

深層学習によるガンマ線とハドロン宇宙線の弁別に関する研究

日大生産工(院) ○中澤 優樹 日大生産工 塩見 昌司

1. まえがき

宇宙線が発見されて以来、百年以上経つ。超新星残骸やブラックホールなどが起源とされ、近年、起源天体の観測結果が出つつあるが、宇宙線のエネルギースペクトルを説明するには程遠く、多くの謎が残されている。

宇宙線の起源の発見が難しい理由として、ほとんどの宇宙線は電荷を持つハドロン宇宙線であり、星間磁場で曲げられ到来方向の情報を失ってしまうことが挙げられる。一方宇宙線が加速現場付近で星間物質と相互作用して作られるガンマ線は星間磁場に曲げられず、直接地球に届くため、宇宙線源の情報を得ることができる。特に100TeV領域のガンマ線の観測は銀河系内の宇宙線の加速限界付近の情報を持っていると考えられる重要な観測窓となる。しかし、ハドロン宇宙線は地球に様に降り注ぐため、ガンマ線観測時のノイズとなる。そこで地球で観測する際のガンマ線とハドロン宇宙線の大気との相互作用の違いによる影響を元にそれらを弁別し、除去することができればノイズに対するガンマ線の有意性が上がり、結果として検出効率や観測誤差が小さくなり、装置の感度の向上が期待できる。¹

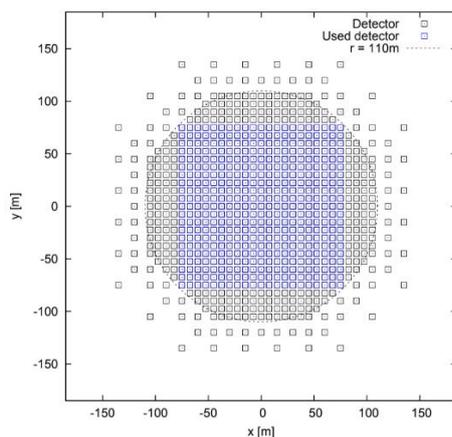


Fig.1 チベット空気シャワー観測装置の配置図。四角が宇宙線を作る二次粒子数を観測する表面積0.5m²のシンチレーション検出器。²

本研究では、Fig.1のチベット空気シャワー観測装置で観測される際の二次粒子密度分布

を再現するシミュレーションデータを用い、深層学習により入射宇宙線がガンマ線かハドロン宇宙線かの弁別の可能性について検討した結果について報告する。

2. 提案手法

2.1 使用ネットワーク

画像弁別において、よく使用されるネットワークがCNN(Convolutional Neural Network)である。CNNを用いることにより、本研究の画像弁別において高い精度が得られる可能性がある。しかし、深い層のネットワークであるため、弁別精度を向上している理由やオーバーフィッティングなどの問題が起きた時の理由がわからない。そこで全結合による浅い層のシンプルなネットワークを用いる。Fig.2が本研究で使用される全結合のネットワークである。ネットワーク構造は入力層と中間層、出力層の三層構造からなる。この全結合のネットワークによる弁別精度を調査した。

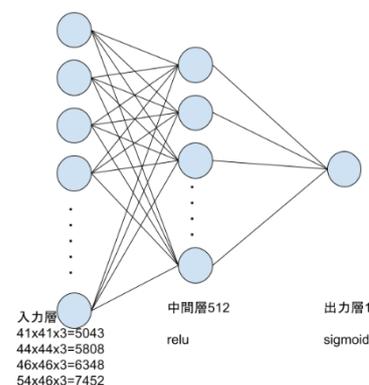


Fig.2 全結合のネットワーク

2.2 使用画像

弁別に使用する画像はFig.3で示したような画像データ(白枠あり640x480、白枠なし440x440)を十分の一に縮小したものを用いる。理由は、640x480の画像で学習を行った際、学習に時間がかかったことや学習が正常終了できていなかった原因が、画素数が大きいことであると判断したためである。また、本研究では縮小画像を使い、二つのことを検証した。一つ

Study on separation between gamma rays and hadron cosmic rays by deep learning

Yuuki NAKAZAWA and Atsushi SHIOMI

目は、白枠有無の入力画像の質の違いを検証した。二つ目は、元の画像データの1検出器が1x1pixelでないことから、1検出器が1x1pixelにしたものとの入力画像の質の違いを検証した。

