



MeVガンマ線カメラの点源分解能改善のための研究

池田智法

谷森達, 高田淳史, 吉川慶, 阿部光, 水村好貴^A, 竹村泰斗, 中村優太, 小野坂健, 齋藤要, 荻尾真吾, 津田雅弥, 吉田有良, 窪秀利, 黒澤俊介^B, 身内賢太郎^C, 澤野達哉^D, 濱口健二^E

京大理, JAXA^A, 東北大^B, 神戸大理^C, 金沢大数物^D, メリーランド大学^E

2020年度大気球シンポジウム

背景

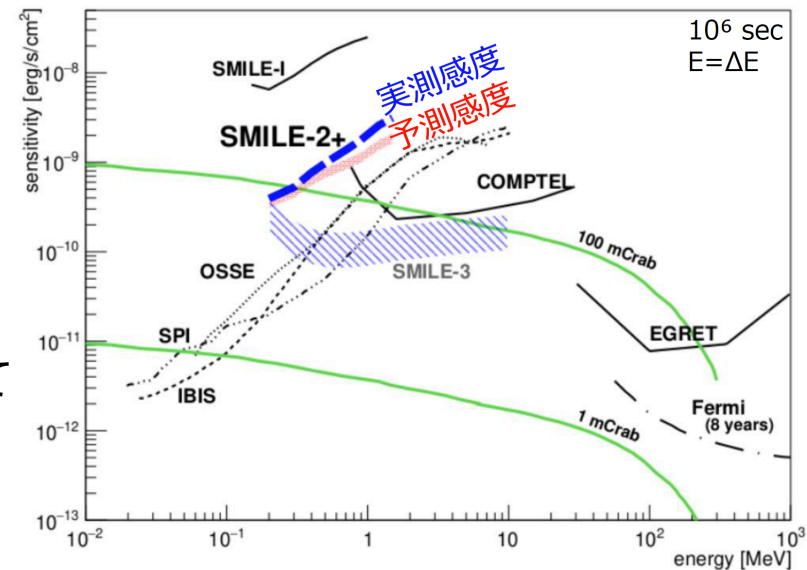


✓ SMILE-3の科学観測に向けて

- 有効面積：5倍

- 点源分解能：数度


詳細は次の津田の講演にて



➤ 解析方法の側面から、点源分解能の向上を目指す

→SMILE-2+@豪州のさらなる詳細解析もできる

ETCC望遠鏡と点源分解能



✓ ETCC検出器は1ガンマ線事象ごとに到来方向決定が可能

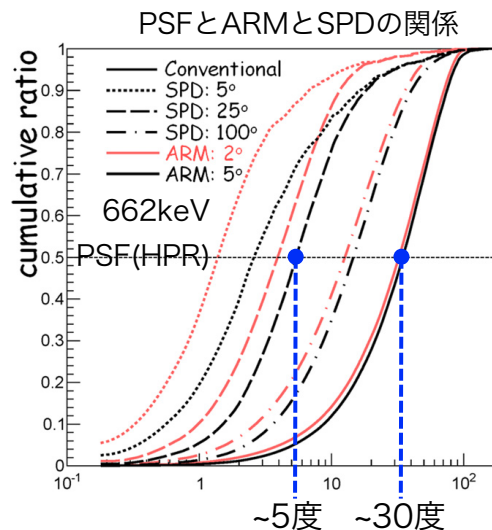
✓ 点源分解能(PSF)を決定する二つの要素

Angular Resolution Measure (ARM):

コンプトン散乱角の決定精度

Scatter Plane Deviation (SPD):


散乱方向を軸とする散乱平面の決定精度



➤ PSFの向上には、**SPD**の改善が必須


T. Tanimori, Apj(2015)

ETCC検出器と点源分解能




- ✓ SPDを特徴づける二つのパラメータ:
散乱点と電子の反跳方向
- ガス μ TPCで得られた飛跡情報から算出される

Micro Pixel Chamber (μ -PIC)



