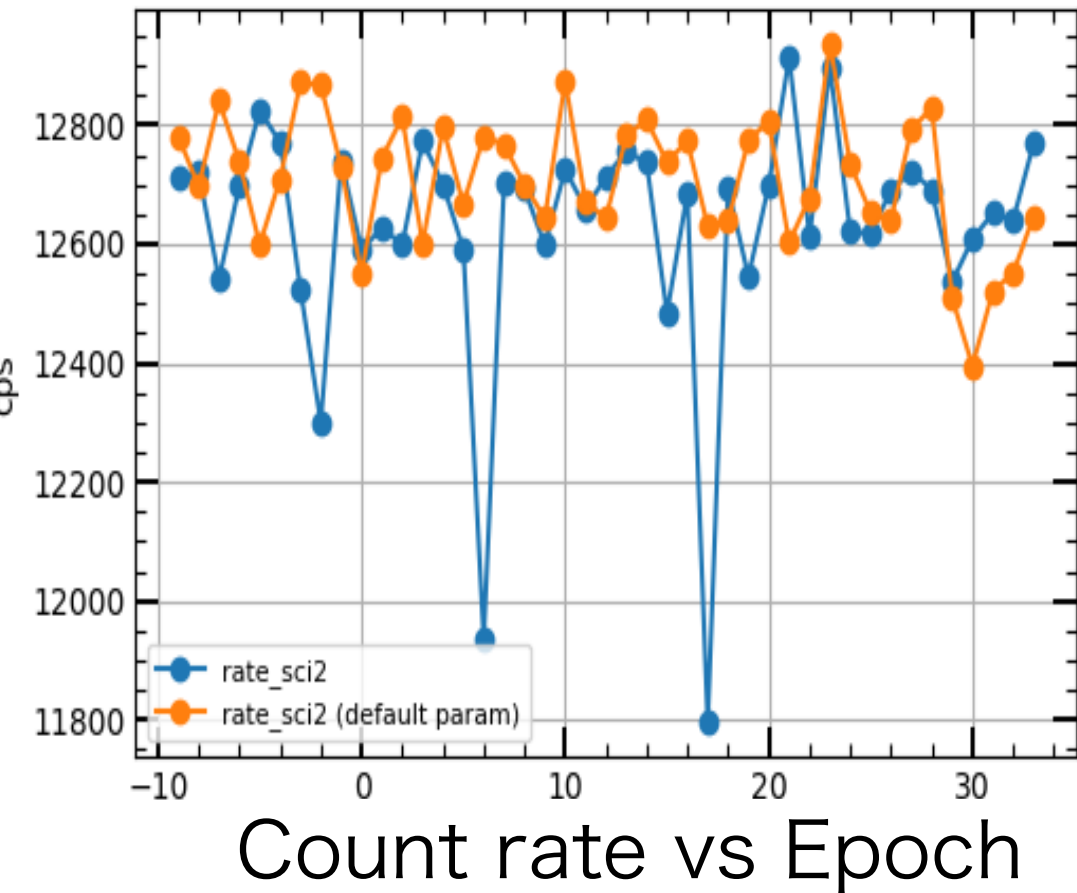
※1 epoch の時間は、
 ・ 電流値のセット
 ・ 検出器の測定
 などで律速



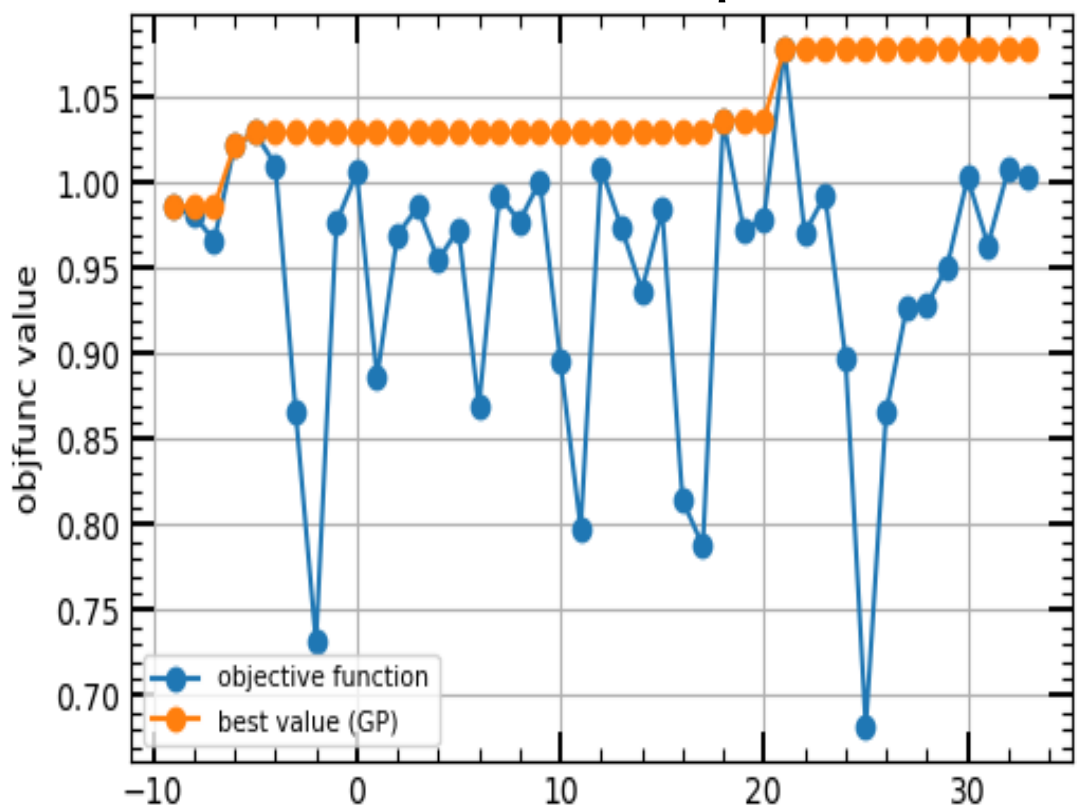
Pos_{h, v} vs Epoch




$\sigma_{h, v}$ vs Epoch




Count rate vs Epoch



評価関数 vs Epoch



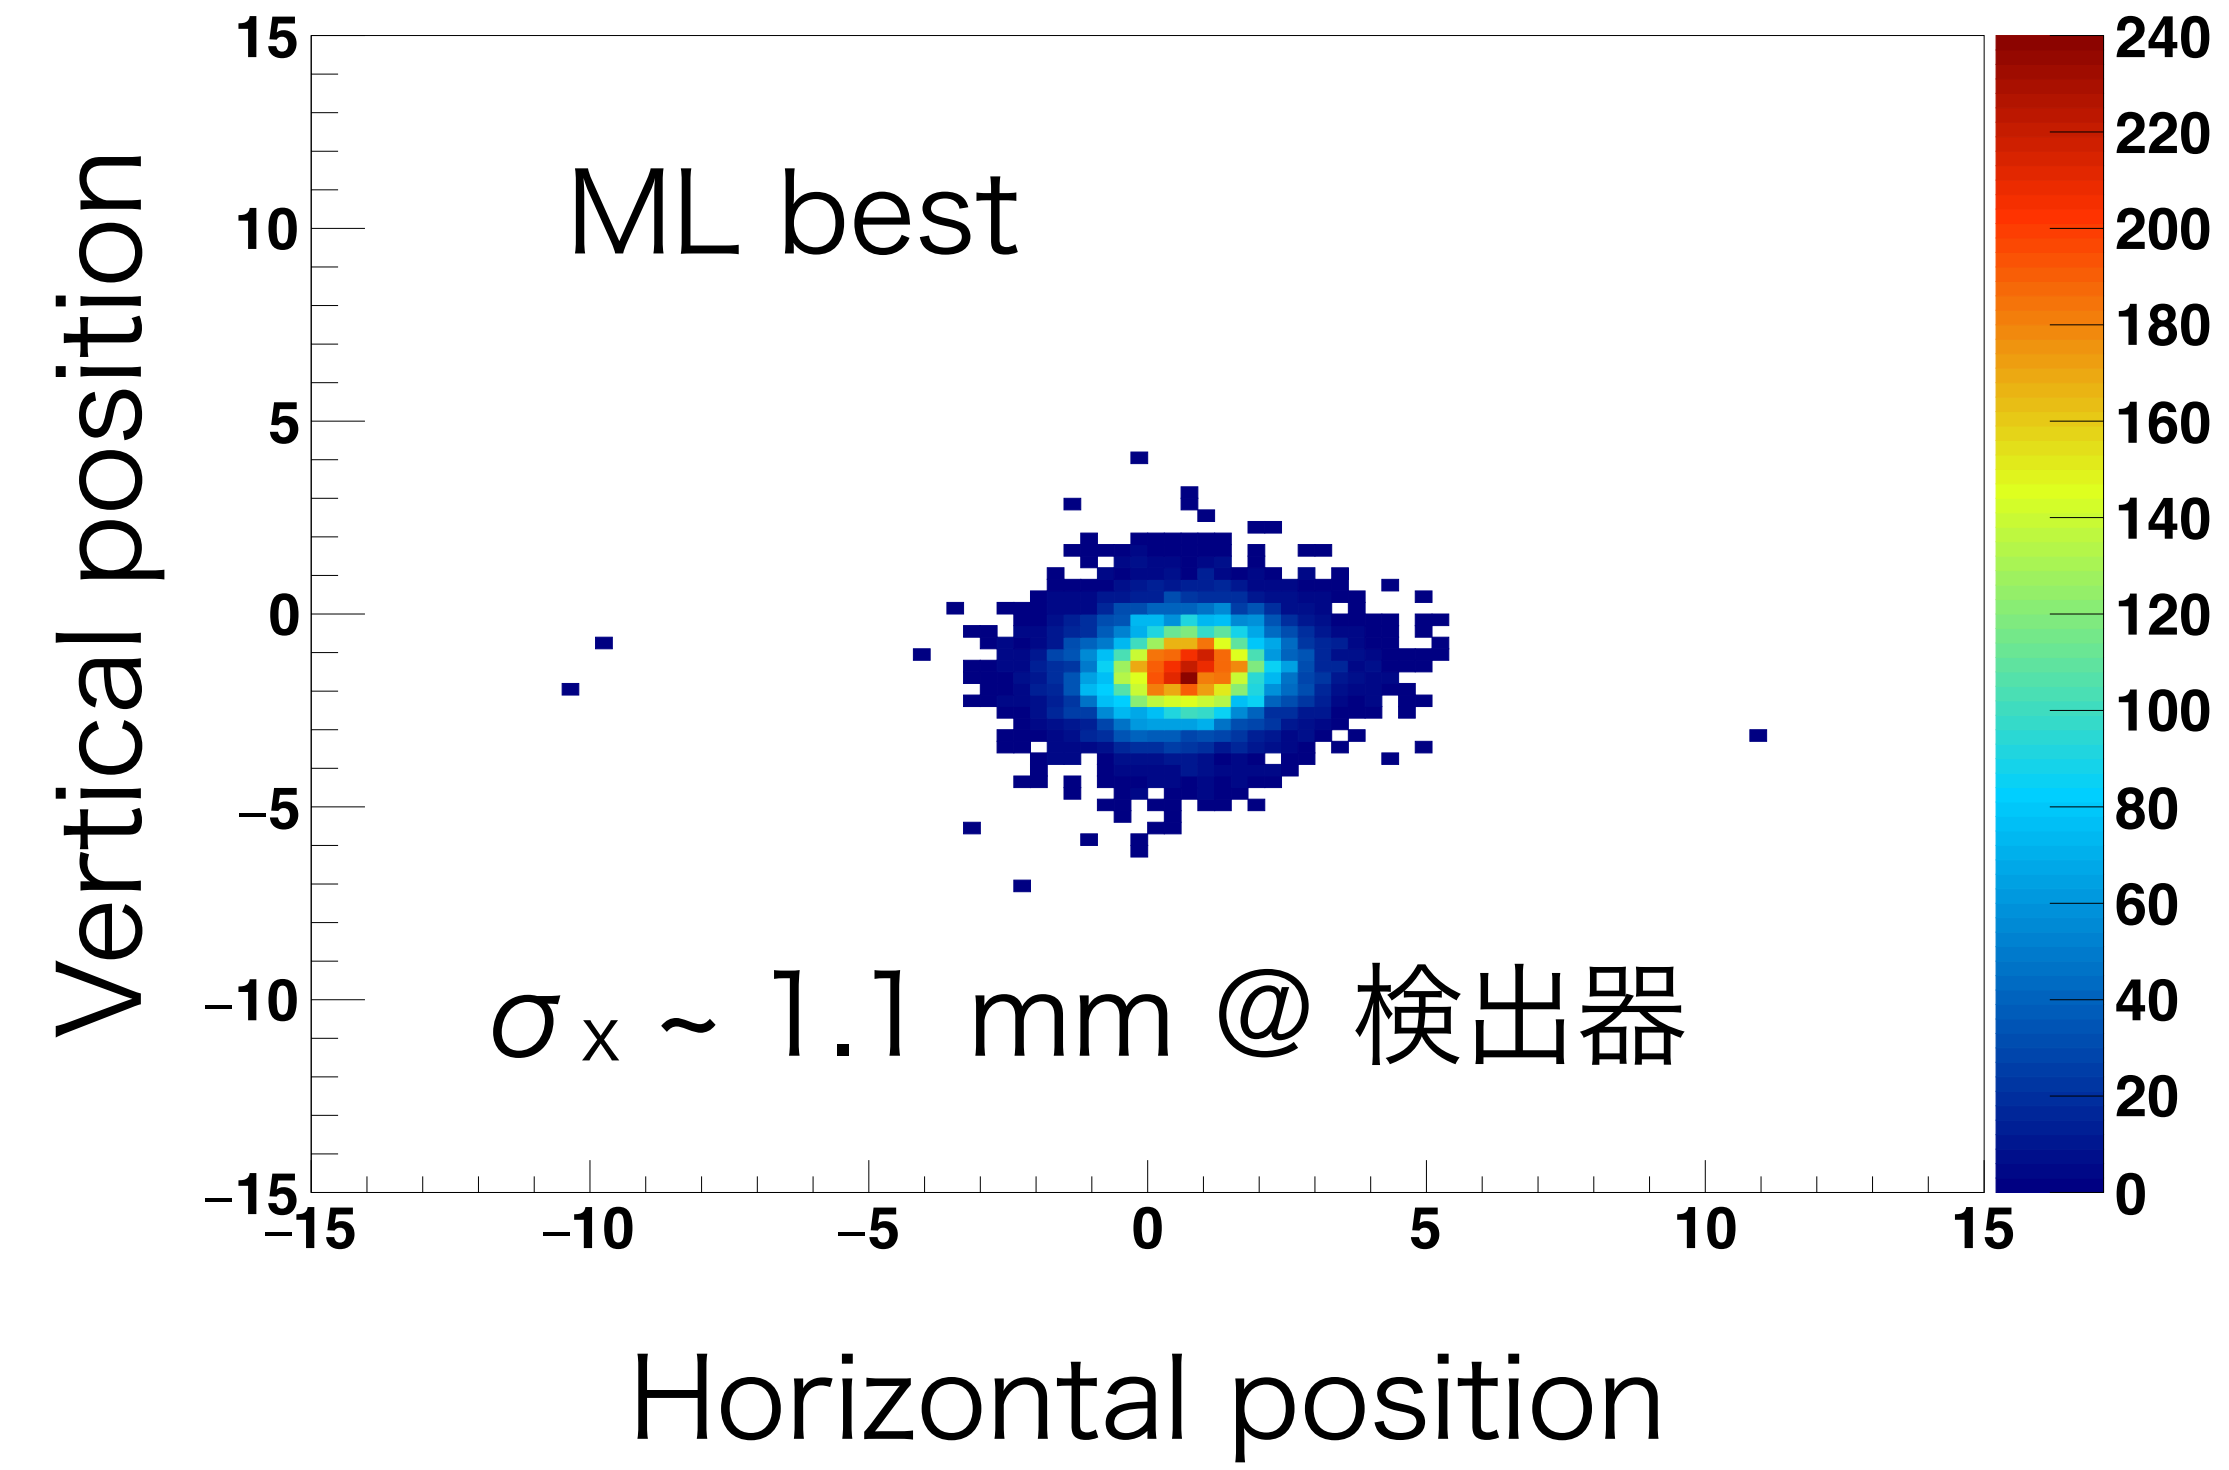
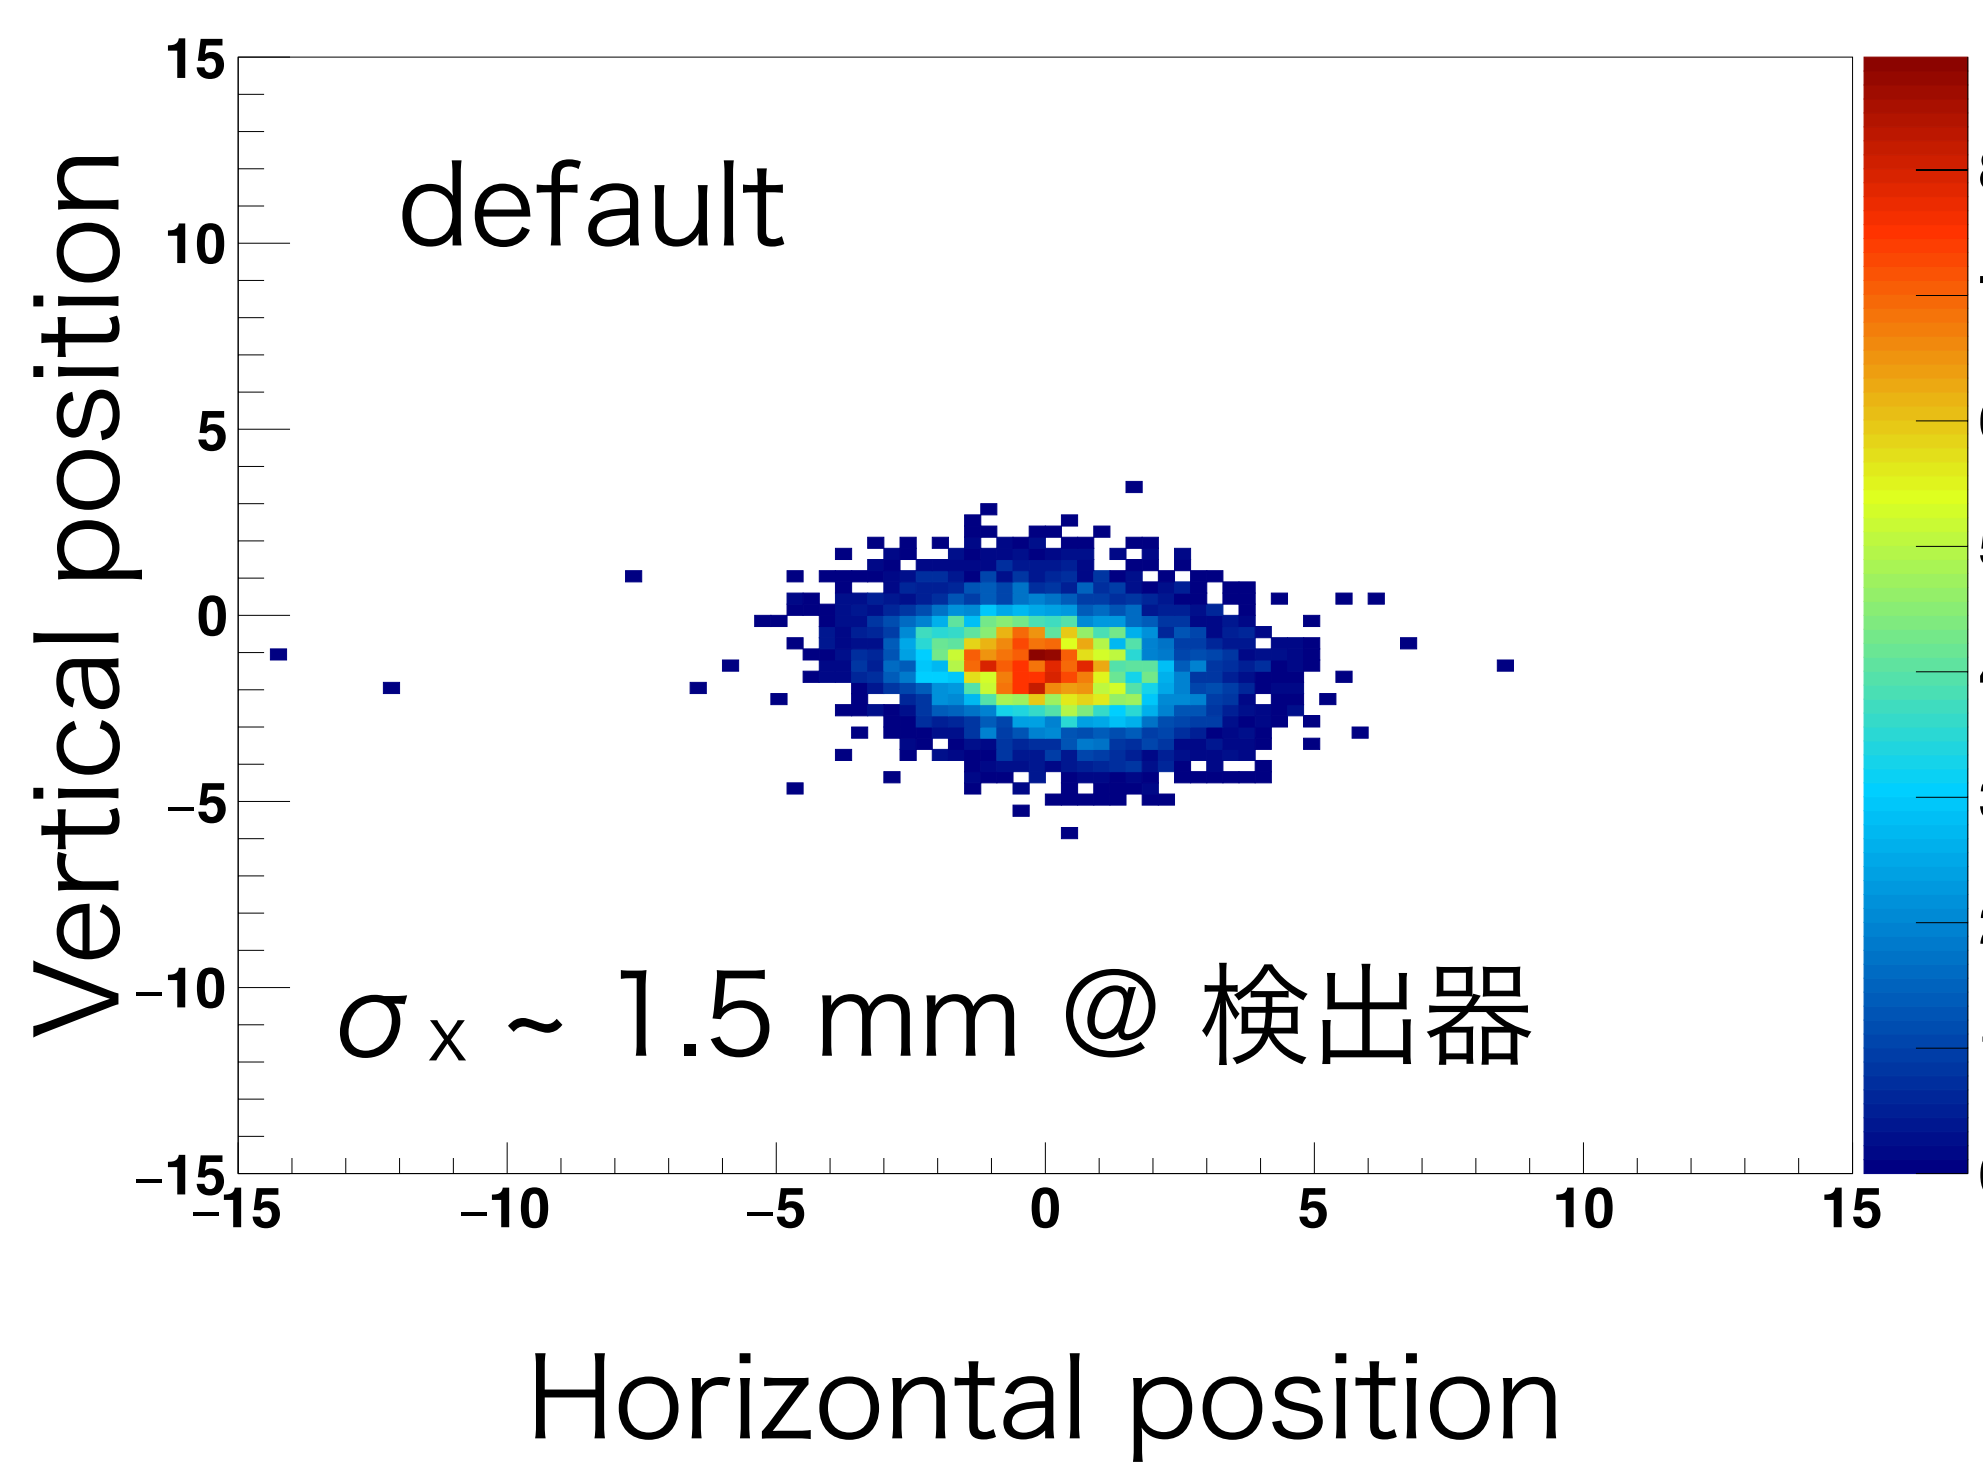
電流値 (相対値) vs Epoch



評価関数 vs 電流値

“高強度”一次ビームで荷電変換粒子の測定による光学系最適化

初期光学系 (人間の手で最適化) と ML で得られた光学系を比較
 → **通過効率はほぼ変わらず。スポットサイズは ~30% 程度減少に成功。**



RIBF におけるベイズ最適化を使った光学系調整の現状

達成

- ・ベイズ最適化 (ガウス過程回帰) プログラムが期待通りに動くことを確認
- ・~ 26 enA までの”高強度” 重イオンビームに対し、スポットサイズ / 通過効率の同時最適化に成功。

