

# ニューラルネットワークを用いたGAPS用粒子識別法の開発

○和田 拓也 (青学大・院)、小財 正義 (JAXA)、清水 雄輝 (神奈川大)、中上 祐輔 (青学大・学)、福家 英之 (JAXA)、吉田 哲也 (JAXA)

## Summary

- General AntiParticle Spectrometer(GAPS)は宇宙線反粒子の高感度探索を通じて暗黒物質を間接的に探査する気球実験計画である。
- 現在、イベント再構築に基づいたGAPS用粒子識別法を開発中である。
- より詳細な粒子識別法を確立するため、これに加えてニューラルネットワーク(NN)を用いた粒子識別法を開発している。
- 限定した条件下での予備検討から、NNを用いて十分な粒子識別能力を達成できる可能性があることが分かった。
- 空間情報を活用できる **Convolutional Neural Network(CNN)**を用いることでより高い識別能力を得られることが分かった。

## Introduction

### General AntiParticle Spectrometer

GAPSは未発見の宇宙線反重陽子の高感度探索により暗黒物質の解明に関する重要な手がかりを得ることを目的とした気球実験計画である。

### GAPS測定器

シリコン半導体(Si(Li))検出器群とそれを二重に取り囲むプラスチックシンチレーションカウンタ群から構成される。

#### ■ Si(Li)検出器

- 12×12×10層
- 一つの検出器に8個のセグメント
- 層間は10 cm

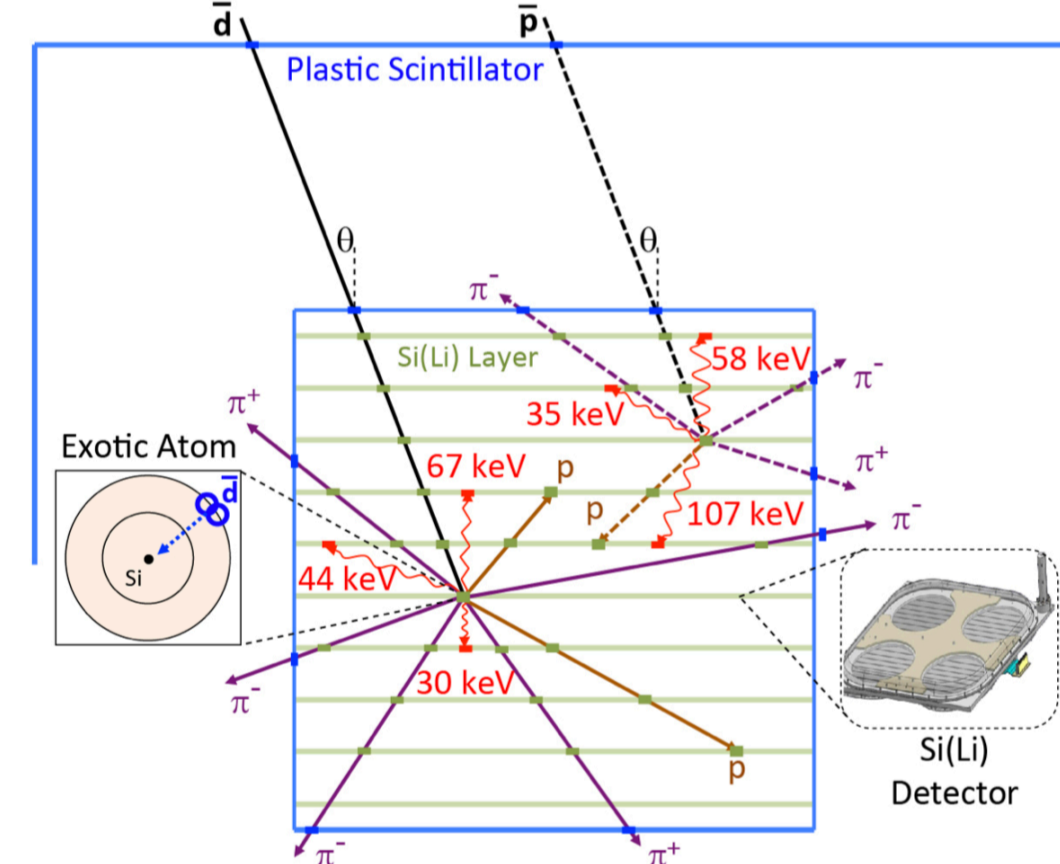

#### ■ Time-of-Flight (TOF) カウンタ

- 内外合わせて204パドル、両読出し
- 6 mm<sup>t</sup> × 16 cm<sup>w</sup> × 1.2 ~ 1.8 m<sup>l</sup>