2次元ガスイメージング検出器



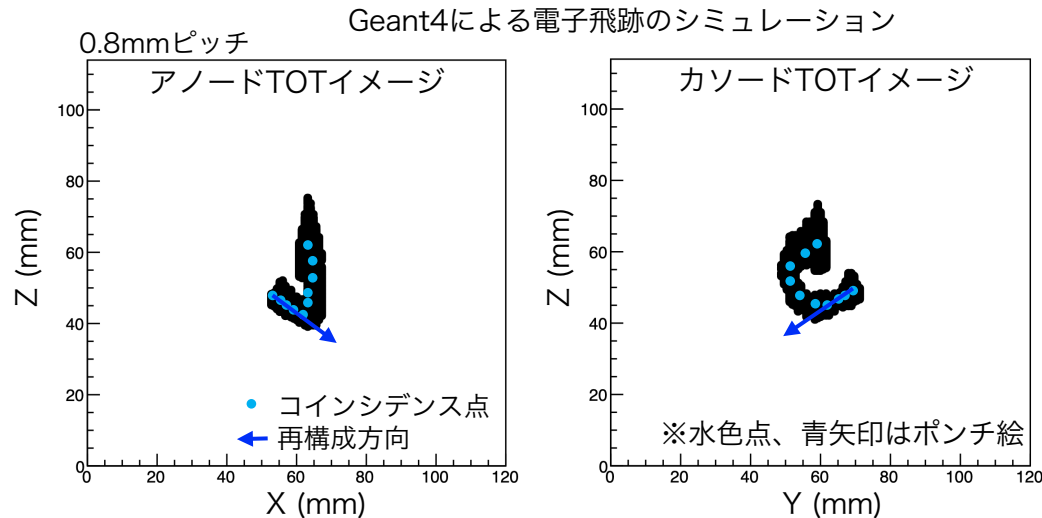
30cm角 μ -PICの実物写真

- ✓ 個々のピクセルでガス増幅(max ~15000)
- ✓ ピクセル間隔: 400 μ m (SMILE2+では800 μ m)
- ✓ ストリップ型読み出し
- ✓ アノードとカソードで時間のコインシデンスによって
3次元飛跡を再構成可能

従来の散乱点と方向再構成方法



- ✓ μ -PICで得られる情報→アノード・カソード平面のTOTイメージ




- ✓ 従来の再構成方法: **TOT-Skewness法**
 - 電荷(TOT)の偏り(Skewness)から散乱点を決定

$$Skewness = \frac{\sum_i^n TOT_i \times (x_i - \langle x \rangle)^3}{n}$$

- タイムウォークを考慮して、時間コインシデンスをとることで飛跡を再構成し、直線フィットによって方向を決定


TOTの概念図



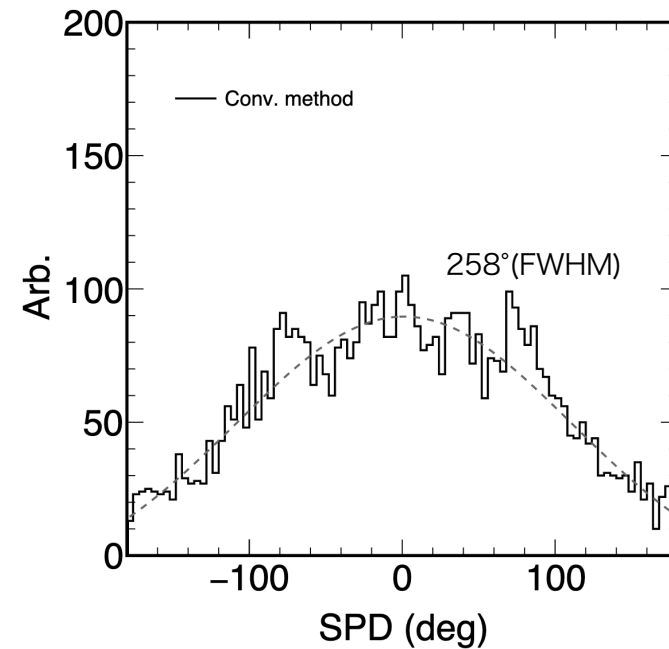
従来の散乱点と方向再構成方法



角度誤差とエネルギー依存性



従来解析のSPD分布



- 従来の解析方法ではSPD=260度で留まっている
- 他の精度の高い再構成方法を模索する


機械学習の試行



✓ 画像認識は機械学習が得意

- 手書き数字(MNIST)の識別正答率99%以上
<https://paperswithcode.com/sota/image-classification-on-mnist>

