E70 meeting

2020/08/04

大橋

Contents

- 従来手法そのものを再現
  - Beam line
  - SKS
  - Beam line – SKS
- 位置検出分解能による影響
  - 影響を抑える工夫

TM(Beam line)をMLで再現

- E05 beam through event (104709 events)
- input: Focal Plane座標(XYUV), BFT pos
- Output: 輸送行列で求めた運動量$\delta_{TM} = (p_{TM} - p_0)/p_0$
  - p_0: TM中心運動量

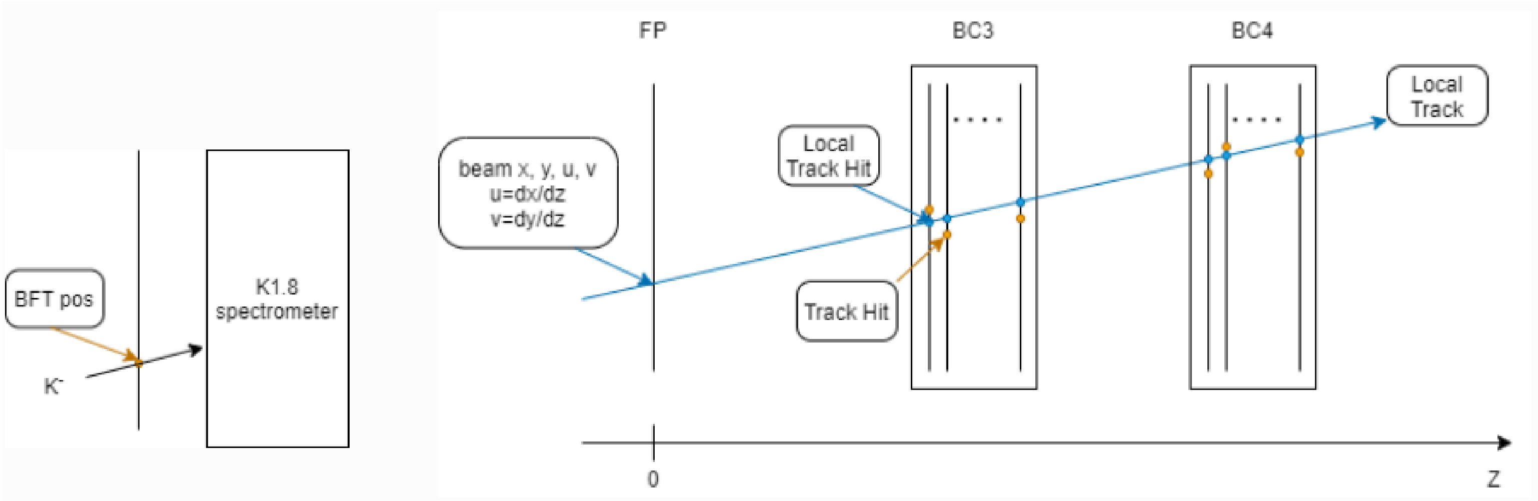

評価手法：Cross-validation