### GAPS検出原理

GAPSはエキゾチック原子を応用した独自の手法により入射反粒子の同定を行う。

1. 測定器に入射した反粒子はTOFカウンタやSi(Li)検出器内でエネルギー損失を起こして**減速・捕獲**される。
2. ターゲット原子核と**励起エキゾチック原子を構成し**、崩壊する。
3. その崩壊過程において、**特性X線**や**ハドロン群**を放出する。
4. 放出される特性X線のエネルギーや生成ハドロン数は**入射反粒子種に依存する**ため、これらを測定することで入射反粒子を同定する。



### GAPS粒子識別

- GAPSの反重陽子探索において、反重陽子と同様にエキゾチック原子を形成しうる**反陽子が最大のバックグラウンド**(反重陽子に対する反陽子のフラックス比は約10<sup>4</sup>以上)となる。
- 現在GAPSではイベント再構築による粒子識別法を開発している。イベント再構築では約10<sup>4</sup>チャンネルから得られるデータ(エネルギー損失など)を用いてトラックの再構成等を行い粒子の識別を行う。これらの情報を合わせることで反陽子に対する十分な識別能力を達成できるという見込みが得られている。
- 複雑な多チャンネル解析の上、要求される粒子識別能力が高いためより詳細な粒子識別法を確立する必要がある。
- そこで、従来のイベント再構築による識別法と並行してNNを用いた粒子識別法を開発している。
- NNを用いた手法で未知のパターンを発見し、従来の手法にフィードバックをかけGAPS粒子識別能力を向上させることを目指す。



## Neural Network

### Neural Network

NNは、脳の機能を模倣した数学的モデルである。NNは入力層、出力層、隠れ層から構成され、各層に複数あるノード(人工ニューロン)はエッジで接続されている。ノードの出力は活性化関数によって決定され、最終的な出力が正解に近づくように各エッジの重みが複数回更新される。特に深い隠れ層を持つNNのことをDeep NN(DNN)という。

### Convolutional Neural Network

CNNはNNの一種で、特に画像認識分野でその能力を発揮している。CNNは隠れ層が主に畳み込み層とプーリング層で構成されている。畳み込み層で画像の特徴を抽出し、プーリング層でその特徴にロバスト性を与える。その後、全結合層によってクラス分類が行われ入力データの識別を行う。NNでは入力を全て一次元データとして扱うが、CNNでは二次元、三次元のデータも扱うことができる。




## 研究手法

### GAPSシミュレーション

GEANT4を基に開発したGAPS用シミュレーションコードを用いてNN用入力データを作成した。本発表では**特性X線、時間情報、検出器の測定誤差は考慮していない。**

### 本発表でのシミュレーション条件

- 入射粒子: 反陽子、反重陽子
- 入射方向: ① 測定器中心の真上から垂直下向き  
② 測定器を囲む領域から下向きに一樣等方
- 入射エネルギー: 0.335 < β < 0.340の範囲内で一樣
- イベント数: 各200万(学習用: 8割、検証用: 2割)
- (入射粒子がSi(Li)内で捕獲され対消滅を起こしたイベントのみを選定)



## DNNによる粒子識別

### DNN用の入力データ

入射方向①の条件下で、8個のセグメントを一つにまとめて得られたエネルギー損失値(計1440チャンネル)(TOFカウンタの情報を含んでいない)

### DNNによる粒子識別能力の検証

ディープラーニングフレームワークKerasを用いてNNを構築し、上記の入力データに対してNNを最適化した。

使用したNNの構成の概要

Layer	ノード数	活性化関数
Input Layer	1440	-
Hidden 1	5000	ReLU
Hidden 2	2500	ReLU
Hidden 3	1000	ReLU
Hidden 4	100	ReLU
Hidden 5	10	ReLU
Output Layer	1	sigmoid