MNISTのデータ

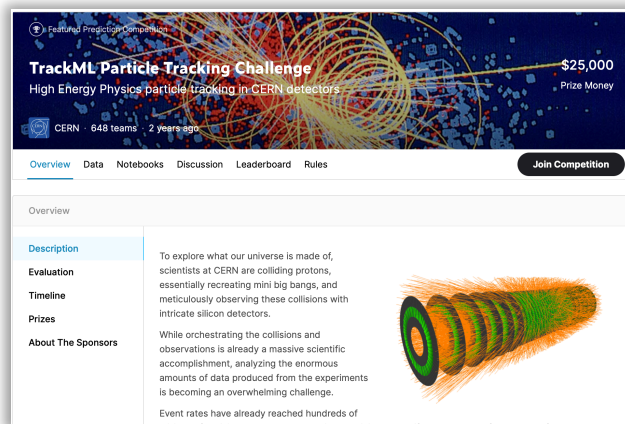


✓ 物理学の分野への応用も盛ん

- KaggleとCERNが共同でコンペを開催(2018)
- MicroBooNE実験のCNN(畳み込みニューラルネットワークを使った粒子識別、Phys. Rev. D 99,092001(2019)
- ガスPIXEL検出器の電子の反跳方向をCNNで決定、NIM A 942(2019) 162389

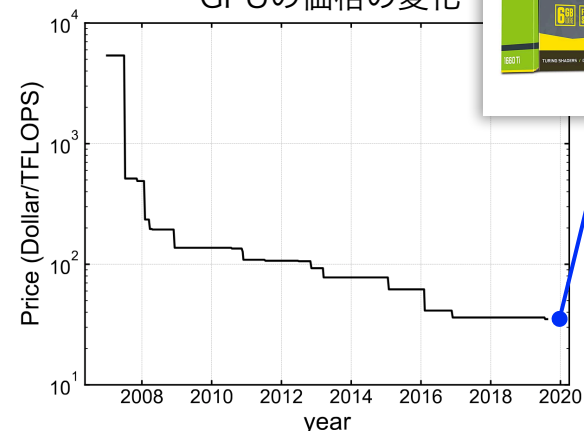
✓ GPUの価格もリーズナブルに

→試してみた



<https://www.kaggle.com/c/trackml-particle-identification>

GPUの価格の変化




GTX 1660Ti
5.5 TFLOPS
~30,000円

出典: <https://aiimpacts.org/2019-recent-trends-in-gpu-price-per-flops/#easy-footnote-23-2316>


機械学習(深層学習)の流れ




■ 入力



■ 畳み込みニューラルネットワーク(CNN)



■ 出力




■ 入力

- Geant4で56万の電子の飛跡(5-200keV)をシミュレーション
- 電気回路の応答をエミュレート
- 150×300pixel@5-50keVのTOTイメージ図の作成
- 1pixel = 0.8mm(μ -PICストリップ幅)×0.38mm(ドリフト速度×10ns)


機械学習(深層学習)の流れ




■ 入力



■ 畳み込みニューラルネットワーク(CNN)



■ 出力




■ 畳み込みニューラルネットワーク(CNN)

- Keras(2.3.1)/Tensorflow(2.1.0)を使用
- 多クラス分類に使用される一般的なネットワークを使用
 - (畳み込み層・プーリング層)×4 + Dropout層
 - 損失関数: 交差エントロピー
 - 24万のパラメータ
- 訓練データ56万イベントをミニバッチ学習
- 使用したGPU: GTX 1660Ti
 - 6GBメモリ、1536コア、1.5GHz
 - 1試行(epoch)あたり10秒(左のネットワークで)