- 未知データに対してのモデルの性能を推定
- 全データに対しての予測値δ_{ML}を得る
- 分割数３とした

データを
いくつかに分割

Training dataで学習, test dataの予測値を出す
全ての分割(fold)で繰り返す

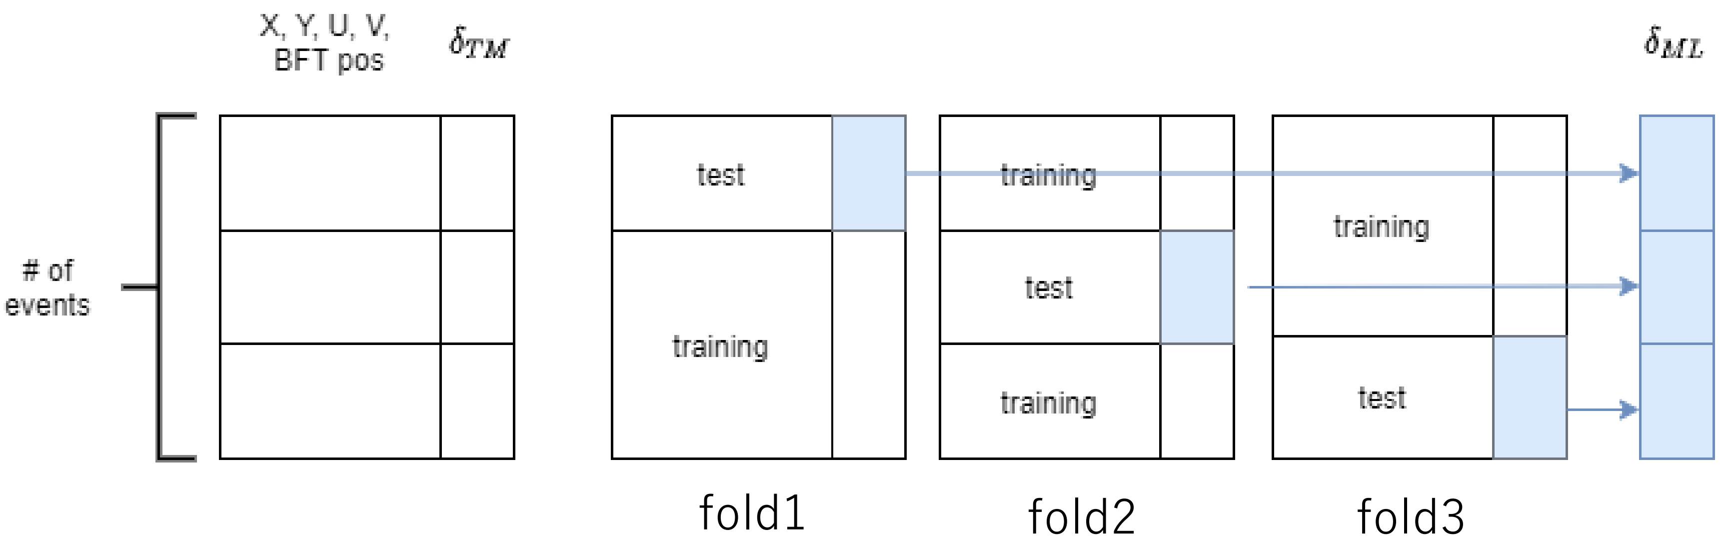

評価指標

- 「TMの結果とのずれ」
- 3つのδ_{ML}に対して
  - $\delta_{ML} - \delta_{TM} = (p_{ML} - p_{TM})/p_0$
  - [-0.001, 0.001], ビン数100でヒストグラム化
  - FWHMをとる
- 3つのFWHMとその平均を示す
- Delta_ML = (p_ML – p_0)/p_0