課題

- ・安全に自動調整を行うシステム (Safe optimization using LineBO)
- ・より効率的な最適化手法へ改善
(現状: 4 パラメータで ~ 30 分 / 50 epoch)

RIBF におけるベイズ最適化を使った光学系調整の現状

達成

- ・ベイズ最適化 (ガウス過程回帰) プログラムが期待通りに動くことを確認
- ・~ 26 enA までの”高強度” 重イオンビームに対し、スポットサイズ / 通過効率の同時最適化に成功。

課題

- ・安全に自動調整を行うシステム (Safe optimization using LineBO)
- ・より効率的な最適化手法へ改善

(現状: 4 パラメータで ~ 30 分 / 50 epoch)

VAE を使った変数の自由度の削減 (次の森田氏の講演)

シミュレーションを基にした事前学習 (physics informed Gaussian Process など)

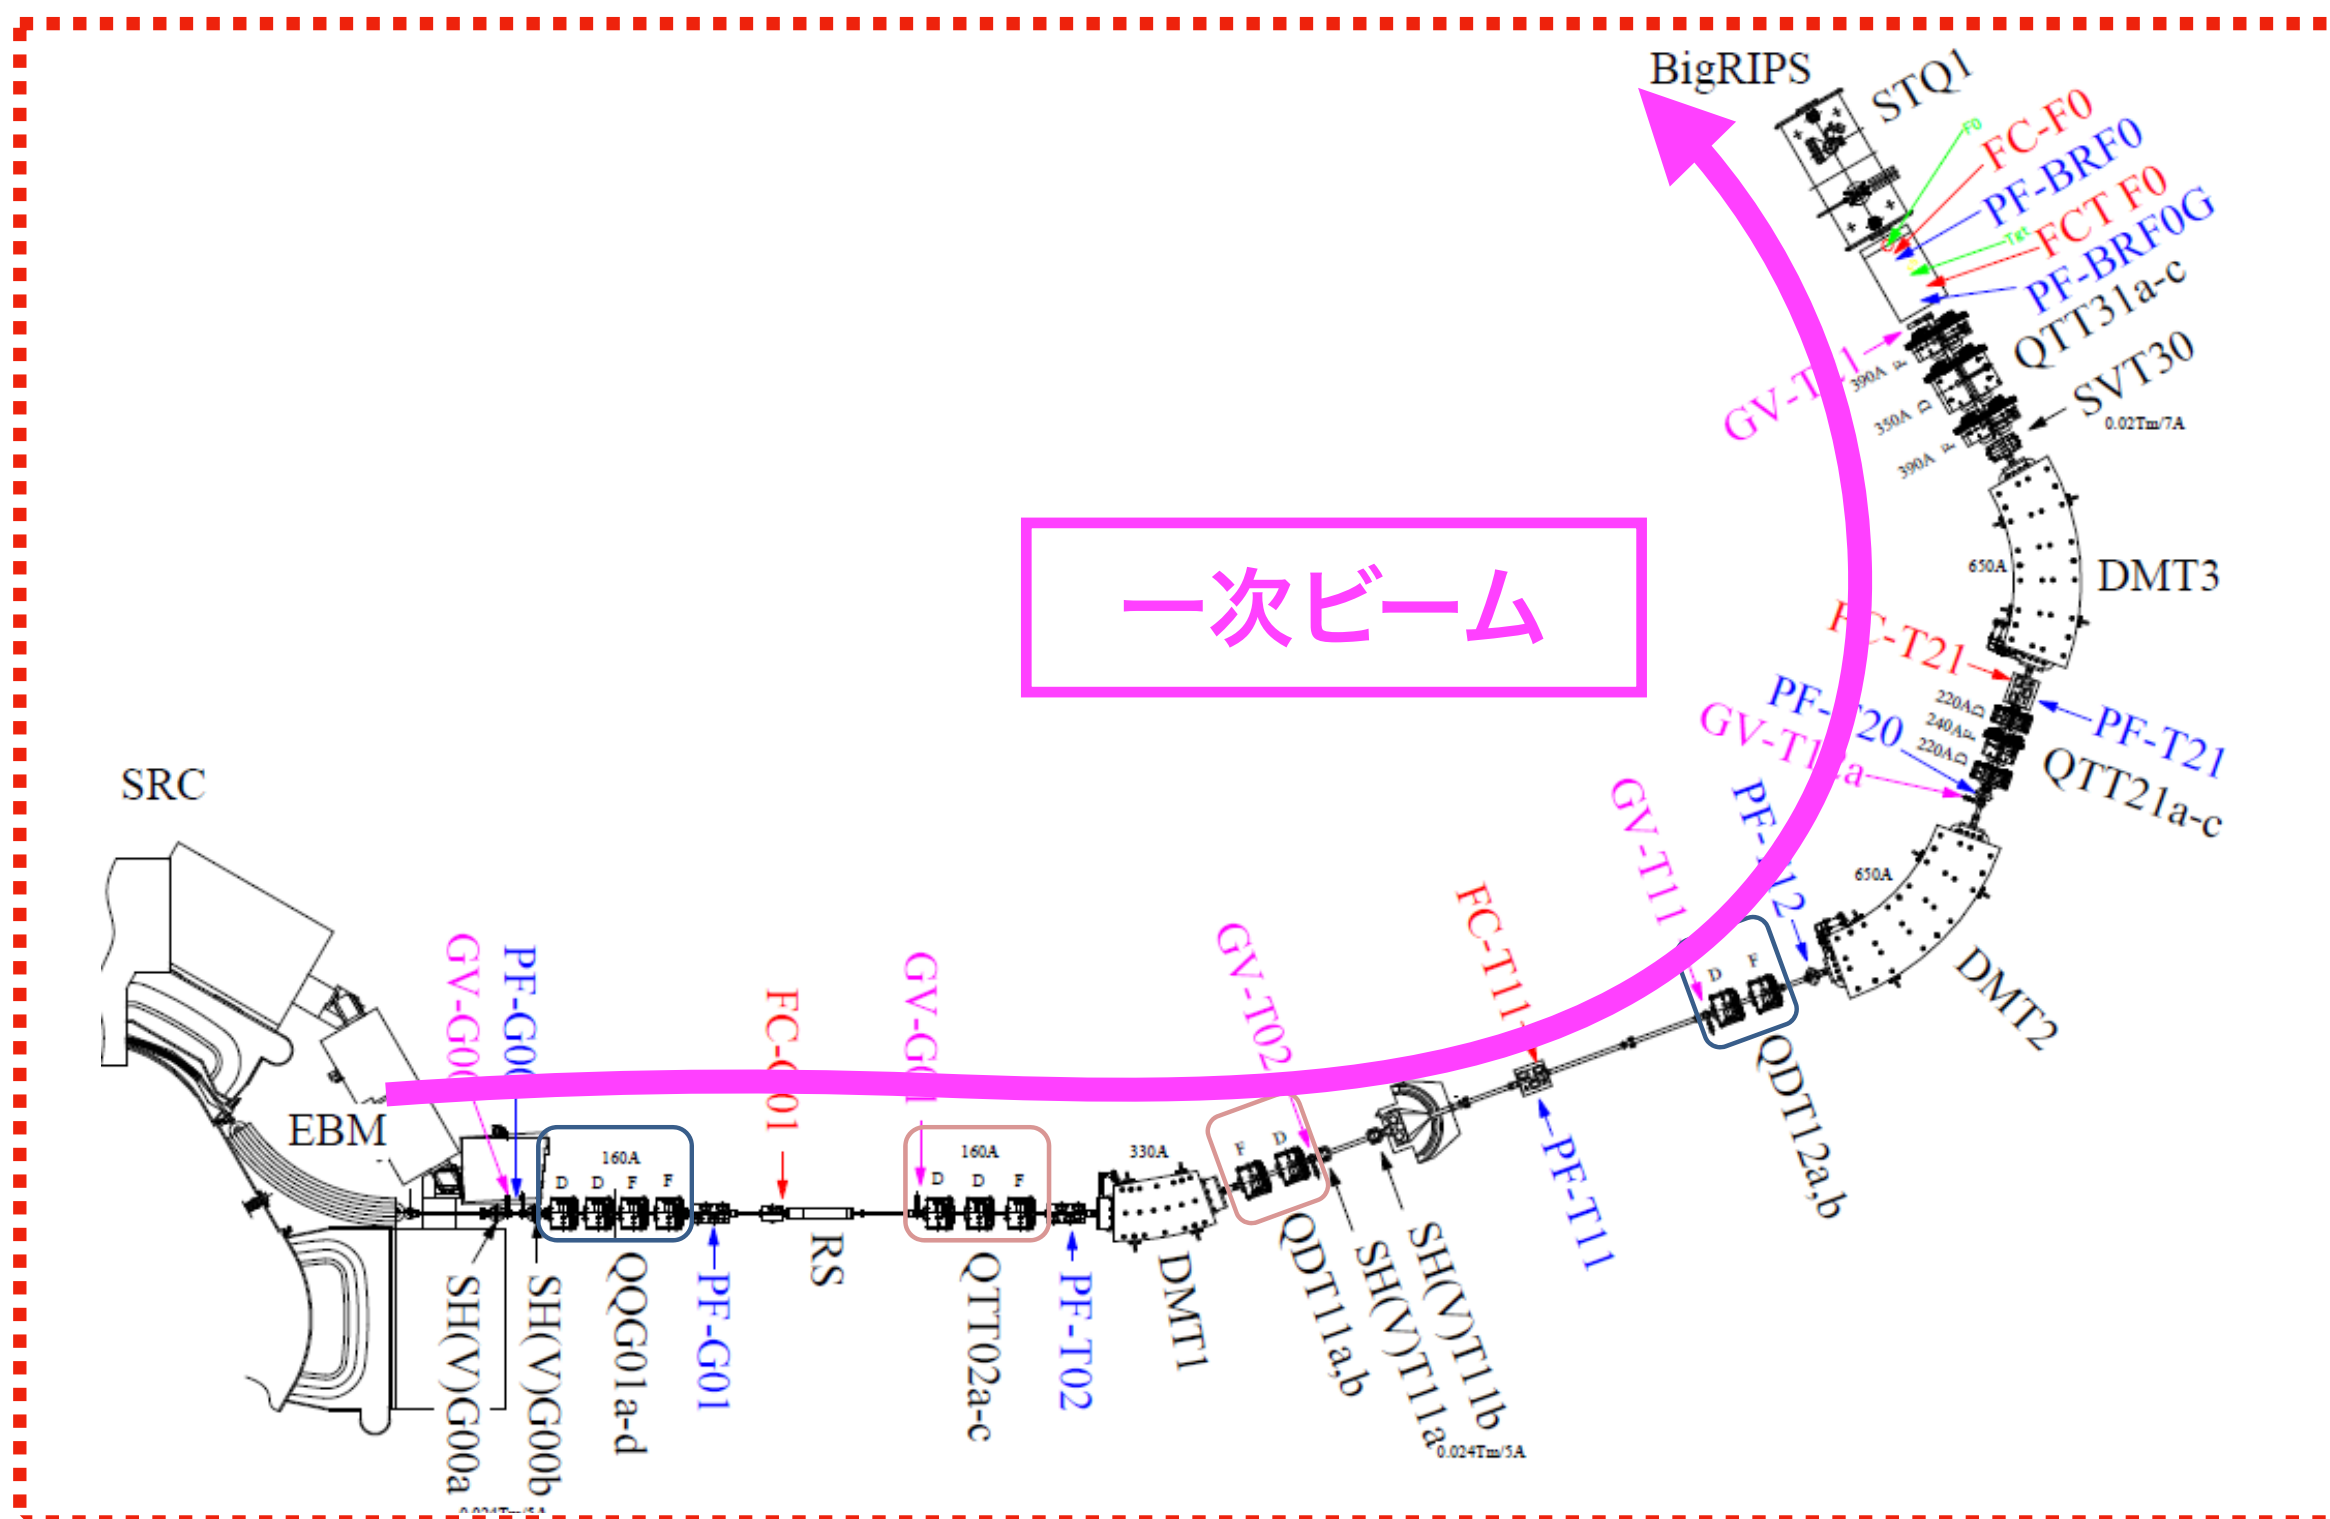
objective / acquisition function の改善

ビーム輸送:

ほとんどシミュレーション通り

になるので相性が良い

なぜシミュレーションできるビーム輸送に機械学習手法が必要か？



- ① ビームの分布の”裾”の問題
 ”ほとんど”はガウス分布を仮定して問題ない。
 → シミュレーション通り
 しかし、ビームロスに残りのビームの裾がきめる。
 このビームロスの量が施設が耐えられるビーム強度を決める

- ② ビームの初期状態の問題
 一次ビームの位相楕円を正確に測定するのは難しい。
 特に大強度化によって変化したビームの位相楕円を測定して計算するのは困難。

- ③ 磁石の配置 / 磁場の誤差
 磁石の位置や磁場などに誤差があった場合にも、
 ベイズ最適化であれば対応できる。


ベイズ最適化のためのシミュレーションの概要

光学系計算 (gicosy)