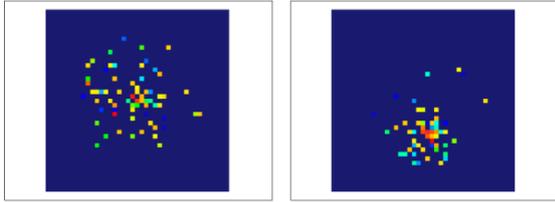


Fig. 3 空気シャワー二次粒子密度分布(左からハドロン宇宙線、ガンマ線の画像640x480例)

2.3 検証方法

弁別を成功させるためにはガンマ線とハドロン宇宙線がより均等に、それぞれ正しく判定される必要がある。例えば全体のaccuracyが70%出たとしてもガンマ線が40%、ハドロン宇宙線100%と偏った弁別になってしまうことも考えられるからである。Fig.4のように、confusion matrixを使用すると全体のaccuracyだけでなく、それぞれの弁別の割合を確認することができる。今回判定においてガンマ線、ハドロン宇宙線共に全部の学習においてconfusion matrixを行い、ガンマ線とハドロン宇宙線がどのように弁別されているか検証した。

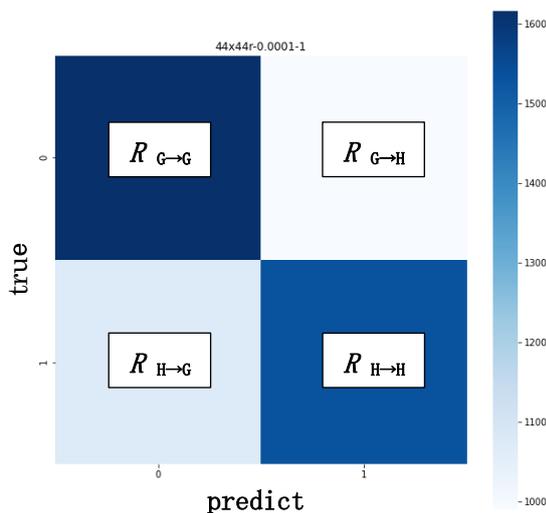


Fig. 4 confusion matrixの例⁴

3. 実験方法および測定方法

実験はGoogle Colaboratoryの環境で行い、画像データをGoogle Driveにアップロードしてマウントして学習を行った。画像は640x480を十分の一に縮小した画像を元に作った54x46、

46x46の白枠あり画像と44x44の白枠なし画像、それから1検出器が1x1pixelに対応した41x41の白枠なし画像の四種類で行った。(64x48についても行ったが、現在の環境や条件では学習が収束しなかった。)

表1 実験条件

実験条件	
trainデータ	15, 642
validationデータ	2, 607
testデータ	2, 607
学習率	0. 0001
学習回数	1500
バッチサイズ	128

実験は表1に示した条件で行った。trainデータ15,642枚、validationデータ2,607枚、testデータ2,607枚の6:1:1で行った。これは深層学習のテストによく使用される、手書き数字の画像データMNISTによるtrainデータとtestデータの比率が6:1であることを参考にした。

Fig. 3に示した全結合のネットワークを用いて学習を行う。入力層は、それぞれの画像の縦×横×3(RGBのカラー画像より)のユニット数とした。中間層は512ユニット、出力層は1ユニットとしてガンマ線とハドロン宇宙線の二値分類により弁別を行った。

学習から得られたFig. 4に示したconfusion matrixを使い、ガンマ線とハドロン宇宙線の弁別精度を算出した。また、式(1)下式より、ノイズに対してガンマ線の信号の有意性の向上割合を求めた。初期乱数による影響を調べるため、これらの作業を乱数のみ変えて各画像データに対し5回行った。

Fig. 4のconfusion matrixの縦は正解のラベルで横は学習したモデルより未学習のtestデータを使い、予測した値である。 $R_{G \rightarrow G}$ はガンマの正解ラベルに対してガンマと正しく予測できたもの、 $R_{G \rightarrow H}$ はガンマの正解ラベルに対してハドロンと間違えて予測したもの、 $R_{H \rightarrow G}$ はハドロンの正解ラベルに対してガンマと間違えて予測したもの、 $R_{H \rightarrow H}$ はハドロンの正解ラベルに対してハドロンと正しく予測できたものである。

(1)式は、およその有意性の向上割合を表す。ここに N_G は、観測する天体を中心とするある視野角からくるガンマ線の数、 N_{BG} は観測天体付近から予想されるバックグラウンドとなるハドロン宇宙線の数である。(1)上式の分母の N_G をノイズの標準偏差 $\sqrt{N_{BG}}$ で割ることにより、ガンマ線の信号のおよその有意性が求めら