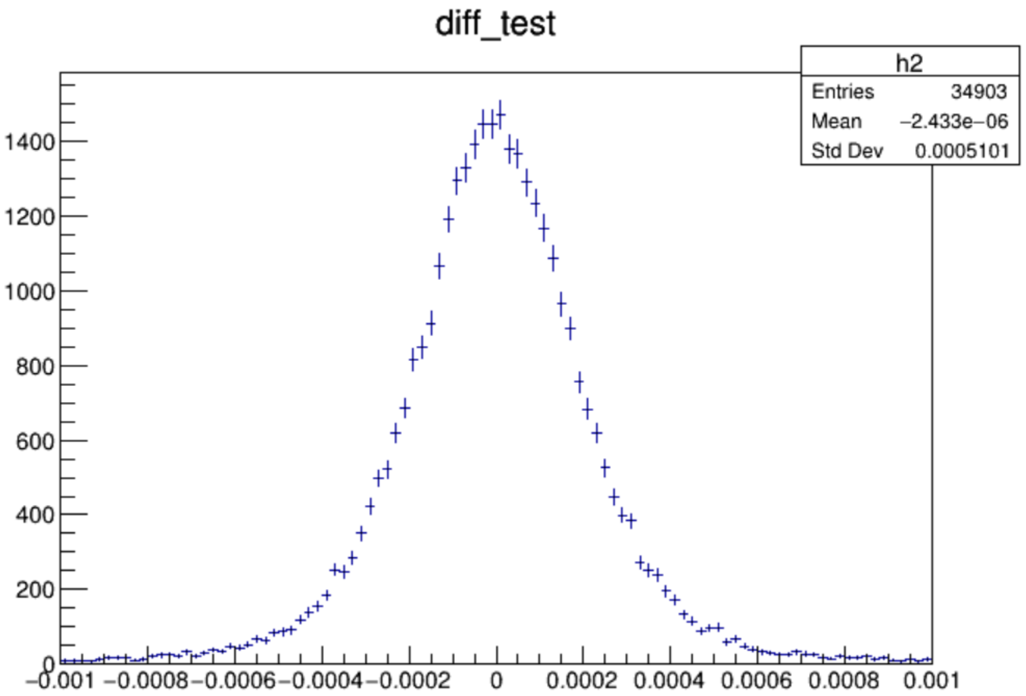

ヒストグラムの1例

学習方法

- Early stopping：過学習防止
  - Training dataをさらに9:1に分割(InnerTrain: InnerTest)
  - 9割のInner Trainを使って学習
  - 毎ステップごとに1割のInnerTestに対して評価
    - 評価指標：Root Mean Square Error
  - InnerTestの評価が100ステップ間改善が見られなければ、学習をストップ
- ２つのモデル
  - Light gbm: default hyper parameter(=lgb1)
    - https://lightgbm.readthedocs.io/en/latest/
  - Light gbm: hyper parameter tuning by optuna(=lgb2)
    - 分割パターンごとにチューニング
    - Optuna: hyper parameter tuningのフレームワーク
      - Light gbmに関しては経験的に重要なパラメータを選択してチューニング
      - https://optuna.readthedocs.io/en/stable/reference/generated/optuna.integration.lightgbm.train.html?highlight=lightgbm#optuna.integration.lightgbm.train

学習結果

FWHM

	Fold1	Fold2	Fold3	mean
lgb1	3.8×10^{-4}	3.8×10^{-4}	4.2×10^{-4}	3.9×10^{-3}
lgb2	3.6×10^{-4}	3.0×10^{-4}	4.8×10^{-4}	3.8×10^{-4}