<http://web-docs.gsi.de/~weick/gicosy/>

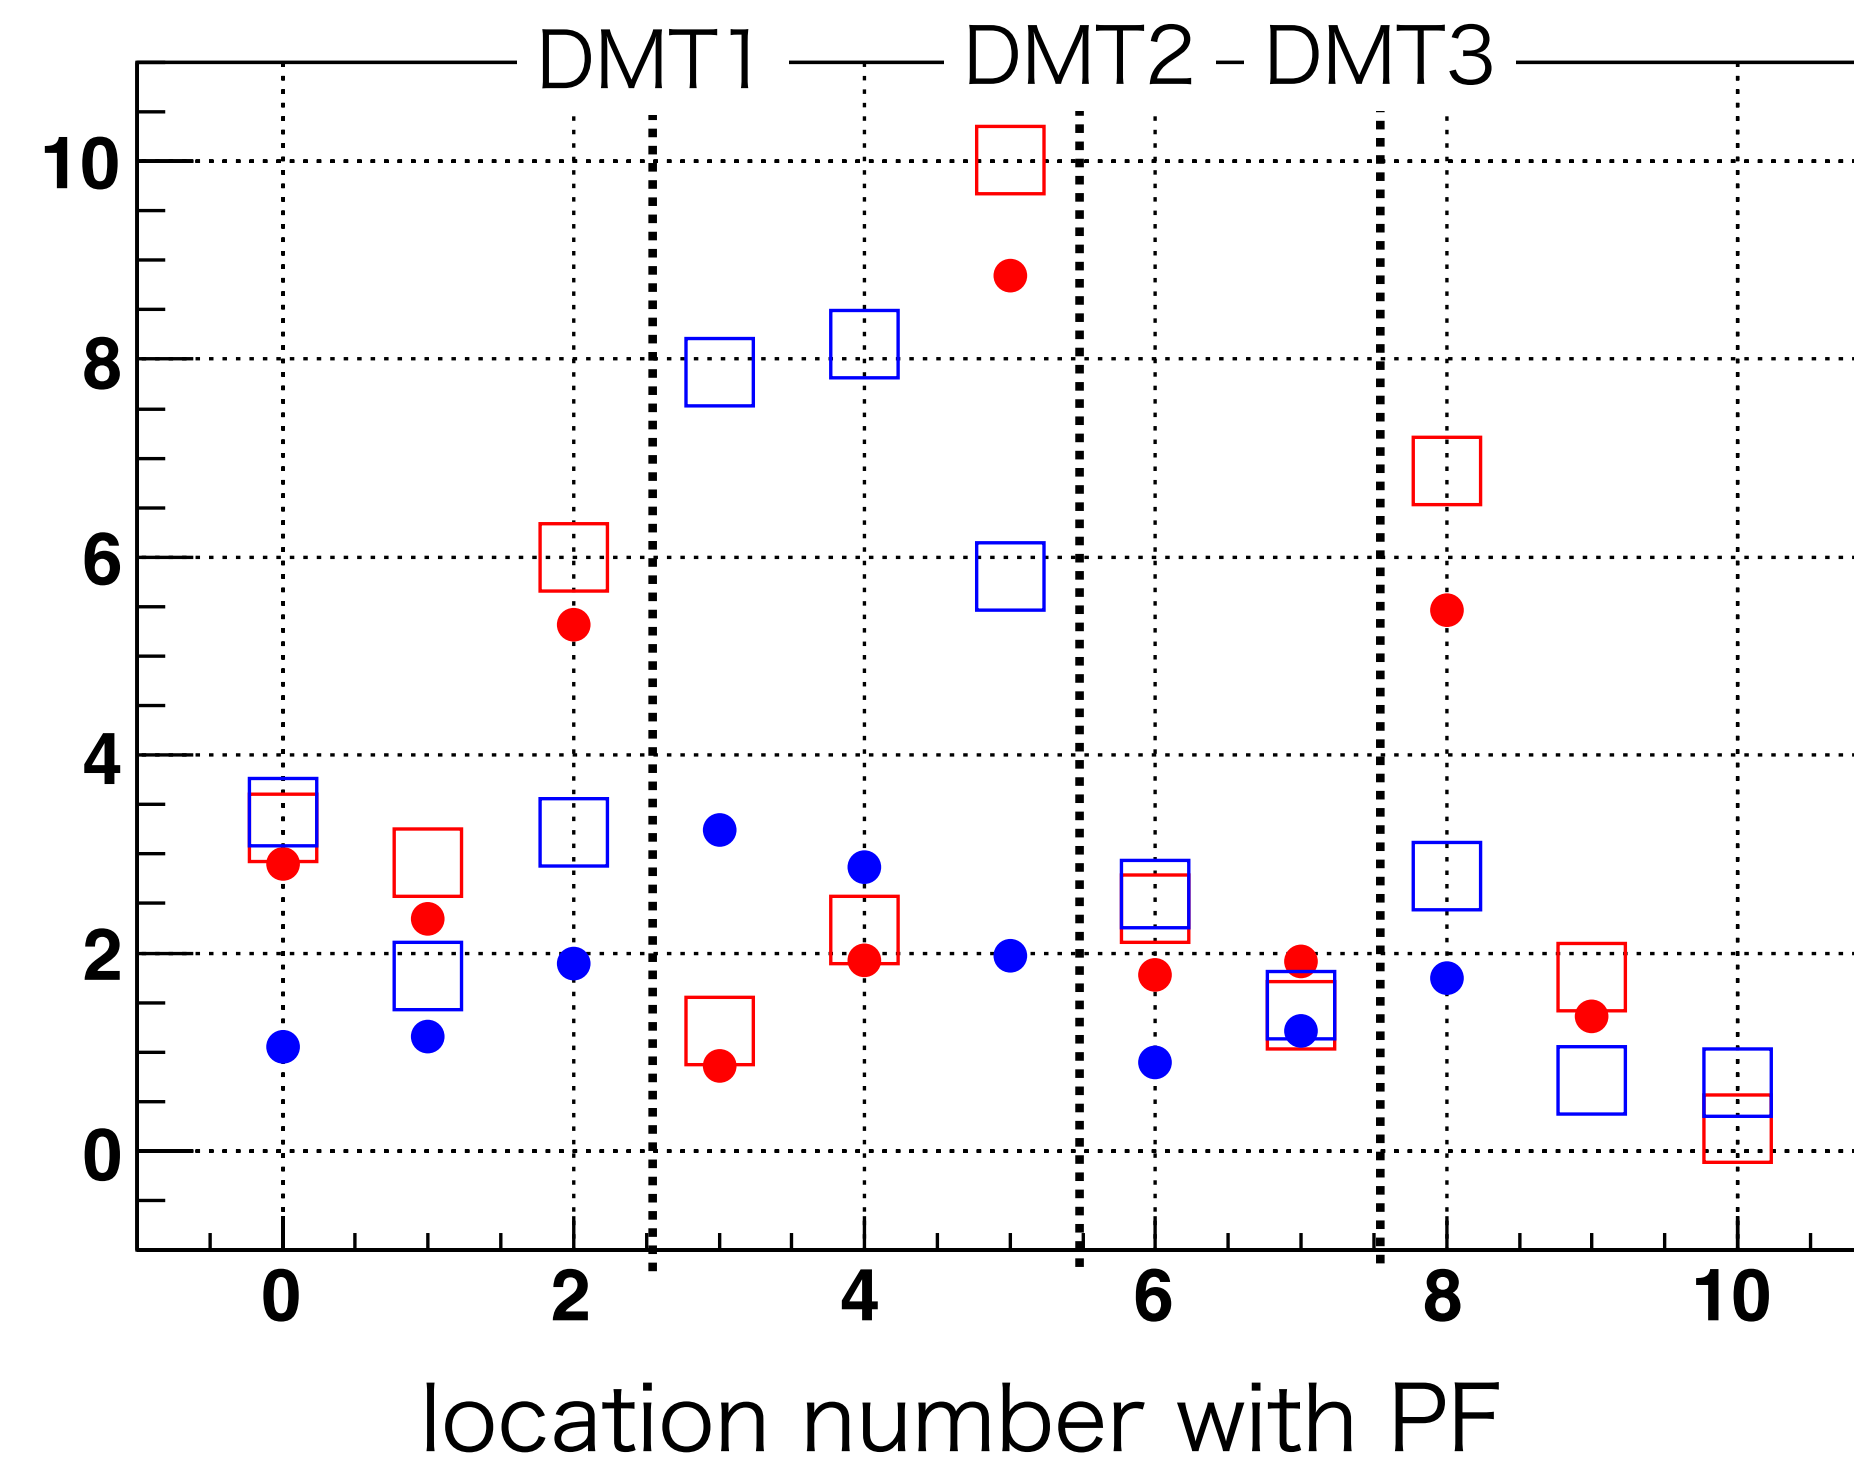
光学計算と wire scanner の比較

特に horizontal はよく一致している。



磁石の geometry と磁場

→ 3 次までの転送行列



horizontal / vertical

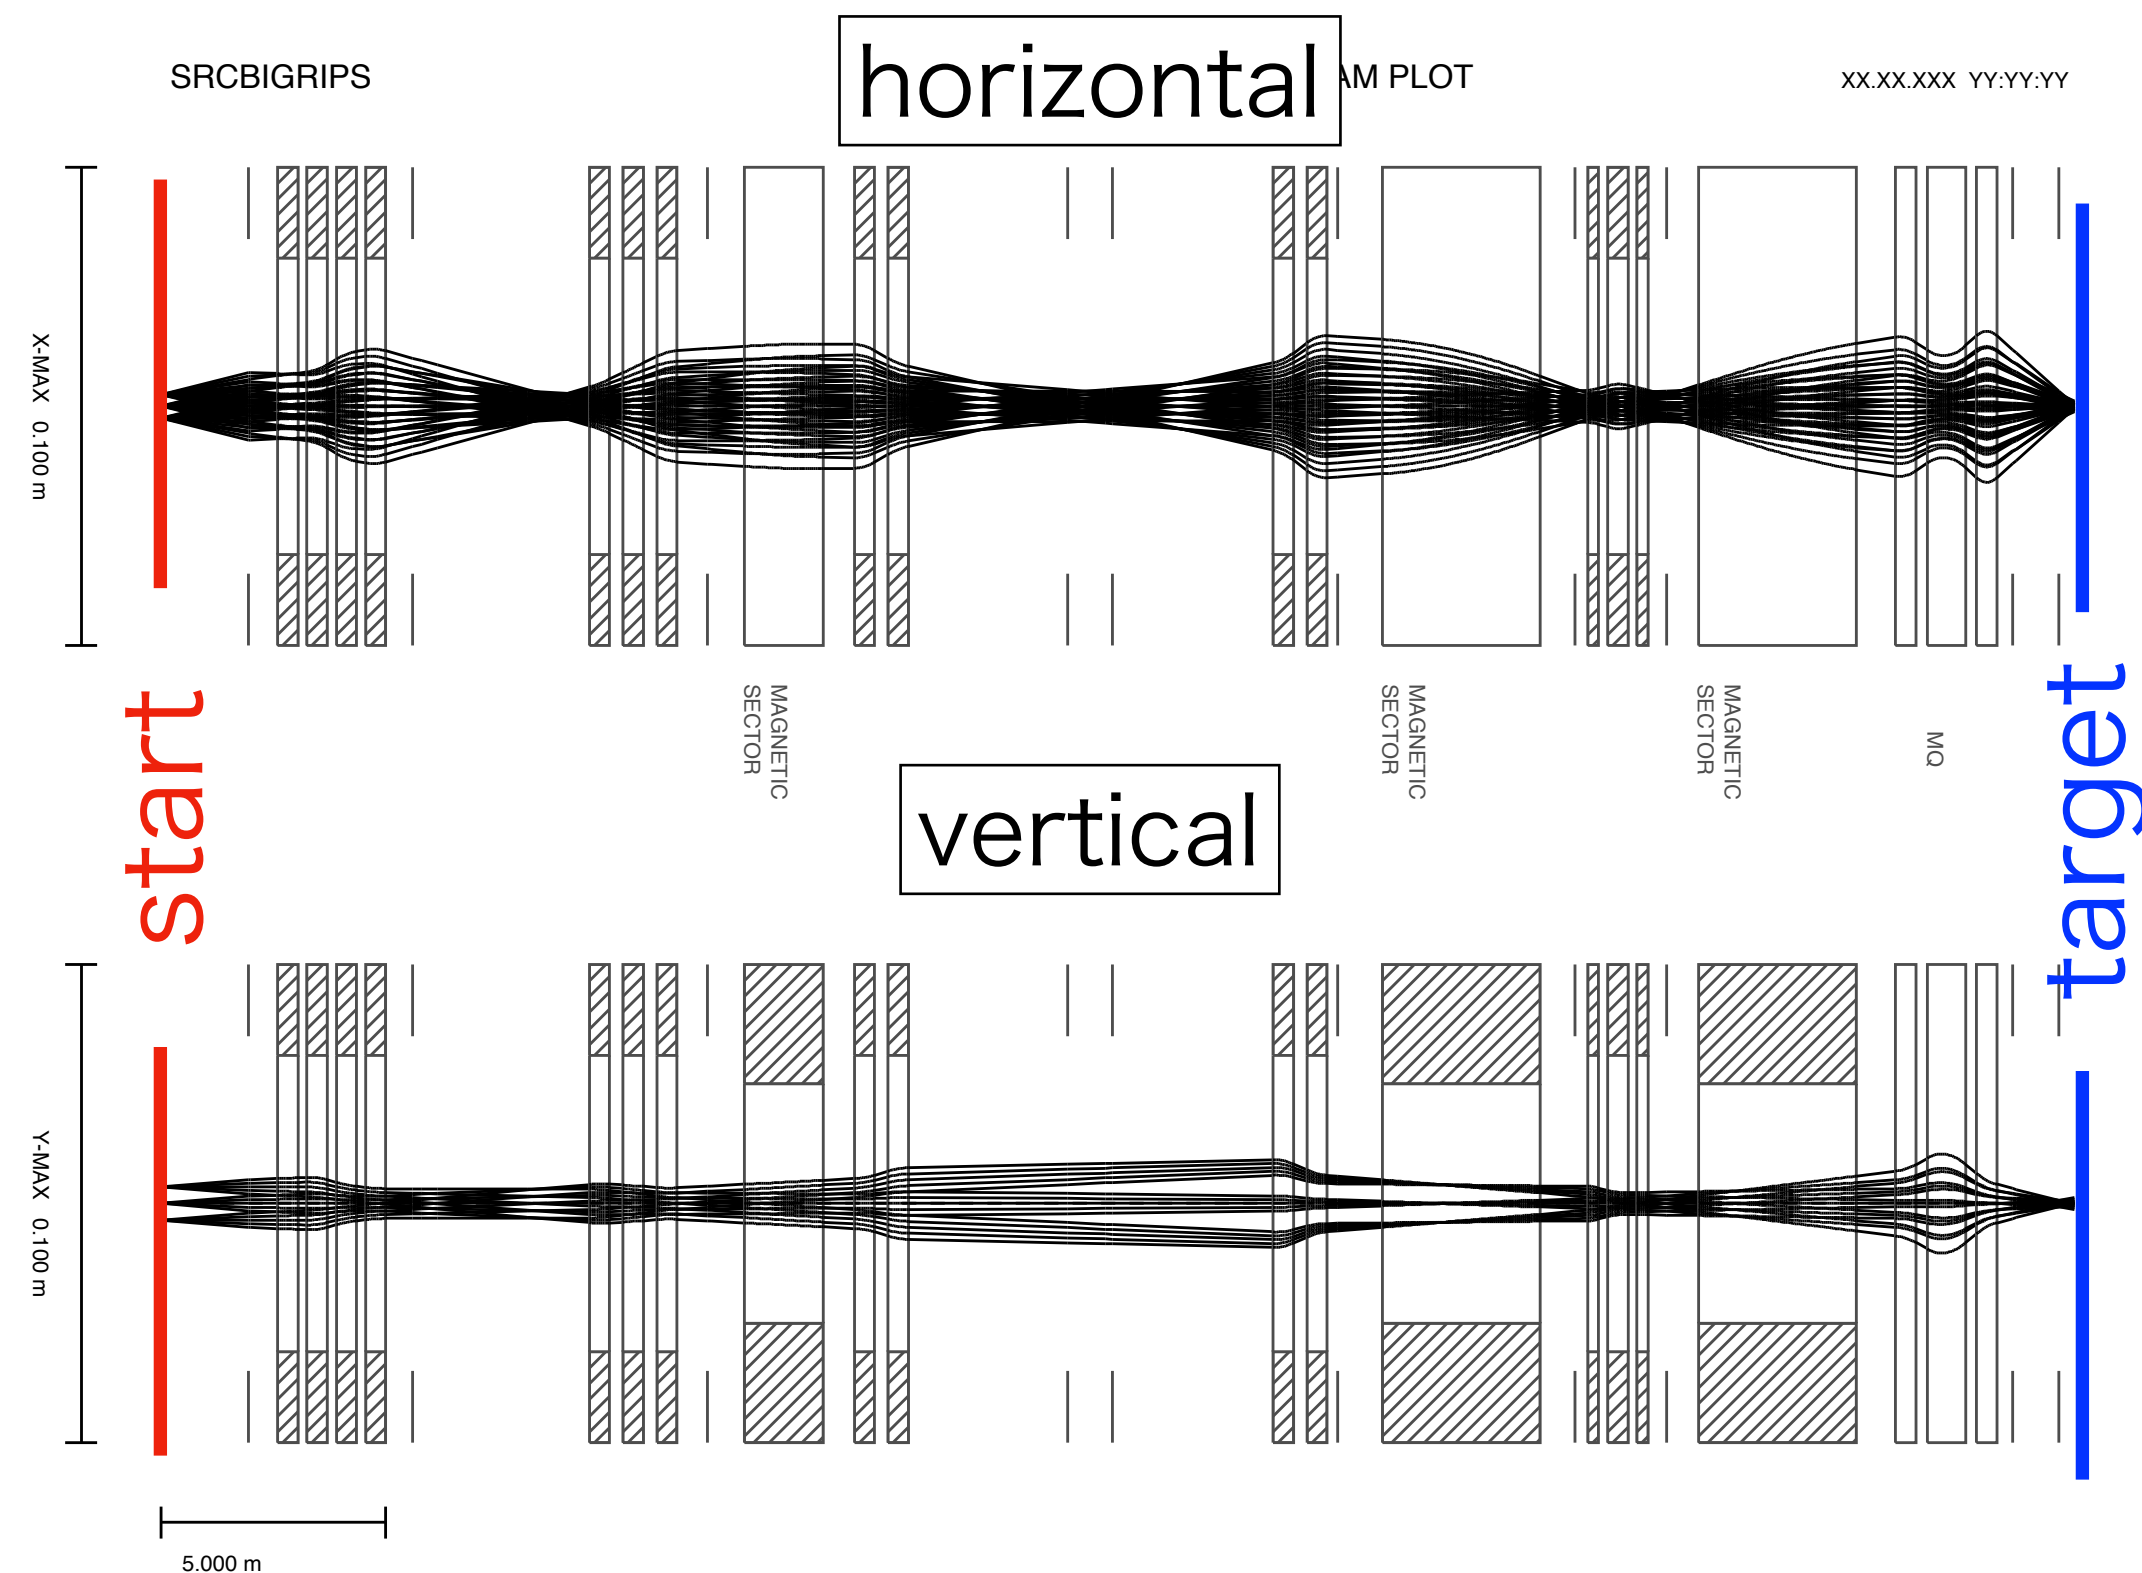
● wire scanner / □ gicosy calc.

ベイズ最適化のためのシミュレーションの概要

光学系計算 (gicosy)

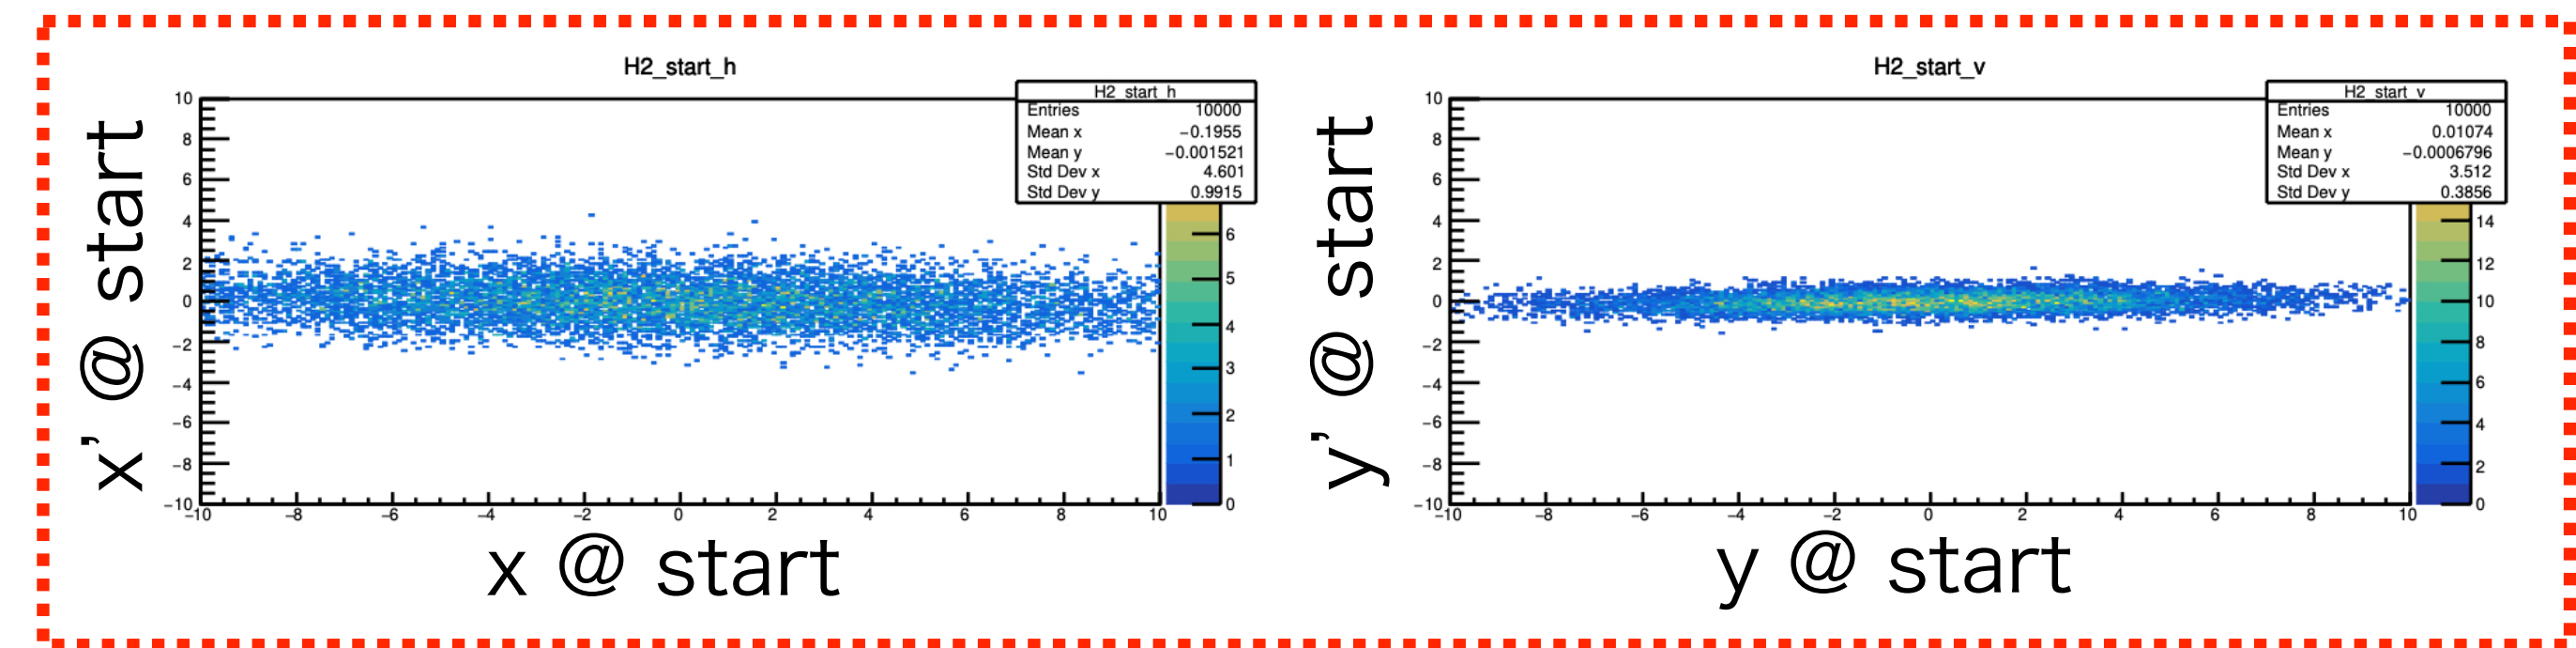
<http://web-docs.gsi.de/~weick/gicosy/>

モンテカルロシミュレーション(MOCADI※)



磁石の geometry と磁場

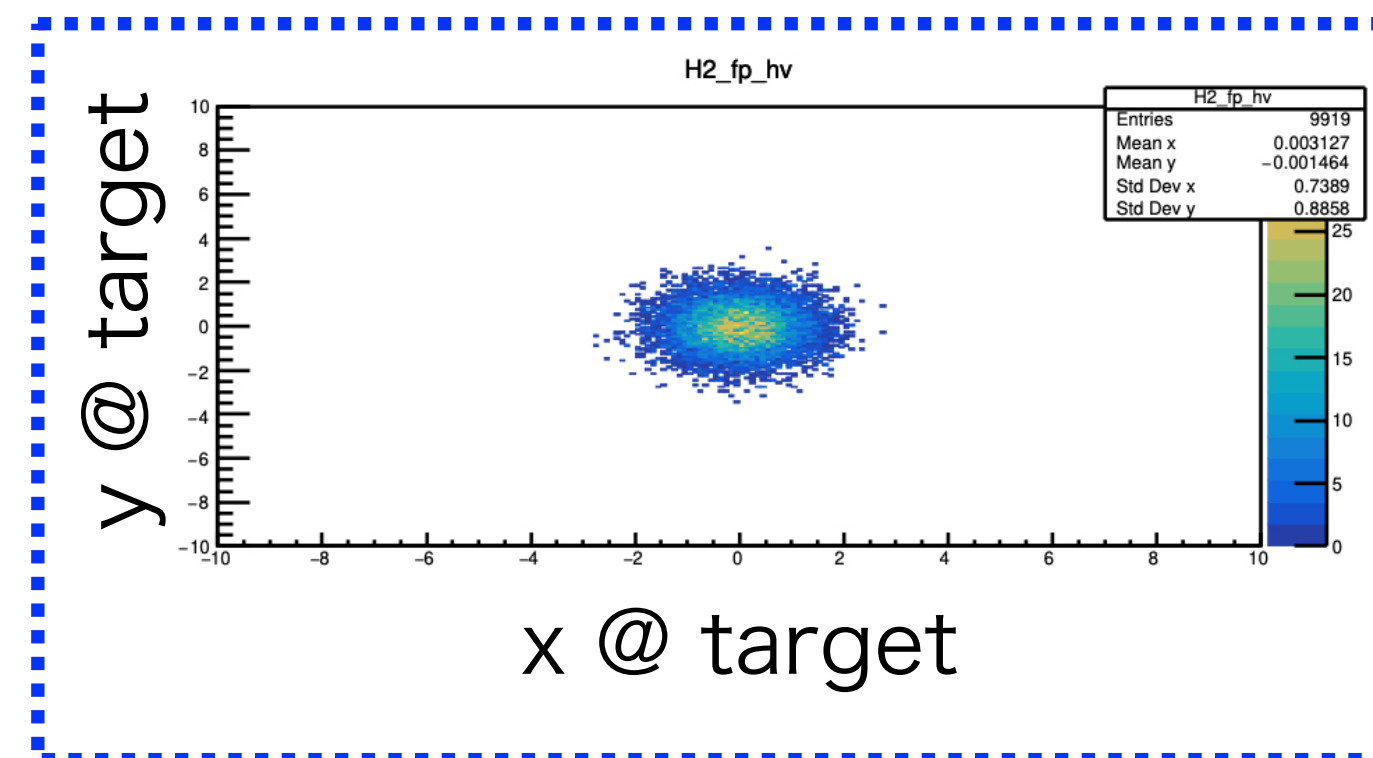
→ 3 次までの転送行列



start の位相楕円 + 転送行列

→ 各光学要素での粒子の位置を計算 / Aperture を判定。

target で”生きている” 粒子の数と分布の幅を測定。



※[1] N.Iwasa et al., Nucl. Instr. Meth. B126, 284 (1997); Th.Schwab, GSI Report No. 91-10 (1991).

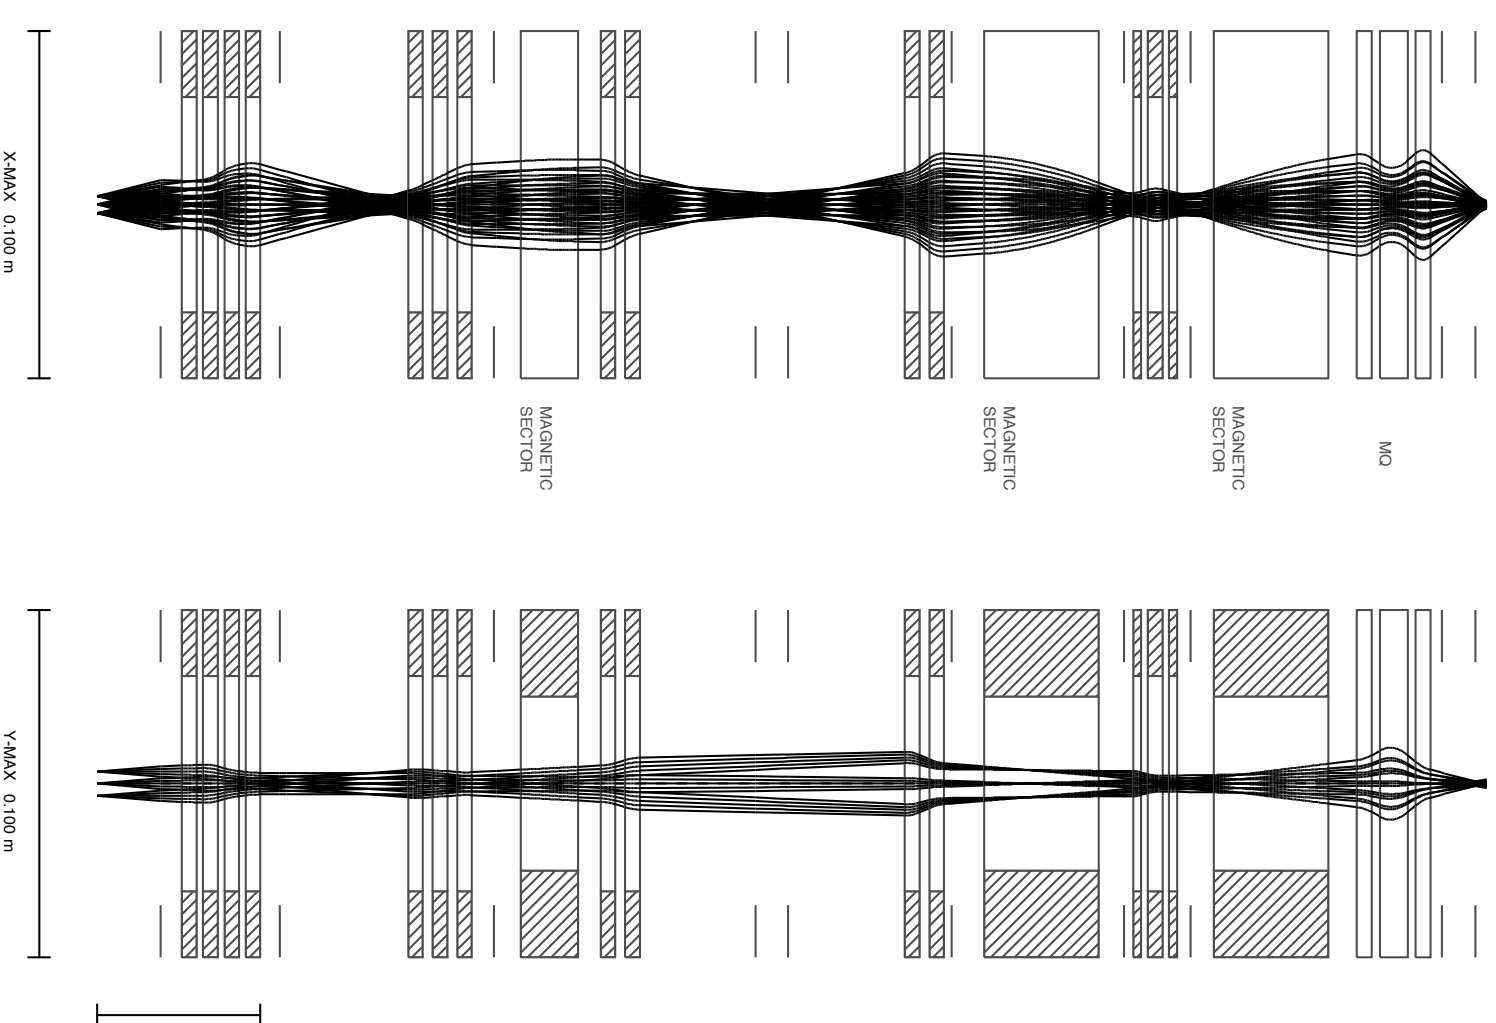
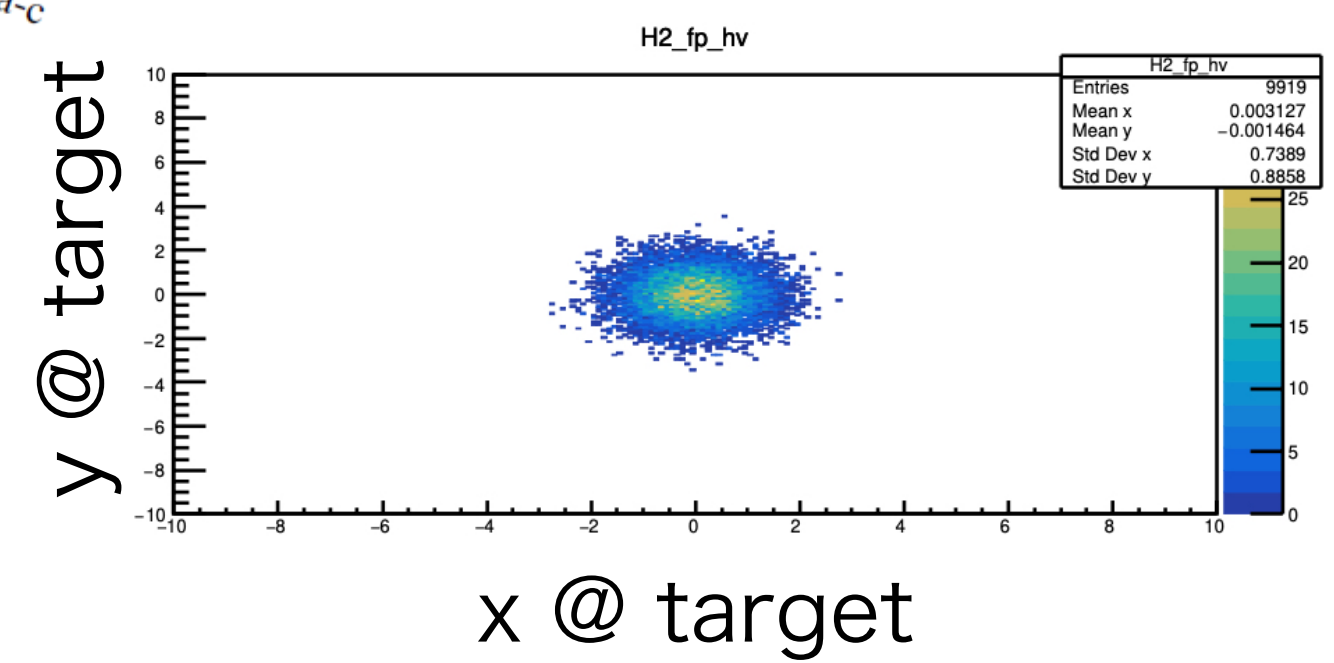
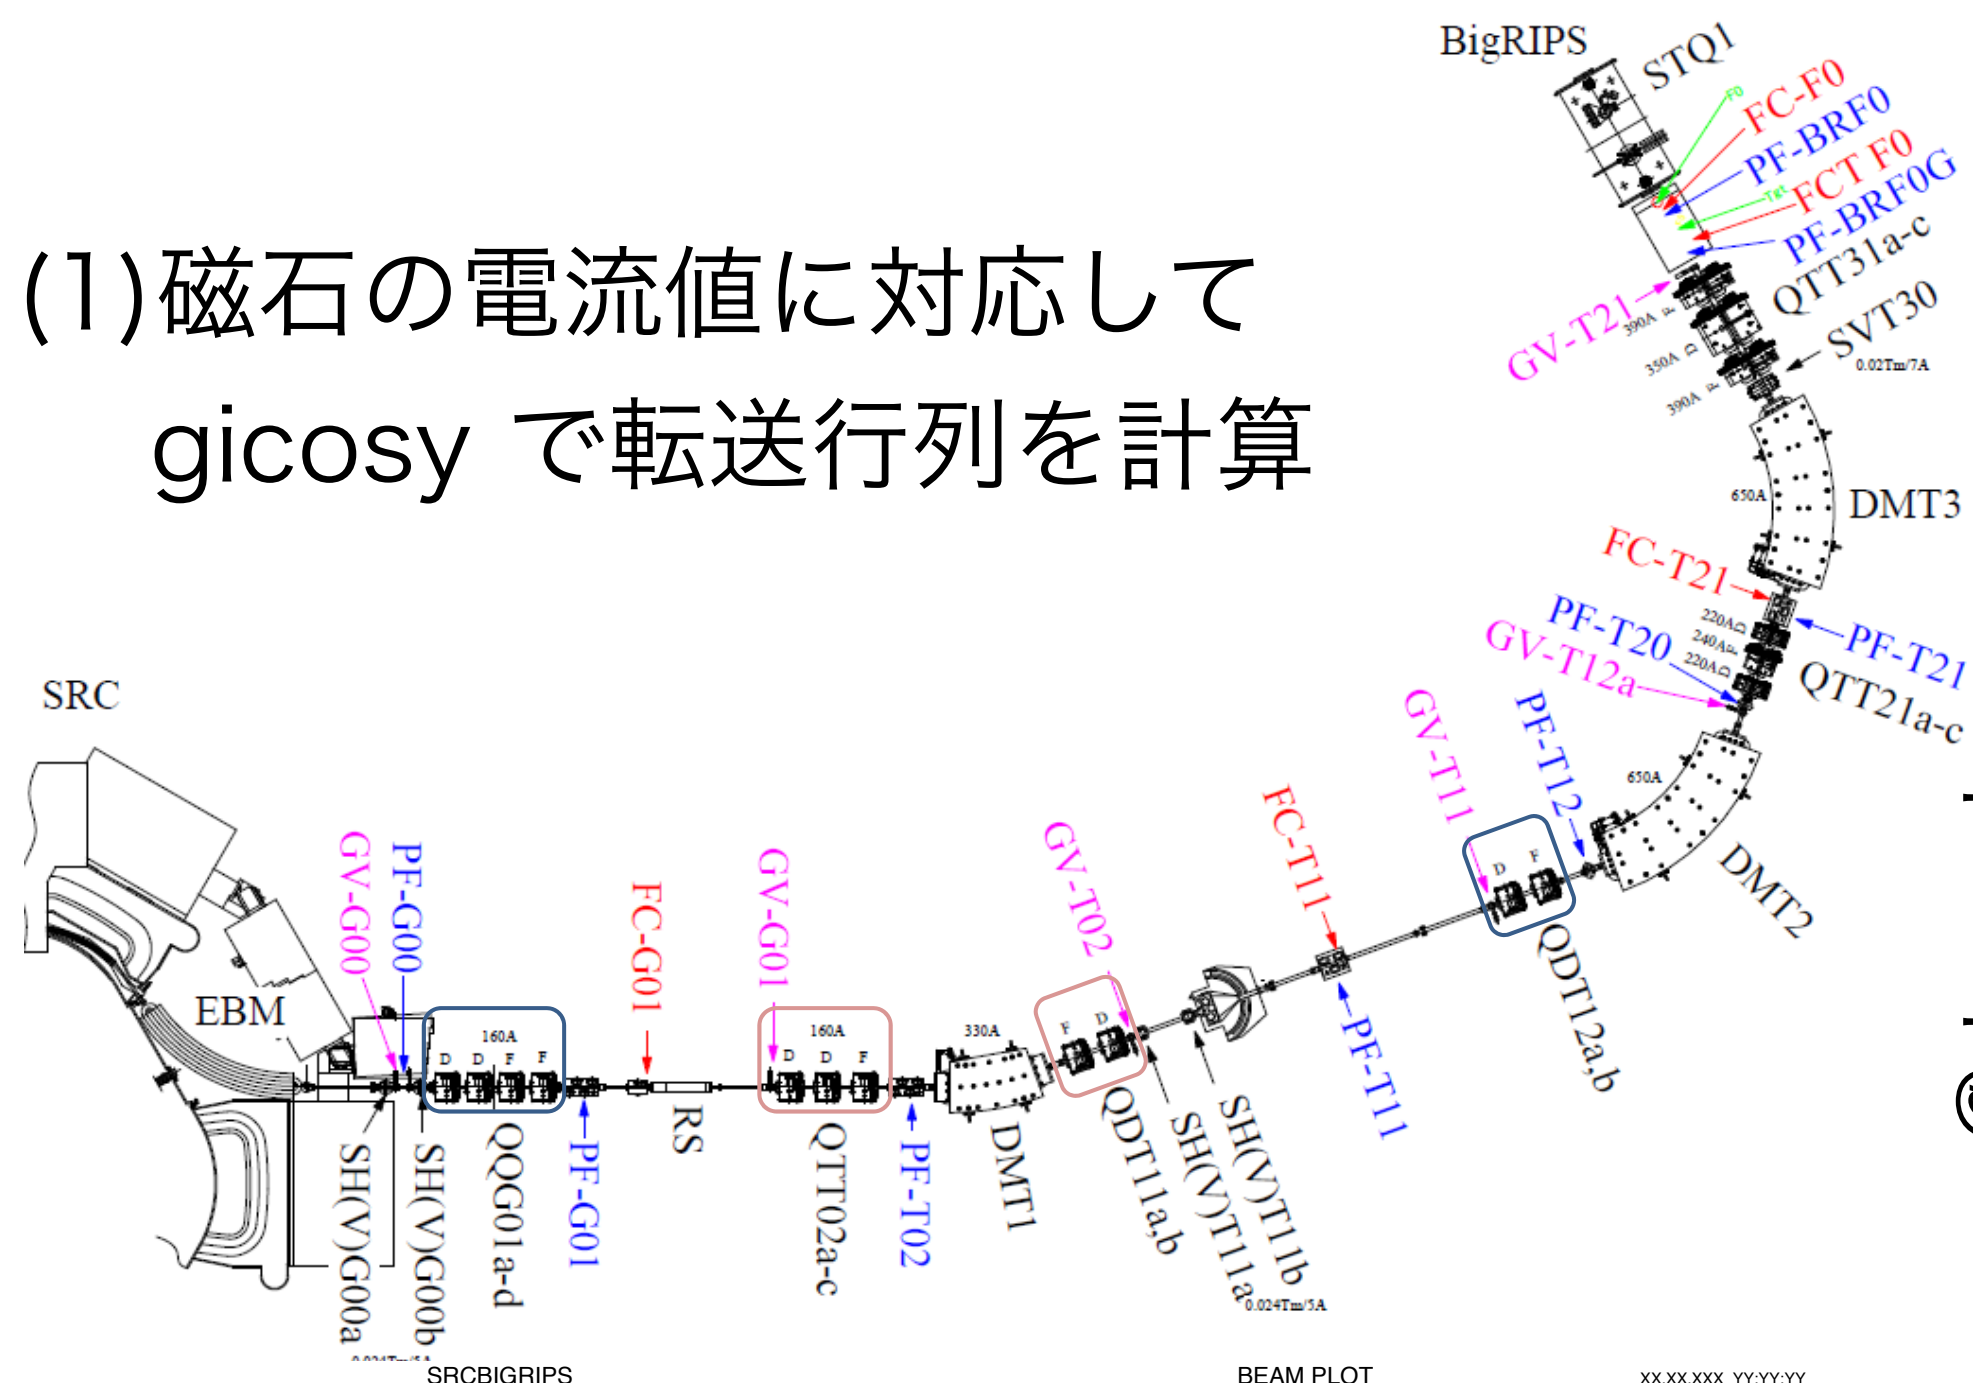
[2] C.Scheidenberge et al., Phys. Rev. Lett. 73, 50 (1994); C.Scheidenberge et al., Phys. Rev. Lett. 77, 3987 (1996).