れる。また、分子のガンマ線を抽出できた数 $R_{G \rightarrow G} \cdot N_G$ をハドロン宇宙線にも関わらず、ガンマ線と判断してしまったノイズ $\sqrt{R_{H \rightarrow G} \cdot N_{BG}}$ で割ることにより、学習において抽出できたガンマ線の信号のおよその有意性が求められる。(1)下式が1を超えることは、弁別精度が向上することを意味する。

$$\text{有意性の向上割合} = \frac{\frac{R_{G \rightarrow G} \cdot N_G}{\sqrt{R_{H \rightarrow G} \cdot N_{BG}}}}{\frac{N_G}{\sqrt{N_{BG}}}}$$

$$= \frac{R_{G \rightarrow G}}{\sqrt{R_{H \rightarrow G}}} > 1 \quad (1)$$

($R_{G \rightarrow G}$:ガンマ線と正しく予測できた数、 $R_{H \rightarrow G}$:ハドロン宇宙線にもかかわらず、ガンマ線と間違えて予測した数、 N_G :観測する天体を中心とするある視野角からくるガンマ線の数、 N_{BG} :観測天体付近から予想されるバックグラウンドとなるハドロン宇宙線の数)

4. 実験結果および検討

Fig. 5とFig. 6はそれぞれaccuracyとlossを表す。epoch数と共にtrain accuracyは上がっていき、train lossは下がっていくことから、それぞれ学習が正常に行えていることがわかる。Fig. 6のtrain lossより画像が小さいほど、0に近づきlossが平らになっていき、学習収束が早いことがわかった。

表2、表3は画像タイプ毎に行った5回の試行におけるconfusion matrixの結果をまとめたものである。灰色に塗りつぶされている回は、ガンマ線・ハドロン宇宙線の正答率のどちらかが45%以下の回である。これらは判定器として用いるには十分でない学習であると考えられる。これらのデータを除いたデータから平均値を求めた結果を表4に示す。

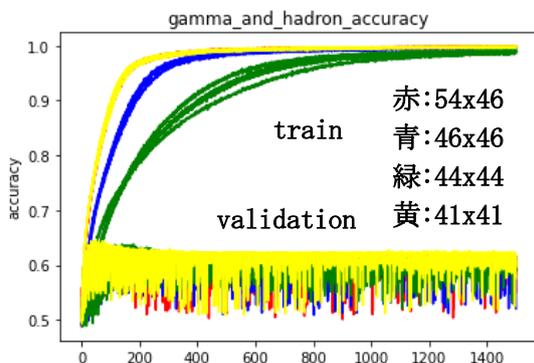


Fig. 5 gamma and hadron accuracy(表4に用いた学習全てをプロット)

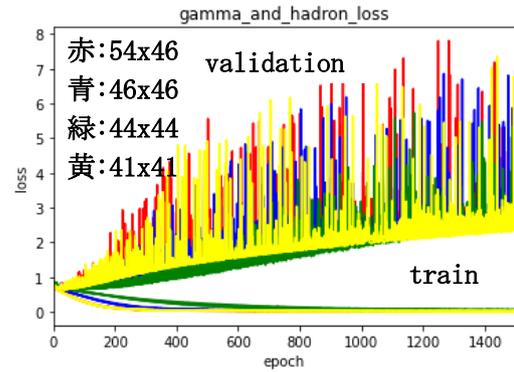


Fig. 6 gamma and hadron loss(表4に用いた学習全てをプロット)

表2 54x46(左)と46x46(右)の結果

回数	54x46				46x46			
	$R_{G \rightarrow G}$	$R_{H \rightarrow G}$	全体	有意性	$R_{G \rightarrow G}$	$R_{H \rightarrow G}$	全体	有意性
1	0.63	0.44	0.59	0.95	0.08	0.04	0.52	0.40
2	0.57	0.38	0.59	0.92	0.53	0.34	0.59	0.91
3	0.60	0.43	0.59	0.91	0.62	0.43	0.60	0.95
4	0.61	0.43	0.59	0.93	0.61	0.42	0.60	0.94
5	0.61	0.45	0.58	0.91	0.61	0.41	0.60	0.95

(有意性:有意性の向上割合)

