

# 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<sup>1</sup>, 谷森達<sup>1</sup>, 高田淳史<sup>1</sup>, 吉川慶<sup>1</sup>, 阿部光<sup>1</sup>, 水村好貴<sup>2</sup>, 竹村泰斗<sup>1</sup>, 中村優太<sup>1</sup>, 小野坂健<sup>1</sup>, 齋藤要<sup>1</sup>, 荻尾真吾<sup>1</sup>, 津田雅弥<sup>1</sup>, 吉田有良<sup>1</sup>, 窪秀利<sup>1</sup>, 黒澤俊介<sup>3</sup>, 身内賢太郎<sup>4</sup>, 澤野達哉<sup>5</sup>, and 濱口健二<sup>6</sup>

<sup>1</sup> 京都大学, <sup>2</sup> JAXA, <sup>3</sup> 東北大学, <sup>4</sup> 神戸大学, <sup>5</sup> 金沢大学, <sup>6</sup> メリーランド大学

## 概要

SMILE プロジェクトでは ETCC 望遠鏡を開発してきた。ETCC 望遠鏡の点源分解能は電子の反跳方向と散乱点の決定精度に大きく依存しているため、これらを改善することは ETCC 望遠鏡の重要な課題となっている。本研究では畳み込みニューラルネットワークを利用して、シミュレーションで模擬されたガス飛跡検出器のイメージデータから電子の反跳方向を決定し、その精度を評価した。結果、50-100 keV の電子に対して従来使われてきた解析法と比べて 1.7 倍精度が向上した。また、662 keV のガンマ線に対して散乱ガンマ線の方に垂直な面の決定精度 (SPD) は 2 倍以上改善した。したがって、畳み込みニューラルネットワークはガス飛跡検出器で得られる電子の飛跡解析にも有用性が確認され、これにより ETCC 望遠鏡の点源分解能の向上が期待できる。

## 1 はじめに

宇宙 MeV ガンマ線観測では元素合成や活動銀河核、ガンマ線バーストにおける粒子加速、ブラックホール近傍の強い重力場、宇宙線と星間物質の相互作用といった現象を観測できると期待されている。しかし、MeV 帯域のガンマ線観測は keV・TeV 帯域に比べて検出感度が非常に悪く、20 年以上前に発表された COMPTEL の衛星実験 [1] が現在でも最も感度の良い観測結果となっている。図 1 に keV・MeV 帯域について、現在までに行われたガンマ線観測の  $3\sigma$  の点源検出感度を示した。MeV ガンマ線観測が停滞してきた主な理由は、MeV 帯域のイメージング技術が確立しておらず、多くの雑音ガンマ線が視野内に混入しているため、予測よりもはるかに悪い実測感度しか到達できていないためである。そこには従来型のコンプトン望遠鏡が採用されており、入射ガンマ線の方角を統計的手法でしか推定できないといった根拠的な原因が存在している。そこで、SMILE プロジェクトでは MeV ガンマ線に関しても光学原理に基づく定量的なイメージングができるように、入射ガンマ線の方角を一意的に決定することができる電子飛跡検出型コンプトン望遠鏡 (ETCC) を開発してきた [2]。2018 年の気球実験 SMILE2+ ではその予測感度が実測感度と完全に一致し、ETCC 望遠鏡の性能を証明した [3]。この結果をもとに、2024 年以降に 1ヶ月間の気球実験によって

宇宙 MeV ガンマ線を観測する SMILE3 実験が計画されており、COMPTEL 実験の 10 倍良い検出感度での探索には ETCC 望遠鏡の点源分解能 (PSF) を改善する必要がある。




図 1: keV・MeV・sub-GeV 帯域のガンマ線の  $3\sigma$  点源検出感度図。緑の実践はそれぞれ OSSE, SPI, IBIS による keV 領域の観測。青は EGRET, Fermi-LAT の sub-GeV 領域の観測。黒の実践は COMPTEL による MeV 領域の観測。

## 2 ETCC 望遠鏡と点源分解能

従来型コンプトンカメラは散乱点と散乱ガンマ線のエネルギーだけを取得していたことで、ガンマ線の到来方向を円環状にしか再構成できていなかった。一方、ETCC 望遠鏡は加えて電子の反跳方向も取得している。これによって、コンプトン散乱運動学を完全に解き、ガンマ線の到来方向を一意に決定することが可能である。