ベイズ最適化のためのシミュレーションの概要


(1) 磁石の電流値に対応して
gicosy で転送行列を計算

(2) MOCADI で target の像を
シミュレート
通過率と像幅を測定

(3) objective function を計算
acquisition function に
従って、新しい候補を選定



**ガウス過程回帰
(逐次学習)**



(1)~ (3) を繰り返して
最適な電流値を探す

ベイズ最適化のためのシミュレーションの概要

今回の fit 範囲

今回のシミュレーションの条件

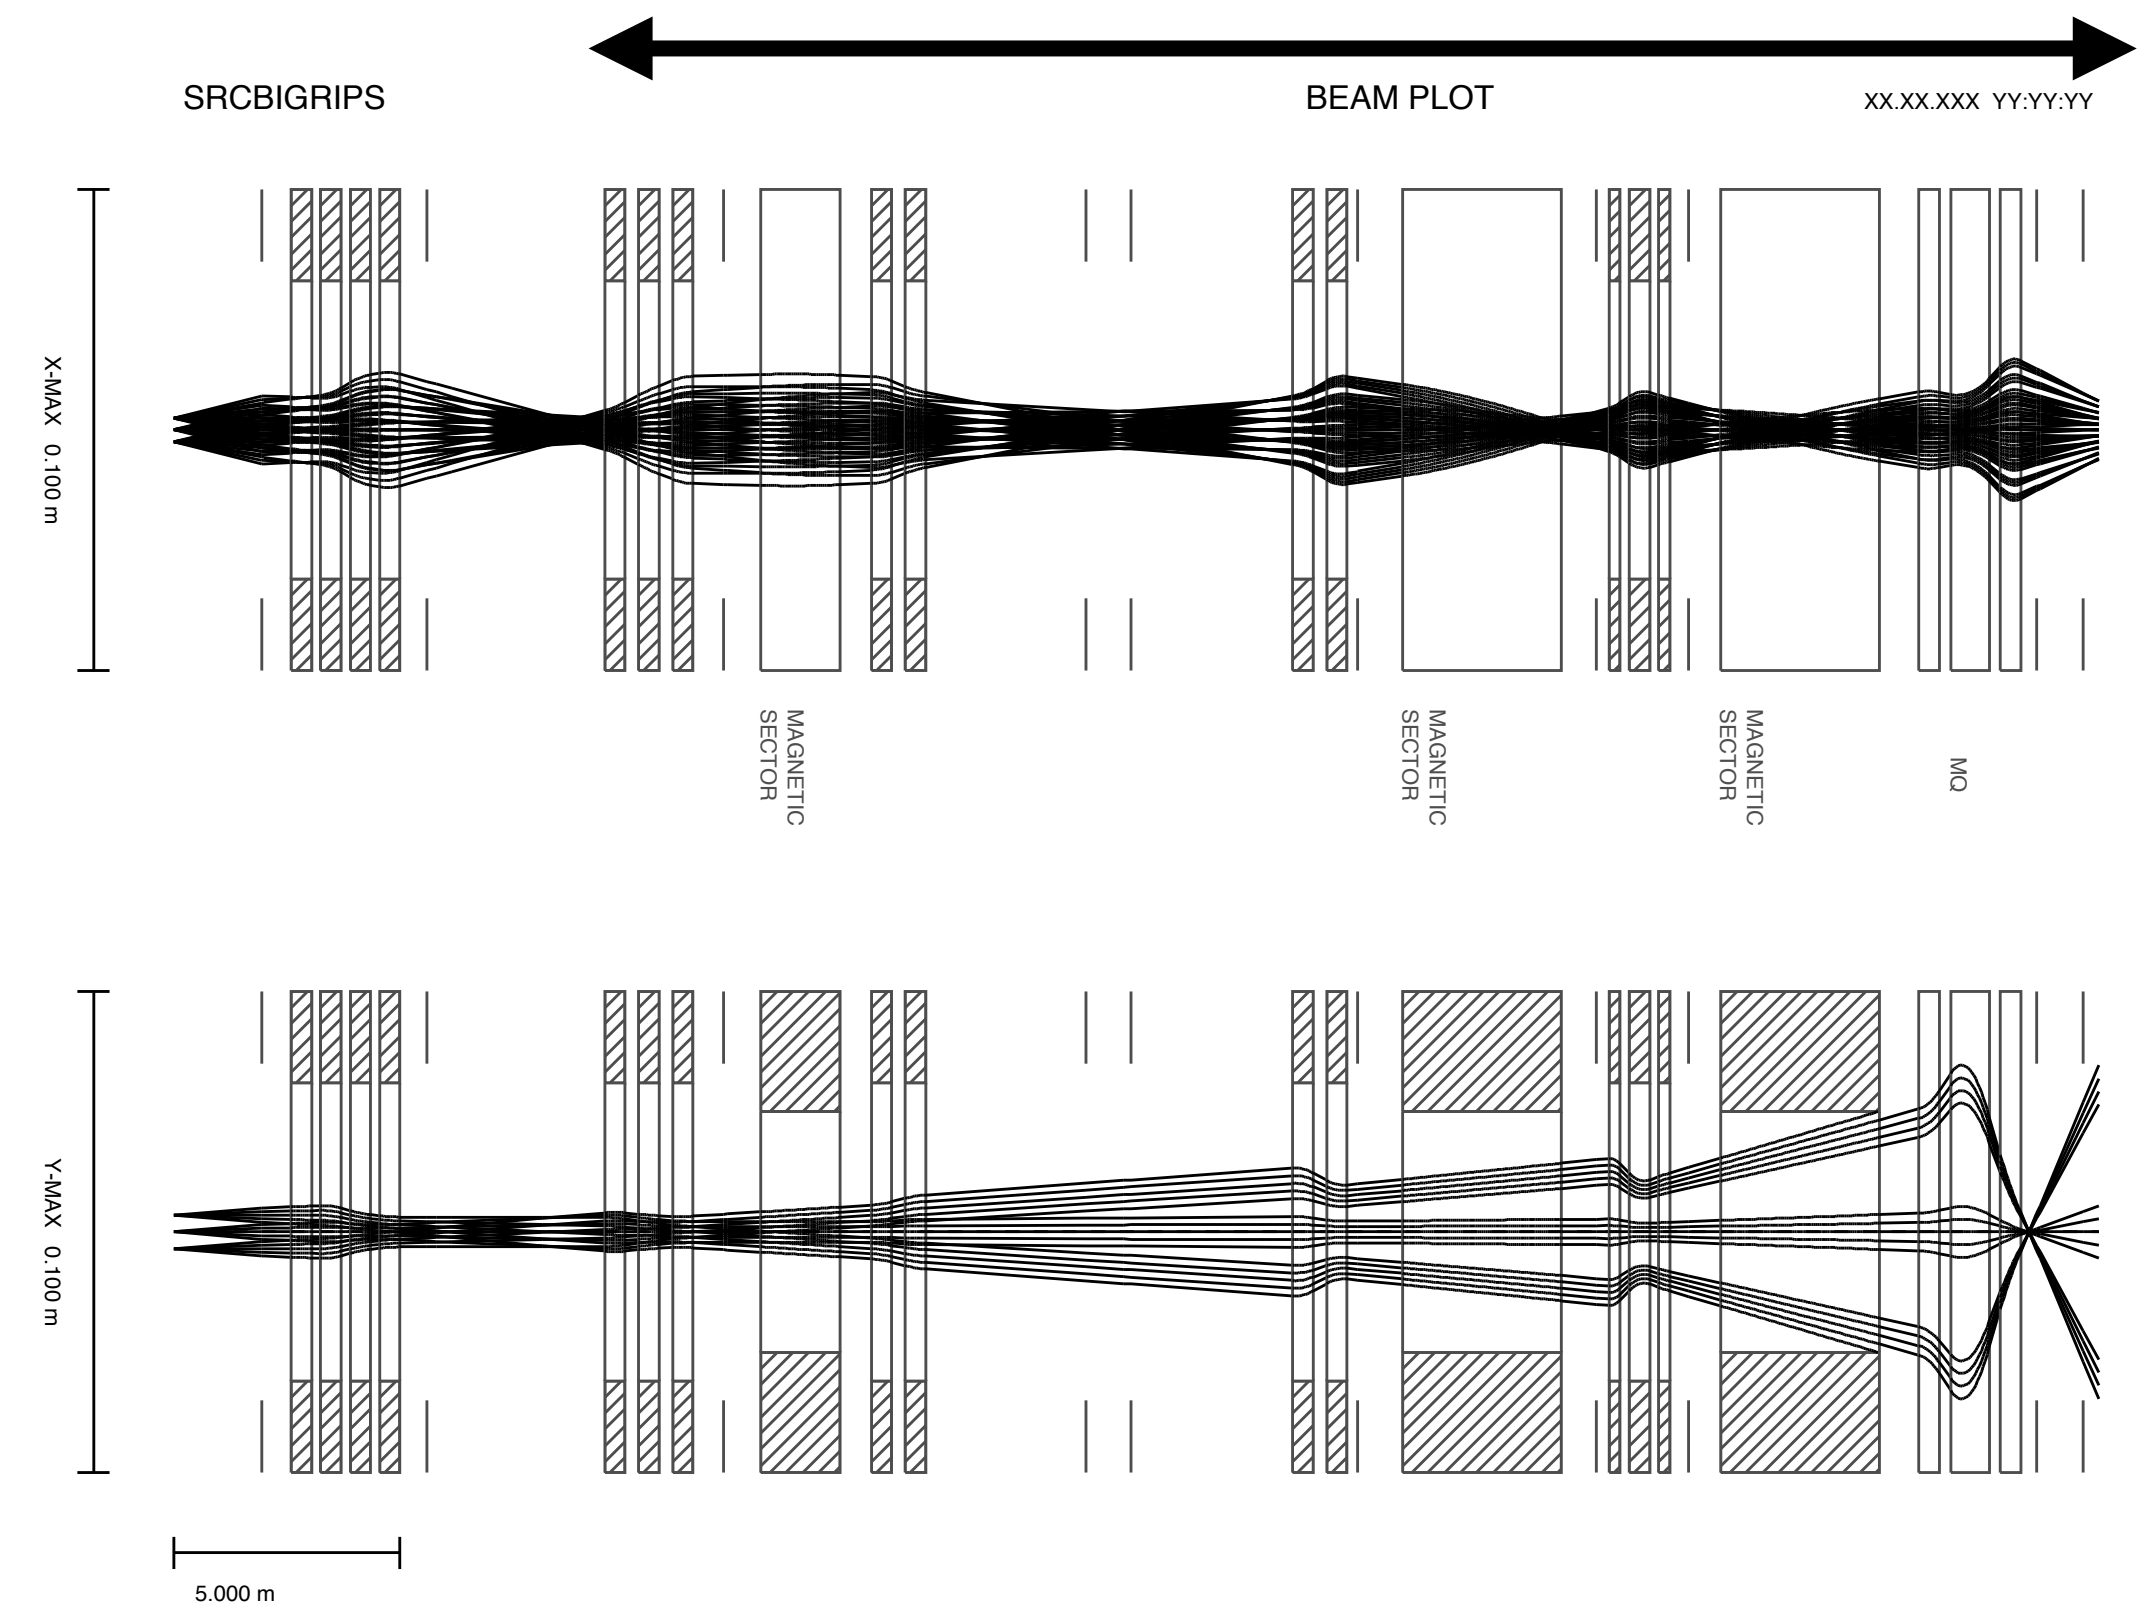
Variable : Quadrupole magnet × 13

電流値の範囲: 0 ~ 100 A (最後のTQのみ ~ 250 A)

初期電流値 : 過去の試験データから少しずらしたもの
(通過率 ~ 73%, $(\sigma_x, \sigma_y) = (4.2, 5.8)$)

変化させるもの

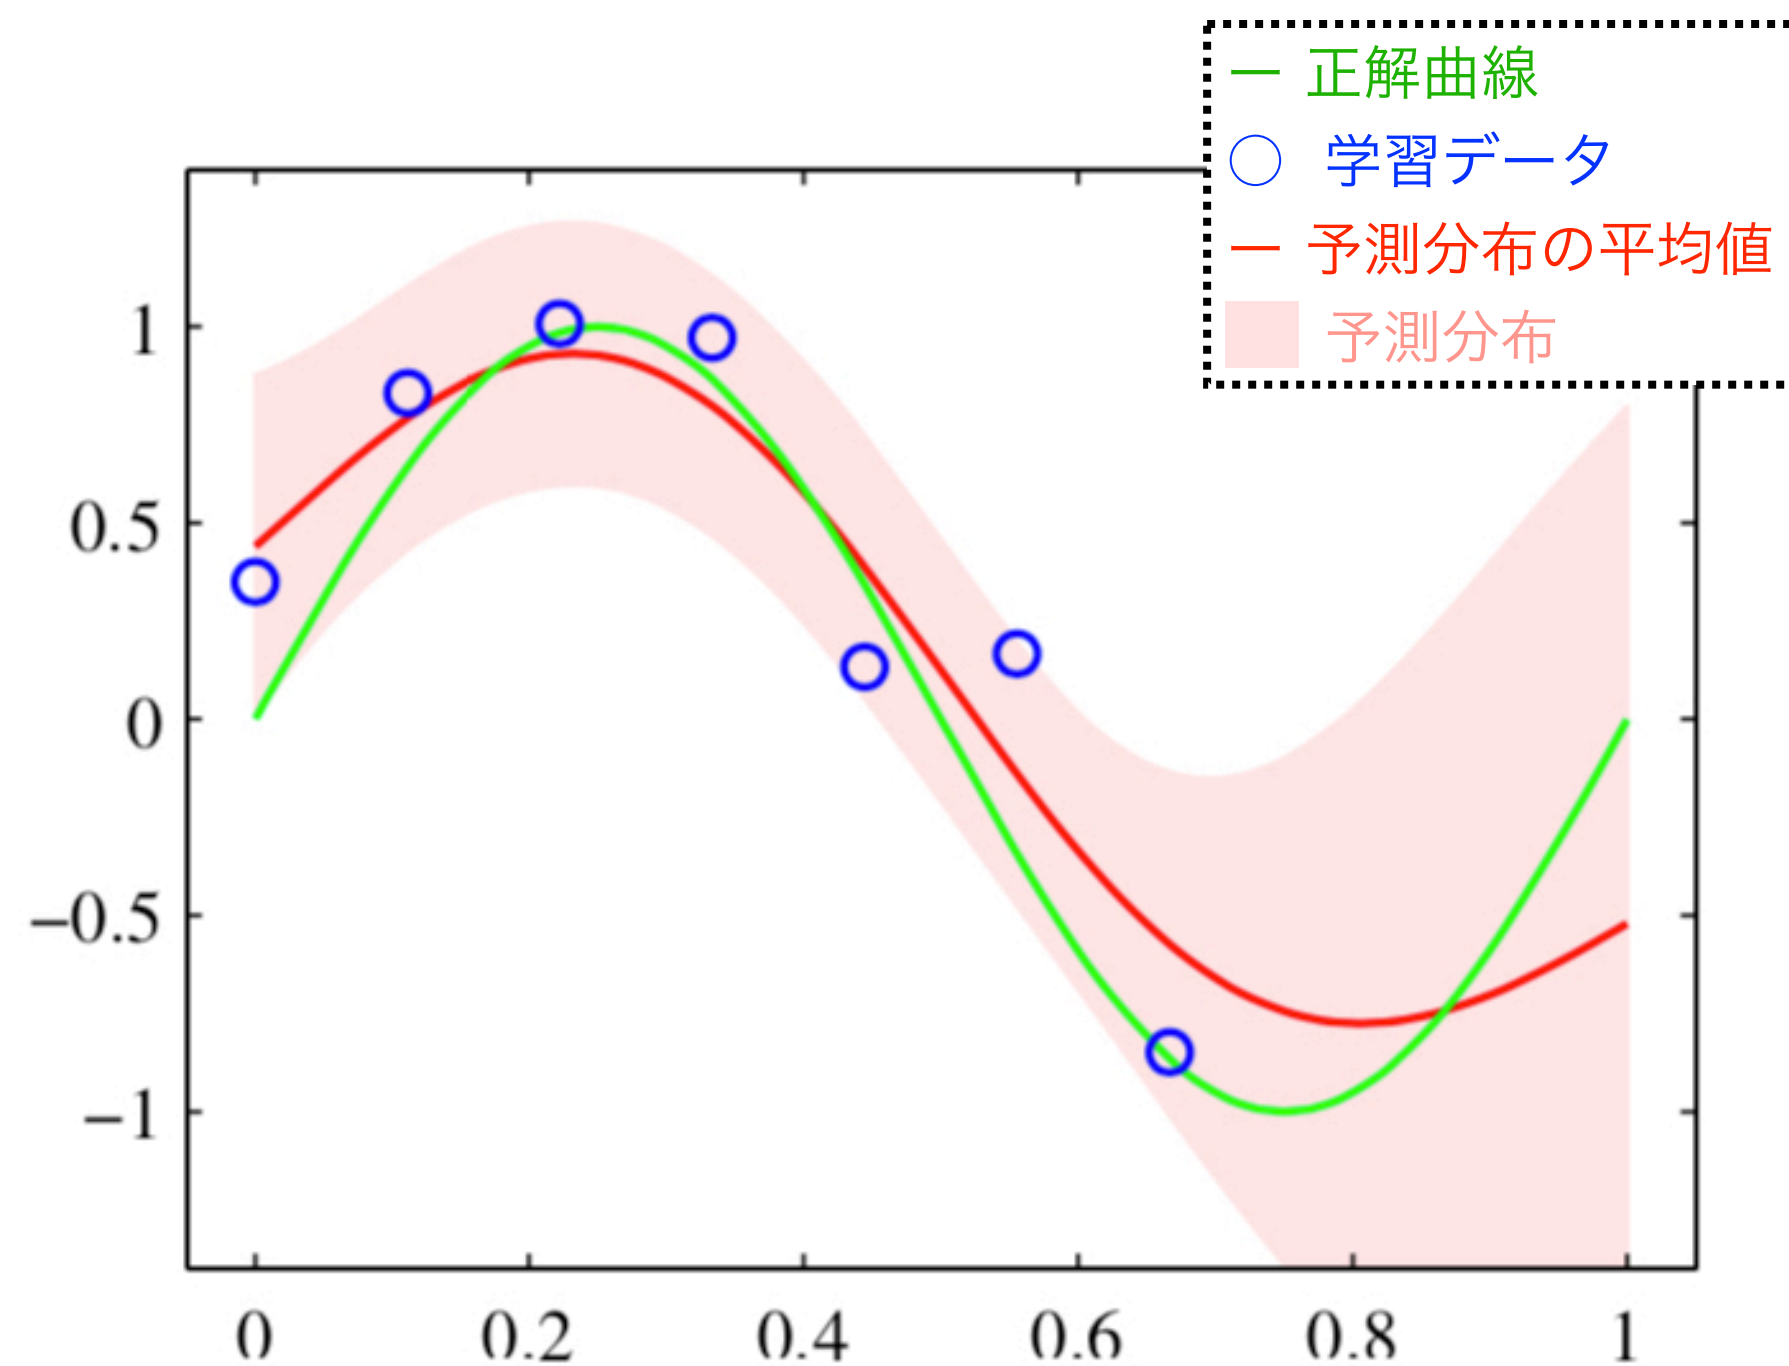
- acquisition function
- objective function
- 初期位相楕円 (結果の robustness の確認のため)



最大 ~ 200 epoch (⇔ 現状だと 2 時間) 程度で、効率的に良い解を見つける条件を確認する。
または、その手法を探す。

ベイズ最適化のハイパーパラメータ: ① acquisition function

acquisition function / 獲得関数：
 これまでのデータを基に作った
 予測分布から、次の探索パラメータ
 をどこにするか決める指標
活用と探索のバランスを決める。



Probability of Improvement (PI)

$$\vec{x}_{next} = \operatorname{argmax}_{\vec{x}} P(f(\vec{x}) > y_{max})$$

活用 >> 探索

これまでの最大値 y_{max} よりも得られる値が
 大きくなる確率を最大にする x

Expected Improvement (EI)

これまで採用

$$\vec{x}_{next} = \operatorname{argmax}_{\vec{x}} E[\max(f(\vec{x}) - y_{max}, 0)]$$

活用 > 探索 (?)

