

# 地表空気シャワーアレイを用いた TeV領域ガンマ線観測における ニューラルネットワークの応用

横浜国立大学 理工学府 奥川創介

第八回 空気シャワー観測による宇宙線の起源探索研究会  
2025年3月25日

# 発表内容

## ニューラルネットワークについて

- 基礎的な考え方
- 誤差逆伝播法による学習方法

(参考 : C M. Bishop. *Neural Networks for pattern Recognition*. 1995 )

## 畳み込みニューラルネットワーク (CNN)への発展

- 基礎的な考え方 (入力データとして画像を使用)
- フィルターによる特徴抽出


## Tibet AS $\gamma$ 実験における、TeVガンマ線観測へのCNNの応用

- ガンマ線、宇宙線起源空気シャワーの選別
- ガンマ線の到来方向決定精度の向上

# ニューラルネットワーク


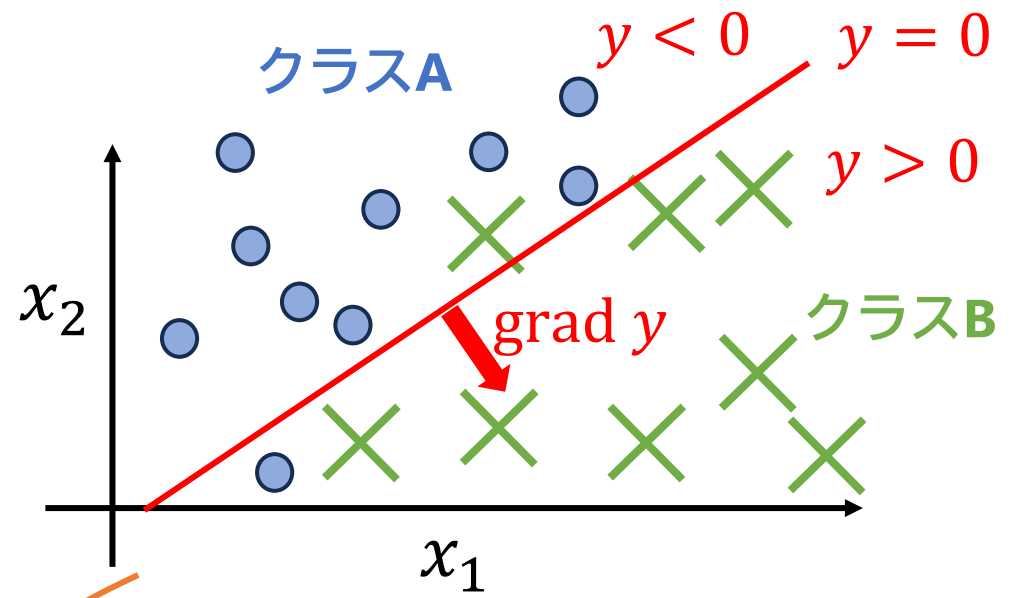

課題：クラスAとクラスBの分類  
入力 $x_1, x_2$ から出力 $y$  (A: -1, B: 1)を得る

単純なニューラルネットワーク







$y = \tanh(w_1 x_1 + w_2 x_2 + b)$

- $w_1, w_2, b$  は学習で決定 (後述)
- 学習済みパラメータを仮定




# 多層化する

1層だけでは分類できない  
2層目に2つのユニットを追加



# 内部パラメータの最適化：学習について



重み $w$ を最適化する必要がある。

出力の理想値との乖離を表す関数

$$\text{例: } L = \frac{1}{2} (z - z_{true})^2$$

“損失関数”


$$L = \frac{1}{2} (z - z_{true})^2$$

が小さくなるように、重み $w$ を最適化する

“誤差逆伝播法”

(バイアス項 $b$ についても同様に)

# 誤差逆伝播法

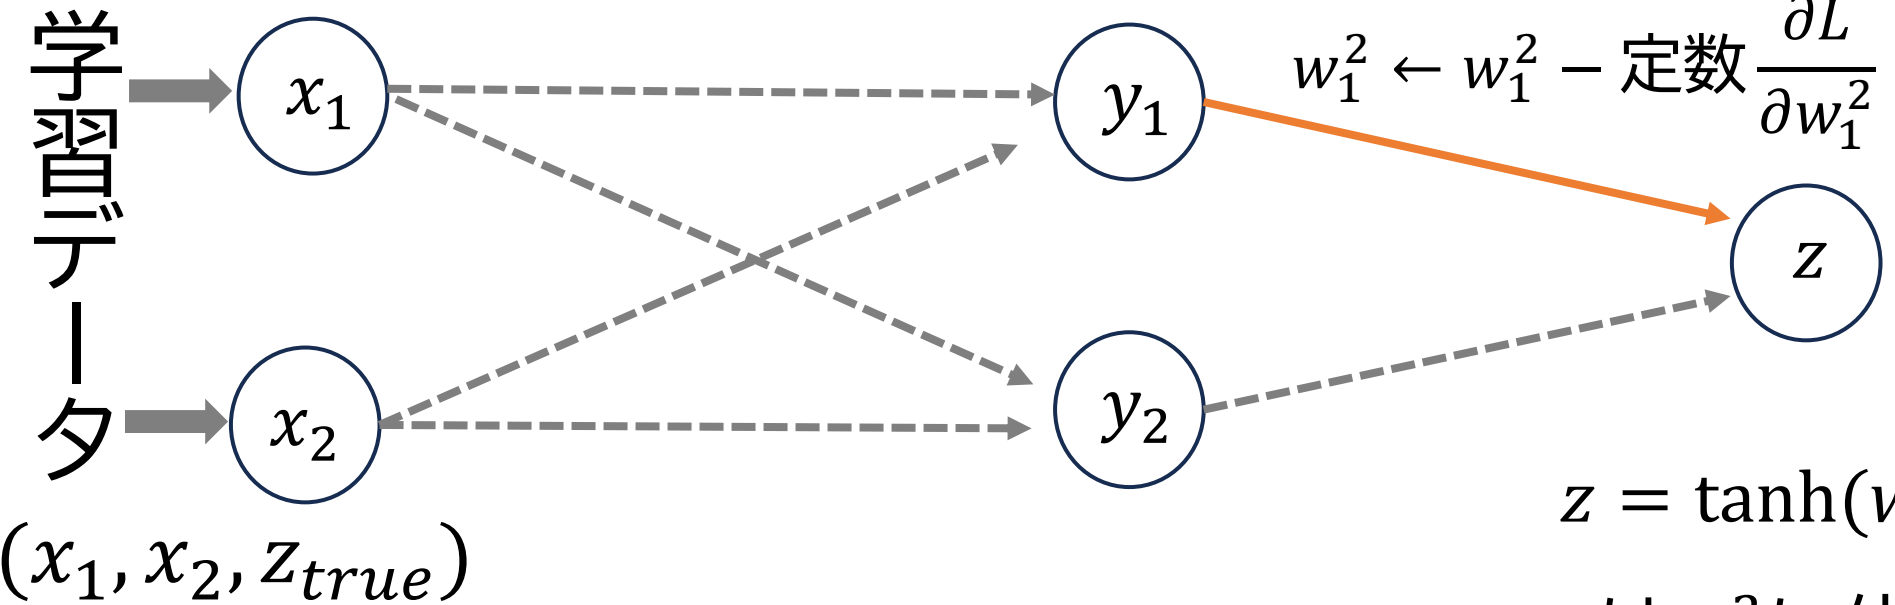


正解値

損失関数

$$L = \frac{1}{2} (z - z_{true})^2$$

# 誤差逆伝播法



$$\frac{\partial L}{\partial w_1^2} = \frac{\partial L}{\partial z} \frac{\partial z}{\partial w_1^2}$$