SMILE プロジェクトで開発している ETCC 望遠鏡の模式図を図 2a に示す。ETCC 望遠鏡の PSF はコンプトン散乱角  $\phi$  の決定精度 (ARM) と散乱ガンマ線の方向に垂直な面の決定精度 (SPD) によって特徴づけられている。これらの依存関係を数値計算によって求めた結果を図 2b に示した。この図から SPD が数百度の悪いところでは ARM による PSF の改善は期待できず、SPD の向上が重要な要素であることがわかる。また、SPD は散乱点と反跳電子の決定精度に依存している。したがって、電子の飛跡を精度よく再構成できるかどうかが鍵となってくる。

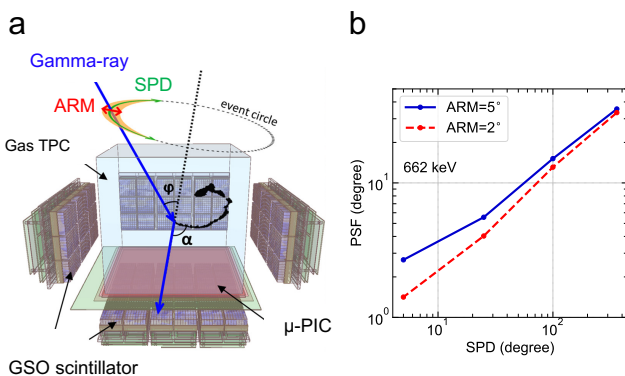


図 2: a:ETCC 望遠鏡の模式図。b:662 keV のガンマ線に対する、数値計算によって得られた PSF と SPD, ARM の関係。

SMILE プロジェクトでは反跳電子の飛跡情報をより細かく捉えるために、2次元ガス飛跡検出器  $\mu$ -PIC [4] を読み出しに利用したガス TPC を用いている。 $\mu$ -PIC は 400  $\mu$ m ストリップ間隔のアノード・カソードストリップが垂直な方向に並べられた構造をしており<sup>1</sup>、それぞれから得られた 2 枚のイメージデータによって、散乱点と反跳方向が算出される。従来の解析手法では、ストリップ位置の電荷の偏りから散乱点を決定していた。また反跳方向は、アノードとカソードの同時刻計測を用いて 3 次元の飛跡を再構成し、散乱点から一定の距離内の

<sup>1</sup>SMILE2+実験では 2 ストリップ毎に接続しているため、0.8  $\mu$ m 間隔の読み出しとなっている

再構成点を線形フィットすることで算出していた。しかし、電子拡散の効果や多重散乱によってその決定精度が悪化している。そこで、本研究では画像認識精度の高い畳み込みニューラルネットワークを用いて、2 枚のイメージデータから反跳方向を直接決定することを試行した。

## 3 畳み込みニューラルネットワークによる飛跡解析

機械学習は今日のコンピュータサイエンスの分野で急速に発展しており、その中でも画像認識では畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) が非常に良い性能を示している。手書き数字データベース (MNIST [6]) を使った数字認識では 99% 以上の正答率を得ていることが一つの良い例である。近年では素粒子・宇宙観測実験の解析への応用も盛んに行われてきた [7, 8]。また、計算リソースである GPU の価格は年々下落しており、TensorFlow [5] などのオープンソースの機械学習用フレームワークも充実してきている。これらも本研究の一つの背景となっている。

人工ニューラルネットワークはノードを持ったいくつかの層から構成される。ノードの入力値は前段のノードの線形結合とバイアスによって計算され、非線形変換である活性化関数によって出力値が決定される。線形結合の重みとバイアスはフリーパラメータであり、入力と出力がペアとなっている教師データによる学習によって最適化される。

CNN は人工ディープニューラルネットワークの一種であり、入力層、隠れ層、出力層を持つ。隠れ層は畳み込み層、プーリング層、全結合層の組み合わせから構成される。CNN の重要な要素である畳み込み層では、フィルターまたはカーネルと呼ばれる重み付け行列 (畳み込み操作) によってイメージから特徴量を自動的に抽出する。プーリング層では特徴量を維持するように畳み込みイメージを縮小する。全結合層では、一つの層のすべてのノードと他の層のすべての層を結合する。