これまでの最大値 y_{max} よりも得られる値が
 大きくなる期待値 (悪化は無視) を最大にする x

Lower Confidence Bound (LCB)

$$\vec{x}_{next} = \operatorname{argmax}_{\vec{x}} (\mu_{\vec{x}} + \beta^{1/2} \sigma(\vec{x}))$$

活用 ~ 探索 (?)
 β 次第...

$\beta^{1/2} \sigma$ まで考慮したときに最も良い値を得る
 可能性のある x

ベイズ最適化のハイパーパラメータ: ② objective function

最大化 (最小化) したいもの: 粒子数 N , 像幅 σ_x, σ_y @ target

従来の獲得関数:

$$f(N, \sigma_x, \sigma_y) = -c_0 \frac{N}{N_0} + \left(\frac{\sigma_x}{\sigma_x^*} \right)^2 + \left(\frac{\sigma_y}{\sigma_y^*} \right)^2$$

c_0 : 任意の係数 (~ 1)

N_0 : 初期値での標的上での粒子数

$\sigma^*_{x,y}$: 像幅の目安 ~ 1 mm

問題点: 符号が反転する場合がある。各項が同じ程度の寄与になってない。

ベイズ最適化のハイパーパラメータ: ② objective function

最大化 (最小化) したいもの: 粒子数 N , 像幅 σ_x, σ_y @ target

常に符号を変えず、かつ各要素が同程度の寄与になるように考案

sum 型:

$$f_{sum}(N, \sigma_x, \sigma_y) = -\frac{N}{N_0} - \frac{\sigma_x^*}{\sigma_x^* + \sigma_x} - \frac{\sigma_y^*}{\sigma_y^* + \sigma_y}$$

multilied 型:

$$f_{multi}(N, \sigma_x, \sigma_y) = -\frac{N}{N_0} \cdot \frac{\sigma_x^*}{\sigma_x^* + \sigma_x} \cdot \frac{\sigma_y^*}{\sigma_y^* + \sigma_y}$$

各 transmission, σ での f_{sum} / f_{multi} の絶対値

$\sigma \backslash$ Transmission	0.75	0.85	0.95
1.5	1.8 / 0.16	2.0 / 0.19	2.1 / 0.21
1.0	2.0 / 0.26	2.2 / 0.29	2.3 / 0.33
0.5	2.4 / 0.46	2.5 / 0.52	2.6 / 0.58

N_0 : 初期値での標的上での粒子数

$\sigma^*_{x,y}$: 像幅の目安 ~ 1 mm

ベイズ最適化のハイパーパラメータ: ② objective function

最大化 (最小化) したいもの: 粒子数 N , 像幅 σ_x, σ_y @ target

常に符号を変えず、かつ各要素が同程度の寄与になるように考案

sum 型:

$$f_{sum}(N, \sigma_x, \sigma_y) = -\frac{N}{N_0} - \frac{\sigma_x^*}{\sigma_x^* + \sigma_x} - \frac{\sigma_y^*}{\sigma_y^* + \sigma_y}$$

multilied 型:

$$f_{multi}(N, \sigma_x, \sigma_y) = -\frac{N}{N_0} \cdot \frac{\sigma_x^*}{\sigma_x^* + \sigma_x} \cdot \frac{\sigma_y^*}{\sigma_y^* + \sigma_y}$$

N_0 : 初期値での標的上での粒子数

$\sigma^*_{x,y}$: 像幅の目安 ~ 1 mm

各 transmission, σ での f_{sum} / f_{multi} の絶対値

transmission 85% / $\sigma_{x,y} \sim 1\text{mm}$ を基準とした時

$\sigma \backslash$ Transmission	0.75	0.85	0.95
1.5	0.8 / 0.6	0.9 / 0.6	1.0 / 0.7
1.0	0.9 / 0.9	1.0 / 1.0	1.1 / 1.1
0.5	1.1 / 1.6	1.2 / 1.8	1.2 / 2.0

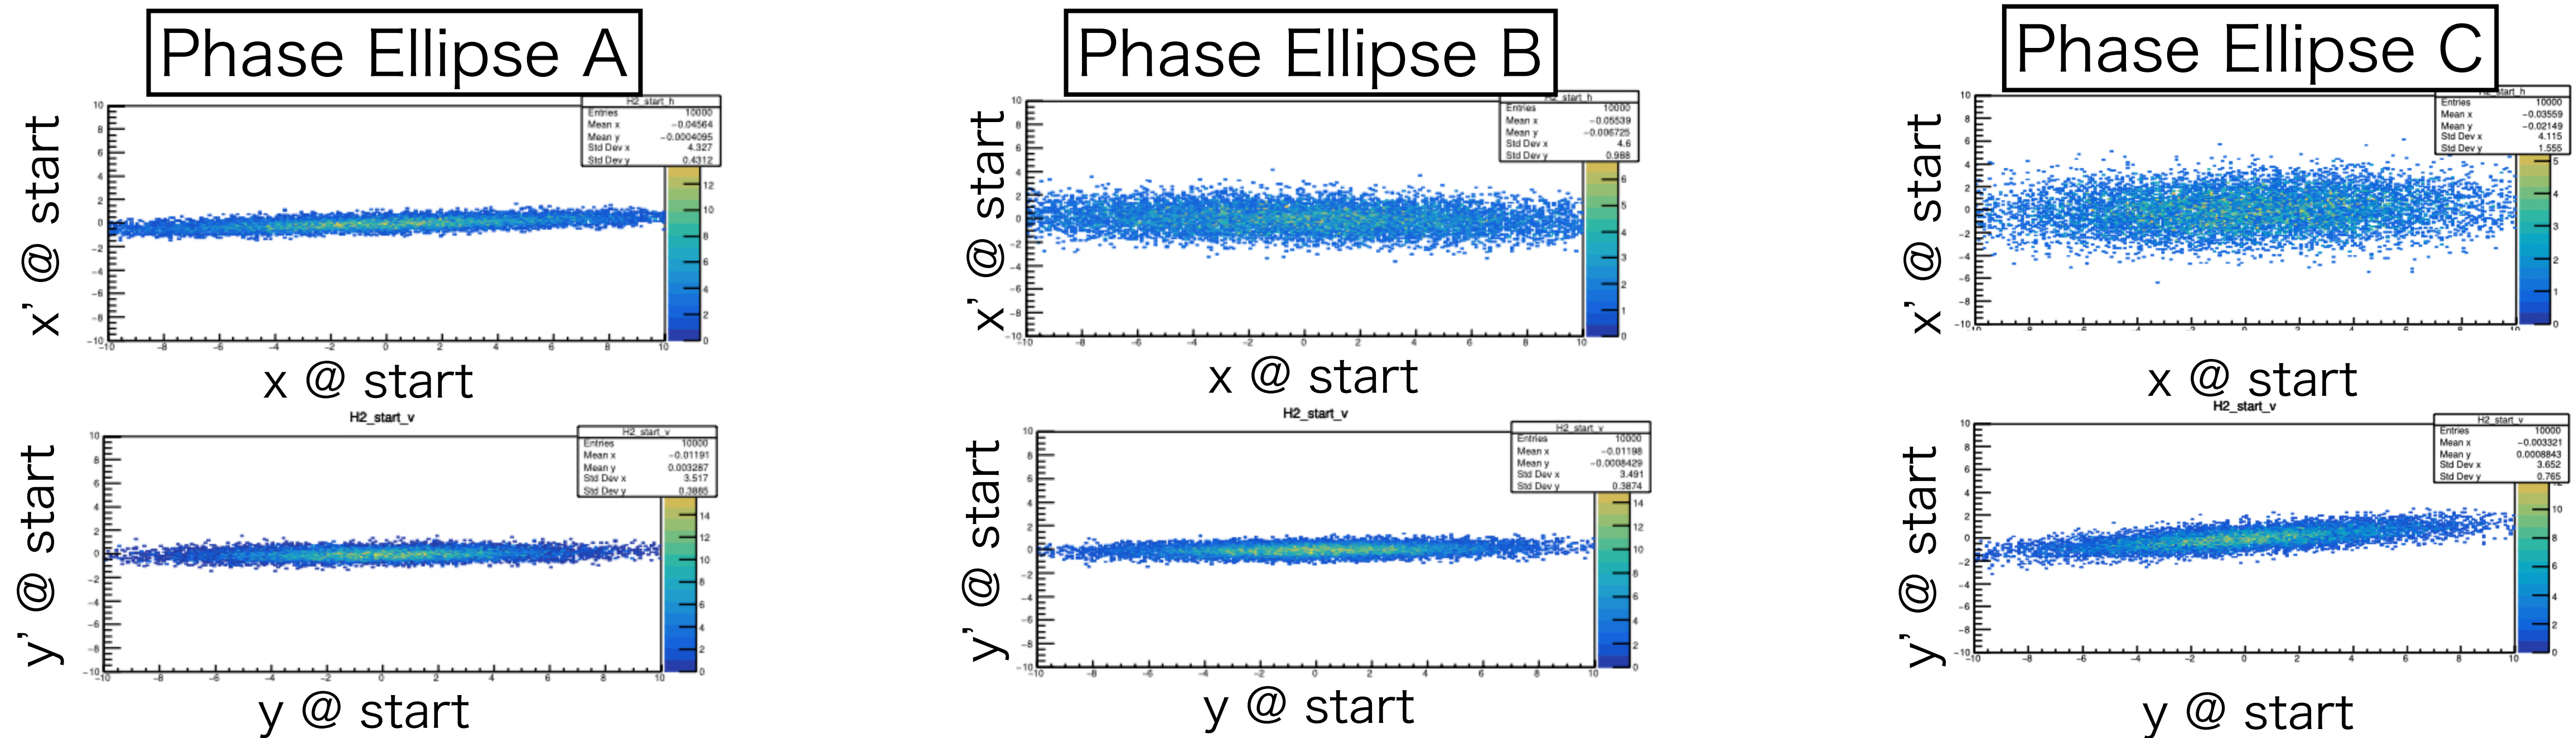
f_{multi} では

- より σ の影響が大きくなる。
- transmission / σ を同時に良くすると特に値が伸びる

これが一番いい形? 他に経験や提案があればぜひ!

ベイズ最適化のハイパーパラメータ(?): ③ phase ellipse

結果の robustness を確認するため、複数の phase ellipse についてシミュレーションを行う。



EDC を抜けるために角度方向が抑えられているはずなので、ある程度扁平な楕円を仮定した上で ϵ 、 α 、 δ との相関などを変更。

各ハイパーパラメータでのシミュレーション結果の比較

比較するもの


- ・ 300 epoch 以内で最も”良い” 光学系
- ・ Transmission 90% 以上 / $\sigma_{x,y} < 1$ mm 以下の解を最初に見つけた epoch
- ・ 最適化の過程
- ・ 得られた解の variety

各ハイパーパラメータでのシミュレーション結果の比較

比較するもの

- ・ 300 epoch 以内で最も”良い” 光学系
- ・ Transmission 90% 以上 / $\sigma_{x,y} < 1$ mm 以下の解を最初に見つけた epoch
- ・ **最適化の過程**
- ・ 得られた解の variety


Graph



各ハイパーパラメータでのシミュレーション結果の比較

比較するもの

- ・ 300 epoch 以内で最も”良い” 光学系
- ・ Transmission 90% 以上 / $\sigma_{x,y} < 1$ mm 以下の解を最初に見つけた epoch
- ・ 最適化の過程
- ・ **得られた解の variety**



元の電流値に対する”内積” とノルムで定義

$$\vec{Q}_{norm} \equiv \{Q_i / Q_i^0\}$$

$$r \equiv |\vec{Q}_{norm}| / |\vec{Q}^0_{norm}|$$

$$\theta \equiv \arccos \frac{\vec{Q}_{norm} \cdot \vec{Q}^0_{norm}}{|\vec{Q}_{norm}| |\vec{Q}^0_{norm}|}$$

($r \cos \theta, r \sin \theta$) で距離が 0.5 以上
→異なる解と判定

Qi : 磁石の電流値
Qi⁰ : 電流値の初期値

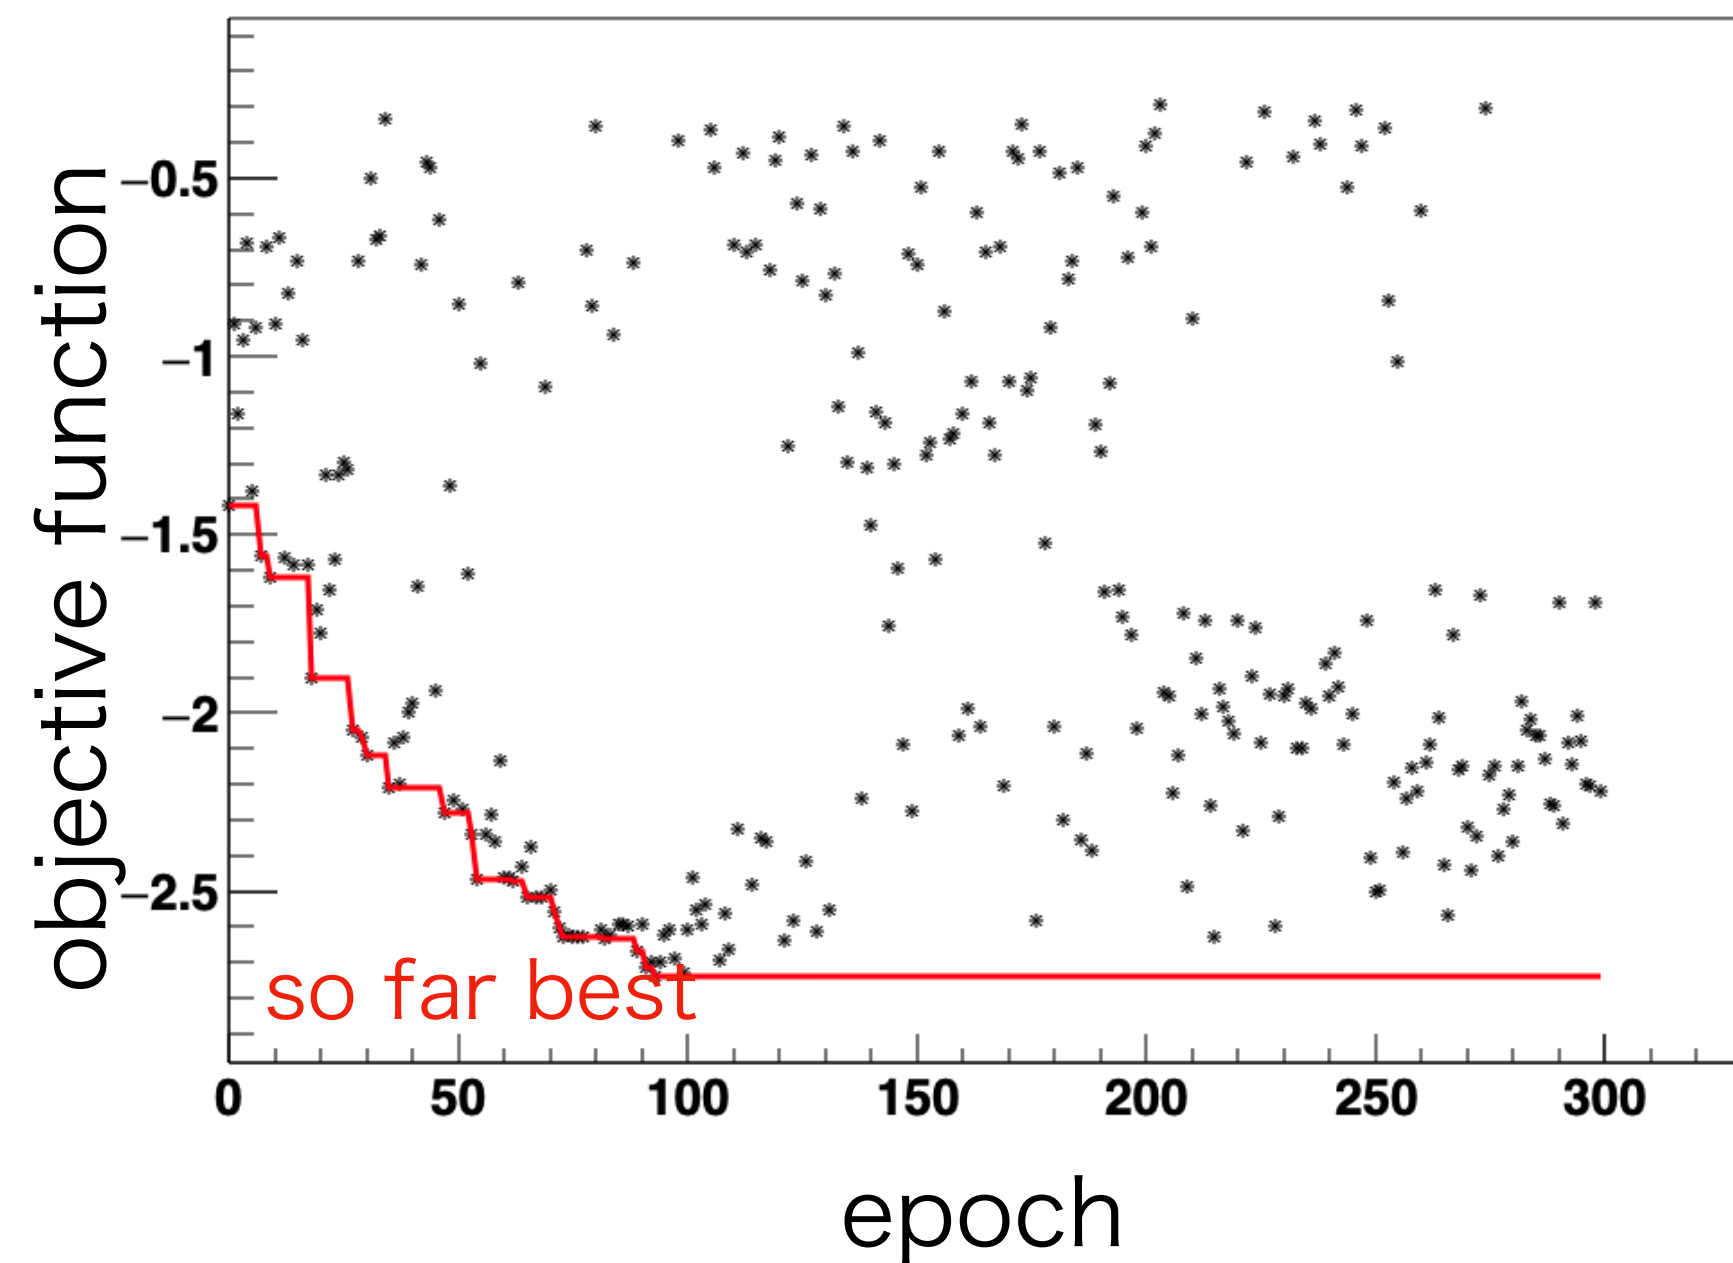
これが一番いい形？他に経験や提案があればぜひ！

各ハイパーパラメータでのシミュレーション結果の比較

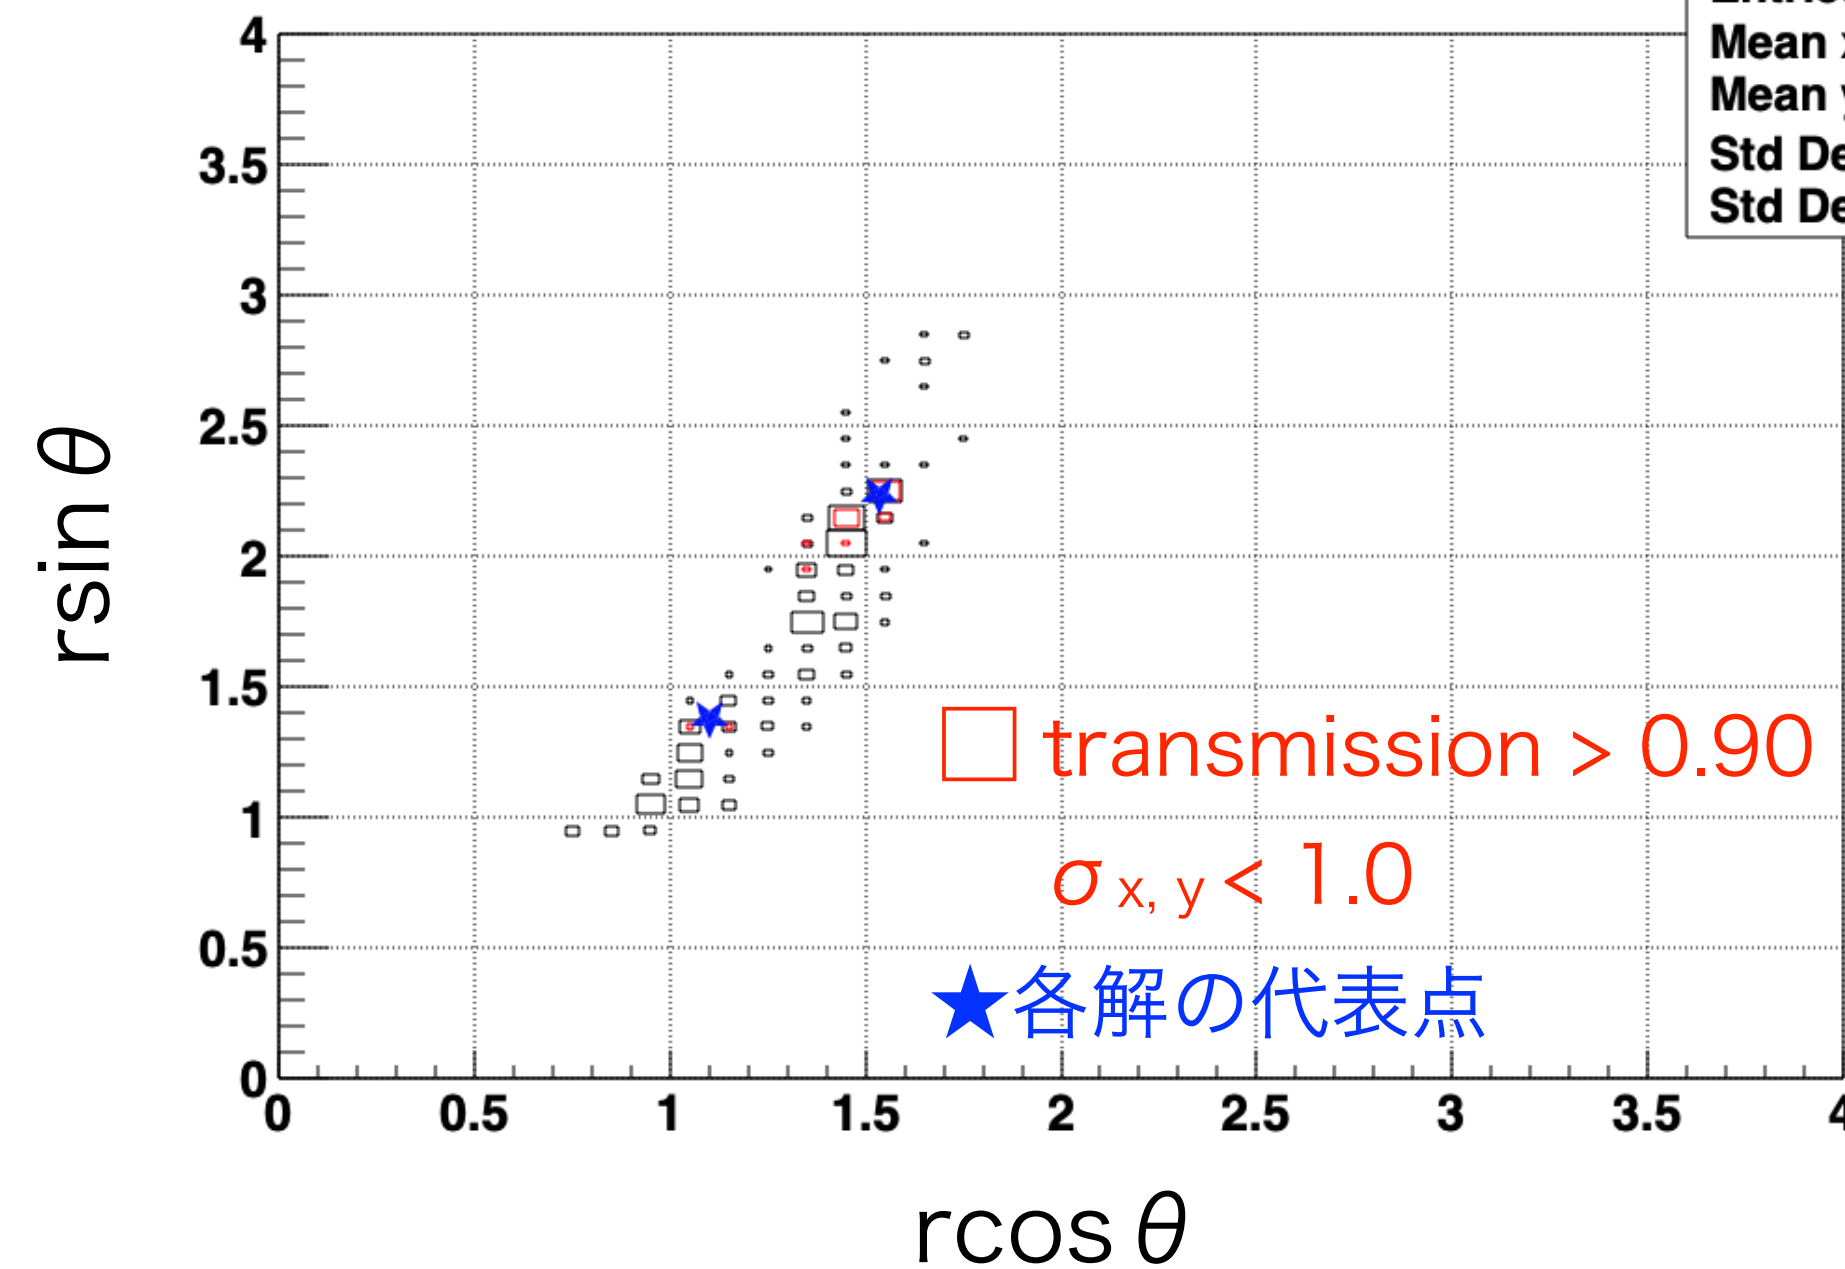
異なる Acquisition function の比較 (objective function: f_{sum} / phase ellipse A)