損失関数  
 $L = \frac{1}{2} (z - z_{true})^2$   
 Lはzに依存

$z = \tanh(w_1^2 y_1 + w_2^2 y_2 + b_1^2)$   
 zは $w_1^2$ に依存

# 誤差逆伝播法



後ろの層の微分

この重みを更新

$$\frac{\partial L}{\partial w_{11}^1} = \frac{\partial L}{\partial y_1} \frac{\partial y_1}{\partial w_{11}^1} = \frac{\partial L}{\partial z} \frac{\partial z}{\partial y_1} \frac{\partial y_1}{\partial w_{11}^1}$$




学習データ

$(x_1, x_2, z_{true})$



$$y_1 = \tanh(w_{11}^1 x_1 + w_{12}^1 x_2 + b_1^2)$$

$y_1$ は $w_{11}^1$ に依存



$$w_{11}^1 \leftarrow w_{11}^1 - \text{定数} \frac{\partial L}{\partial w_{11}^1}$$

$$w_1^2 \leftarrow w_1^2 - \text{定数} \frac{\partial L}{\partial w_1^2}$$

損失関数

$$L = \frac{1}{2} (z - z_{true})^2$$

$L$ は $z$ に依存

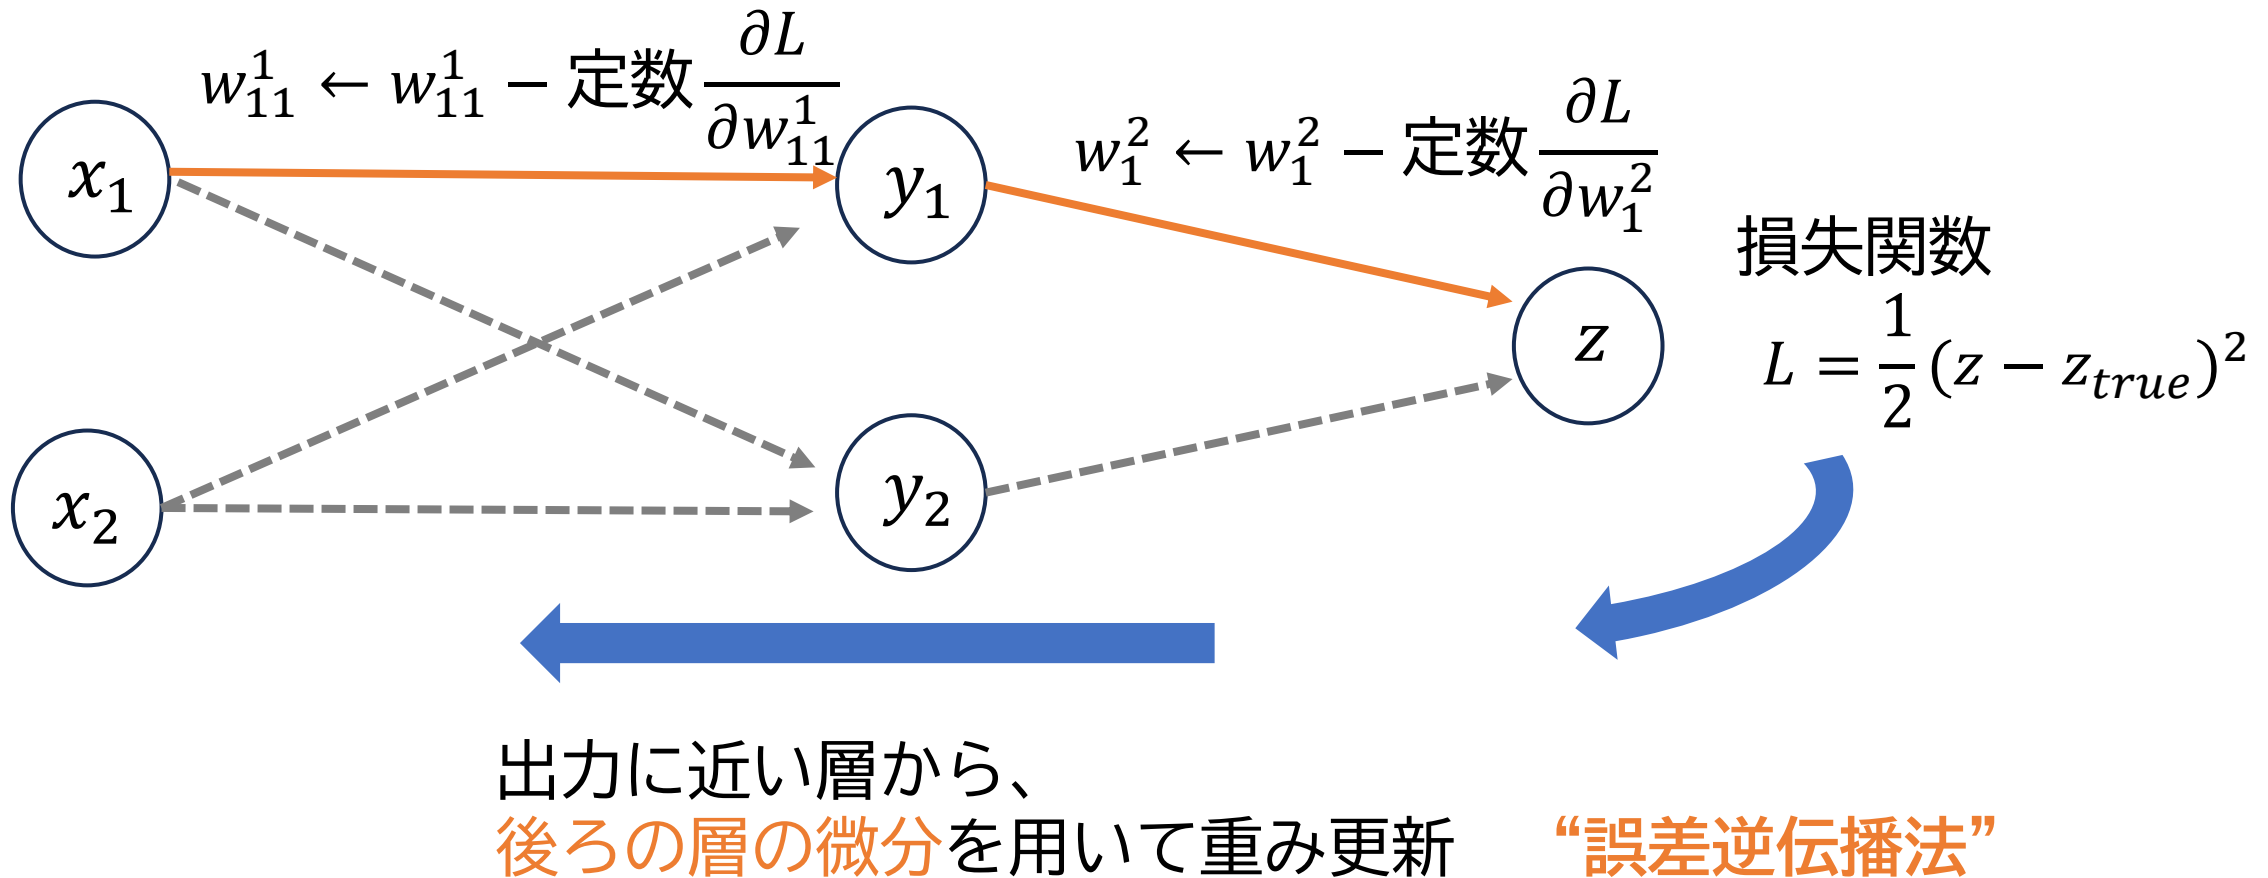
$$z = \tanh(w_1^2 y_1 + w_2^2 y_2 + b_1^2)$$