$\Rightarrow (p_{ML} - p_{TM})/p_0 \sim 4 \times 10^{-4}$

Lgb2はどんなデータについて比較的よく再現できたのか？

- Input(BFT pos, XYUV)の散布図、ヒスト
  - 青：FWHM内
  - 橙：FWHM外

⇒橙の分布に特徴的な構造が見て取れる
  - Uのヒスト
  - 散布図に縞状構造

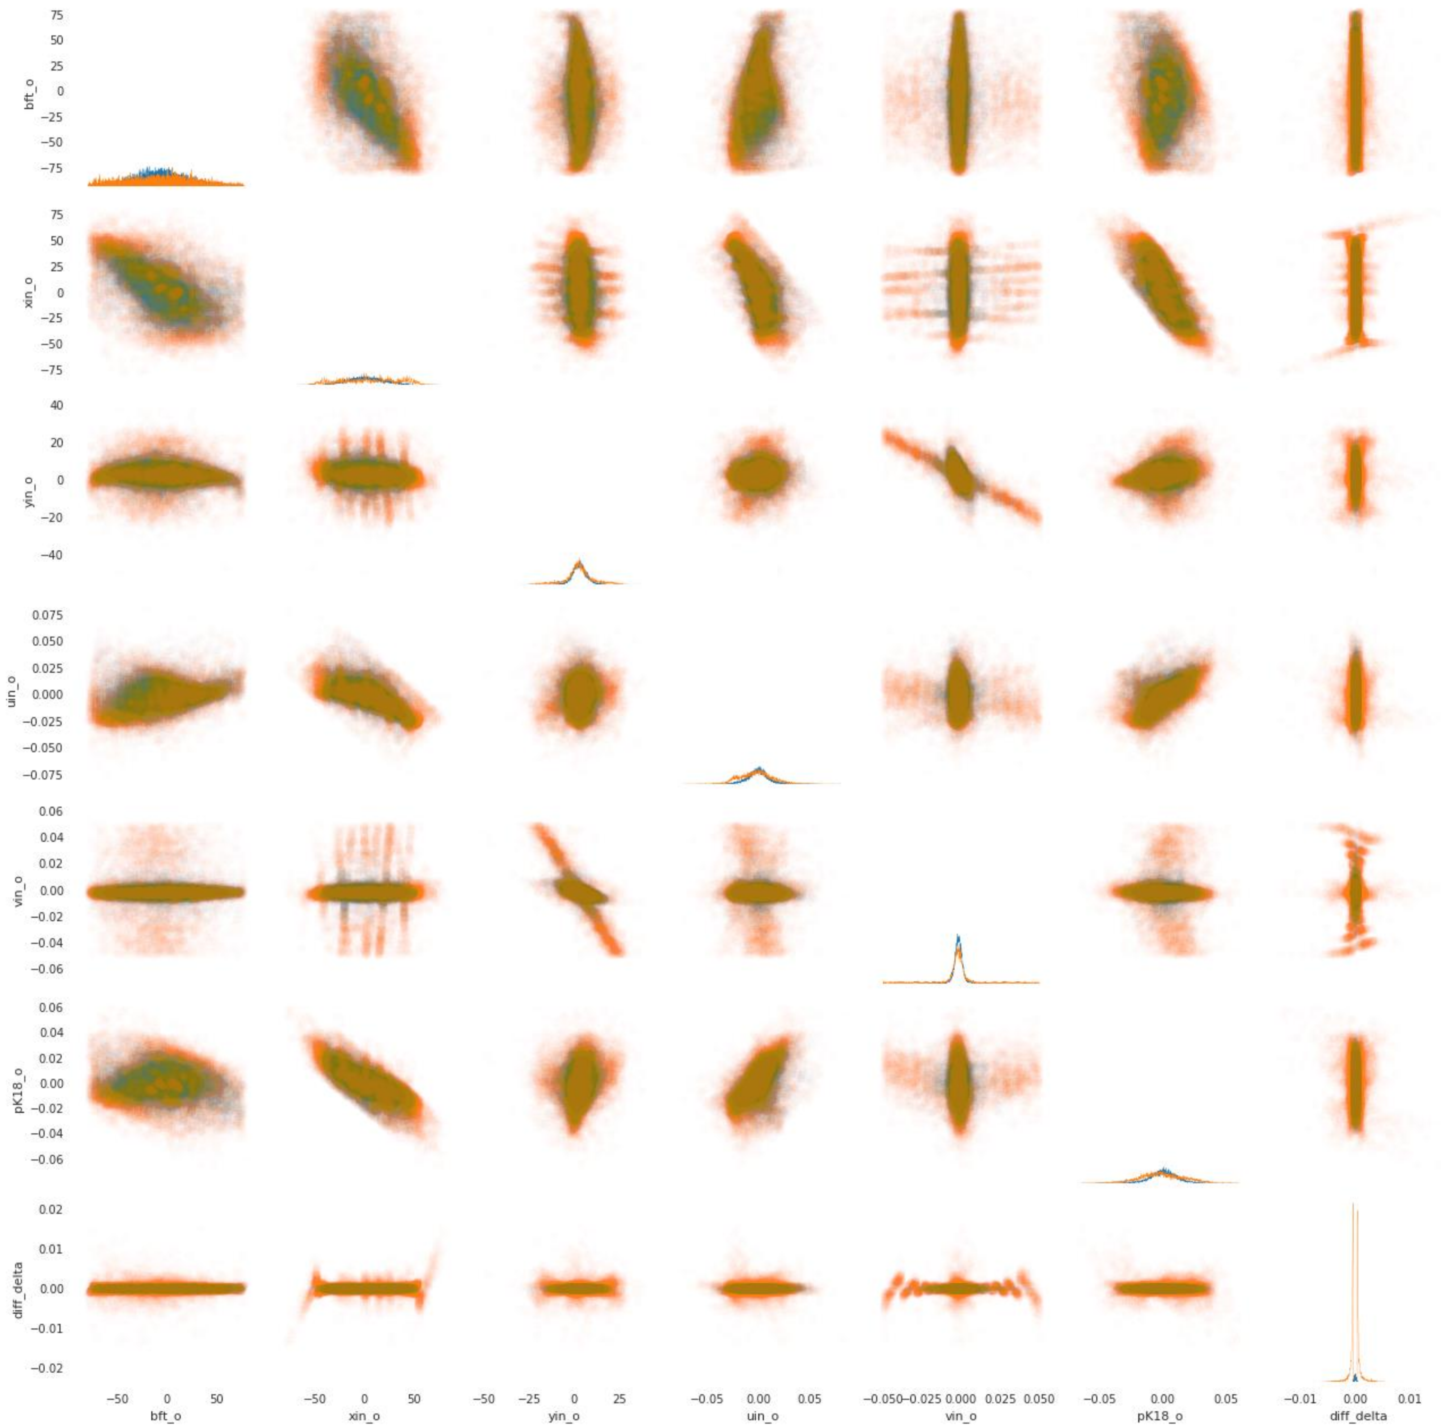

Lgb2の再現度が悪かったデータをもう一度重点的に学習させると？

- FWHM外になったデータを学習時に2倍に増加させる(lgb2_weight)
  - 詳細
    - Loss functionの計算時にFWHM外のデータのweightを増加
    - FWHM外のデータのweightをFWHM内のデータの2倍に
- 元々の結果(lgb2)と比較

	Fold1	Fold2	Fold3	mean
Lgb2	3.6×10^{-4}	3.0×10^{-4}	4.8×10^{-4}	3.8×10^{-3}
Lgb2_weight	5.0×10^{-4}	4.4×10^{-4}	5.8×10^{-4}	5.1×10^{-4}

- ⇒特異なデータの影響を受け、再現度は悪くなった

RK(SKS)をMLで再現

- TM(beam line)と同様の方法
- Input: XYUVin, XYUVout
- 評価指標
  - $p_{ML} - p_{SKS}$ [GeV/c]
  - p_0で割っていない
  - $\overline{p_{SKS}} = 1.8$ GeV/c