機械学習(深層学習)の流れ



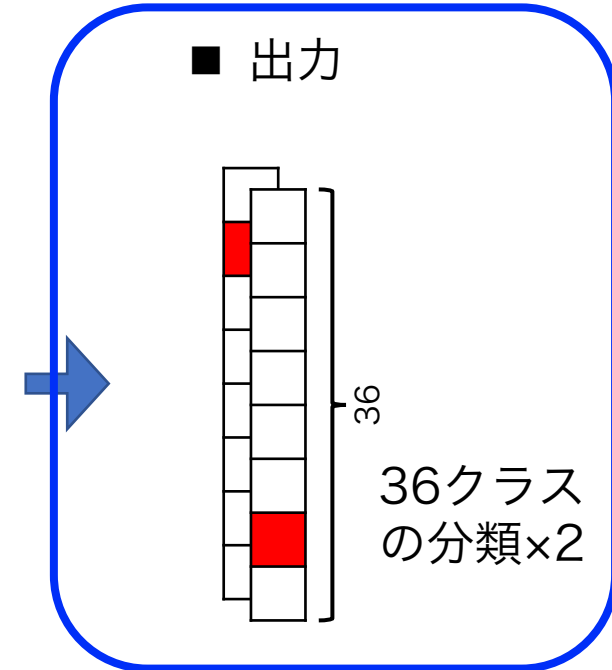
■ 入力



■ 畳み込みニューラルネットワーク



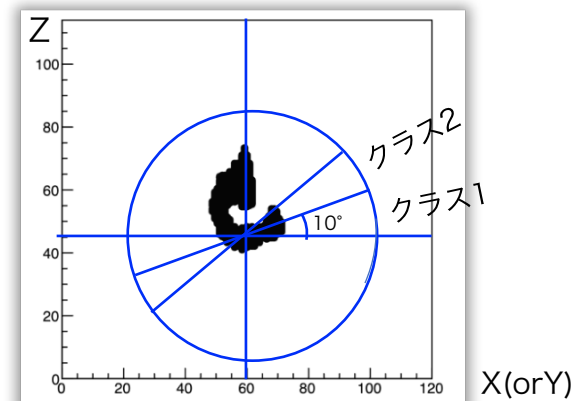
■ 出力



■ 出力

- ソフトマックス関数で活性化
- アノード・カソード画像の角度を36等分した確率分布が得られる

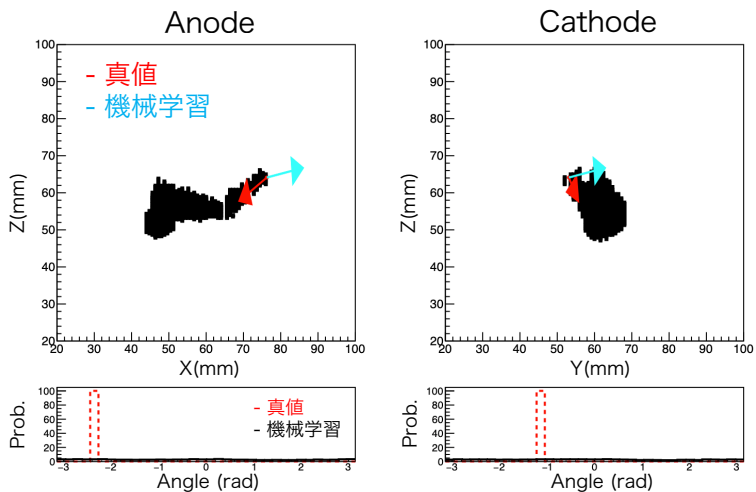
※今回は方向のみ学習・予測