Probability of Improvement (PI)

Graph



H2_diff_Q



$$\vec{Q}_{norm} \equiv \{Q_i/Q_i^0\}$$

$$r \equiv |\vec{Q}_{norm}| / |\vec{Q}_{norm}^0|$$

$$\theta \equiv \arccos \frac{\vec{Q}_{norm} \cdot \vec{Q}_{norm}^0}{|\vec{Q}_{norm}| |\vec{Q}_{norm}^0|}$$


	epoch	obj.	transmission	σ_x	σ_y
最初に閾値を超えたもの	73	-2.63	0.91	0.34	0.53
best	93	-2.74	0.98	0.45	0.36

各ハイパーパラメータでのシミュレーション結果の比較


異なる Acquisition function の比較 (objective function: f_{sum} / phase ellipse A)

Probability of Improvement (PI)

代表点 1 (93 epoch)



代表点 2 (266 epoch)




~ 最大 40 A 程度電流が変化している。

各ハイパーパラメータでのシミュレーション結果の比較


異なる Acquisition function の比較 (objective function: f_{sum} / phase ellipse A)

Expected Improvement (EI)

Graph



H2_diff_Q



H2_diff_Q	
Entries	300
Mean x	1.315
Mean y	1.707
Std Dev x	0.1987
Std Dev y	0.4567

$$\vec{Q}_{norm} \equiv \{Q_i/Q_i^0\}$$

$$r \equiv |\vec{Q}_{norm}| / |\vec{Q}_{norm}^0|$$

$$\theta \equiv \arccos \frac{\vec{Q}_{norm} \cdot \vec{Q}_{norm}^0}{|\vec{Q}_{norm}| |\vec{Q}_{norm}^0|}$$


	epoch	obj.	transmission	σ_x	σ_y
最初に閾値を超えたもの	241	-2.40	0.98	0.98	0.78
best	241	-2.40	0.98	0.98	0.78

各ハイパーパラメータでのシミュレーション結果の比較


異なる Acquisition function の比較 (objective function: f_{sum} / phase ellipse A)

Lower Confidence Bound (LCB) / $\beta = 0.2$ (default)

Graph



H2_diff_Q



H2_diff_Q	
Entries	300
Mean x	1.299
Mean y	1.697
Std Dev x	0.2045
Std Dev y	0.4773

$$\vec{Q}_{norm} \equiv \{Q_i/Q_i^0\}$$

$$r \equiv |\vec{Q}_{norm}| / |\vec{Q}_{norm}^0|$$

$$\theta \equiv \arccos \frac{\vec{Q}_{norm} \cdot \vec{Q}_{norm}^0}{|\vec{Q}_{norm}| |\vec{Q}_{norm}^0|}$$

	epoch	obj.	transmission	σ_x	σ_y
最初に閾値を 超えたもの	57	-2.64	0.95	0.35	0.63
best	82	-2.68	0.99	0.49	0.50


各ハイパーパラメータでのシミュレーション結果の比較

異なる Acquisition function の比較 (objective function: f_{sum} / phase ellipse A)


Minimize (scipy.optimize / Powell)

やはりこれは全くダメそう

Graph



H2_diff_Q



H2_diff_Q	
Entries	300
Mean x	1.43
Mean y	1.867
Std Dev x	0.02593
Std Dev y	0.1075

$$\vec{Q}_{norm} \equiv \{Q_i/Q_i^0\}$$

$$r \equiv |\vec{Q}_{norm}| / |\vec{Q}_{norm}^0|$$

$$\theta \equiv \arccos \frac{\vec{Q}_{norm} \cdot \vec{Q}_{norm}^0}{|\vec{Q}_{norm}| |\vec{Q}_{norm}^0|}$$

	epoch	obj.	transmission	σ_x	σ_y
最初に閾値を超えたもの	—	—	—	—	—
best	298	-2.28	0.97	1.27	0.90

各ハイパーパラメータでのシミュレーション結果の比較

異なる Acquisition function の比較 (objective function: f_{sum})

phase ellipse A	PI	EI	LCB
最初に閾値を超えた epoch	73	241	57
best obj.	-2.74	-2.40	-2.68

phase ellipse B	PI	EI	LCB
最初に閾値を超えた epoch	127	—	51
best obj.	-2.46	-2.31	-2.65

phase ellipse C	PI	EI	LCB
最初に閾値を超えた epoch	283	—	143
best obj.	-2.28	-2.04	-2.22


LCB がもっともバランスが良さそうに見える。

各ハイパーパラメータでのシミュレーション結果の比較


異なる Objective function の比較 (f_{multi})

Lower Confidence Bound (LCB) / $\beta = 0.2$ (default)

Graph



H2_diff_Q



$$\vec{Q}_{norm} \equiv \{Q_i/Q_i^0\}$$

$$r \equiv |\vec{Q}_{norm}| / |\vec{Q}_{norm}^0|$$

$$\theta \equiv \arccos \frac{\vec{Q}_{norm} \cdot \vec{Q}_{norm}^0}{|\vec{Q}_{norm}| |\vec{Q}_{norm}^0|}$$

	epoch	obj.	transmission	σ_x	σ_y
最初に閾値を 超えたもの	—	—	—	—	—
best	27	-0.42	0.94	1.20	0.38

各ハイパーパラメータでのシミュレーション結果の比較

それぞれの Acquisition function での f_{multi} の結果

phase ellipse A	PI	EI	LCB
最初に閾値を 超えた epoch	—	—	—
best obj.	-0.30	-0.20	-0.42

phase ellipse B	PI	EI	LCB
	obj.	obj.	obj.
最初に閾値を 超えたもの	—	—	130
best	-0.23	-0.20	-0.51


f_{multi} は f_{sum} に比べて機能しなさそう

各ハイパーパラメータでのシミュレーション結果の比較


LCB における β の違い (objective function: f_{sum} / phase ellipse B)

Lower Confidence Bound (LCB) / $\beta = 0.01$

Graph



H2_diff_Q



$$\vec{Q}_{norm} \equiv \{Q_i/Q_i^0\}$$

$$r \equiv |\vec{Q}_{norm}| / |\vec{Q}_{norm}^0|$$

$$\theta \equiv \arccos \frac{\vec{Q}_{norm} \cdot \vec{Q}_{norm}^0}{|\vec{Q}_{norm}| |\vec{Q}_{norm}^0|}$$


	epoch	obj.	transmission	σ_x	σ_y
最初に閾値を超えたもの	93	-2.54	0.996	0.93	0.52
best	290	-2.32	0.960	0.62	0.76

各ハイパーパラメータでのシミュレーション結果の比較


LCB における β の違い (objective function: f_{sum} / phase ellipse B)

Lower Confidence Bound (LCB) / $\beta = 0.2$

Graph



H2_diff_Q



$$\vec{Q}_{norm} \equiv \{Q_i/Q_i^0\}$$

$$r \equiv |\vec{Q}_{norm}| / |\vec{Q}_{norm}^0|$$

$$\theta \equiv \arccos \frac{\vec{Q}_{norm} \cdot \vec{Q}_{norm}^0}{|\vec{Q}_{norm}| |\vec{Q}_{norm}^0|}$$


	epoch	obj.	transmission	σ_x	σ_y
最初に閾値を 超えたもの	89	-2.25	0.939	0.96	0.59
best	237	-2.65	0.920	0.49	0.37

各ハイパーパラメータでのシミュレーション結果の比較


LCB における β の違い (objective function: f_{sum} / phase ellipse B)

Lower Confidence Bound (LCB) / $\beta = 1.0$

Graph



H2_diff_Q



H2_diff_Q	
Entries	300
Mean x	1.408
Mean y	1.938
Std Dev x	0.1589
Std Dev y	0.403

$$\vec{Q}_{norm} \equiv \{Q_i/Q_i^0\}$$

$$r \equiv |\vec{Q}_{norm}| / |\vec{Q}_{norm}^0|$$

$$\theta \equiv \arccos \frac{\vec{Q}_{norm} \cdot \vec{Q}_{norm}^0}{|\vec{Q}_{norm}| |\vec{Q}_{norm}^0|}$$


	epoch	obj.	transmission	σ_x	σ_y
最初に閾値を 超えたもの	67	-2.51	0.918	0.52	0.64
best	154	-2.66	0.915	0.31	0.52

各ハイパーパラメータでのシミュレーション結果の比較


LCB における β の違い (objective function: f_{sum} / phase ellipse B)

Lower Confidence Bound (LCB) / $\beta = 9.0$

Graph



H2_diff_Q



$$\vec{Q}_{norm} \equiv \{Q_i/Q_i^0\}$$

$$r \equiv |\vec{Q}_{norm}| / |\vec{Q}_{norm}^0|$$

$$\theta \equiv \arccos \frac{\vec{Q}_{norm} \cdot \vec{Q}_{norm}^0}{|\vec{Q}_{norm}| |\vec{Q}_{norm}^0|}$$

	epoch	obj.	transmission	σ_x	σ_y
最初に閾値を 超えたもの	111	-2.46	0.966	0.59	0.92
best	51	-2.55	0.960	1.05	0.31

各ハイパーパラメータでのシミュレーション結果の比較

LCB における β の違い (objective function: f_{sum} / phase ellipse B)

phase ellipse B	0.01	0.2	0.5	1.0	9.0	100.0
最初に閾値を超えた epoch	93	51	157	67	111	82
best obj.	-2.54	-2.65	-2.75	-2.66	-2.55	-2.57

phase ellipse C	0.01	0.2	0.5	1.0	9.0	100.0
最初に閾値を超えた epoch	262	143	216	151	—	89
best obj.	-2.3	-2.22	-2.16	-2.28	-2.15	-2.32

系統的な β への依存性は今回の比較では不明。。。。

解析の現状まとめと今後の予定

- ・ 理研RIBF において、将来的な高強度ビームをより高精度で取り扱うために機械学習を用いたビーム制御のための研究を始めている。
- ・ シミュレーションを用いて、ビームトランスポートに対するベイズ最適化についてハイパーパラメータの最適化手法の検討を行った。
- ・ Acquisition function については、今回の範囲では LCB (UCB) が最も優秀な結果を示した。
- ・ Objective function については、sum の形での定義した場合にうまく機能した。
- ・ LCB のパラメータ β の効果は今回の検証では確認できなかった。
- ・ 今後、ある程度の候補が見つかった時点で**より近傍探索の手法に切り替える**ことを考える。
(ただし、近傍から通常的最急降下法は最適化までの 試行回数の短縮には繋がらなかった)
- ・ また、シミュレーションを基にした事前学習を取り入れていく。
(VAE / physics informed Gaussian process など)
- ・ RIBF の他のビームライン (RILAC/LEBTなど) にもシミュレーション含め適応していく予定。

Detail of Algorithm: Bayesian Optimization with GPR

1. Measurement of data as “initial values”

for N parameters, measurement of $2N + 1$ data point : default $\pm \sigma_i (i = 1, 2, \dots, N)$

2. Create a model of the distribution of the objective function based measured data using GPR

In Bayesian estimation, objective function has distribution for any x , i.e.,

$$p(t | x) = \frac{1}{\sqrt{2\pi}\sigma(x)} \exp\left(-\frac{(x - m(x))^2}{2\sigma(x)^2}\right)$$

Create a model means estimate $m(x)$ and $\sigma(x)$ for any x .

In linear estimation model,

Detail of Algorithm: Bayesian Optimization with GPR

1. Measurement of data as “initial values”

for N parameters, measurement of 2N + 1 data point : default $\pm \sigma_i$ (i = 1, 2, ..., N)

2. Create a model of the distribution of the objective function based measured data using GPR

In Bayesian estimation, objective function has distribution for any x, i.e.,

$$p(t | x) = \frac{1}{\sqrt{2\pi}\sigma(x)} \exp\left(-\frac{(x - m(x))^2}{2\sigma(x)^2}\right)$$

Create a model means estimate $m(x)$ and $\sigma(x)$ for any x.

In linear estimation model,

$$m(x) = \sum w_m \phi_m(x)$$

w: model parameter ϕ : basis function

C. M. Bishop, Pattern Recognition and Machine Learning, Springer (2006)




Figure 3.1 Examples of basis functions, showing polynomials on the left, Gaussians of the form (3.4) in the centre, and sigmoidal of the form (3.5) on the right.

Detail of Algorithm: Bayesian Optimization with GPR

1. Measurement of data as “initial values”

for N parameters, measurement of 2N + 1 data point : default $\pm \sigma_i$ (i = 1, 2, ..., N)

2. Create a model of the distribution of the objective function based measured data using GPR

In Bayesian estimation, objective function has distribution for any x, i.e.,

$$p(t | x) = \frac{1}{\sqrt{2\pi}\sigma(x)} \exp\left(-\frac{(x - m(x))^2}{2\sigma(x)^2}\right)$$

Create a model means estimate m(x) and $\sigma(x)$ for any x.

In linear estimation model,

$$m(x) = \sum w_m \phi_m(x)$$

w: model parameter ϕ : basis function

Instead of determine w from data set, estimate probability distribution of w and integral it as

$$p(t | x) = \int p(t | x, \vec{w}) p(\vec{w} | \underbrace{\{x_i, t_i\}}_{\text{measured data set so far}}) d\vec{w} .$$

Detail of Algorithm: Bayesian Optimization with GPR

1. Measurement of data as “initial values”

for N parameters, measurement of 2N + 1 data point : default $\pm \sigma_i$ (i = 1, 2, ..., N)

2. Create a model of the distribution of the objective function based measured data using GPR

In Bayesian estimation, objective function has distribution for any x, i.e.,

$$p(t | x) = \frac{1}{\sqrt{2\pi}\sigma(x)} \exp\left(-\frac{(x - m(x))^2}{2\sigma(x)^2}\right)$$

m(x) and $\sigma(x)$ are calculated with $\{x_i, \sigma_i\}_N$ as

$$m_N(x) = \sum k(x, x_i)t_i, \quad \sigma_N(x)^2 = \frac{1}{\beta} + \vec{\phi}(x)^T \mathbf{S}_N \vec{\phi}(x),$$

$$k(x, x') \equiv \beta \phi(x) \mathbf{S}_N \phi(x'), \quad \mathbf{S}_N^{-1} = \alpha \mathbf{I} + \beta \Phi^T \Phi.$$

$$\Phi = \begin{pmatrix} \phi_0(\mathbf{x}_1) & \phi_1(\mathbf{x}_1) & \cdots & \phi_{M-1}(\mathbf{x}_1) \\ \phi_0(\mathbf{x}_2) & \phi_1(\mathbf{x}_2) & \cdots & \phi_{M-1}(\mathbf{x}_2) \\ \vdots & \vdots & \ddots & \vdots \\ \phi_0(\mathbf{x}_N) & \phi_1(\mathbf{x}_N) & \cdots & \phi_{M-1}(\mathbf{x}_N) \end{pmatrix}.$$

※ α : parameter of prior distribution of w

β : precision parameter of the measurement itself

Detail of Algorithm: Bayesian Optimization with GPR

1. Measurement of data as “initial values”
for N parameters, measurement of 2N + 1 data point : default ± σ_i (i = 1, 2, ..., N)
2. Create a model of the distribution of the objective function based measured data using GPR

In Bayesian estimation, objective function has distribution for any x, i.e.,

$$p(t | x) = \frac{1}{\sqrt{2\pi}\sigma(x)} \exp\left(-\frac{(x - m(x))^2}{2\sigma(x)^2}\right)$$

m(x) and σ(x) are calculated with {x_i, σ_i}_N as


$$m_N(x) = \frac{\sum k(x, x_i)t_i}{\sum k(x, x_i)}, \quad \sigma_N(x)^2 = \frac{1}{\beta} + \vec{\phi}(x)^T \mathbf{S}_N \vec{\phi}(x),$$

kernel function:

“Indicator of the strength of correlation between x_i and x”

C. M. Bishop, Pattern Recognition and Machine Learning, Springer (2006)

Figure 3.11 Examples of equivalent kernels $k(x, x')$ for $x = 0$ plotted as a function of x' , corresponding (left) to the polynomial basis functions and (right) to the sigmoidal basis functions shown in Figure 3.1. Note that these are localized functions of x' even though the corresponding basis functions are nonlocal.



Detail of Algorithm: Bayesian Optimization with GPR

1. Measurement of data as “initial values”

for N parameters, measurement of 2N + 1 data point : default $\pm \sigma_i$ (i = 1, 2, ..., N)

2. Create a model of the distribution of the objective function based measured data using GPR

In Bayesian estimation, objective function has distribution for any x, i.e.,

$$p(t | x) = \frac{1}{\sqrt{2\pi}\sigma(x)} \exp\left(-\frac{(x - m(x))^2}{2\sigma(x)^2}\right)$$

m(x) and $\sigma(x)$ are calculated with $\{x_i, \sigma_i\}_N$ as

$$m_N(x) = \sum k(x, x_i)t_i, \quad \sigma_N(x)^2 = \underbrace{\frac{1}{\beta}}_{\text{Intrinsic error of the measurement}} + \underbrace{\vec{\phi}(x)^T S_N \vec{\phi}(x)}_{\text{Ambiguity from the estimation}},$$

Intrinsic error of the measurement

Ambiguity from the estimation

Detail of Algorithm: Bayesian Optimization with GPR

1. Measurement of data as “initial values”

for N parameters, measurement of $2N + 1$ data point : default $\pm \sigma_i (i = 1, 2, \dots, N)$

2. Create a model of the distribution of the objective function based measured data using GPR

3. Calculate EI (Expected Improvement) for all x based on the created model

Expected improvement is defined as

$$\mathbb{E}_{\alpha}(\max\{f(x, \alpha) - f(\hat{x}), 0\}) \equiv \int P(\alpha) \max\{f(x, \alpha) - f(\hat{x}), 0\} d\alpha .$$

$f(x, \alpha)$: objective function α : error indicators $P(\alpha)$: Probability function of α

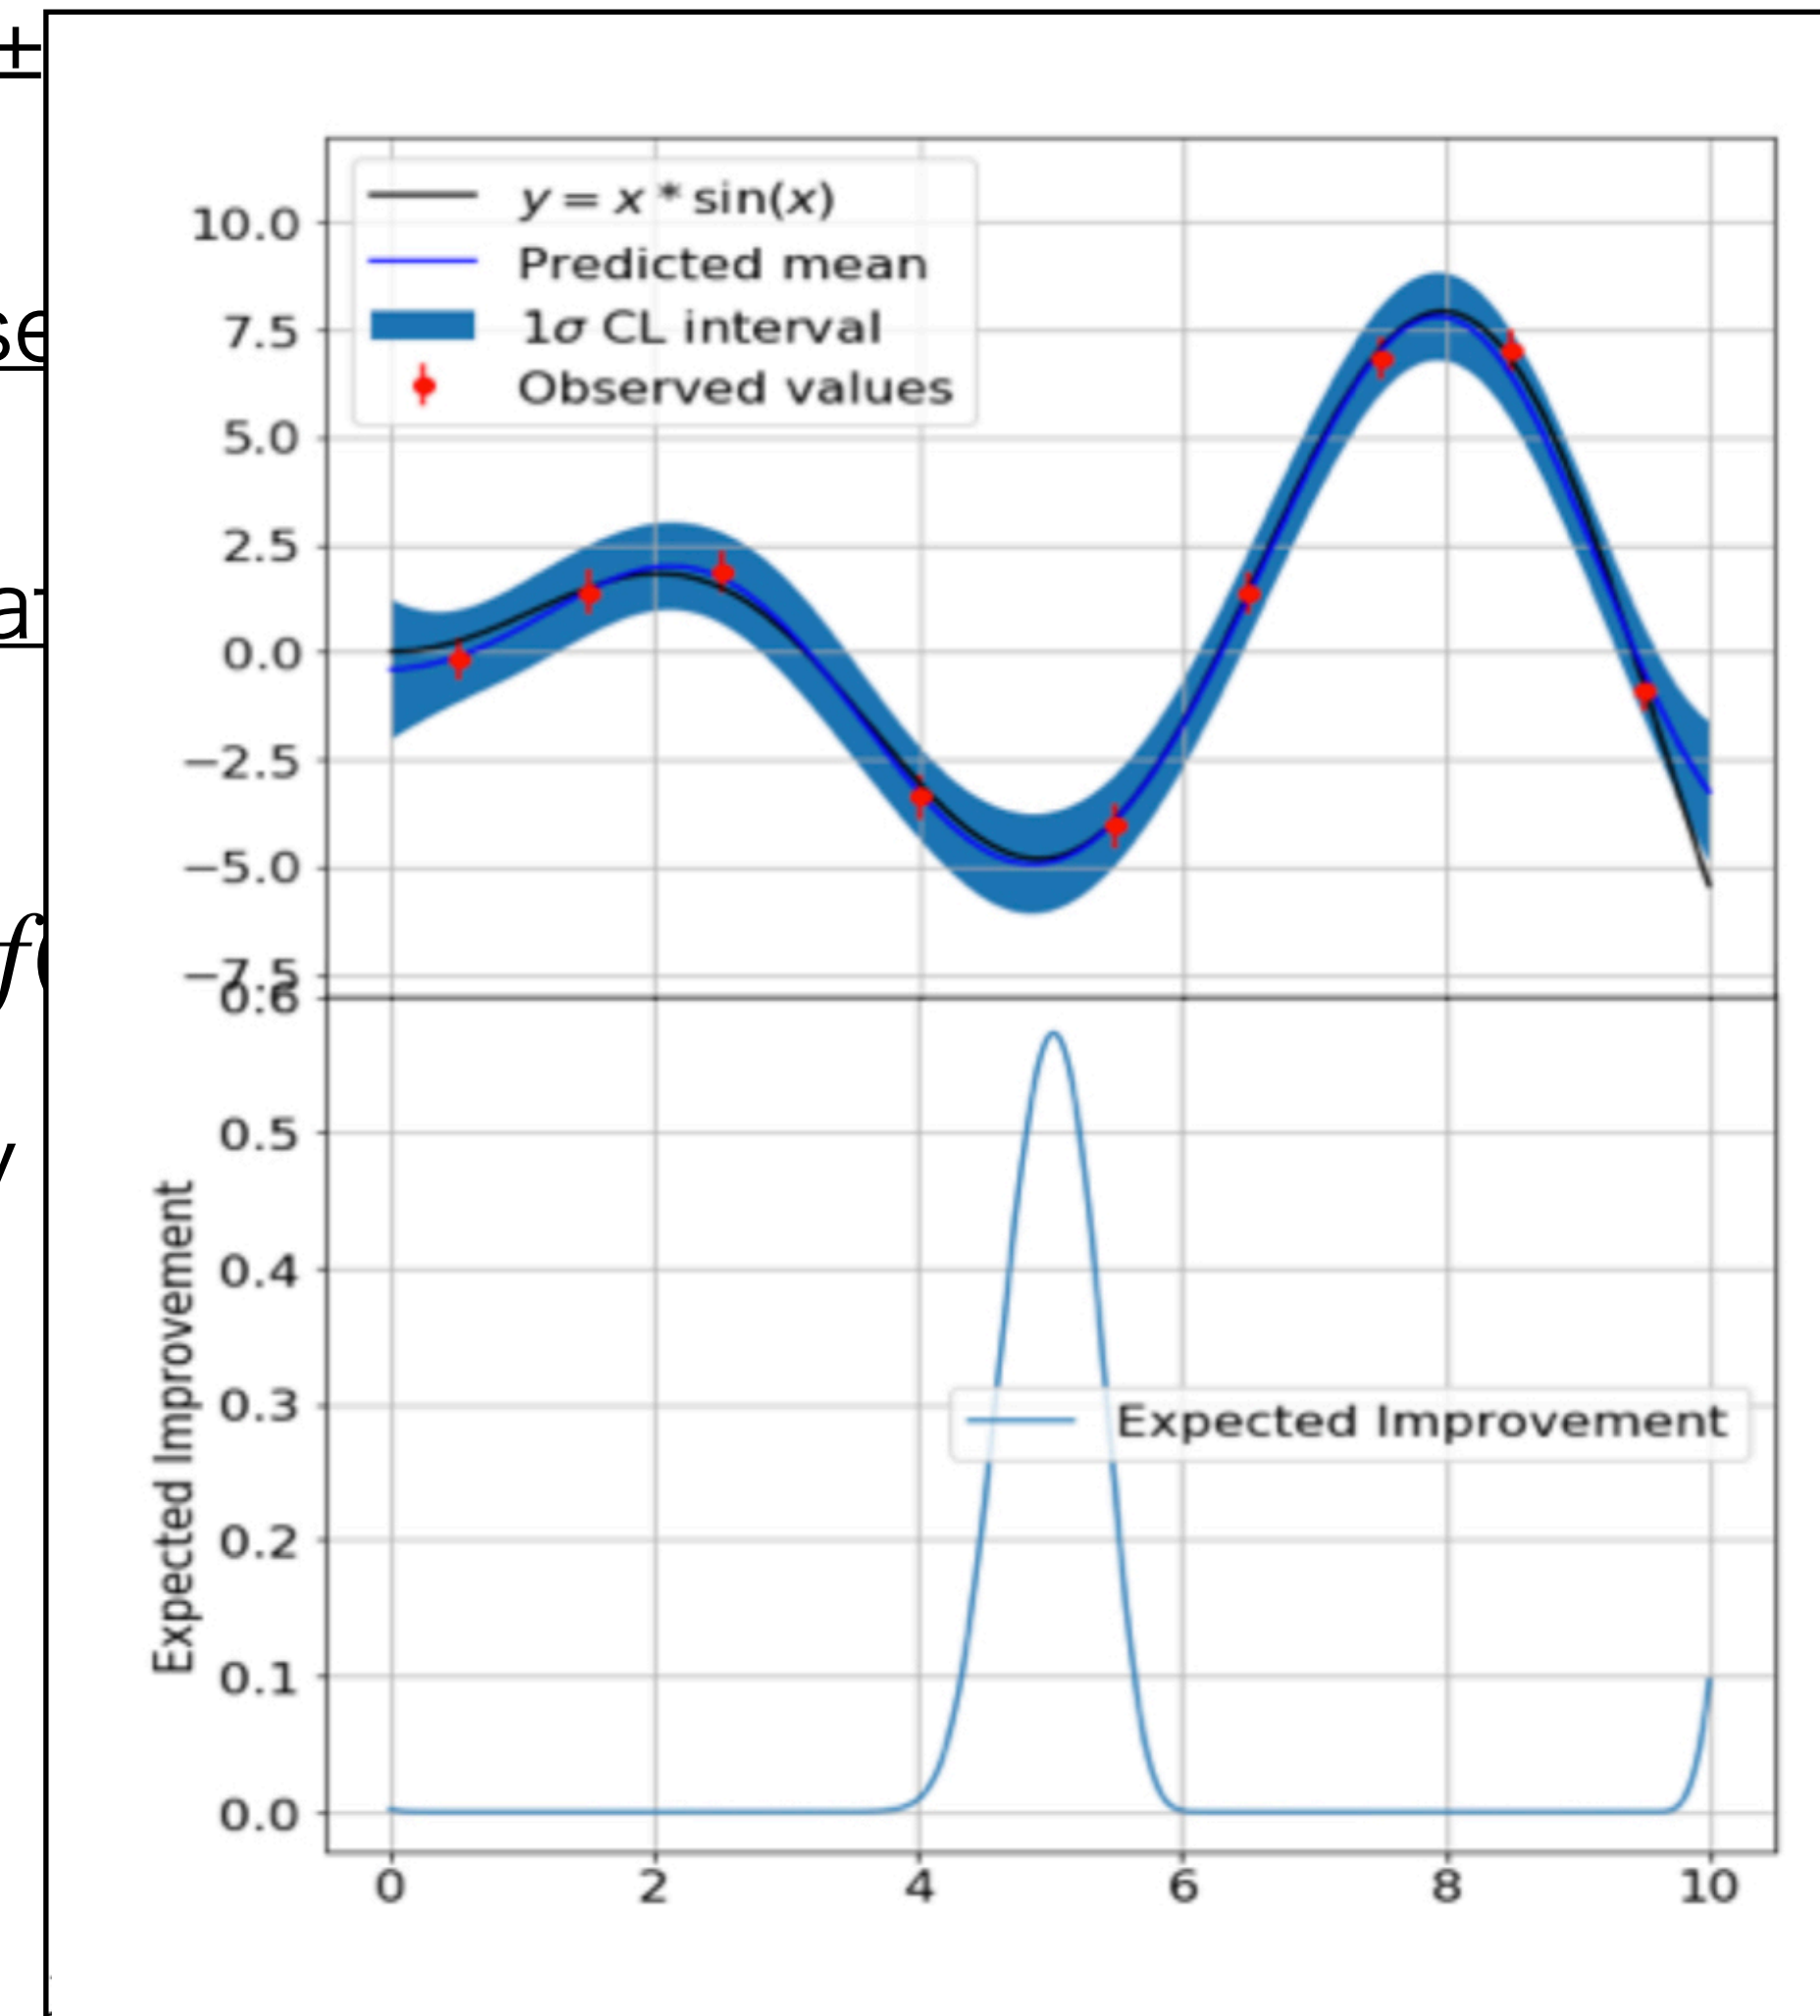
This value becomes large when the information is insufficient.