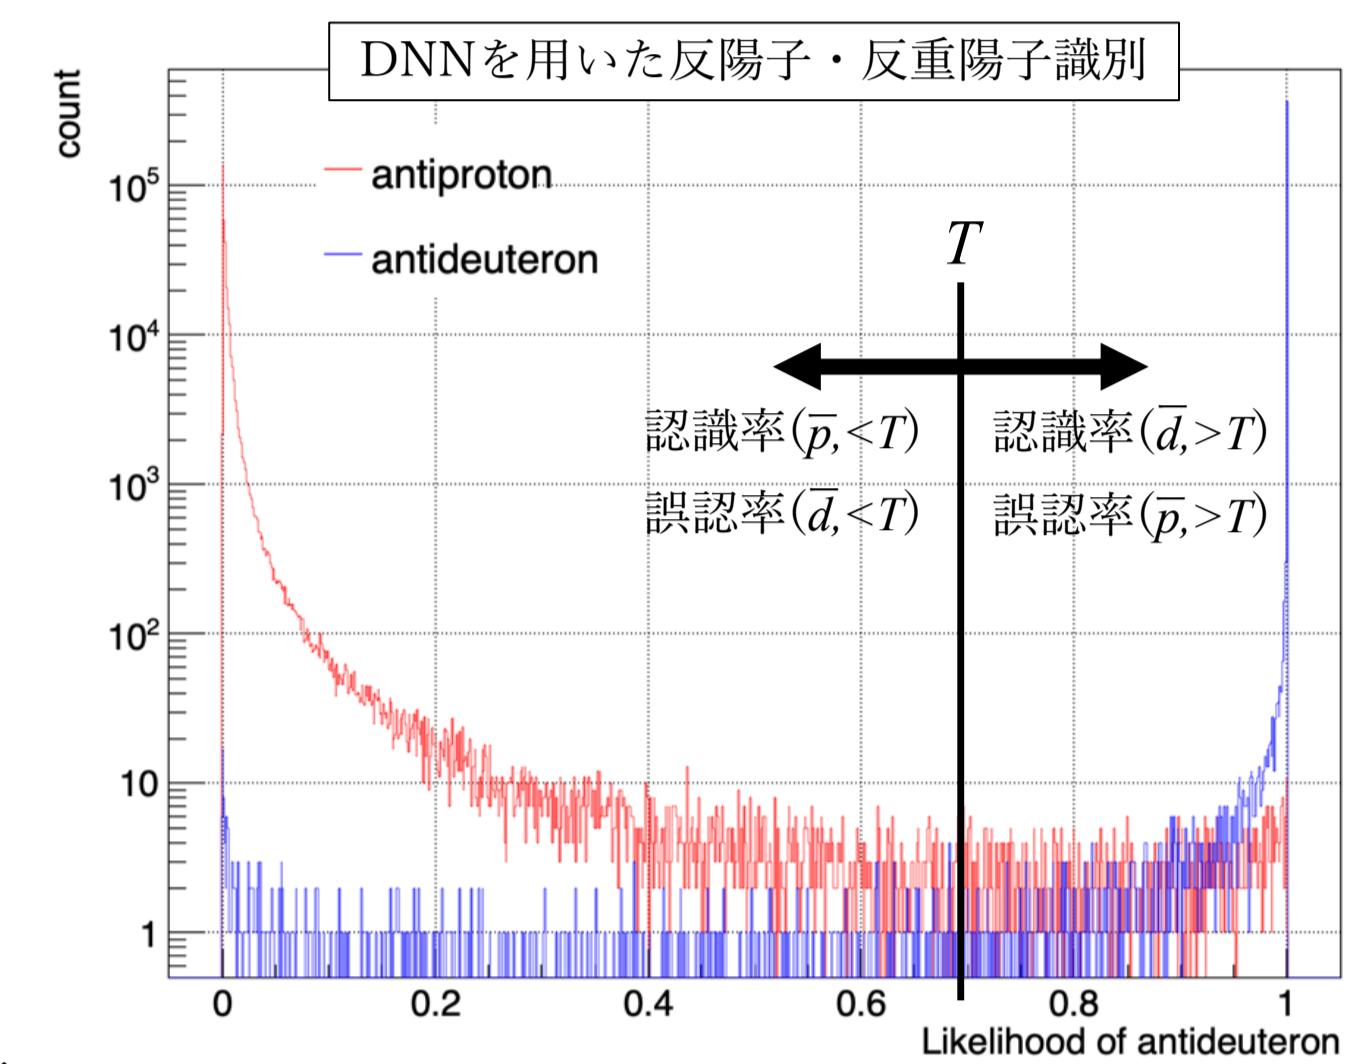
反重陽子らしさのヒストグラムから反重陽子の認識率に対する反陽子のRejection Powerを計算した。

$$\text{誤認率}(\bar{p}, > T) = \frac{\text{反重陽子として判断された反陽子のデータ数}}{\text{反陽子の全データ数}}$$