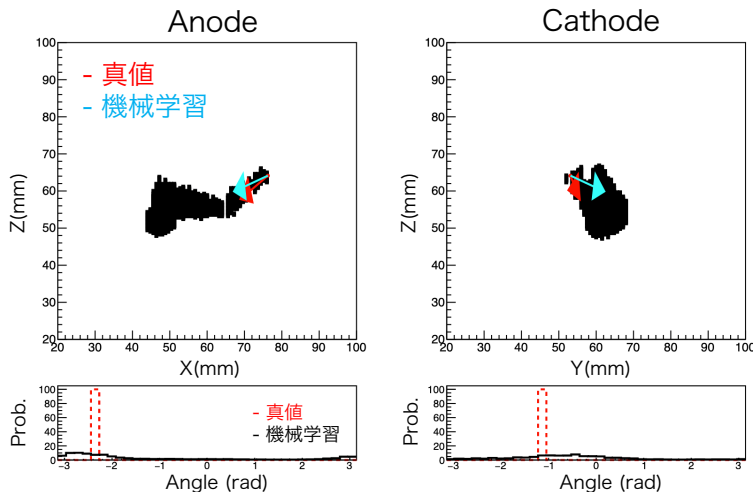
学習経過



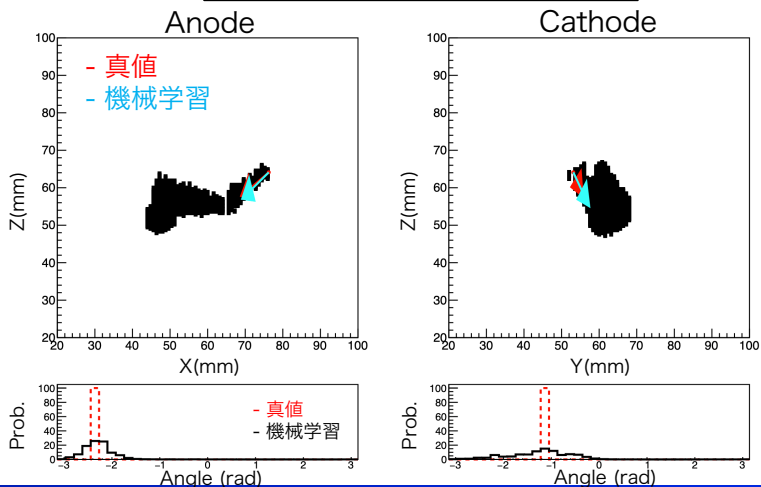
試行回数(Epoch数) 1



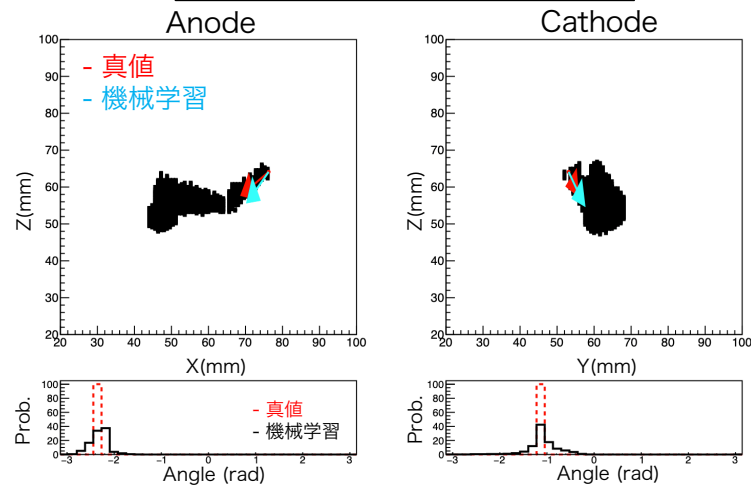
試行回数(Epoch数) 10



試行回数(Epoch数) 40



試行回数(Epoch数) 100



50-100keV
電子シミュレーション
800 μ mピッチ