$z$ は $y_1$ に依存

すべての重みの更新が終了  
→ 次の学習データ入力



# 誤差逆伝播法




# 畳み込みニューラルネットワーク (CNN)

10/29

畳み込みニューラルネットワークとは

- 画像認識を得意とするニューラルネットワーク
- 畳み込み層とプーリング層が追加
- フィルターにより、画像の特徴を抽出する

特徴を組み合わせせて出力



# 畳み込み層

フィルターにより、画像の特徴を抽出

①

0	0	6	8	1	0
1	5	2	0	8	3
5	2	0	1	1	8
1	0	8	0	0	3
0	0	8	0	0	1
1	0	8	1	2	0

入力データ

⊛

10	2	0
0	10	2
1	1	10

フィルター



61	250
107	5

入力画像のピクセル値とフィルターの値で畳み込み

$$\begin{aligned}
 &0 \times 10 + 0 \times 2 + 6 \times 0 + \\
 &1 \times 0 + 5 \times 10 + 2 \times 2 + \\
 &5 \times 1 + 2 \times 1 + 0 \times 10 \\
 &= 61
 \end{aligned}$$

# 畳み込み層

フィルターにより、画像の特徴を抽出

②

0	0	6	8	1	0
1	5	2	0	8	3
5	2	0	1	1	8
1	0	8	0	0	3
0	0	8	0	0	1
1	0	8	1	2	0

入力データ

⊛

10	2	0
0	10	2
1	1	10

フィルター



61	250
107	5

入力画像のピクセル値とフィルターの値で畳み込み

$$\begin{aligned}
 &8 \times 10 + 1 \times 2 + 0 \times 0 + \\
 &0 \times 0 + 8 \times 10 + 3 \times 2 + \\
 &1 \times 1 + 1 \times 1 + 8 \times 10 \\
 &= 250
 \end{aligned}$$

# 畳み込み層

フィルターにより、画像の特徴を抽出

③

0	0	6	8	1	0
1	5	2	0	8	3
5	2	0	1	1	8
1	0	8	0	0	3
0	0	8	0	0	1
1	0	8	1	2	0

入力データ

\*

10	2	0
0	10	2
1	1	10

フィルター

61	250
107	5

入力画像のピクセル値とフィルターの値で畳み込み

$$\begin{aligned}
 &1 \times 10 + 0 \times 2 + 8 \times 0 + \\
 &0 \times 0 + 0 \times 10 + 8 \times 2 + \\
 &1 \times 1 + 0 \times 1 + 8 \times 10 \\
 &= 107
 \end{aligned}$$

# 畳み込み層

フィルターにより、画像の特徴を抽出

④

0	0	6	8	1	0
1	5	2	0	8	3
5	2	0	1	1	8
1	0	8	0	0	3
0	0	8	0	0	1
1	0	8	1	2	0

入力データ

\*

10	2	0
0	10	2
1	1	10

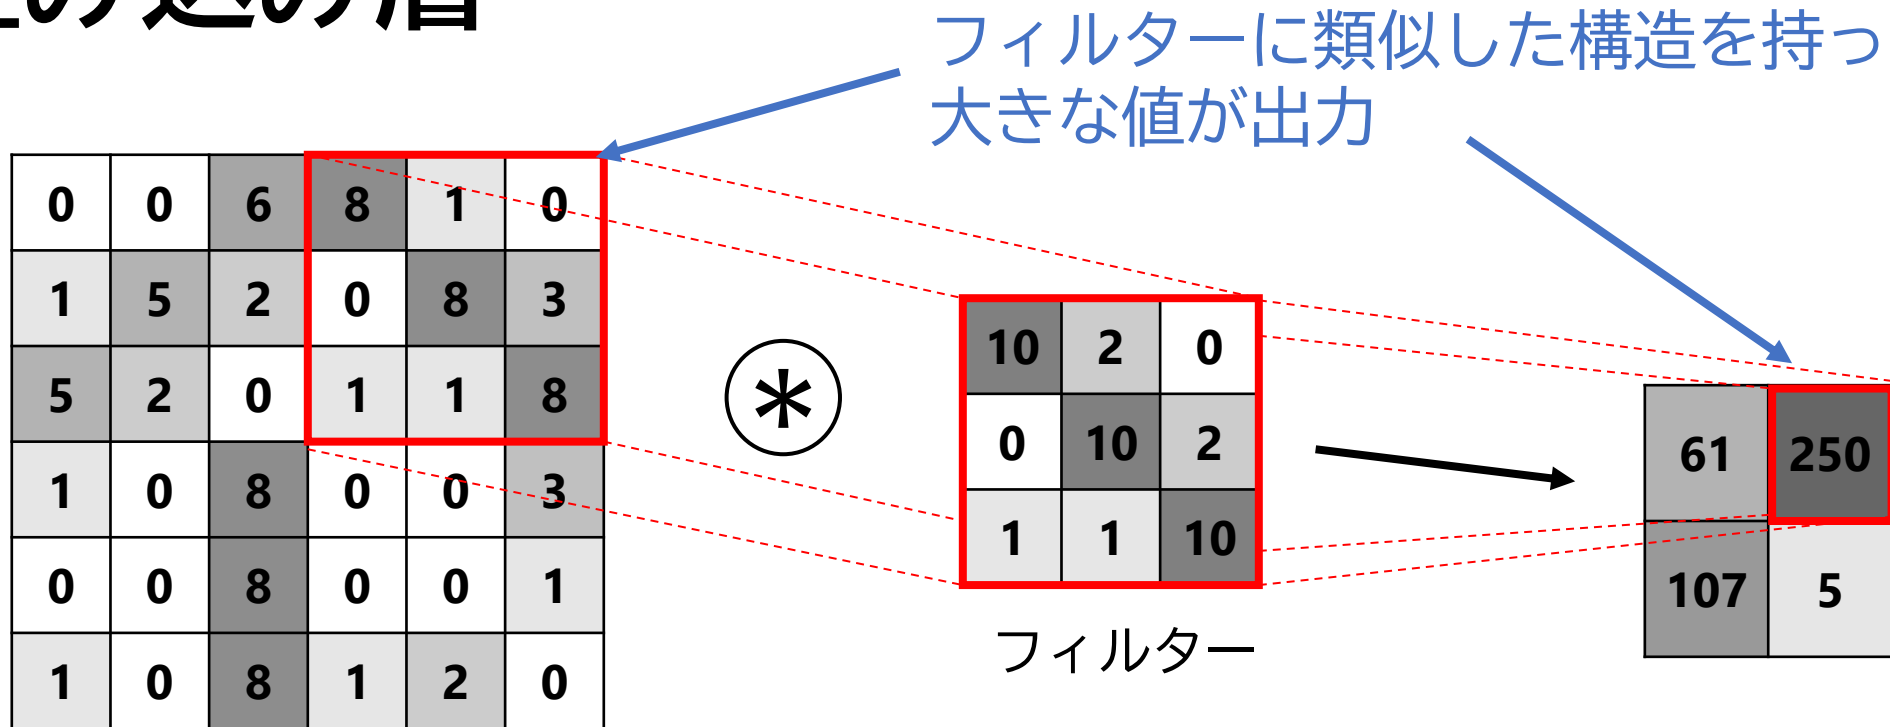
フィルター

61	250
107	5

入力画像のピクセル値とフィルターの値で畳み込み

$$\begin{aligned}
 &0 \times 10 + 0 \times 2 + 3 \times 0 + \\
 &0 \times 0 + 0 \times 10 + 1 \times 2 + \\
 &1 \times 1 + 2 \times 1 + 0 \times 10 \\
 &= 5
 \end{aligned}$$