本研究で用いたネットワークモデルの模式図を図 3 に示す。このネットワークの入力層には  $\mu$ -PIC のアノード (X-Z 平面)・カソード (Y-Z 平面) で得られた 150×300 ピクセルの 2 つのイメージが入力される。出力層では X-Y 平面、Y-Z 平面でのそれぞれの反跳角度が同時に予測される。教師あり機械学習では主に連続した数値における予測を行う回帰問題と入力されたデータがどのグループに属するかを予測する分類問題がある。本実験では反跳角 360 度を 10 度ごとに 36 クラスに分類することで、多クラス分類問題に帰着することにした。隠れ層は 4 つの畳み込み層、4 つのプーリング層が入れ子で構成されている。これらの層では活性化関数として ReLU

関数が使われている。また、過学習を防ぐためにドロップアウト層を組み込んだ。全結合層ではソフトマックス関数によって各クラスに属する確率、つまりは確率分布が得られ、最確値が反跳角として選択される。損失関数にはクロスエントロピー関数を使用した。

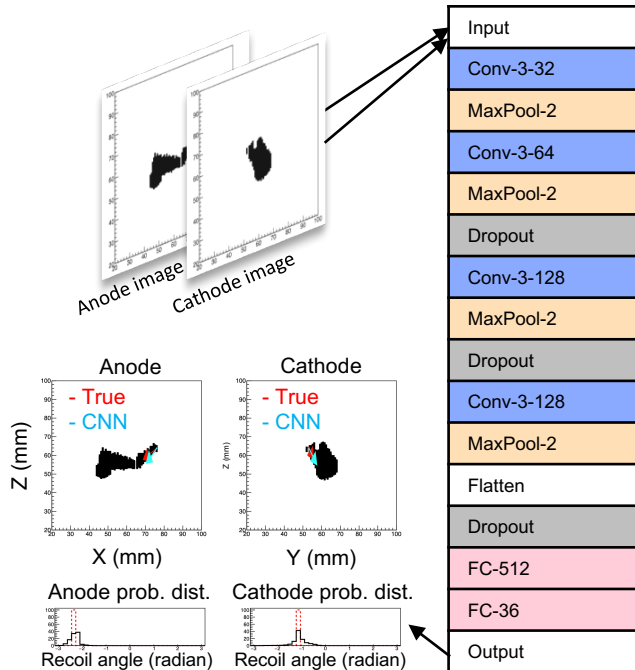


図 3: CNN モデルの模式図。畳み込み層は Conv-(フィルターサイズ)-(チャンネル数) で、プーリング層は MaxPool-(フィルターサイズ) で表現されている。左上図は入力に用いられるシミュレーションによって作成された 2 つの擬似イメージデータ。左下図は CNN によって予測された反跳角度とその確率分布。

CNN モデルを訓練するためには、大量の入力データ (X-Z 平面と Y-Z 平面のイメージデータ) と答えとなるデータ (X-Z 平面と Y-Z 平面の反跳角度) が必要である。そこで、シミュレーションによって訓練データを作成した。ガス中の電子の反応点と損失エネルギーは Geant4 によって計算され、ポアソン分布に従った電離電子数が算出される。これら電離電子は MAGBOLTZ [9] によって計算された電子拡散係数によって拡散され、 $\mu$ -PIC の各ストリップに入力される電荷が算出される。その後アナログ波形が模擬され、実験データと同形式の擬似イメージデータが作成される (図 3 左上)。この 2 つのイメージデータは各ストリップのデジタル閾値を超えた時間 (Time-Over Threshold: TOT) 分布に相当する。

## 4 実験結果と議論

本実験では、Keras version 2.3.1 [10] と TensorFlow version 2.1.0 によって CNN を実装した。また、GPU は NVIDIA GeForce GTX 1660Ti を用いて、8 万の訓練データ、16 のバッチサイズでミニバッチ学習を行った。学習率は 0.00002 に設定し、300 エポックで損失関数が収束した。1 エポックあたりの計算時間は約 10 秒である。評価用の 2 万のシミュレーションデータによって計算された散乱角度誤差の分布を図 4 に示す。20 keV 以下では多重散乱効果が大きく決定精度が悪いが、多重散乱効果が小さくなる場所では CNN による決定精度も向上し、従来の解析法よりも良いことがわかる。50-100 keV の電子に関しては 1.7 倍の精度向上が確認された。