イベント例



電子シミュレーション
800 μ mピッチ

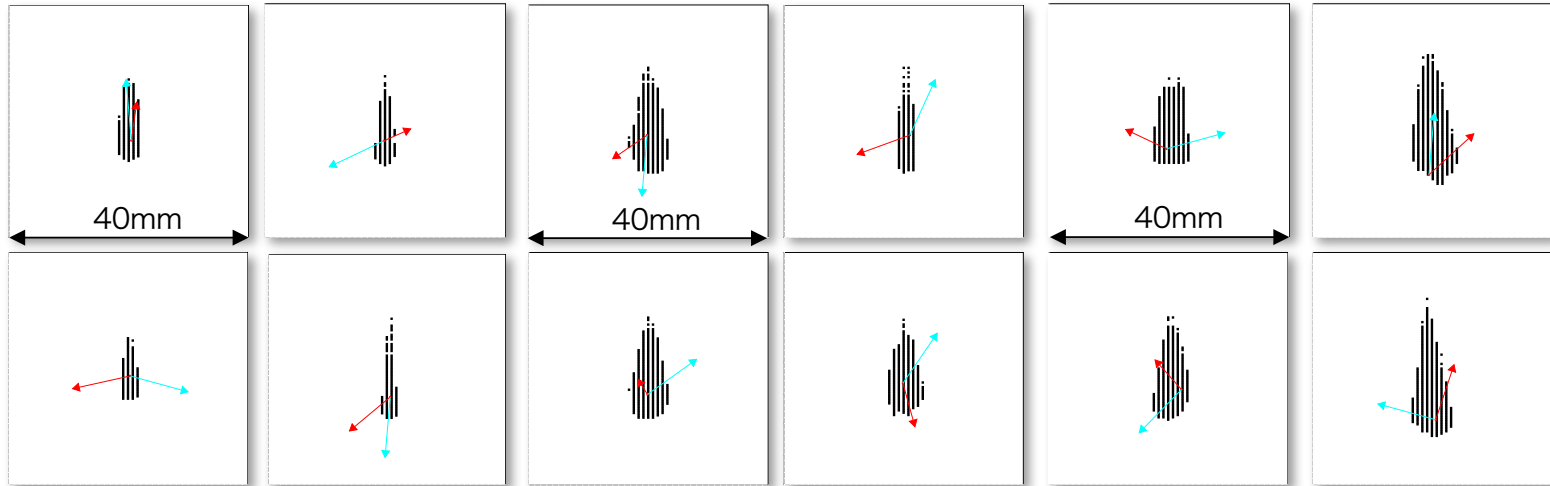
赤：真値

水色：機械学習

10-20 keV

20-30 keV


30-40 keV



40-50 keV

50-100 keV

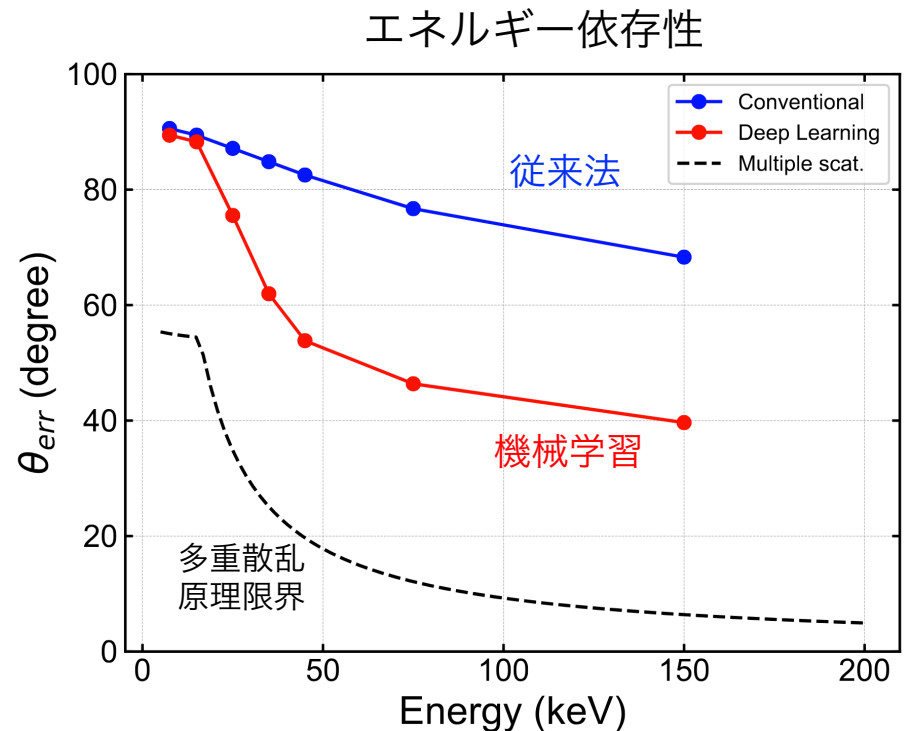
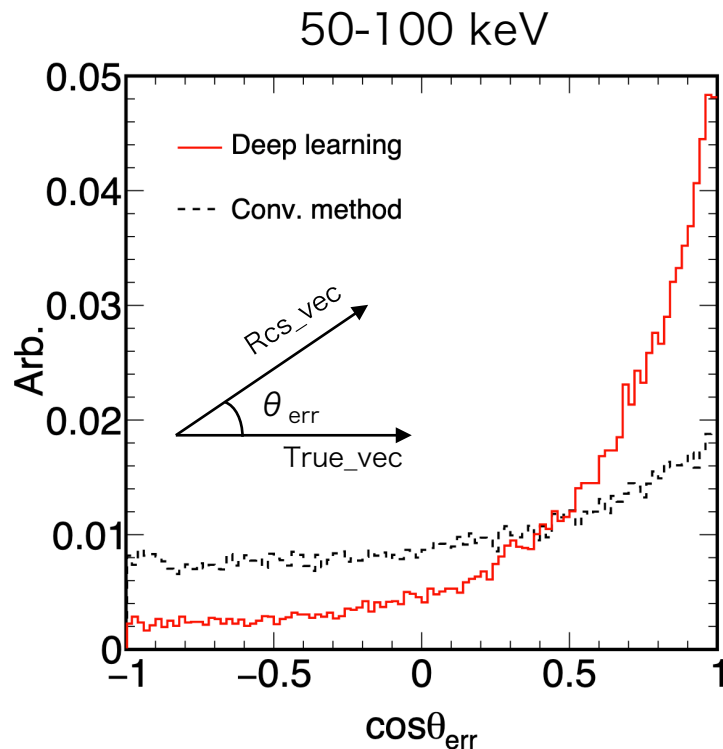
100-200 keV