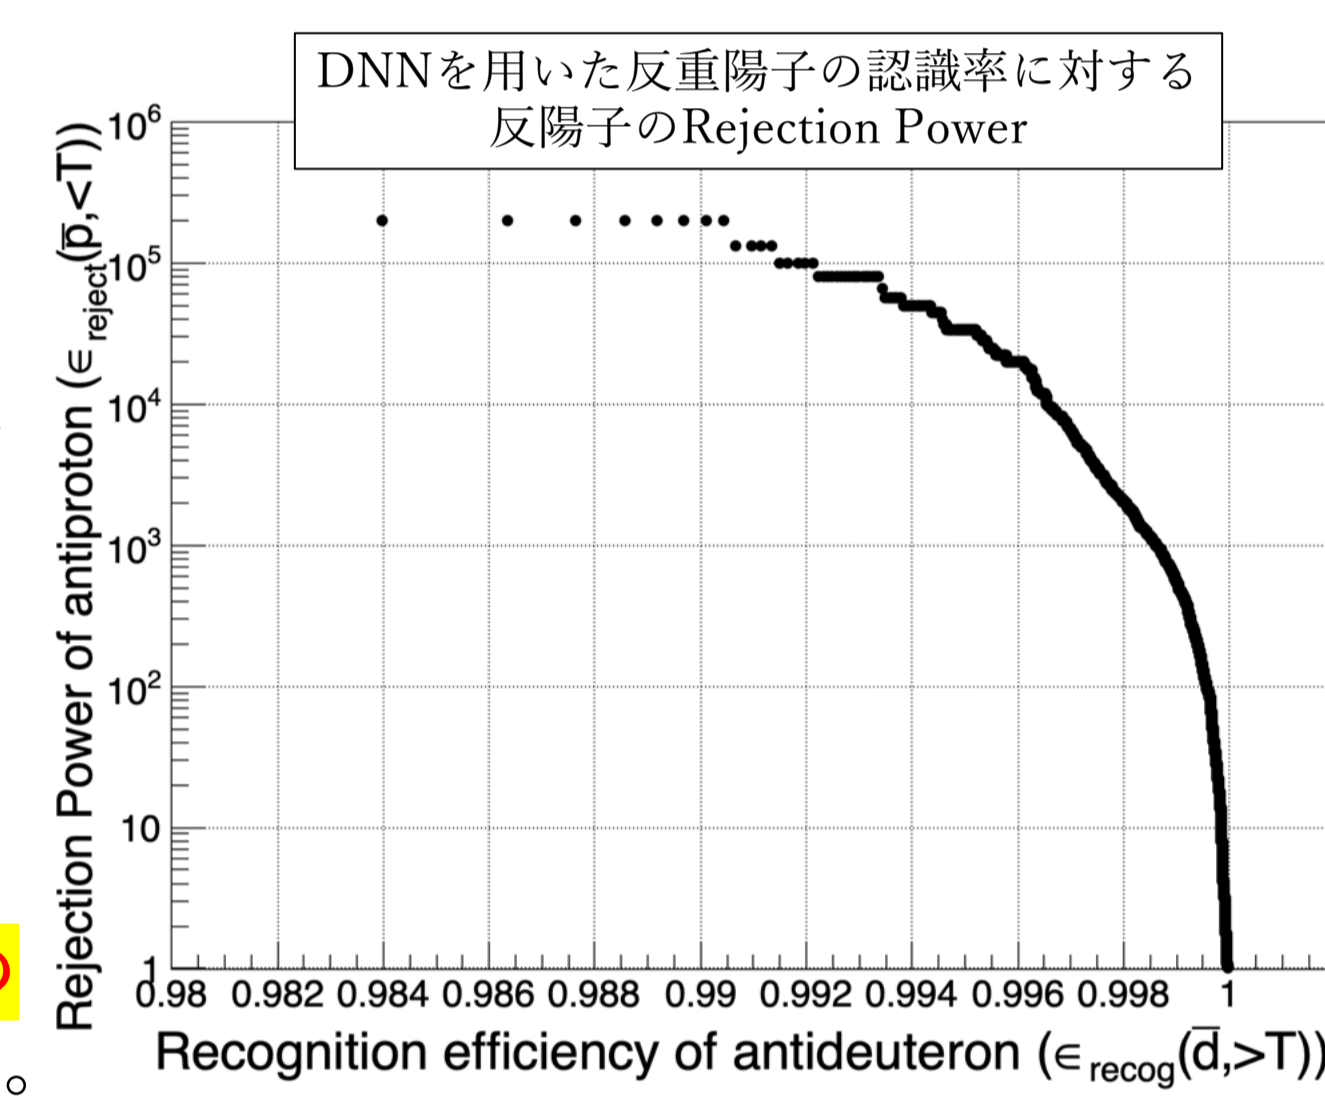
$$\text{認識率}(\bar{d}, > T) = \frac{\text{反重陽子として判断された反重陽子のデータ数}}{\text{反重陽子の全データ数}}$$