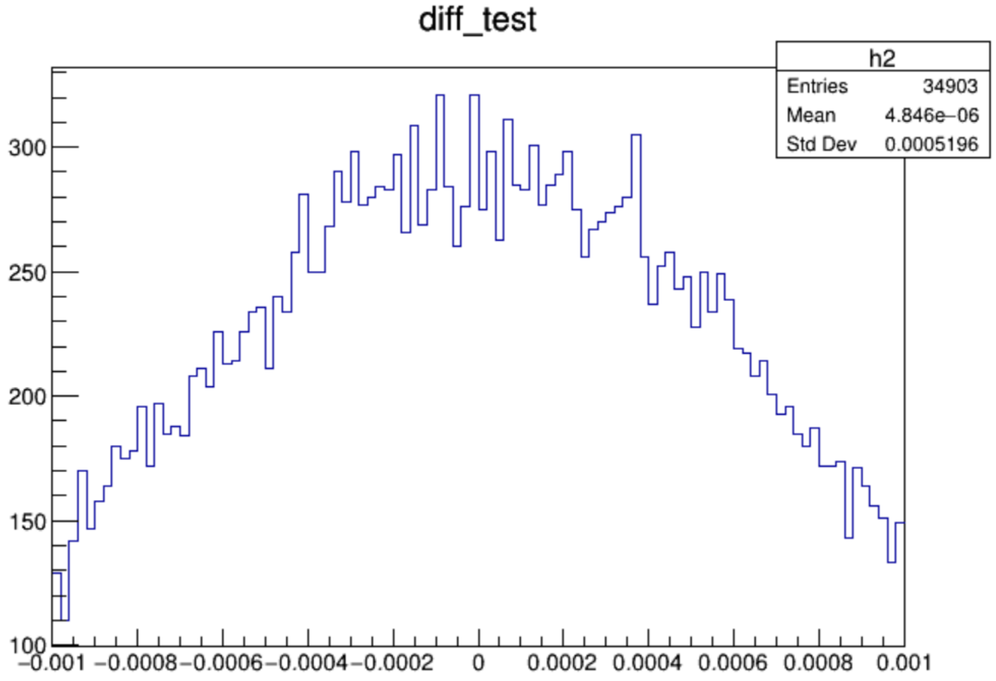

$p_{ML} - p_{SKS}$の一例

	Fold1	Fold2	Fold3	mean
lgb1	1.8×10^{-3}	2.0×10^{-3}	1.7×10^{-3}	1.8×10^{-3}
lgb2	2.0×10^{-3}	2.0×10^{-3}	2.0×10^{-3}	2.0×10^{-3}