# 畳み込み層



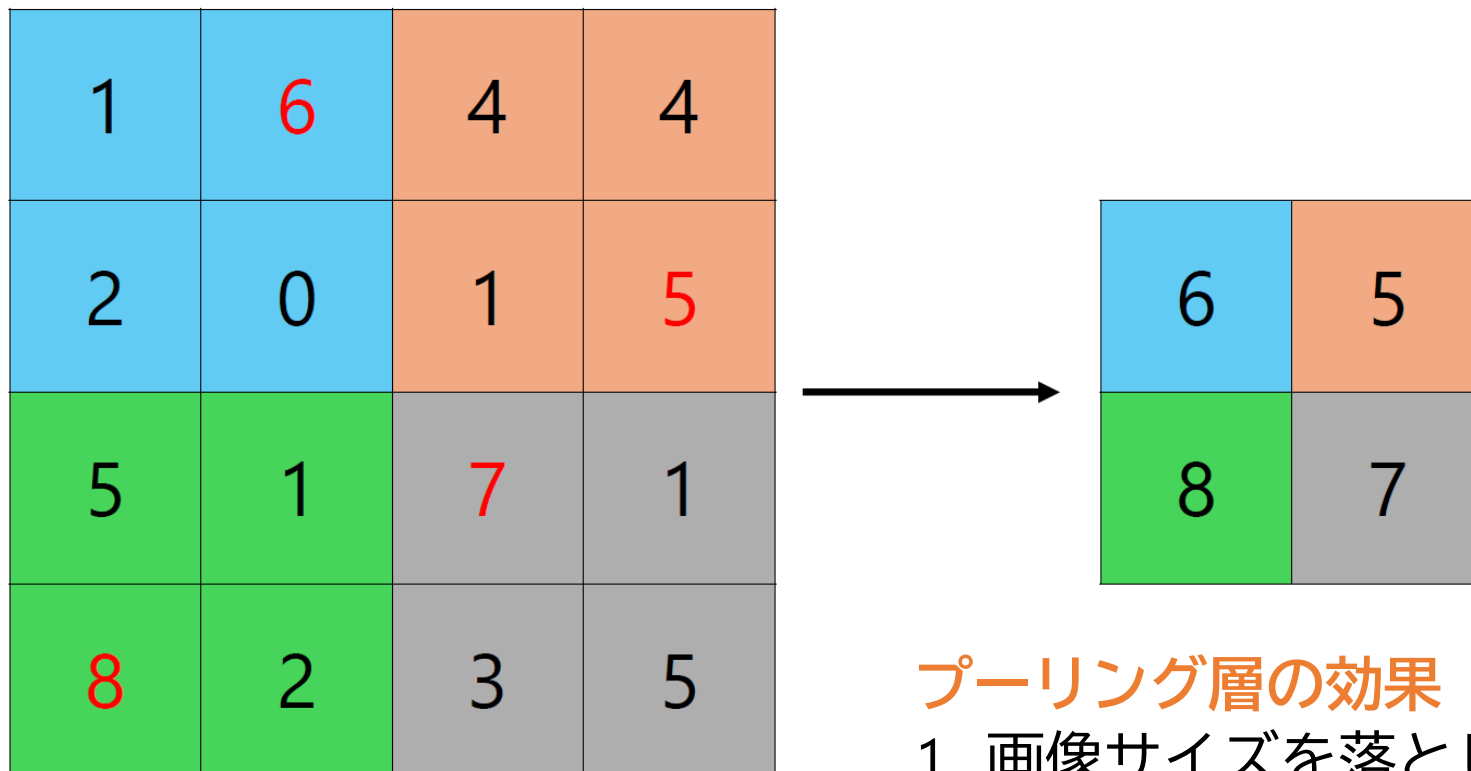
畳み込み層を何層も重ねる  
→様々な画像の特徴を抽出

フィルターの値の学習 (最適化)  
→修正された誤差逆伝播法

# プーリング層

## Maxプーリングについて

画像の領域（今回は $2 \times 2$ ）の最大値だけを出力（ダウンサンプリング）



## プーリング層の効果


1. 画像サイズを落とし、畳み込み層のフィルター適用範囲を広げる
2. 物体の回転・平行移動・スケールの不変性



# 畳み込みニューラルネットワーク (CNN)


## 通常のニューラルネットワーク

入力する特徴量を自分で設計する必要がある




## 畳み込みニューラルネットワーク

入力が画像形式であれば、自動的に最適な特徴抽出



# 空気シャワーアレイによるTeVガンマ線観測へのCNNの応用

地表空気シャワーアレイ

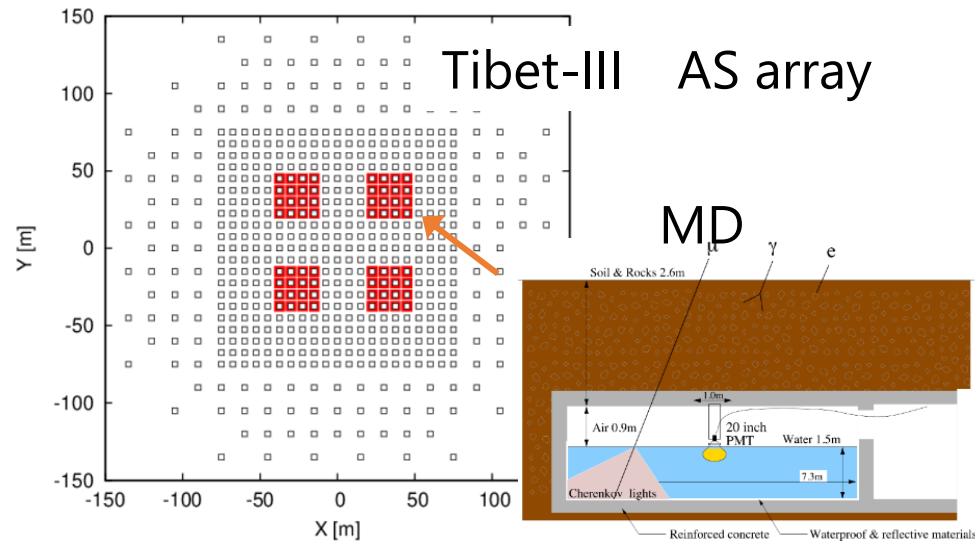


- 空気シャワーアレイの検出器が**碁盤の目状**に並んでいる  
→観測データを画像形式データ化  
→**CNN**を適用

# Tibet AS $\gamma$ 実験での高エネルギーガンマ線観測

## 2014年以降のガンマ線観測

地表空気シャワーアレイ (Tibet-III AS array) + 地下ミューオン検出器 (MD)



ミューオン数 少 → ガンマ線  
ミューオン数 多 → 宇宙線


## CNNの応用

- ① 2014年以前は空気シャワーアレイのみで観測、過去の観測データをガンマ線観測に活用するため、  
→ CNNを用いたガンマ線・宇宙線空気シャワー選別法の開発 (クラス分類問題)
- ② CNNを用いたガンマ線の到来方向決定性能の向上 (回帰問題: 数値の予測)


# ガンマ線・宇宙線空気シャワー選別 CNNの入力データについて

入力データ：2次粒子数密度の数値配列


- 各検出器は41x41の格子状に当てはめ
- 配列の要素の添え字が検出器の位置に対応
- 各要素に検出粒子数密度を格納する
- RGBの3チャンネルのうち1チャンネルのみ使用