$$\text{反陽子のRejection Power}(> T) = \frac{1}{\text{誤認率}(\bar{p}, > T)}$$

- ✓ 反重陽子の**認識率99%**を保ちながら**10<sup>5</sup>以上の反陽子のRejection Power**を得ることができた。



入力データの反重陽子らしさのヒストグラム。値が1に近いほどNNはそのデータを反重陽子らしいと判断した



## CNNによる粒子識別

### CNNの導入

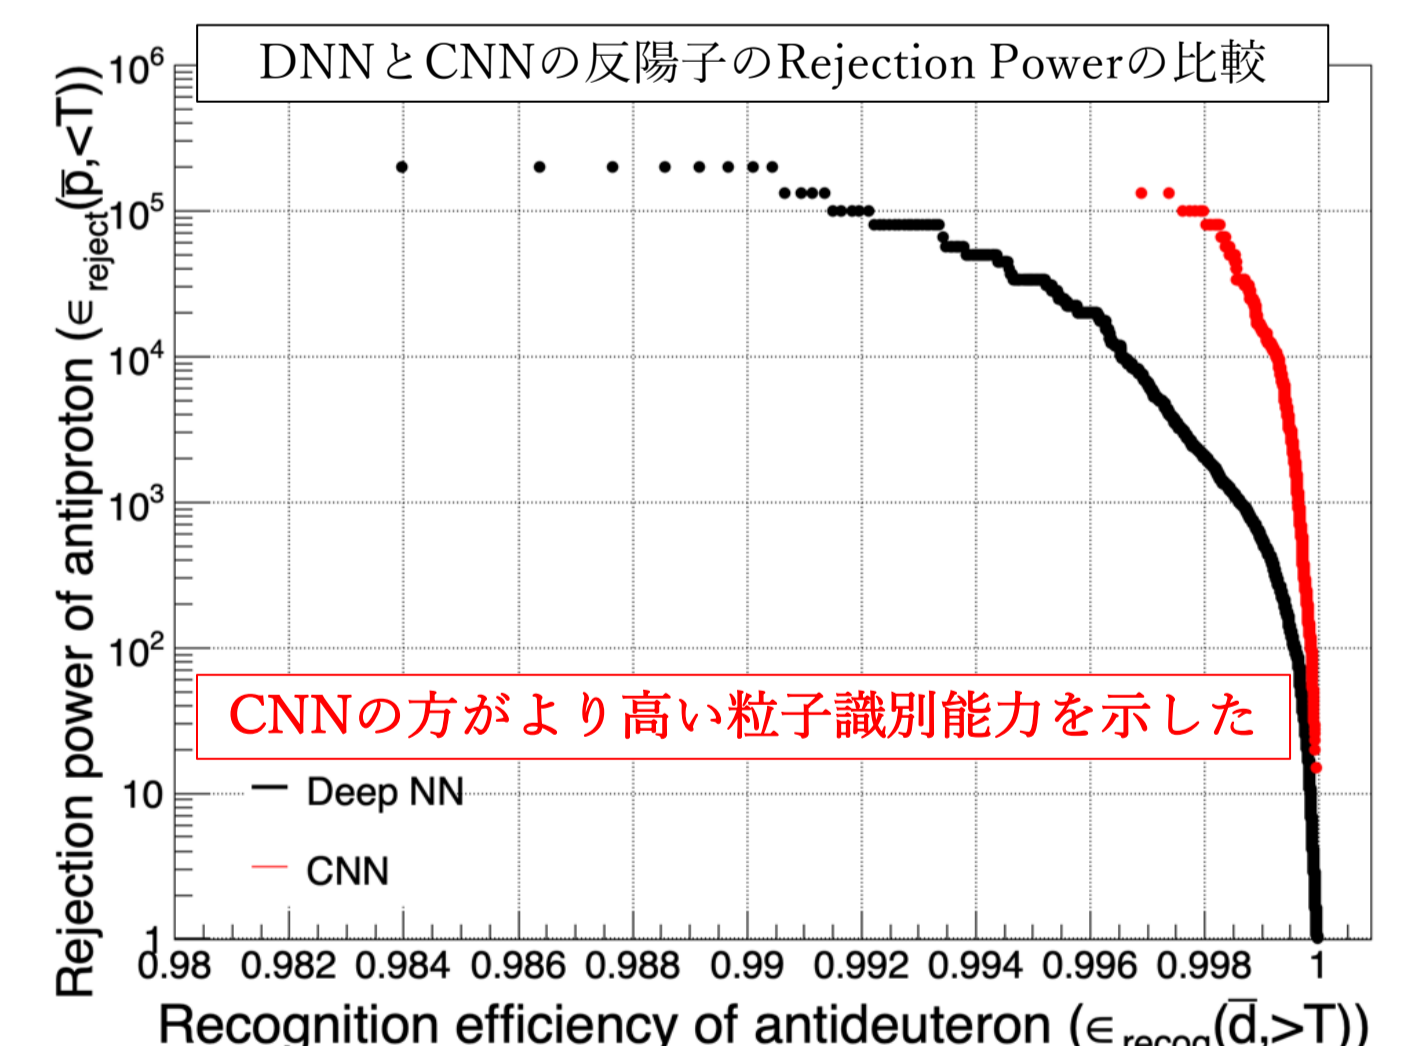
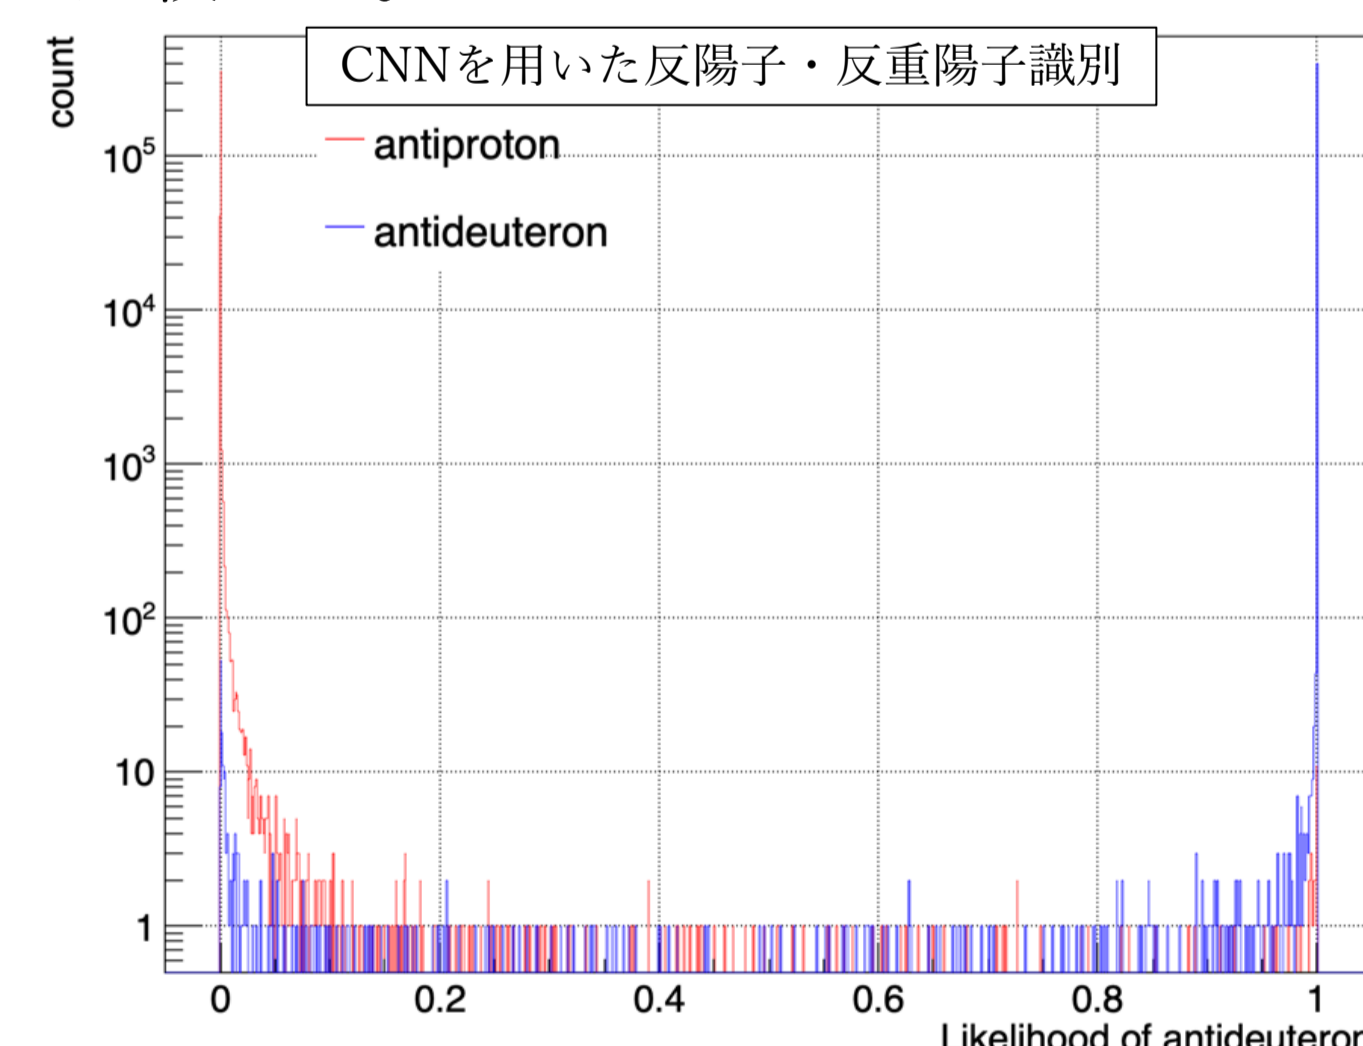
DNNでは入力データは全て一次元データとして扱われるため、**空間的な情報は失われる**。粒子の飛跡などの空間情報を取り込むことで粒子識別能力の向上が期待される。故に、空間情報を扱うことができるCNNに着目した。