Detail of Algorithm: Bayesian Optimization with GPR

1. Measurement of data as “initial values”
for N parameters, measurement of 2N + 1 data point : default ±
2. Create a model of the distribution of the objective function base
3. Calculate EI (Expected Improvement) for all x based on the crea
Expected improvement is defined as

$$\mathbb{E}_{\alpha}(\max\{f(x, \alpha) - f(\hat{x}), 0\}) \equiv \int P(\alpha) \max\{f(x, \alpha) - f(\hat{x}), 0\} P(\alpha) d\alpha$$

f(x, α): objective function α: error indicators P(α) : Probability
This value becomes large when the information is insufficient.



Detail of Algorithm: Bayesian Optimization with GPR



1. Measurement of data as “initial values”
for N parameters, measurement

2. Create a model of the distributic

3. Calculate EI (Expected Improven
Expected improvement is define

$$\mathbb{E}_{\alpha}(\max\{f(x, \alpha) - f(x)$$

$f(x, \alpha)$: objective function α : error indicators $P(\alpha)$: Probability
This value becomes large when the information is insufficient.



Detail of Algorithm: Bayesian Optimization with GPR

1. Measurement of data as “initial values”
for N parameters, measurement of $2N + 1$ data point : default $\pm \sigma_i (i = 1, 2, \dots, N)$
2. Create a model of the distribution of the objective function based measured data using GPR

3. Calculate EI (Expected Improvement) for all x based on the created model

Expected improvement is defined as

$$\mathbb{E}_{\alpha}(\max\{f(x, \alpha) - f(\hat{x}), 0\}) \equiv \int P(\alpha) \max\{f(x, \alpha) - f(\hat{x}), 0\} d\alpha .$$

$f(x, \alpha)$: objective function α : error indicators $P(\alpha)$: Probability function of α

This value becomes large when the information is insufficient.

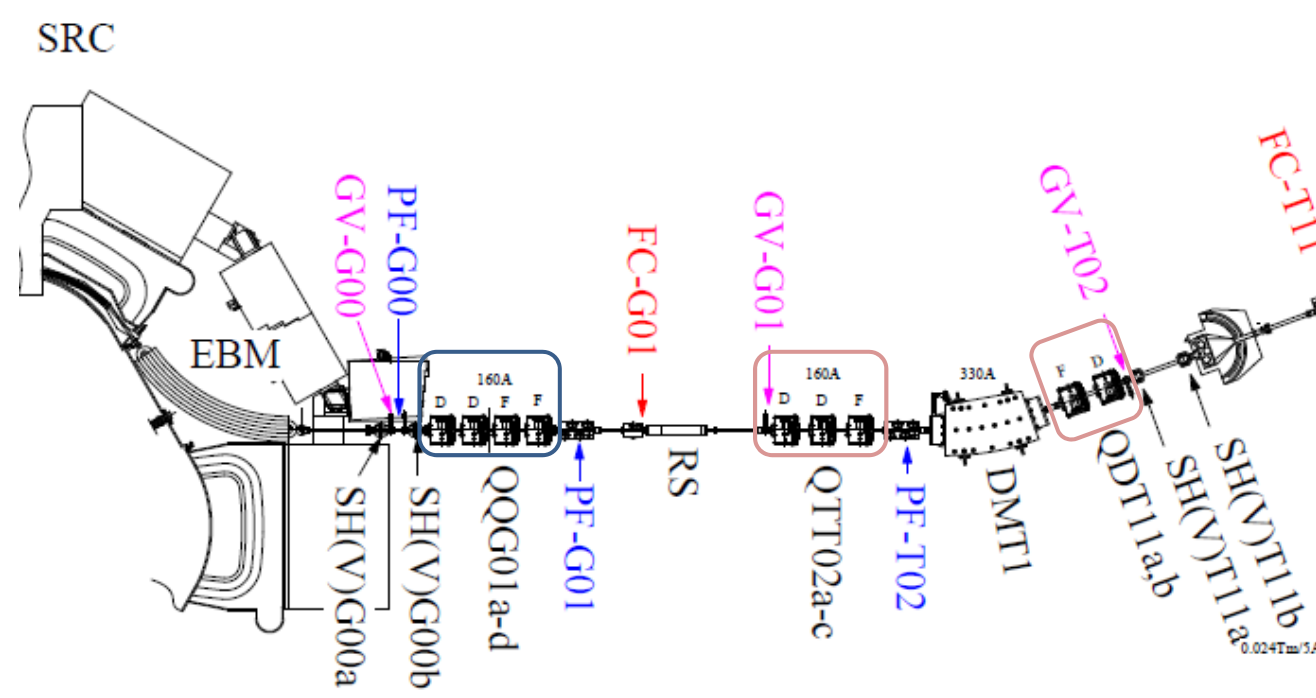
4. Apply a new parameter with maximum EI to the real system and measure the data
to search the point with the maximum EI, we use the library BoTorch /GPyTorch
5. Repeat 2 ~ 4 and search the best point

Development History of GPR Optimization System@RIBF

- **1st attempt an automatic optics optimization by ML**
 - simultaneous optimization of transmission and beam spot
- **Development of indicators for high intensity beams**
 - secondary beam with charge conversion



Automatic Optics Optimization ①: Test with Low Intensity Beam

(1) Change parameters
(Q / Steerer) by EPICS



U⁸⁶⁺ 345 MeV/u
~ 0.001 enA
2.0 e+7 cps

(2) Measure beam spot
by fluorescent viewer



(3) Calculate objective function
Create model by GPR
Choose next param.

Gaussian Process Regression
(Bayesian Optimization)

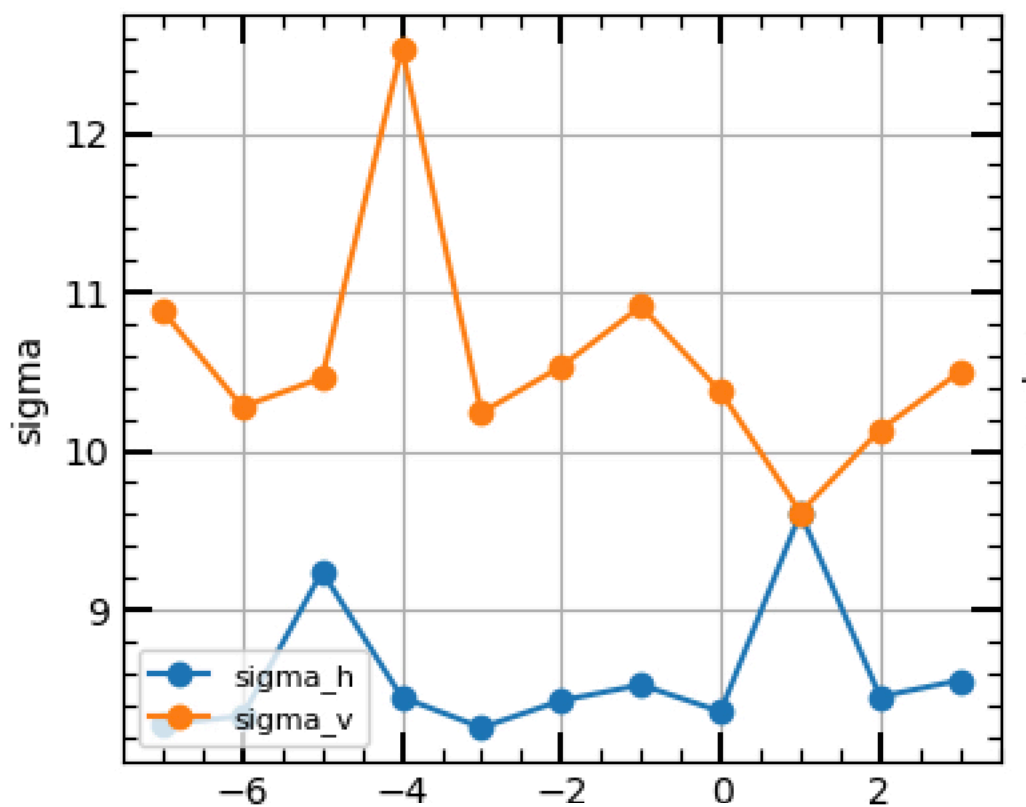


Intensity : Integral of image luminosity
Spot : Image width


Repeat (1) — (3)
to optimize optics

1st Exp. : Auto Tuning with Low Intensity Beam


Demonstration test at 2020 Oct. 21:00 ~ 9:00




$\sigma_{h,v}$ vs Epoch




Pos_{h,v} vs Epoch




S_{h,v} vs Epoch



Objective function vs Epoch



Current of Q vs Epoch



Objectives vs Current of Q

Initial: manually optimized params.
Goal : good transmission
small beam spot

- 3 ~ 7 params. (Quadrupoles)
 - 1 epoch ~ 1 s
 - 1 try ~ 5 min (~300 epoch)
 - ~ 0.001 enA
- try optimization with several conditions

1st Exp. : Auto Tuning with Low Intensity Beam

Demonstration test at 2020 Oct. 21:00 ~ 9:00

Compare the result of manual optimization / manual + ML optimization using high intensity beams and wire scanner / Faraday cups

	Manual Optimization	Manual + ML Optimization
FC _{up} [eμA]	7.20	7.8
Beam Dump [eμA]	7.25	8.0
Ratio (BD/FC _{up})※	1.01	1.03
Wire Scanner の像		

• Transmission ↗ 2%
• Beam width ↘ 13%

Significant improvements
in the 1st test

※ Beam dump does not have good suppressor

1st Exp. : Auto Tuning with Low Intensity Beam

Demonstration test at 2020 Oct. 21:00 ~ 9:00

Compare the result of manual optimization / manual + ML optimization using high intensity beams and wire scanner / Faraday cups

	Manual Optimization	Manual + ML Optimization
FC _{up} [eμA]	7.20	7.8
Beam Dump [eμA]	7.25	8.0
Ratio (BD/FC _{up})※	1.01	1.03
Wire Scanner の像		

• Transmission ↗ 2%
• Beam width ↘ 13%


Significant improvements
in the 1st test

※ Beam dump does not have good suppressor

- Algorithm works as expected
- Optics is improved with low intensity beam (limit by fluorescent viewer: 0.001 enA)
- △ Effective algorithm

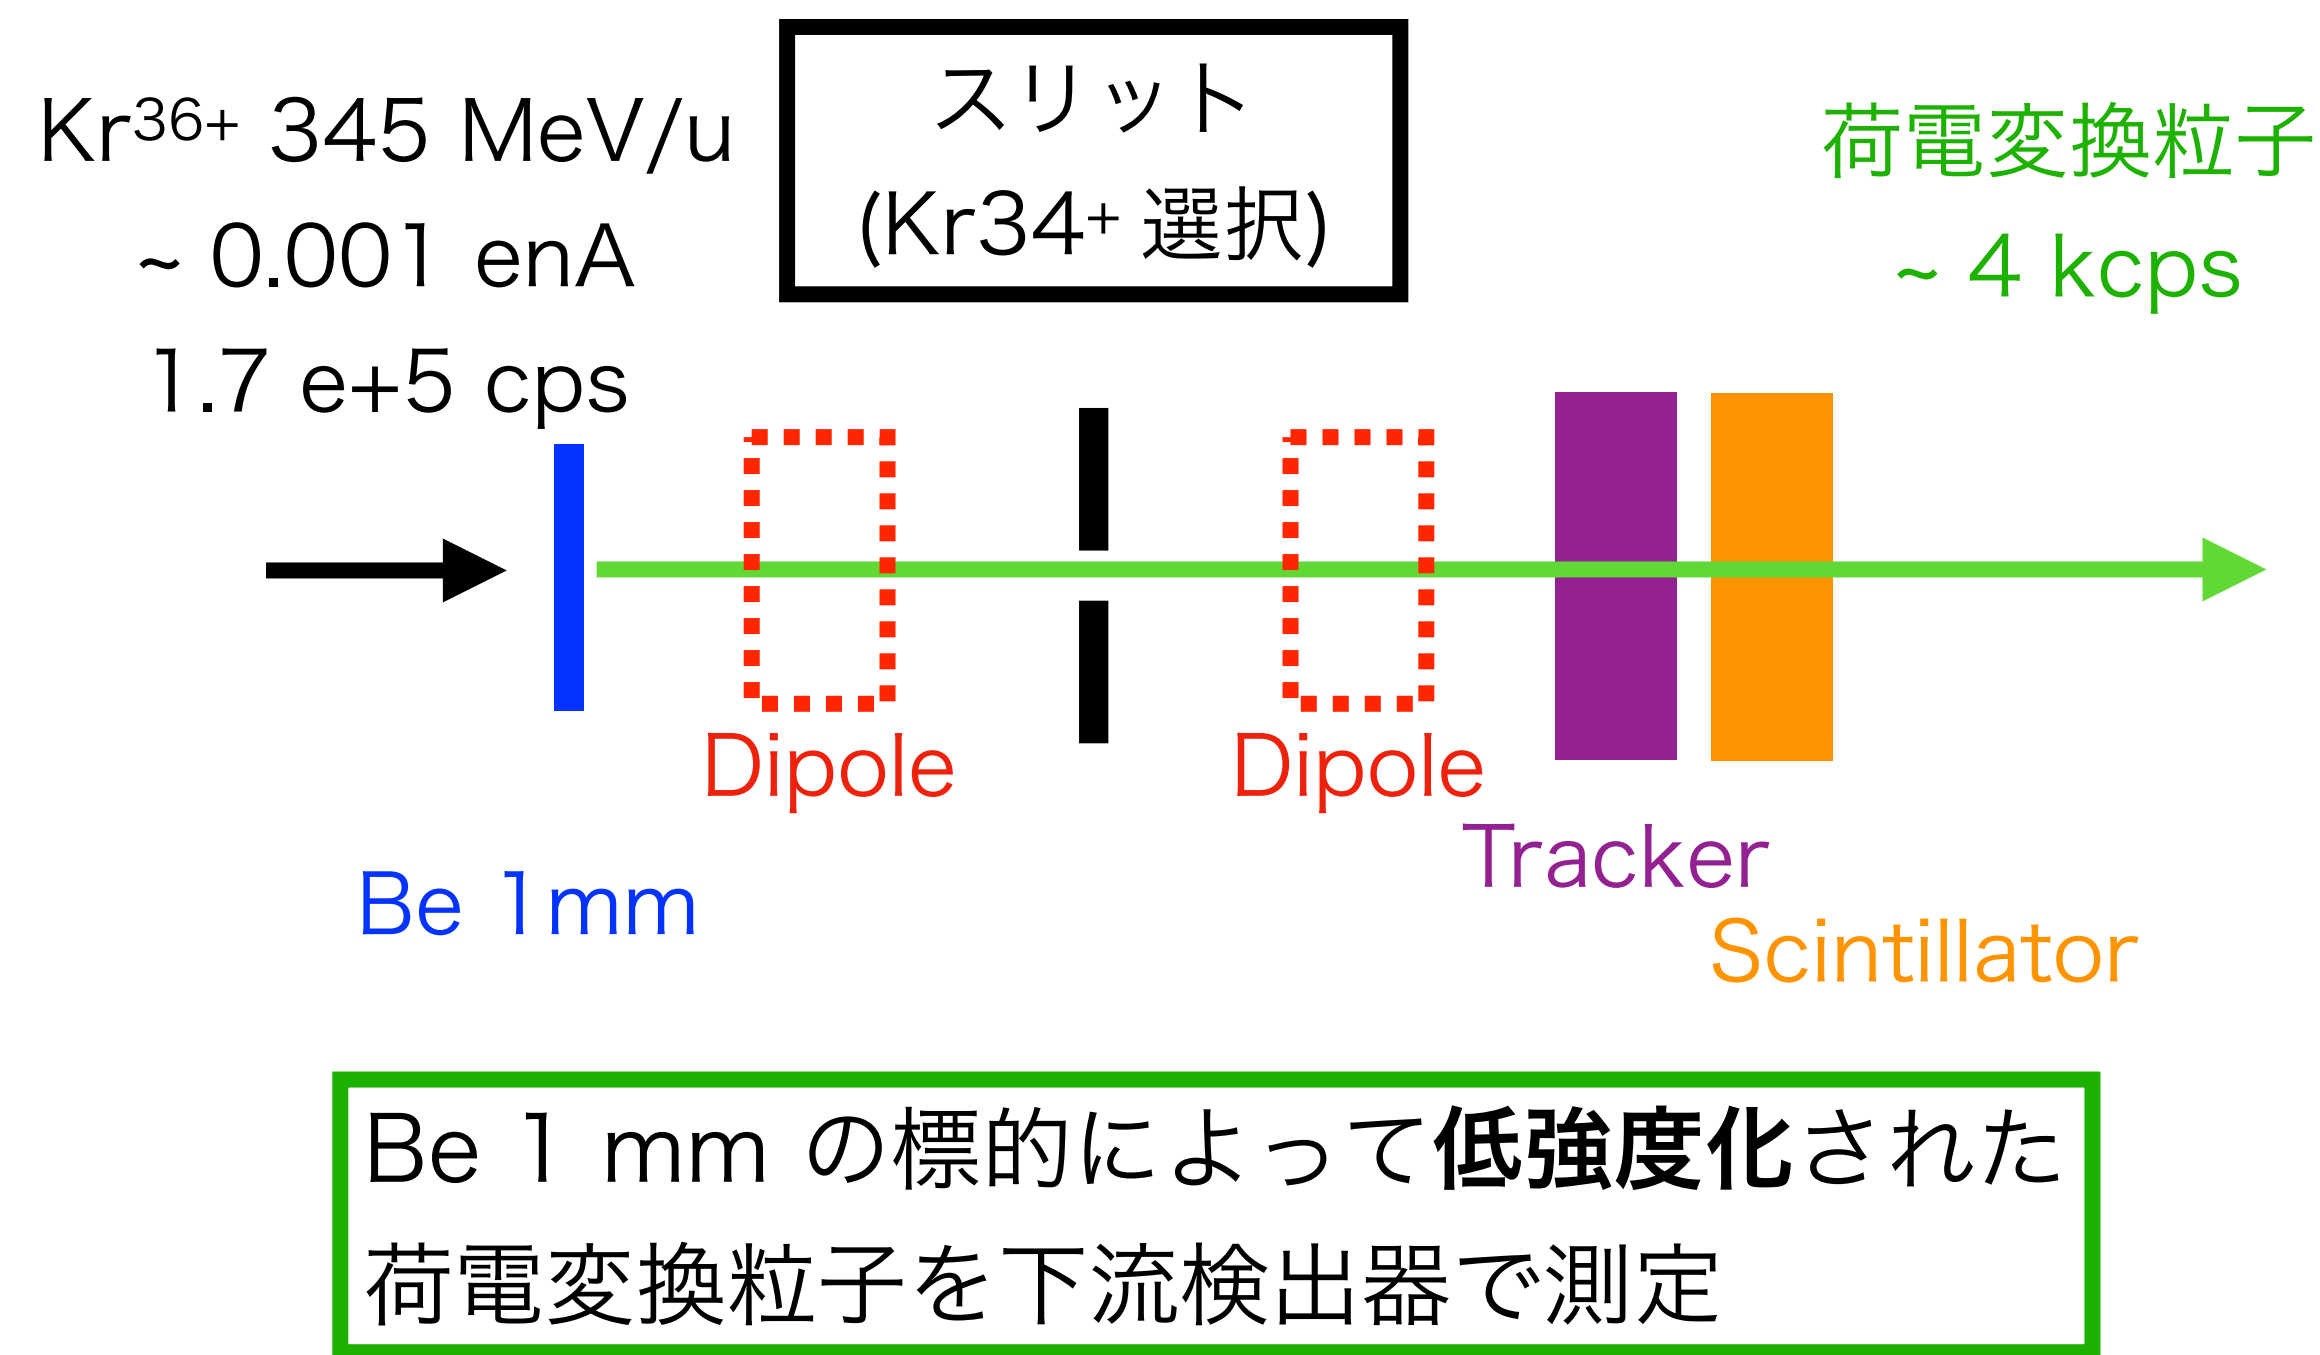
“高強度”一次ビームで荷電変換粒子の測定による光学系最適化

一次標的の下流スリット位置での荷電粒子分布



ビーム強度 : 標的の下流のSci. (荷電変換粒子)
ビーム幅 : 標的の下流の飛跡検出器 (荷電変換粒子)

PPAC (飛跡検出器) / シンチレータ
 で荷電変換粒子を測定




検出粒子	一次ビームの強度	下流検出器でのビーム強度
Kr ³⁵⁺	0.001 enA	1 kcps
Kr ³⁴⁺	1 enA	2 kcps
Kr ³³⁺	(300 enA)	1 kcps

A. Compare Beam Spot measured by Viewer and Tracker

Change optics and compare

- fluorescent viewer image of primary beam (Kr^{36+})
- position distribution of secondary beam (Kr^{34+}) tracked by PPAC (gas detector)



Red : Viewer



Black: Gas tracker

※ Viewer and gas tracker is calibrated by optics 0 data.