入力データを可視化




10TeV Gamma



21TeV Proton



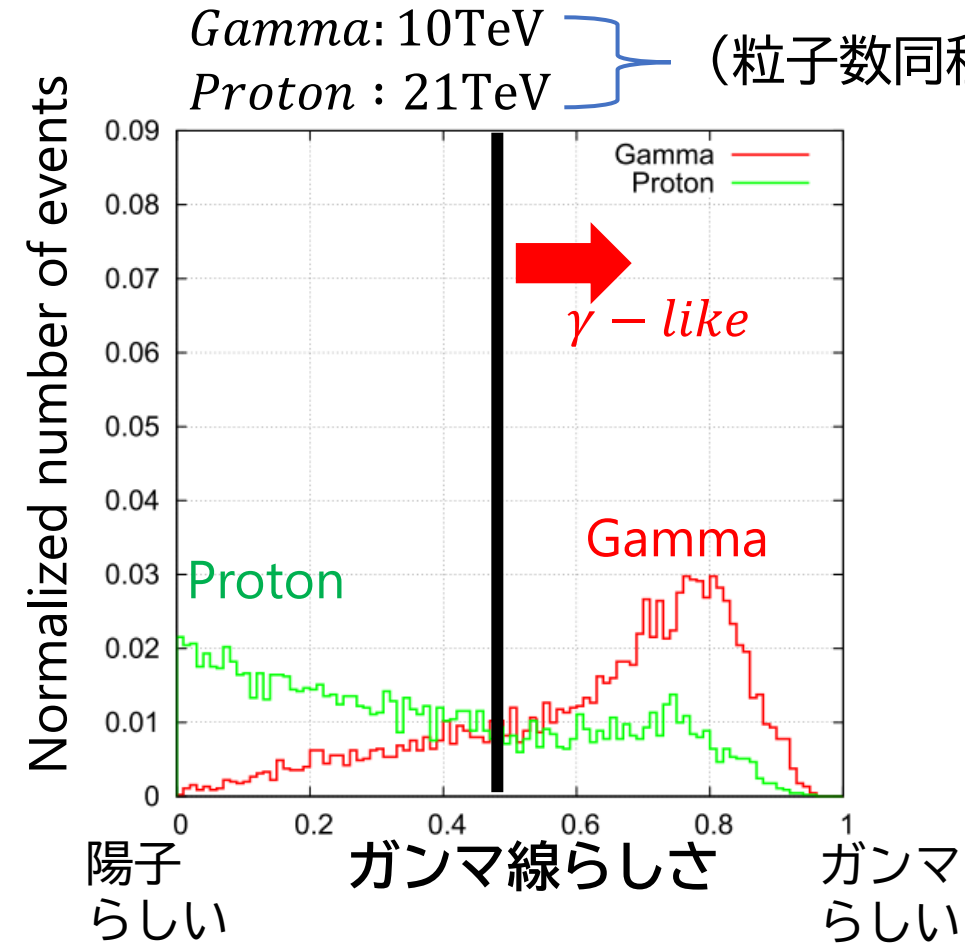
100TeV Gamma



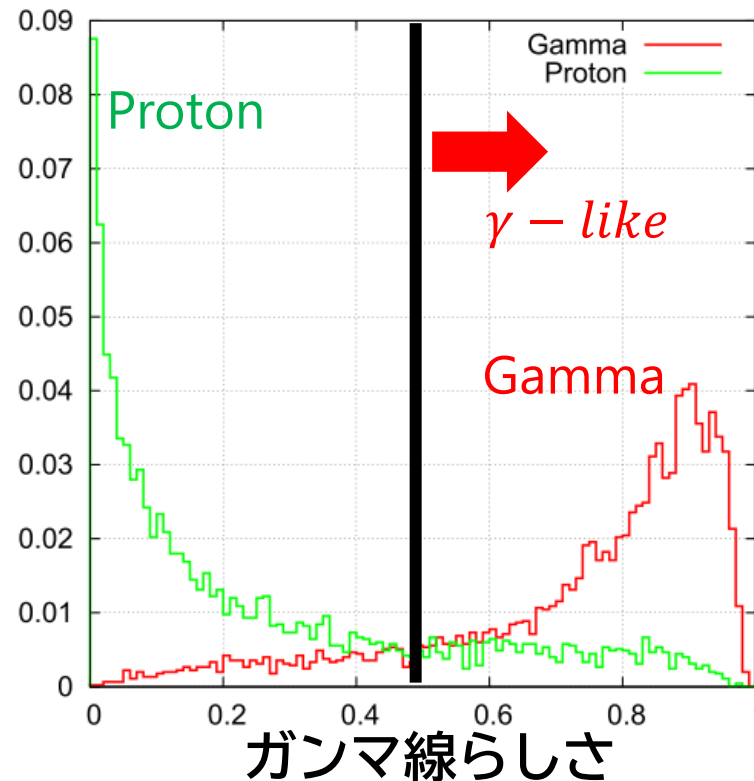
165TeV Proton

# CNNによる鉛直ガンマ線選別


鉛直入射ガンマ線、陽子空気シャワー



ガンマ線生存率 = 78%  
陽子除去率 = 74%



ガンマ線生存率 = 85%  
陽子除去率 = 80%



ガンマ線選別にCNNが有効  
→CNNの選別根拠を可視化

# Grad-CAMによるCNN選別根拠の可視化


## Grad-CAMによるヒートマップ

- 正しく選別されたイベントを4イベントずつ表示
- ヒートマップの赤い部分が、CNNの選別結果に大きく影響を与えた部分。


シャワー中心の特徴  
を基に選別

より広い領域の特徴  
を基に選別

### 100TeV Gamma




### 165TeV Proton




周辺部分の特徴  
を基に選別

中心や周辺の特徴  
を基に選別

### 10TeV Gamma



### 21TeV Proton

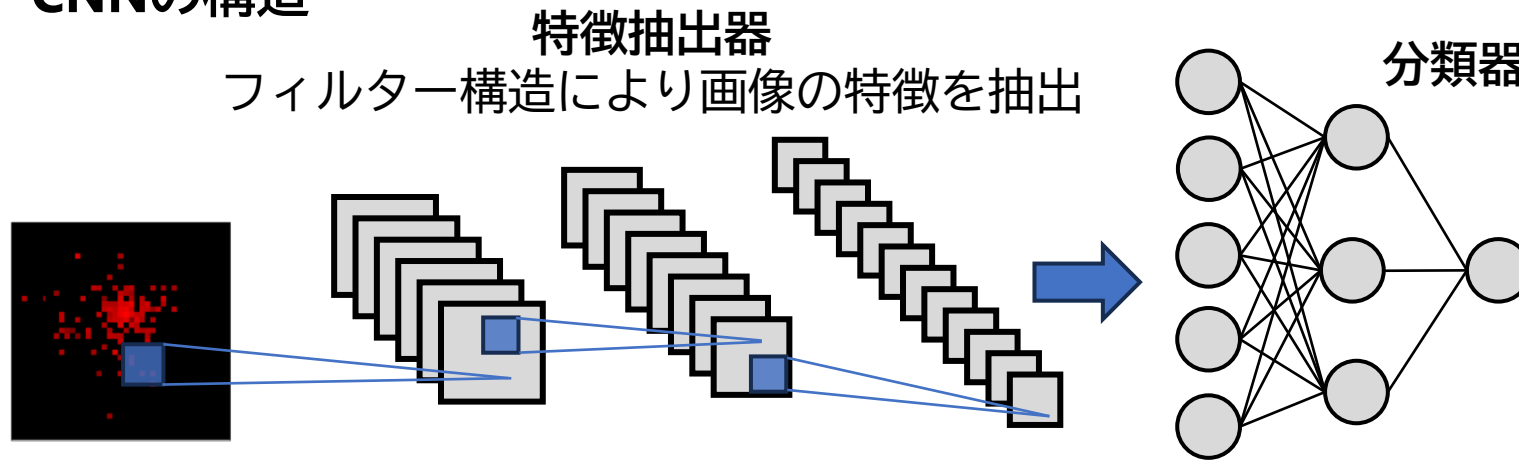


- 選別に使われる特徴がエネルギーに依存
- CNNの学習がエネルギーにより、柔軟に変化

# CNNの“かに星雲”観測へ適用 — 転移学習を応用した学習手法 —

- CNNの学習：かに星雲軌道(≠鉛直)の実験データ宇宙線とMCシミュレーションガンマ線を使用  
→ 実験データとMCSデータ間の違いを、CNNが学習する可能性