表3 44x44(左)と41x41(右)の結果

回数	44x44				41x41			
	$R_{G \rightarrow G}$	$R_{H \rightarrow G}$	全体	有意性	$R_{G \rightarrow G}$	$R_{H \rightarrow G}$	全体	有意性
1	0.62	0.41	0.60	0.97	0.31	0.17	0.57	0.75
2	0.51	0.30	0.60	0.93	0.44	0.24	0.60	0.90
3	0.60	0.40	0.60	0.95	0.62	0.40	0.61	0.98
4	0.44	0.27	0.59	0.85	0.62	0.42	0.60	0.96
5	0.28	0.15	0.56	0.72	0.47	0.25	0.61	0.94

(有意性:有意性の向上割合)

表4からわかるように、 $R_{G \rightarrow G}$ が約60%、 $R_{H \rightarrow G}$ は約40%、全体は約60%の弁別精度となった。有意性の向上割合は0.93から0.96となり1を超える値を得られなかった。しかしながら、全体のaccuracyが、画像の不要な部分を除くことで向上していること、また1検出器が1pixelに対応している画像データが最もよい結果となっていることがわかった。有意性の向上割合も同様の傾向が見られた。学習が不十分と考えられるデータを除いての検討のため、試行回数が若干少ないが、質の良い画像が良い結果を生む傾向が見受けられる。

表4 表2と表3の結果の学習が成功した confusion matrixの弁別精度の平均をまとめた結果

画像 タイプ (標本数)	$\overline{R_{G \rightarrow G}}$	$\frac{\overline{R_{H \rightarrow H}}}{\overline{R_{H \rightarrow G}}}$	全体	有意性
54x46 (5)	0.604	0.574 0.426	0.590 ± 0.005	0.927 ± 0.015
46x46 (4)	0.593	0.600 0.400	0.597 ± 0.003	0.937 ± 0.022
44x44 (3)	0.578	0.627 0.373	0.603 ± 0.002	0.948 ± 0.019
41x41 (3)	0.570	0.641 0.359	0.606 ± 0.004	0.956 ± 0.024

(有意性:有意性の向上割合)

5. まとめ

今回の学習において以下の六つのことがわかった。一つ目は、画像を縮小することにより学習時間が早くなり、正常に学習が収束したことである。二つ目は、confusion matrixにより全体のaccuracyだけでなく、ガンマ線とハドロン宇宙線のそれぞれのaccuracyがわかり、弁別による、およその有意性の向上割合が求められたことである。三つ目は、画像が小さいほどlossが早めに0に近づき平らになっており、学習の収束が早かったことである。四つ目は、直接的に比較はできないが、過去に行った640x480の画像を用いた学習済みネットワーク(VGG16)という精度が上がると考えられる深い層で行っていた時と同じような精度となっているため、現在の全結合のネットワークから徐々に大きくすることで、前よりも良い精度が出ると期待ができることである。五つ目は、入力画像の白枠ありなしにおいて精度の差が出る可能性があること、また、1検出器が1pixelに対応した41x41の白枠なし画像が最も良い結果であり、入力画像の質が重要という当然と思われる結

果が確かに出ていることである。ただし、試行回数の少なさによる効果も考えられる点は注意する必要がある。六つ目は、有意性の向上割合と有意性の向上割合が1より大きくなっていないことである。つまり、現在のネットワークでは有意性を向上させる弁別器ができていないことである。

今後は今回も行った全結合層のみの浅いネットワークで、最も入力画像として最小かつ質の良い1検出器が1x1pixelに対応した41x41の白枠なし画像にしたものを使って学習を行っていく。学習の中で必要に応じて学習率の変更によりその画像に最適な学習率を見つけることや中間層を追加してネットワークの変更、データ比率の変更やデータ拡張によりtrainデータを増やすこと、正則化(Dropout、weight decay)を使ってオーバーフィッティングを防ぐことなどを行っていく。それにより弁別精度と有意性の向上割合を上げていく。また、CNNや学習済みネットワークなどの深い層のネットワークも弁別精度や有意性の向上割合を上げていくために必要に応じて使う予定である。

参考文献

- 1) 齋藤 隆之, 東京大学大学院理学系研究科物理専攻修論Study of Gamma-ray/Hadron Separation Using the Tibet Air Shower Array, (2006) pp. 1-76.
- 2) 塩見昌司, 機械学習用入力空気シャワー粒子数分布図について, (2019) pp. 1-10.
- 3) Francois Chollet, DEEP LEARNING WITH Python, 巢籠悠輔, Pythonとkerasによるディープラーニング, 株式会社クイープ, マイナビ出版, (2018) pp. 1-392.
- 4) Valueログ, Seabornのヒートマップで混合行列を美しくつくる (Scikit-learn・matplotlib), (2021) <https://evaluelog.com/post-122/>, (参照2021)