Data of viewer and tracker

→ (qualitatively) consistent

※ When the spot become wide,
non linearity may not be negligible




**Tracking distribution of secondary beam
is good probe for the primary beam spot!!**

Auto Tuning with “High Intensity” Beam in 2022 May

Real time tracker system is realized and connected to EPICS*
 → test with ideal situation with Be target and tracker / scintillator

* T. Sumikama *et al*, RIKEN Accel. Prog. Rep 54, 82 (2021)

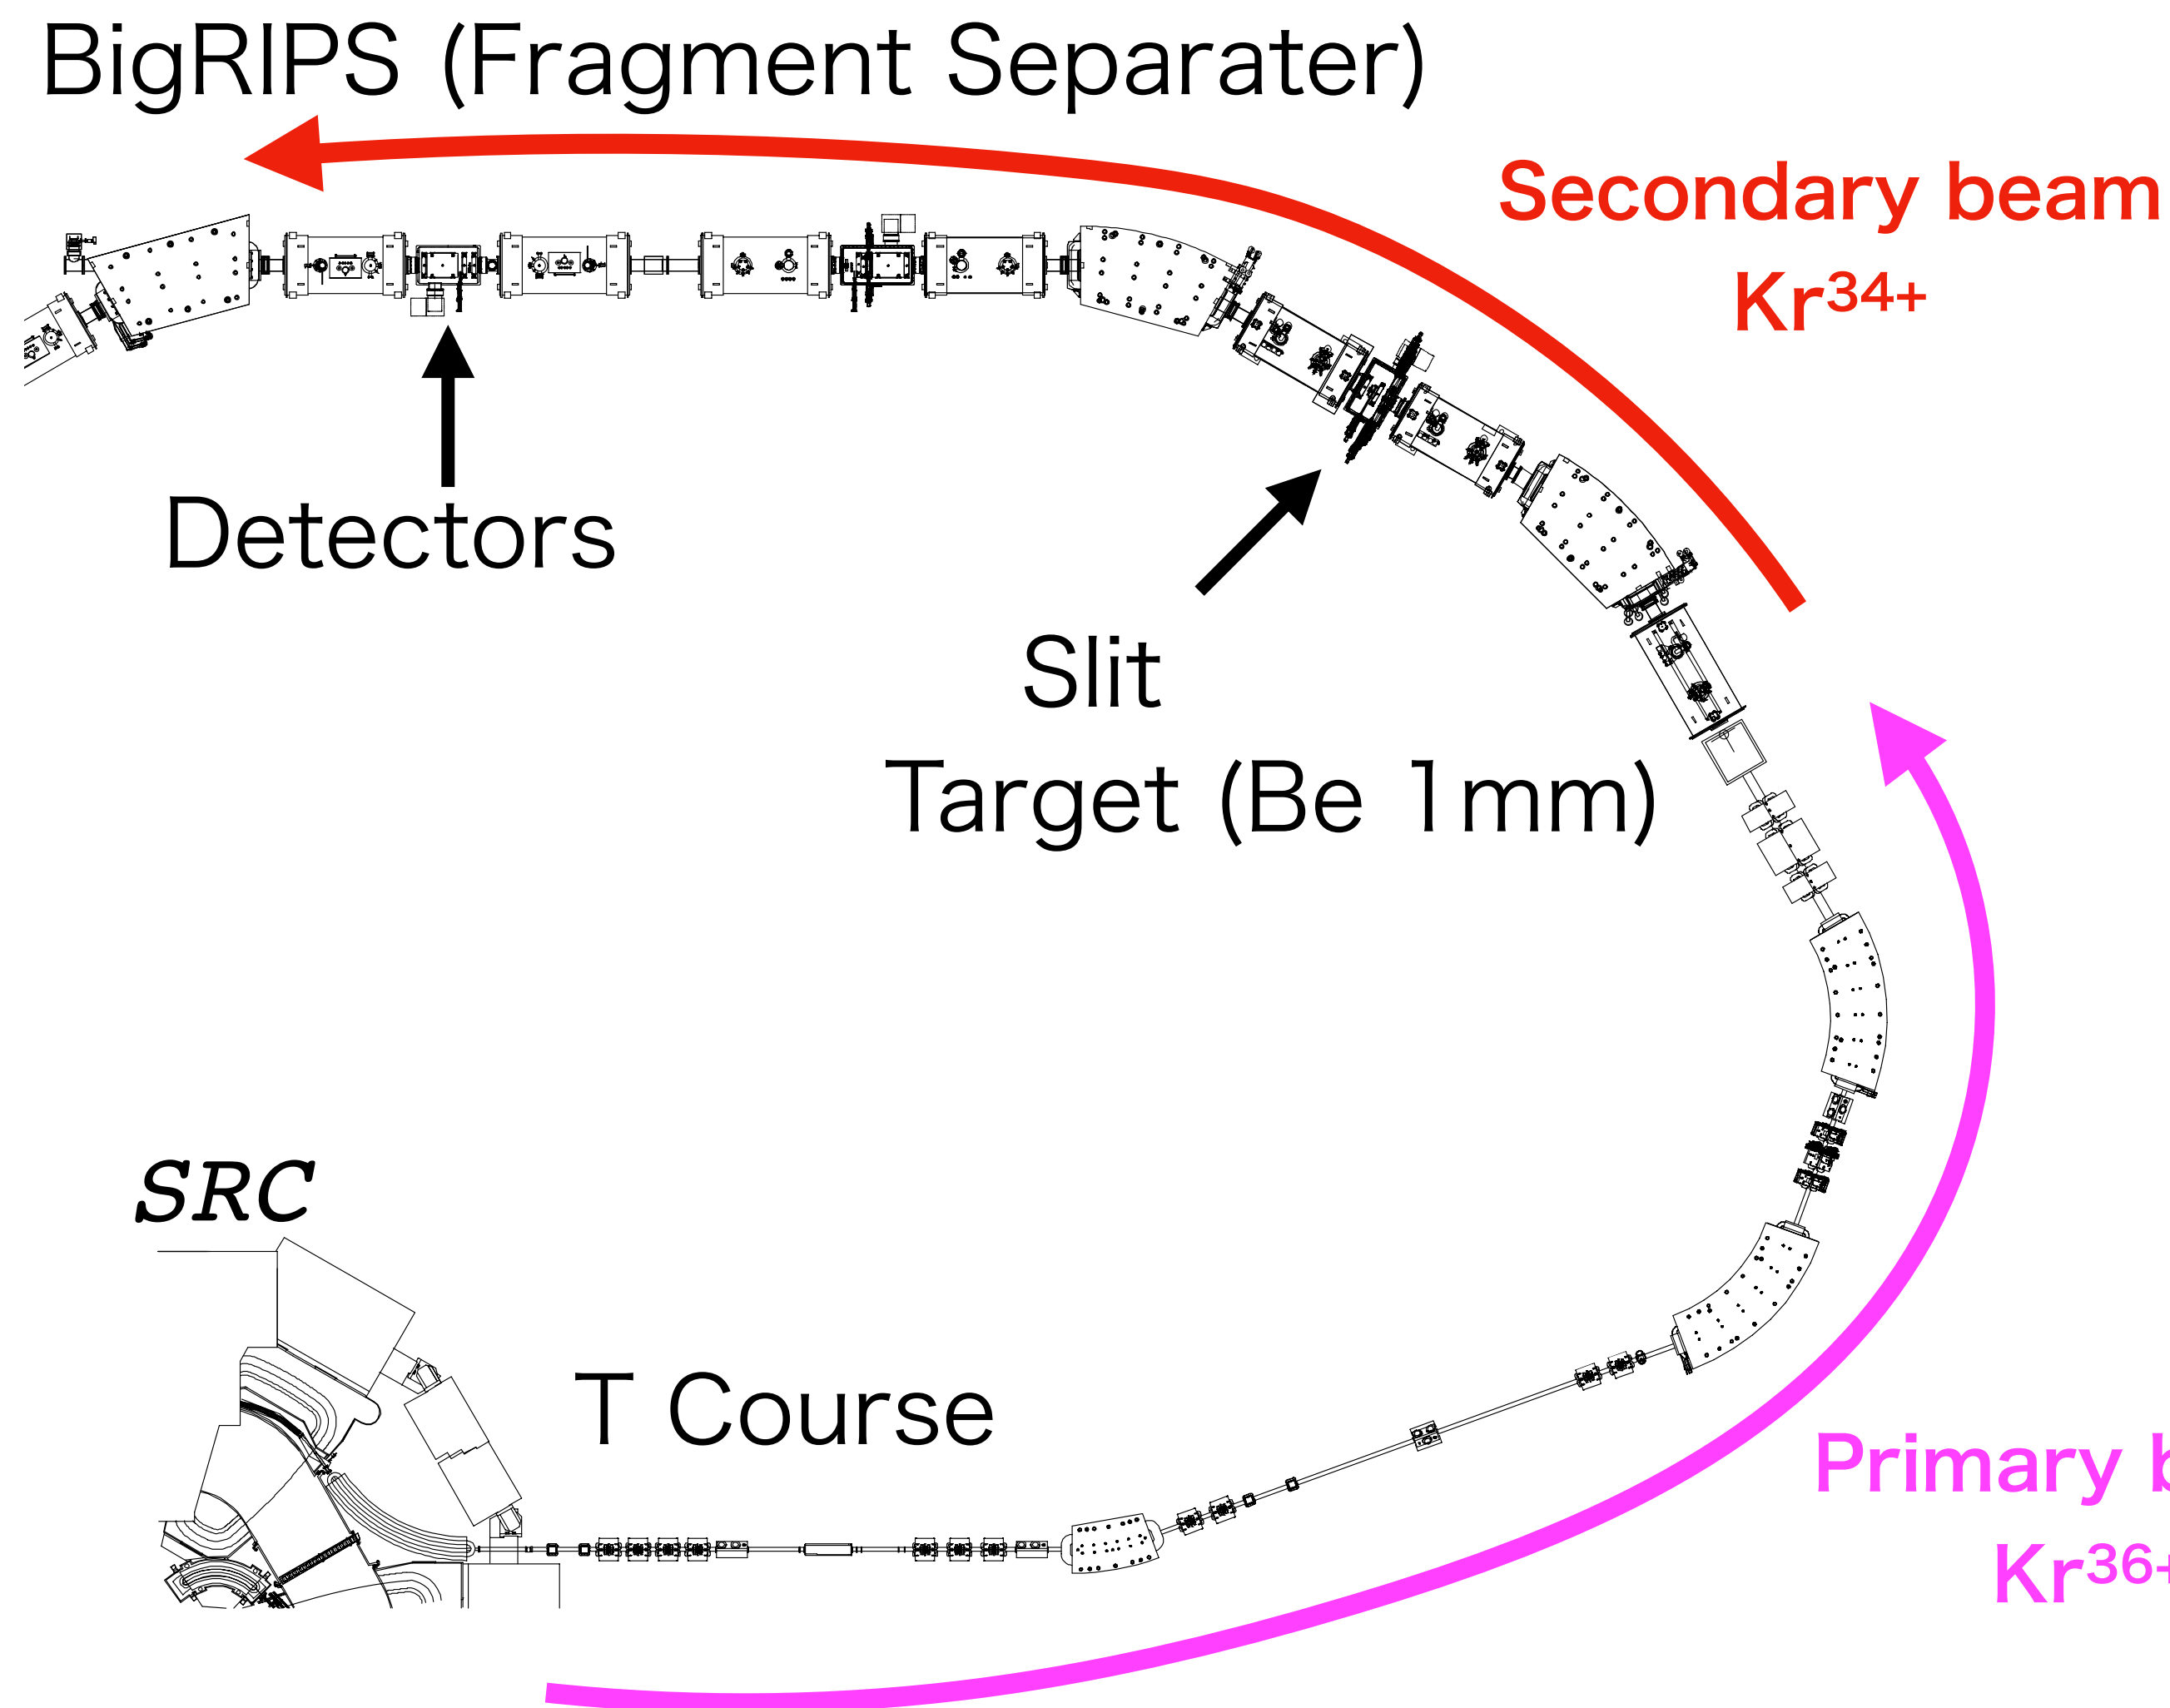
BigRIPS (Fragment Separator)



Experiment items

- A. Compare beam spot measured by **Viewer** and **Tracker**
- B. Increase the beam intensity and optimize beam optics using Tracker / Scintillator

B. Auto Tuning with “High Intensity” Primary Beam



Detector in downstream

- Scintillator (for Transmission)
- Gas tracker (for spot)

measure Kr^{34+} **10 kcps** / 0.0001 enA


optimize **26 enA** primary beam Kr^{36+}

A. Compare Beam Spot measured by Viewer and Tracker


Change optics and compare

- fluorescent viewer image of primary beam (Kr^{36+})
- position distribution of secondary beam (Kr^{34+}) tracked by PPAC (gas detector)

Fluorescent viewer (Kr^{36+})



Gas tracker (Kr^{34+})




※ In this measurement, Fluorescent viewer was removed and Be 1mm was inserted.

A. Compare Beam Spot measured by Viewer and Tracker


Change optics and compare

- fluorescent viewer image of primary beam (Kr^{36+})
- position distribution of secondary beam (Kr^{34+}) tracked by PPAC (gas detector)

Fluorescent viewer (Kr^{36+})



Gas tracker (Kr^{34+})




※ In this measurement, Fluorescent viewer was removed and Be 1mm was inserted.

A. Compare Beam Spot measured by Viewer and Tracker


Change optics and compare

- fluorescent viewer image of primary beam (Kr^{36+})
- position distribution of secondary beam (Kr^{34+}) tracked by PPAC (gas detector)

Fluorescent viewer (Kr^{36+})



Gas tracker (Kr^{34+})




※ In this measurement, Fluorescent viewer was removed and Be 1mm was inserted.

A. Compare Beam Spot measured by Viewer and Tracker


Change optics and compare

- fluorescent viewer image of primary beam (Kr^{36+})
- position distribution of secondary beam (Kr^{34+}) tracked by PPAC (gas detector)

Fluorescent viewer (Kr^{36+})



Gas tracker (Kr^{34+})




※ In this measurement, Fluorescent viewer was removed and Be 1mm was inserted.

A. Compare Beam Spot measured by Viewer and Tracker


Change optics and compare

- fluorescent viewer image of primary beam (Kr^{36+})
- position distribution of secondary beam (Kr^{34+}) tracked by PPAC (gas detector)

Fluorescent viewer (Kr^{36+})



Gas tracker (Kr^{34+})




※ In this measurement, Fluorescent viewer was removed and Be 1mm was inserted.

各ハイパーパラメータでのシミュレーション結果の比較

LCB における β の違い (objective function: f_{sum} / phase ellipse C)

Lower Confidence Bound (LCB) / $\beta = 100.0$



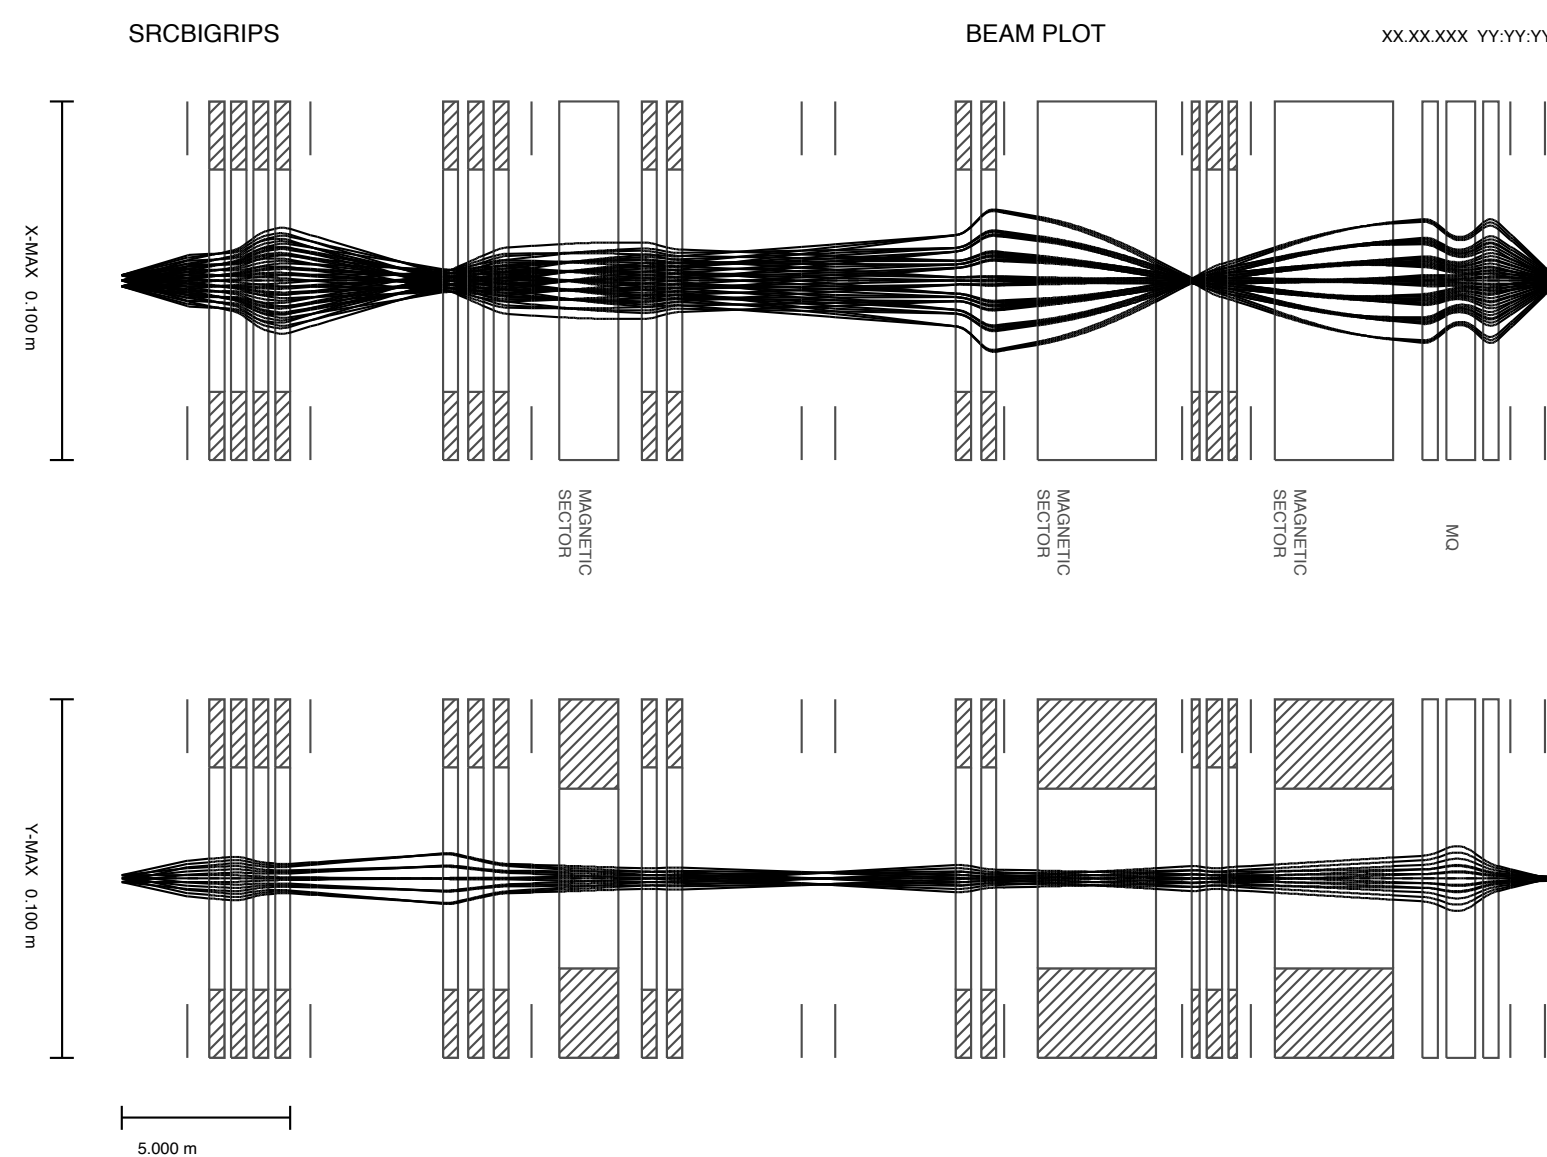
	epoch	obj.	transmission	σ_x	σ_y
最初に閾値を超えたもの	51	-2.46	0.966	0.59	0.92
best	290	-2.55	0.960	1.05	0.31

各 ハイパーパラメータでのシミュレーション結果の比較

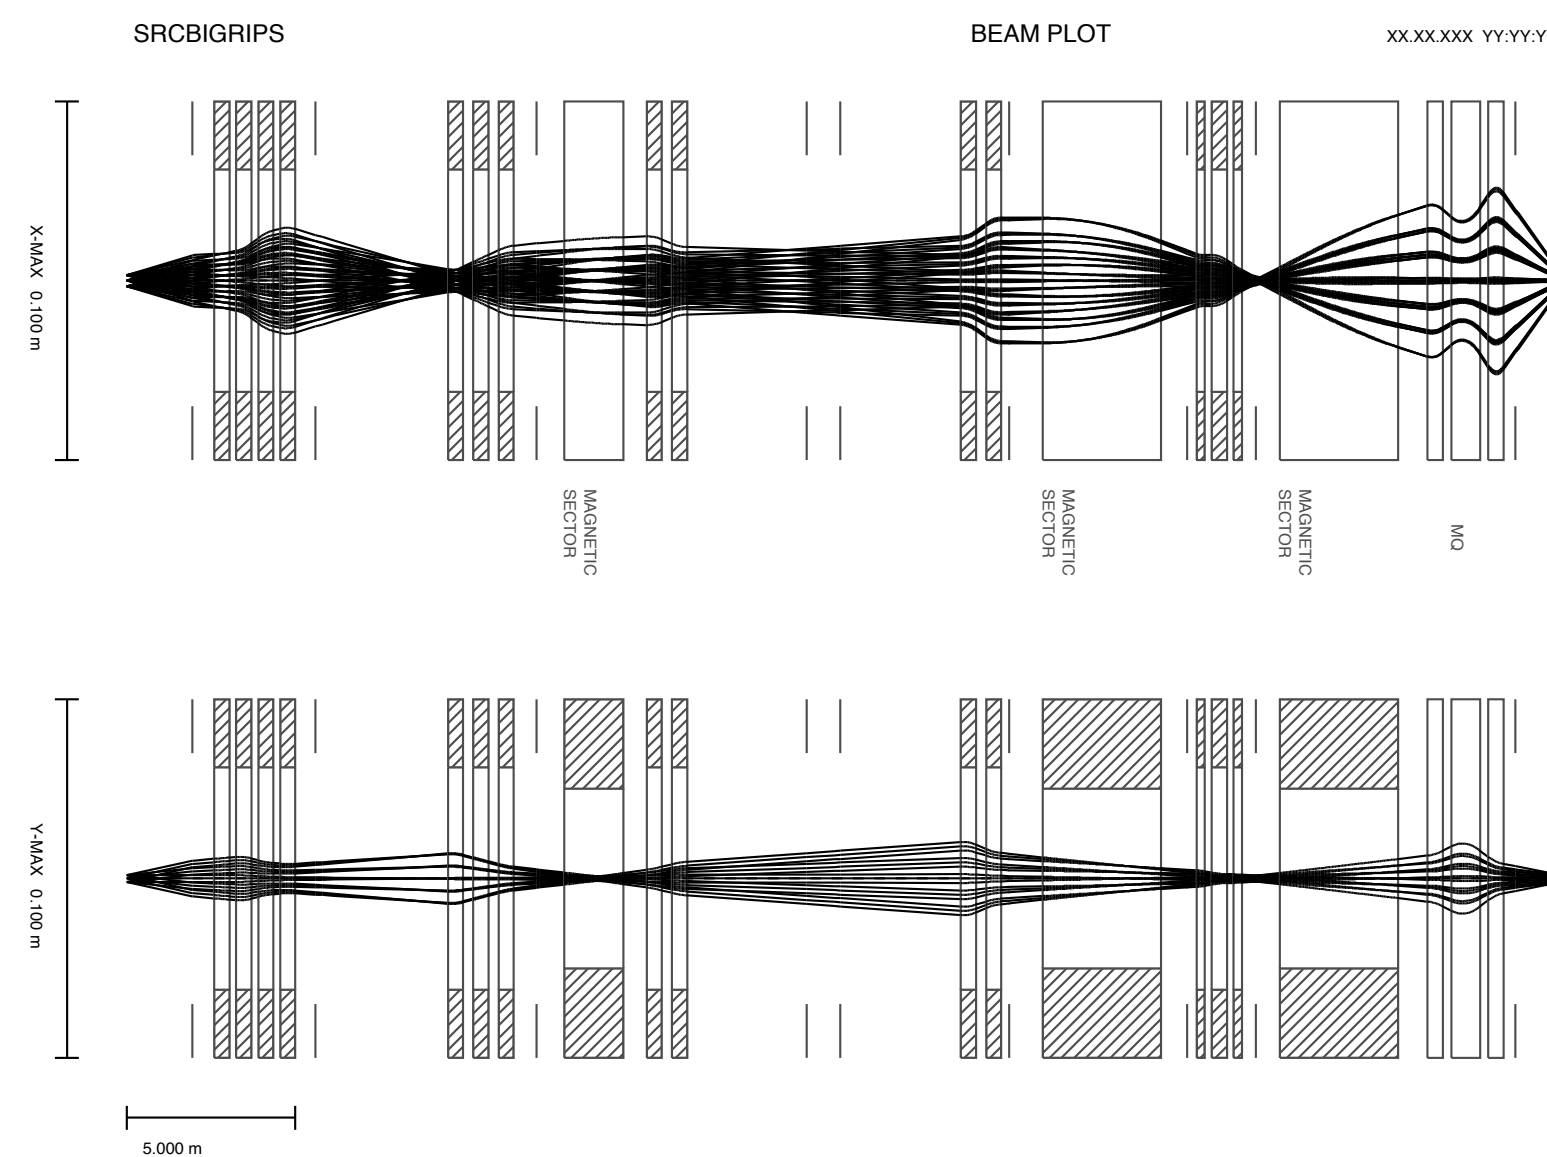
LCB における β の違い (objective function: f_{sum} / phase ellipse C)

Lower Confidence Bound (LCB) / $\beta = 100.0$


代表点 1 (89 epoch)



代表点3 (243 epoch)



代表点2 (290 epoch)



~ 最大 40 A 程度電流が変化している。