## CNNの構造



特徴抽出器が、実験データとMCSデータ間の違いを抽出  
→ 実験データのみによる学習が必要

実験データ宇宙線の中から、横広がりの特徴量使って

- ガンマ線の特徴をもつイベント
- 一般的な宇宙線イベントを抜き出す

## □ 転移学習を応用した学習


- ① 事前学習：実験データのみで特徴抽出器を学習
- ② 本番学習：実験データ宇宙線とMCSガンマ線で分類器を学習  
→ 実験データとMCSデータ間の差異による影響を低減

# CNNの“かに星雲”観測へ適用 - 有意性の向上 -

ガンマ線らしさ分布,  $10 \text{ TeV} \leq E_{rec}$

かに星雲方向の実験データにCNN適用  
@  $10 \text{ TeV} \leq E_{rec}$ 、観測期間: 719日

$P_\gamma > 0.5$  Gamma-like



	ON source	OFF source	Excess (ON - OFF)	Significance ( $\sigma$ )
CNN なし	99038	97744	1172	3.57
CNN あり	33471	32673	712	3.75

地表空気シャワーアレイのみでも、**CNN**によるガンマ線選別で、かに星雲に対する検出有意性の向上を確認


宇宙線  
らしい

ガンマ線らしさ

ガンマ線  
らしい



# CNNの“かに星雲”観測へ適用 — TeV領域ガンマ線スペクトル —



CNNを用いて、かに星雲ガンマ線スペクトルを計算  
@  $10 \text{ TeV} \leq E_{rec}$

過去のTibet AS $\gamma$ の観測結果と比較

(1)2019年:空気シャワーアレイ+地下ミューオン検出器

- 観測期間が本研究と同一

(2)2009年:空気シャワーアレイ

- (1), (2)各フラックス点は、エラーバーの範囲内

(3)ピンクの帯: CNN閾値を0.1 – 0.8で変化

- フラックス点の変化は統計誤差の範囲内

□ CNN手法によるスペクトル再構成の妥当性


□ 過去の観測データにCNN適用して、  
ガンマ線スペクトル再構成が可能に

# CNNによるガンマ線到来方向決定

## □ 今回は

CNN入力データとして、  
**粒子数** & **ヒットタイミング**  
 の画像形式データ（数値配列）を作成

### 数値配列を可視化



二次粒子数

ヒットタイミング

## □ 学習とテストについて (MCデータ使用)

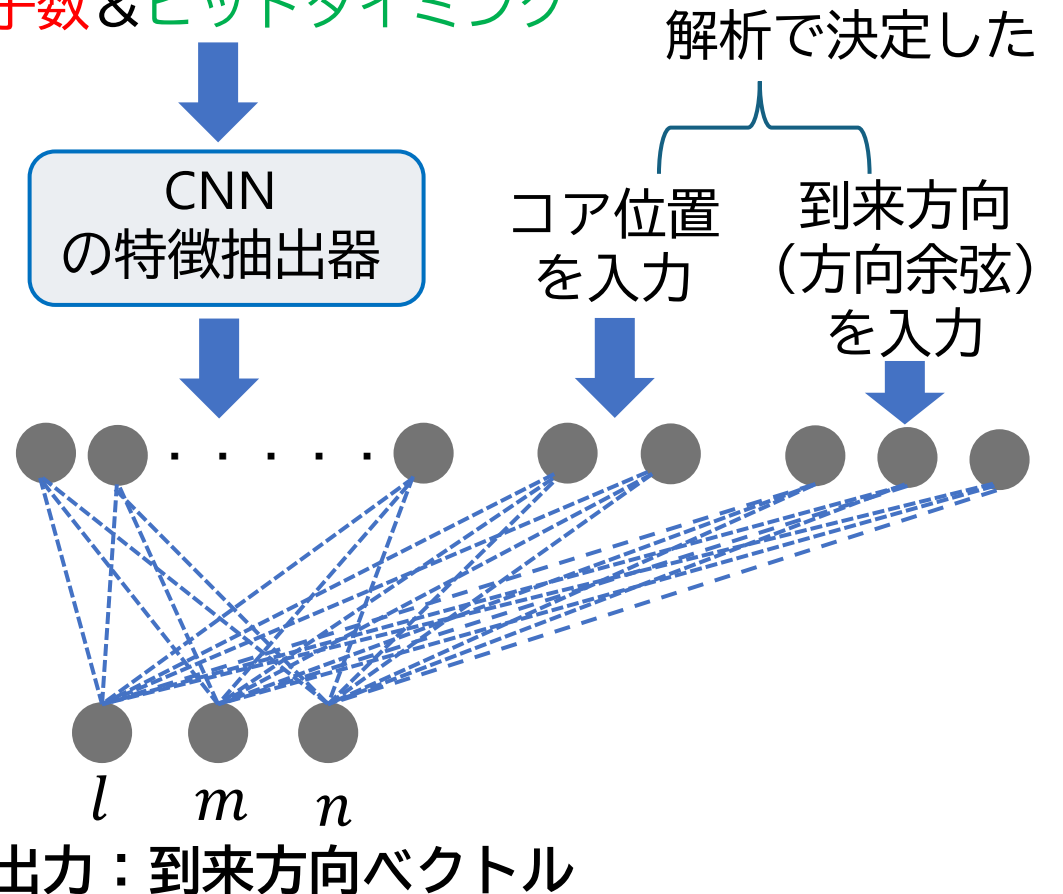
学習：全天一様ガンマ線

テスト：かに星雲軌道ガンマ線

→従来の方法 (Cone-fit) と性能比較


## □ CNNによる到来方向決定

画像形式データを入力  
**粒子数** & **ヒットタイミング**



# 角度分解能：CNNとCone-fitの比較(1)

3162 ≤ 検出粒子数 < 5623 (371 TeV)



全天一様、MCSガンマ線でCNNを学習

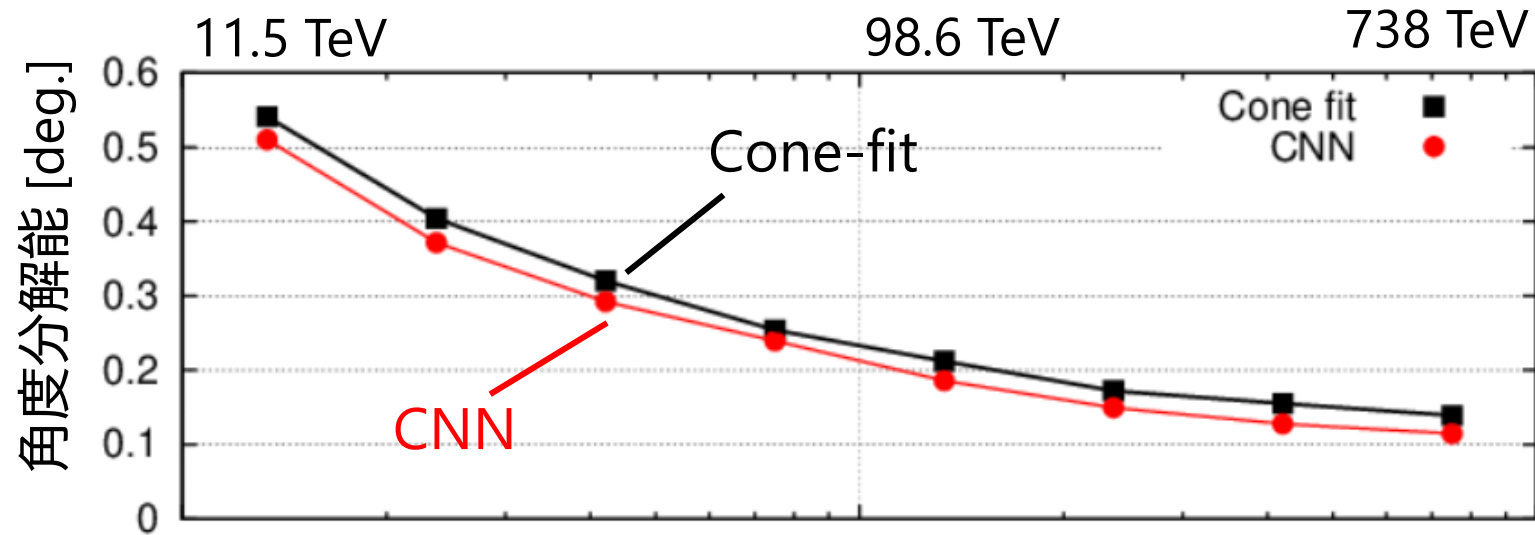


かに星雲方向MCSガンマ線をCNNに入力

角度分解能：角度誤差（図の横軸）順に並べて、50%含む値

他のエネルギービンでも比較

# 角度分解能：CNNとCone-fitの比較(2)



上段

エネルギービン  
VS  
角度分解能

0.320° → 0.292° @32.9 TeV  
0.172° → 0.144° @187 TeV

全てのビンで精度向上


下段

エネルギービン  
VS  
分解能の向上割合

数10TeV以上の領域で、  
10%程度向上

角度分解能

$$\frac{R_{\text{Cone-fit}} - R_{\text{CNN}}}{R_{\text{Cone-fit}}}$$



検出粒子数( $\propto$  一次ガンマ線エネルギー)