### CNN用の入力データ

入射方向①の条件下で、8個のセグメントを一つにまとめて得られたエネルギー損失値(計1440チャンネル)を実際の配置に並び替えた**三次元配列**

### CNNとDNNの粒子識別能力の比較

DNNと同様の手法で反重陽子の認識率に対する反陽子のRejection Powerを計算し、比較する。



- 反重陽子の**認識率99.8%**で10<sup>5</sup>以上の反陽子に対する**Rejection Power**を示し、**CNNがより高い識別能力を持つ**ことがわかった。

特性X線やTOFカウンタの情報等も取り込むことで**反陽子・反重陽子の識別に関して十分な識別能力を達成できる見込み**を得られた。

### 入射方向②のデータに対する識別能力の評価

- 典型的かつ主要な入射イベントの傾向を調べるため、「外側TOF上面」→「内側TOF上面」の順で通過したイベントを選定したデータで学習モデルを作成。
- ①のケースほど高い識別能力は得られなかったが学習イベント数を増やすことでより高い識別能力を持つモデルを作成可能

### 今後の課題

- エネルギー範囲、対象粒子などの条件の拡張
- 時間情報や検出器の応答も考慮したデータによる学習
- 未使用の物理量を用いた詳細な評価
- 粒子の入射角度別の粒子識別能力の評価
- NN構造の最適化
- 従来の手法へのフィードバック