散乱方向の誤差評価



- 機械学習によって再構成された散乱方向と真の散乱方向の間の角を誤差角度として評価

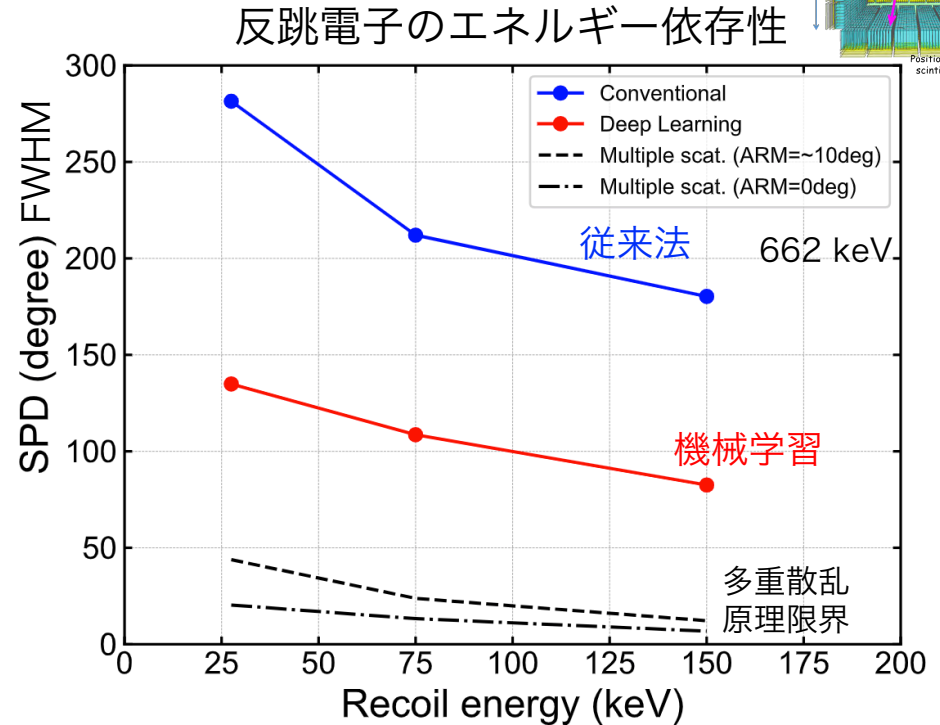
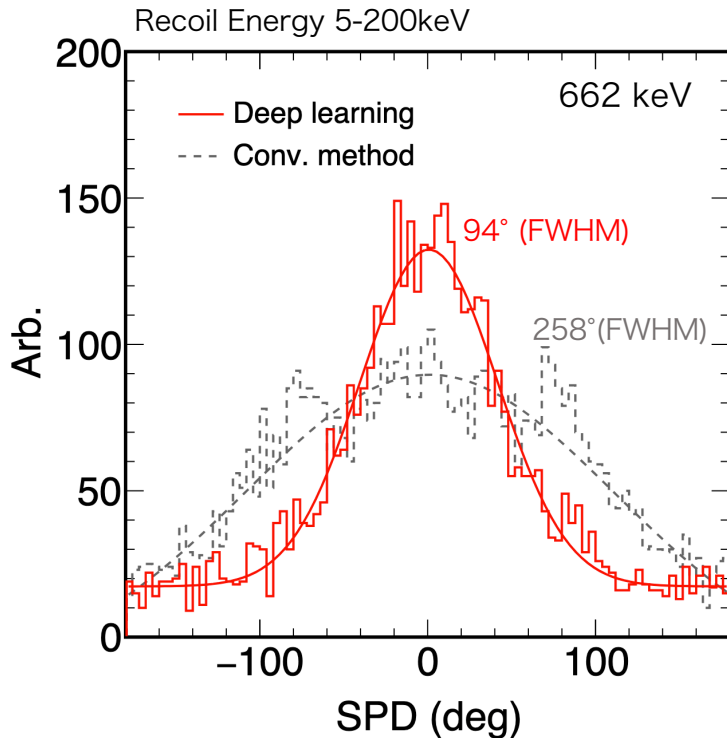