# まとめ

Tibet AS $\gamma$ 実験の地表空気シャワーアレイによる、TeVガンマ線観測にCNN応用

①ガンマ線・宇宙線の選別(ミュオン検出器建設以前のデータを活用するため)

□鉛直10, 100 TeVガンマ線イベント

- ガンマ線選別が可能 (ガンマ線生存率~8割, 宇宙線除去率~8割)
- Grad-CAMによる選別根拠可視化

□かに星雲観測に適用

- 検出有意性向上を確認 ( $3.57\sigma \rightarrow 3.75\sigma$ )
  - スペクトル再構成し、過去のTibet AS $\gamma$ 実験の結果との整合性を確認
- ミュオン検出器建設 (2014年) 以前の観測データが活用可能に

②到来方向決定に使用 (10 - 数100 TeV領域)

角度分解能が10%程度向上




# シミュレーションによる学習、テスト用 空気シャワーイベント生成

## シミュレーション条件


空気シャワーシミュレーション: **CORSIKA7.6400**

	$\gamma$ rays	Protons	
1次粒子エネルギー	10TeV 100TeV	21TeV 165TeV	} 同程度の 粒子数
天頂角	0°		
コア位置	アレイ中心付近 (半径50m)		
総イベント数	$3.0 \times 10^4$ events $2.97 \times 10^4$ events	$2.5 \times 10^5$ events $6.95 \times 10^4$ events	
観測高度	4,300 m		
相互作用モデル	EPOS LHC v3400, fluka 2011.2x		