図 4: CNN によって予測された電子の反跳方向の角度誤差。角度誤差  $\theta_{err}$  の定義は図中内右下。

次に、Geant4 によって SMILE2+ のジオメトリ (図 2a) における 662 keV のガンマ線のシミュレーションを行い、SPD を評価した。ここでは散乱点は従来の解析手法によって再構成されたものを使用している。得られた SPD の分布を図 5 に示す。従来法に比べて 2 倍以上改善していることがわかる。これらの結果から、CNN による電子の反跳方向予測は ETCC 望遠鏡についても有用であることが実証された。

本実験は試行的なものであったため、踏み込んだ解析は行っていない。そのため、多重散乱原理限界に到達するために何を改善すべきかを理解するにはさらなる調査が必要である。しかし、ここでは改善の可能性がある要素を 2 つ述べておく。1 つ目は学習データ数を増やすことである。一般的には訓練データが増えればすべてのデータに共通する特徴を学習できるようになるため未知のデータに対する予測精度が向上する。しかしながら、計算時間を考慮すると膨大な学習データを用いることは現実的でないことがあるため、学習曲線によって適切な学習データ数を評価すべきである。2 つ目はネッ




図 5: 662 keV ガンマ線シミュレーションの SPD の分布。赤の実線が CNN によって計算されたもの。灰色の点線は従来の解析手法によるもの。

トワーク構造の見直しである。本実験のネットワークは AlexNet [11] を基盤に構成したが、画像識別に活用されている CNN モデルには VGG [12] に代表されるような非常に小さな畳み込みフィルタを使ってネットワークの深さを増加させることで識別精度を改善するものも存在する。また近年では Grad-CAM [13] を例に、CNN モデルがイメージのどこに焦点をあてて予測したのかといった判断根拠を視覚化する方法も研究されている。これらの手法を用いることで CNN の構造を精査し、本実験に最適化した CNN モデルを構築することができると期待する。

## 5 まとめと展望

本研究では、畳み込みニューラルネットワークを用いてガス飛跡検出器から得られる 2 つのイメージデータから電子の反跳方向を決定し、シミュレーションデータを用いて SPD の改善を計った。その結果、従来法に比べて 50-100 keV 電子の方向決定精度に関しては 1.7 倍の改善がみられ、また SPD に関しては 2 倍以上の改善が確認された。これにより、ETCC 望遠鏡においても CNN の有用性が実証された。本研究では試験的に電子の反跳方向のみを予測したが、原理的には散乱点も同様の手法によって予測可能である。また、シミュレーションデータを用いた解析手法の評価を行なったが、シミュレーションデータによって訓練された CNN モデルが実験データにも適応できるかを試験しなければならない。そのためには、シミュレーションデータが実験データを正確に再現している必要がある。今後これらについて調査していきたい。

## 参考文献

- [1] V. Schönfelder *et al.*, *Astrophysical Journal* **217**, 306 (1977)
- [2] T. Tanimori *et al.*, *Astrophysical Journal* **810**, 28 (2015).
- [3] T. Tanimori *et al.*, *Journal of Physics: Conference Series* **1468**, 012046 (2020).
- [4] A. Takada *et al.*, *Nuclear Instruments and Methods in Physics Research A* **573**, 195–199 (2007)
- [5] M. Abadi, *et al.*, *ArXiv e-prints* arXiv:1603.04467
- [6] Y. Lecun, *et al.*, *Proc. IEEE* **86**, 2278-2324 (1998)
- [7] T. Kitaguchi, *et al.*, *Nuclear Instruments and Methods in Physics Research A* **942**, 162389 (2019)
- [8] C. Adams, *et al.*, *Physical Review D* **99**, 092001 (2019)
- [9] S. Biagi, *Nuclear Instruments and Methods in Physics Research A* **283**, 2 (2016)
- [10] F. Chollet, *et al.*, Available at: <https://github.com/fchollet/keras>
- [11] A. Krizhevsky, *et al.*, *Neural Information Processing Systems* **25**, (2012)
- [12] K. Simonyan, A. Zisserman, *ArXiv e-prints* arXiv:1409.1556
- [13] R. R. Selvaraju, *et al.*, *International Journal Computer Vision* **128**, 336–359 (2020).