- ⇒ $(p_{ML} - p_{SKS}) / \overline{p_{SKS}} = 1.0 \times 10^{-3}$

$p_{k18} - p_{SKS}$

- 従来法

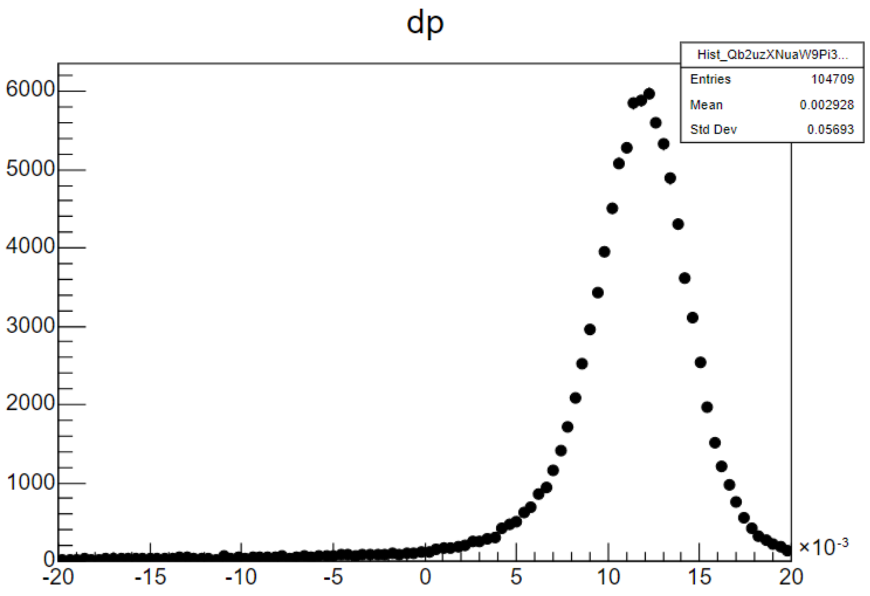

correction

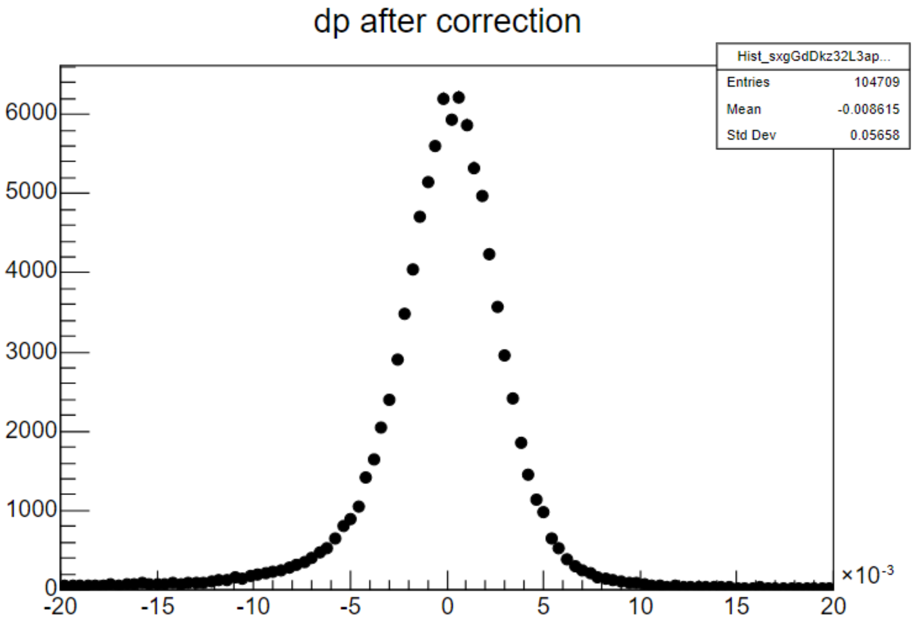

$p_{SKS} - p_{k18}$

- $p_{k18} - p_{SKS}$は従来法とMLでどう異なるか

$p_{k18}^{ML} - p_{SKS}^{ML}$？

- $\left(p_{k18}^{TM} - p_{SKS}^{RK}\right)/p_0 \sim 3 \times 10^{-3} (FWHM)$であった
- Lgb2で出したp_{k18}^{ML}，p_{SKS}^{ML}を対象
- 予想
  - $\left(p_{k18}^{ML} - p_{k18}^{TM}\right)/p_0 \sim 4 \times 10^{-4}, \left(p_{SKS}^{ML} - p_{SKS}^{RK}\right)/p_0 \sim 1 \times 10^{-3}$より二乗和で考えると$\left(p_{k18}^{ML} - p_{SKS}^{ML}\right)/p_0 \sim 3.2 \times 10^{-4}$？