鉛直入射ガンマ線、陽子空気シャワー



検出器シミュレーション: **GEANT4.10.04**




地表 AS アレイ

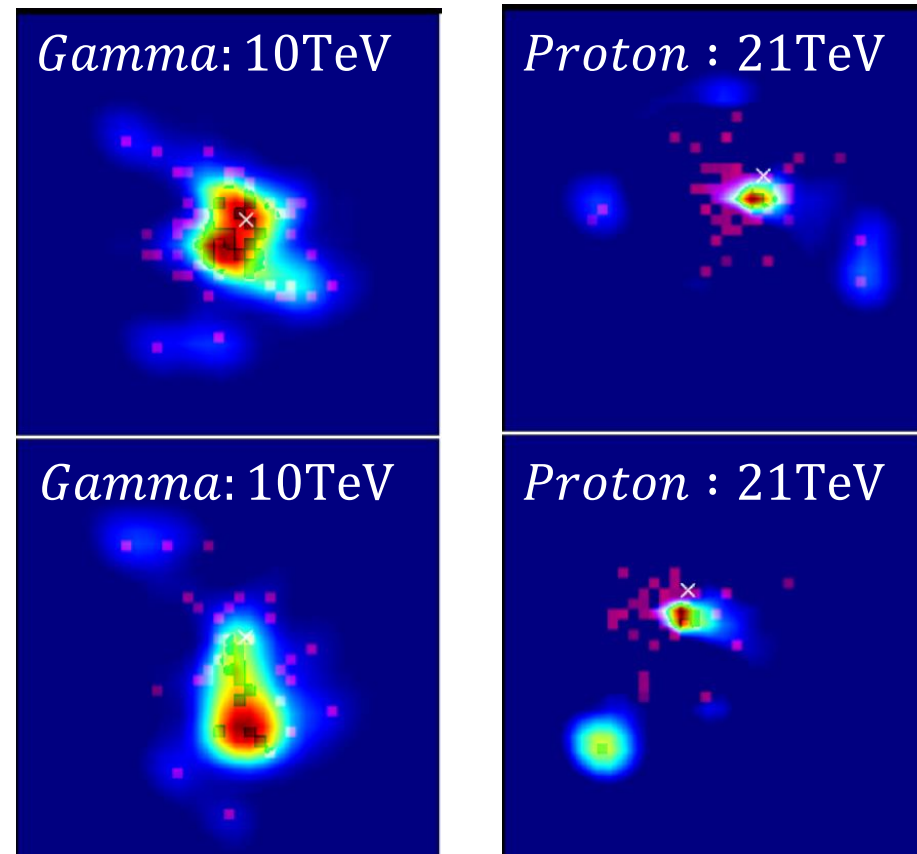
- シンチレーション  
検出器597台

# Grad-CAMによるヒートマップ

正しく選別されたイベントを表示




間違えて選別されたイベントを表示






# Grad-CAMによるヒートマップ

正しく選別されたイベントを表示



間違えて選別されたイベントを表示



# CNN特徴抽出器の学習

実験データ宇宙線の中から、横広がり（の値が、  
小さい（ガンマ線に対応）／ 大きい（宇宙線）

イベントを特徴量を使って抽出

- ① MCガンマ線に  $R_2, N_1$  分布を合わせたイベント
- ② 元の実験データ宇宙線と同じ  $R_2, N_1$  分布のイベントを抽出

## 特徴量

ガンマ線：小、宇宙線：大

特徴量  $R_2$

$$R_2 = \frac{\sum \rho_i^2 \times r_i}{\sum \rho_i^2}$$

$i$ 番目の検出器が検出した  
粒子数密度

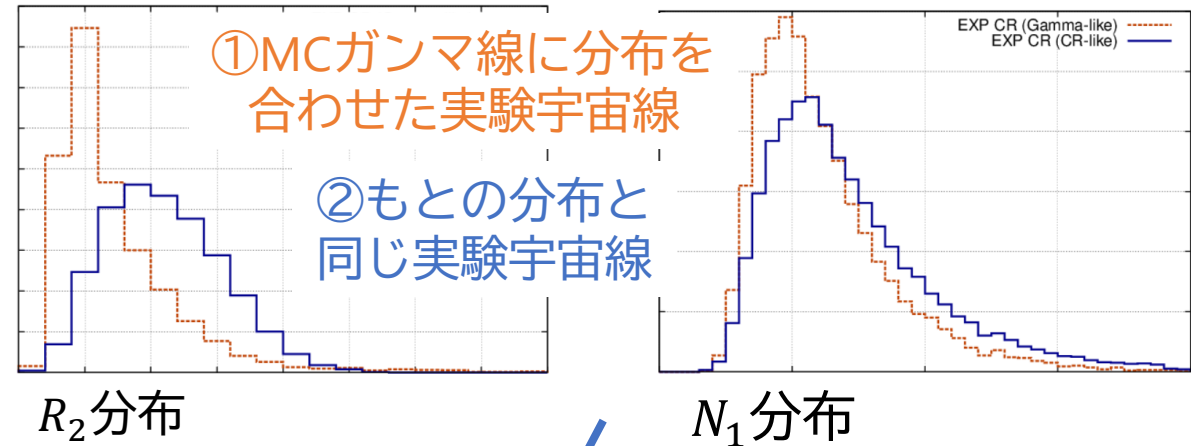
$i$ 番目の検出器の  
シャワーコアからの距離

特徴量  $N_1$

$$N_1 = \rho_{max} \times r$$

1つの検出器が検出した  
粒子数密度の最大値

$31.6 \text{ TeV} \leq E_{rec} < 56.2 \text{ TeV}$





$R_2$  分布

$N_1$  分布


学習により  
最適化

特徴抽出器



分類器


実験データ宇宙線と  
MCガンマ線で学習




# ニューラルネットワーク

最も単純なニューラルネットワーク

例) クラスAとクラスBの分類  
 入力 $x_1, x_2$ から出力 $y$  (A: 0, B: 1)を得る







$y = f(w_1x_1 + w_2x_2)$   
 $f$ : 活性化関数  
 今回はバイアス項は省略



# 多層化する

1層だけでは分類できない  
2層目を追加して表現力向上



# データ取得条件とガンマ線イベント選別

337/429

空気シャワーシミュレーション：CORSIKA7.6400

$\gamma$  rays

生成エネルギー 300GeV-10PeV


スペクトル  $E^{-2.6}$

到来方向 かに星雲軌道


相互作用モデル EPOS LHC v3400, fluka 2011.2x

検出器シミュレーション

GEANT4.10.04




2次粒子数から  
画像形式データ作成



## 実験データの取得

- かに星雲方向 (ON source)
- 非かに星雲方向 (BG推定、宇宙線学習データ)



2次粒子数から  
画像形式データ作成

## ガンマ線イベント選別

学習データによって  
CNNの学習



テストデータ入力  
出力：ガンマ線らしさ  
(シグモイド関数で定義)


$$P_{\gamma} = \frac{1}{1 + e^{-(\text{CNN 最終層の値})}}$$

( $0 \leq P_{\gamma} \leq 1$ )

# 一次粒子の到来方向決定

## Cone-fit

検出器ヒットタイミングをコーン状の関数でフィット  
⇒一次粒子の到来方向を再構成



## Tibet AS $\gamma$ 実験の角度分解能

~0.5° @ 10 TeV  $\gamma$  rays , ~0.2° @ 100 TeV  $\gamma$  rays

# MCデータ生成条件とCNNの学習


## CNNの学習

全天一様、MCガンマ線で学習



## CNNの性能評価

かに星雲方向MCガンマ線を入力  
Cone-fitによる結果と比較



## 空気シャワー生成条件: CORSIKA 7.6400

	学習データ	テストデータ
エネルギー範囲	300 GeV-10 PeV	
スペクトルの冪	2	2.6
到来方向	全天一様	かに星雲軌道
コア位置	半径300 m 以内	
観測高度	4,300 m	
相互作用モデル	EPOS LHC v3400, fluka 2011.2x	
総イベント数	$9.969 \times 10^7$	$6.888 \times 10^8$

## トリガー条件

- 4台以上の検出器が0.6粒子以上を検出

## セレクション条件

- $10^2 < \text{検出粒子数} < 10^4$  (11.5-738TeV)
- Cone-fitによる天頂角  $< 40$
- Cone-fitの剰余誤差  $< 1.0$  m
- 検出粒子数上位6台中、5台がインナーエリア

# 有意性向上割合の統計誤差 計算方法

CNN選別前後の有意性( $S_1$ : 前,  $S_2$ : 後)

$$S_1 = \frac{N_{on1} - \eta_1 N_{off1} / \delta}{\sqrt{\alpha \eta_1 N_{off1} / \delta}}, \quad S_2 = \frac{N_{on2} - \eta_2 N_{off2} / \delta}{\sqrt{\alpha \eta_2 N_{off2} / \delta}}$$

有意性の向上割合:  $\varepsilon_{exp} = \frac{S_2}{S_1}$

方位角異方性補正係数


$$\eta_1 = \frac{\sum_{i=1}^{\theta} N_{on1,i}^{dummy}}{\sum_{i=1}^{\theta} N_{off1,i}^{dummy} / \delta}, \quad \eta_2 = \frac{\sum_{i=1}^{\theta} N_{on2,i}^{dummy}}{\sum_{i=1}^{\theta} N_{off2,i}^{dummy} / \delta}$$

$\eta$ : 方位角補正係数

$$\alpha = 1 + \frac{1}{\theta} + \frac{1}{\theta \delta} + \frac{1}{\delta}$$

$\delta = 16$ : オフソース数

$\theta = 26$ : ダミーソース数



実験で得られた有意性の向上割合  $\varepsilon_{exp}$  の統計誤差を計算する。

ここで、選別前後で変化する変数は、

$$N_{on1} \rightarrow N_{on2}, \quad N_{off1} \rightarrow N_{off2}$$

$$\sum_{i=1}^{\theta} N_{on1,i}^{dummy} \rightarrow \sum_{i=1}^{\theta} N_{on2,i}^{dummy}, \quad \sum_{i=1}^{\theta} N_{off1,i}^{dummy} \rightarrow \sum_{i=1}^{\theta} N_{off2,i}^{dummy}$$

である。

選別前の変数を固定し、選別後の変数を  $N_{trial}$  回変化させ、 $\varepsilon_{sim}$  値の分布を作成する。これにより、得られた実験データ(有意性=3.57 $\sigma$ )に対してCNN選別を行うことによる、有意性向上割合のゆらぎを評価する。



# 有意性向上割合の統計誤差 計算方法

CNN選別による生存率（それぞれ実験データから得られた値）

$$R_{on} = \frac{N_{on2}}{N_{on1}}, R_{off} = \frac{N_{off2}}{N_{off1}}, R_{\eta,on} = \frac{\sum_{i=1}^{\theta} N_{on2,i}^{dummy}}{\sum_{i=1}^{\theta} N_{on1,i}^{dummy}}, R_{\eta,off} = \frac{\sum_{i=1}^{\theta} N_{off2,i}^{dummy}}{\sum_{i=1}^{\theta} N_{off1,i}^{dummy}}$$

生存率の計算には全て、  
実験で得られた値を使う。




上記生存率を用いて、  
二項分布から選別後のイベント数を  $N_{trial}$  回生成する。

$j = 1$  回目の試行

- 1) 上記の生存率  $R_{on}$  から、試行回数  $N_{on1}$ 、確率  $R_{on}$  の二項分布に従い、 $N_{on2}^{j=1}$  を生成。
- 2) 同様の過程で、 $N_{off2}^{j=1}$ ,  $(\sum_{i=1}^{\theta} N_{on2,i}^{dummy})^{j=1}$ ,  $(\sum_{i=1}^{\theta} N_{off2,i}^{dummy})^{j=1}$  を計算。
- 3) これらを用いて、選別後の有意性  $S_2^{j=1}$  と有意性の向上割合  $\varepsilon_{sim}^{j=1} = \frac{S_2^{j=1}}{S_1}$  を計算

$N_{trial}$  回繰り返す.....

$\varepsilon_{sim}^j$  の分布を作成し、その標準偏差から  $\varepsilon_{exp}$  の統計誤差を見積もる。



# 有意性向上割合の統計誤差 計算方法

CNNによるガンマ線選別 ( $10 \text{ TeV} \leq E_{rec}$ )  
 $3.57\sigma \rightarrow 3.75\sigma$ に向上 (検出有意性向上割合  $\epsilon_{exp} = 1.05$ )  
 右図の分布の幅から、 $\epsilon_{exp} = 1.05$ の統計誤差は $\pm 0.23$ となる。  

$$\epsilon_{exp} = 1.05 \pm 0.23$$

MCSガンマ線を用いた予測では、 $\epsilon_{MCS} = 1.23$

MCSガンマ線による予測とは矛盾していない。

本研究の観測期間は2年間で、BGの不確実性が影響を及ぼしたと考えられるが、十分な期間であれば1.23倍の向上が予想できる。