- 従来法と比べて精度が向上、[1.7倍@50-100keV](#)
- ~50度@75keVはシリコン(Si)の30 μ mの飛跡の多重散乱相当

SPD(FWHM)の評価



- Geant4で662keV(^{137}Cs)のガンマ線のシミュレーション



- 従来法に比べて、SPDが2倍以上改善@662keV
- SMILE2+検出器のデータでも、CNNを使った解析は有効な手段

まとめ



- ✓ ETCC検出器の点源分解能(PSF)向上にはSPDの改善が必須
- ✓ Keras/Tensorflowを使って畳み込みニューラルネットワークを構築、電子の反跳方向を学習させた
 - 56万の学習データをMCシミュレーションで作成
 - アノード・カソードTOTイメージを入力
 - 36クラス分類で評価
- ✓ 反跳方向誤差は従来に比べて1.7倍改善、 ~ 50 度@50-100keV
- ✓ SPDは2倍以上改善、 ~ 94 度@662keV
- ✓ 今後、実データについても試行予定




バックアップ

方向一様性の図




- 50-100keVの電子ビーム一様照射シミュレーション、20000イベント
- 再構成方向分布

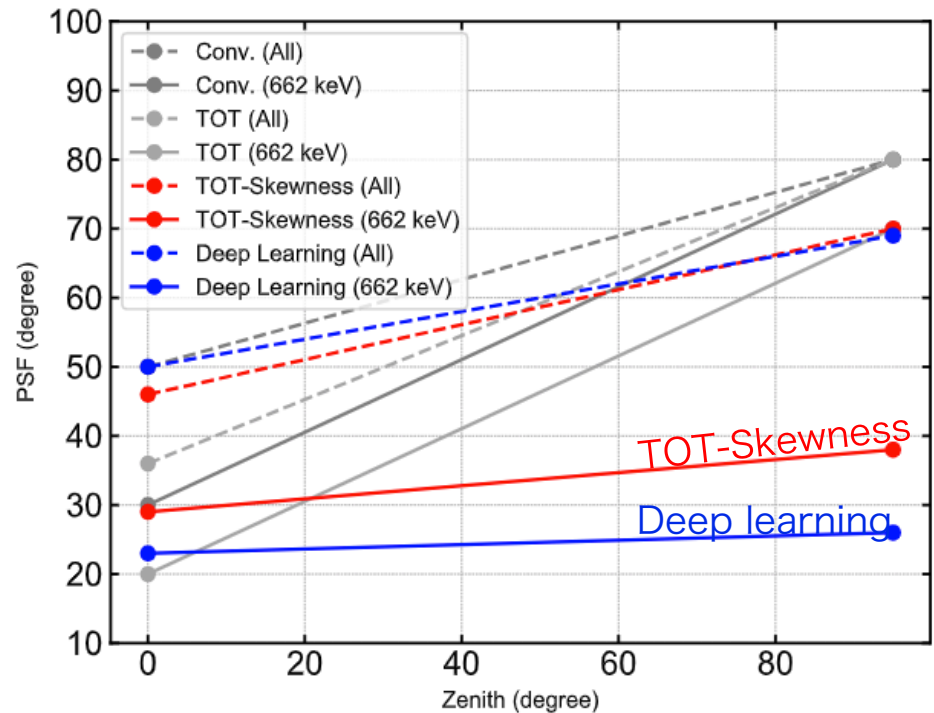

機械学習




従来法(TOT-Skewness)



PSFのZenith角度依存性







40-50keV 電子シミュレーション