$$\left(p_{k18}^{ML} - p_{SKS}^{ML}\right)/p_0$$

- 青：従来法
  - FWHM~3×10^{-3}
- 赤：ML
  - FWHM~3.2×10^{-3}

- ⇒予想通りの差分

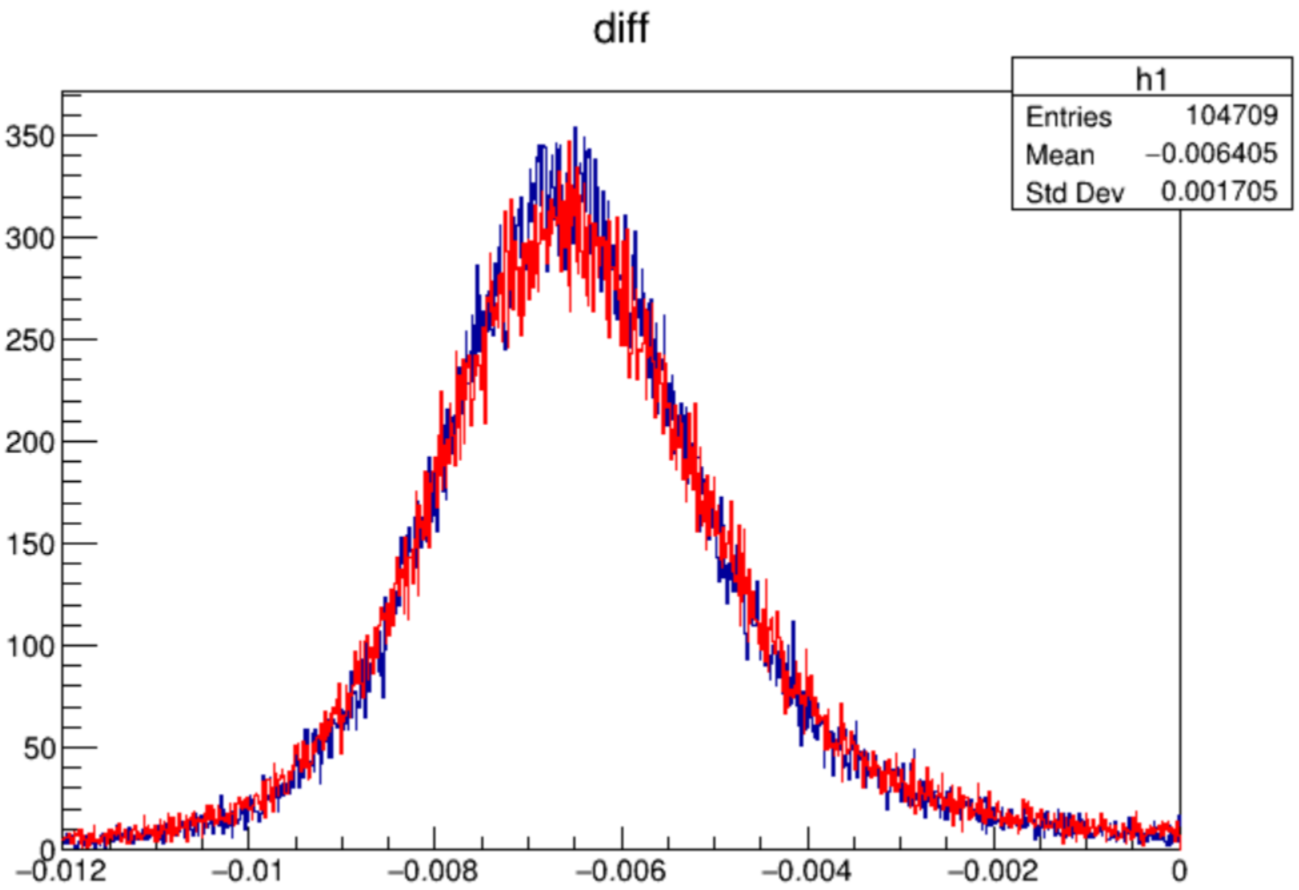

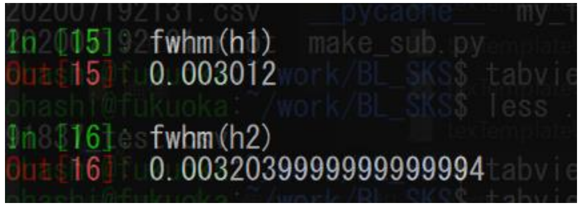

入力データを変える

- TM,RKの再現のインプットに、それぞれk1.8での座標、SKSでの座標のみを与えていた。
- 再現時に、すべての座標(BFT pos, k1.8out, SKSin, SKSout)を与えると？
- 予想
  - TM, RKはそれぞれの座標しか用いていないのでMLの結果に変化はない
  - むしろ、あると誤った学習を疑う

入力データを変える

- モデルはlgb2に固定
- 評価指標は先ほどまでと同じ
  - SKS [GeV/c] に注意
- 結果（座標全て）

	Fold1	Fold2	Fold3	mean
K1.8	3.2×10^{-4}	3.0×10^{-4}	3.8×10^{-4}	3.3×10^{-4}
SKS	1.9×10^{-3}	2.0×10^{-3}	1.7×10^{-3}	1.9×10^{-3}

- 比較の為に、以前の結果（座標それぞれのみ）

	Fold1	Fold2	Fold3	mean
K1.8	3.6×10^{-4}	3.0×10^{-4}	4.8×10^{-4}	3.8×10^{-4}
SKS	2.0×10^{-3}	2.0×10^{-3}	2.0×10^{-3}	2.0×10^{-3}

⇒有意な差はなし（に見える）

位置情報のブレに対する頑健性