

FDのための深層学習を用いた 宇宙線空気シャワー解析手法の開発

第5回 空気シャワー勉強会
大阪電気通信大学(oecu) B4
佐藤 聖真

目次

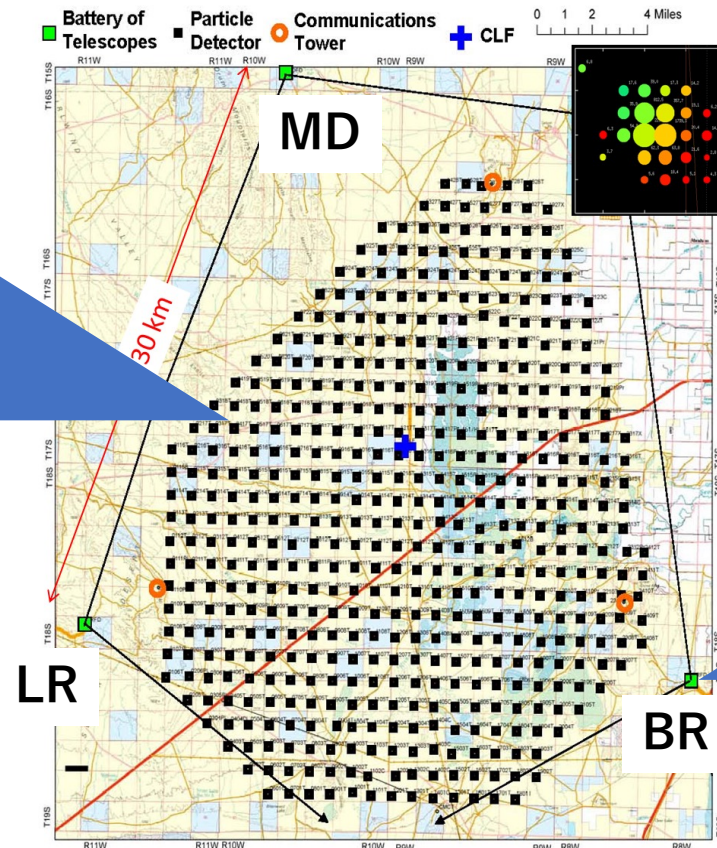

1. テレスコープアレイ実験
2. 大気蛍光望遠鏡の観測手法
3. 研究目的
4. FDイベントディスプレイ
5. 深層学習
6. 深層学習の学習手順
7. クラス分類学習
8. 天頂角の分類学習
9. 改良点
10. 改良前と改良後の結果比較

テレスコープアレイ (TA) 実験

- アメリカユタ州で行われている、日米韓露白の国際共同実験で、北半球最大の宇宙線観測実験。
- TA実験は大気蛍光望遠鏡や地表粒子検出器を用いて、 10^{18} eV以上のエネルギーを持つ超高エネルギー宇宙線を観測している。


地表粒子検出器

プラスチックシンチレータが使われている



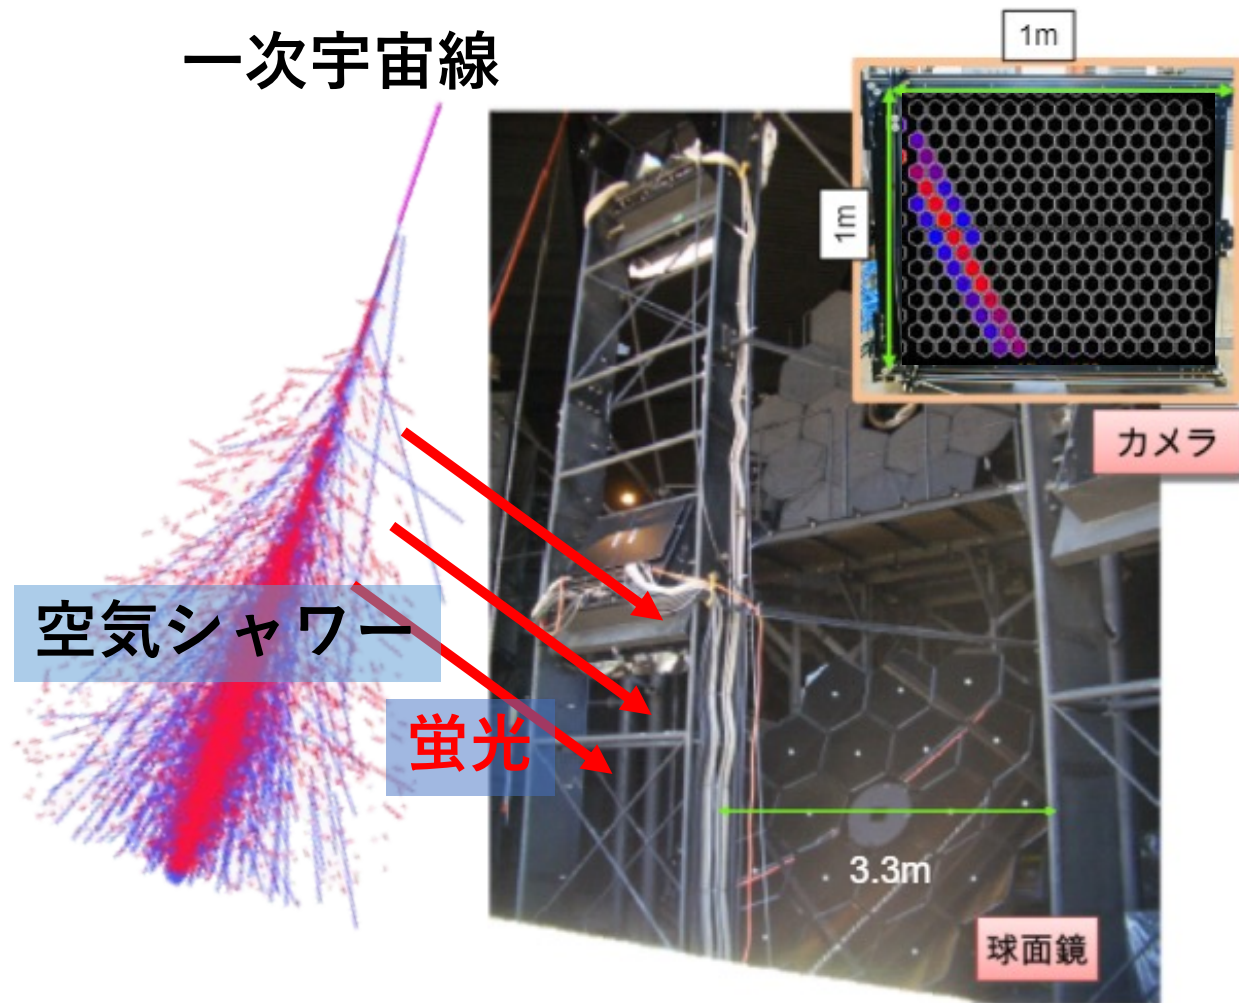
大気蛍光望遠鏡

地表粒子検出器を囲むように3台設置



大気蛍光望遠鏡 (FD) の観測手法

一次宇宙線





大気蛍光望遠鏡

大気蛍光望遠鏡

- 望遠鏡は256本のPMTと口径3.3mの球面鏡で構成。
- 1ステーションに上下6台、計12台の望遠鏡が設置されている。
- ステーション全体で方位角 108° 、仰角 $3^\circ - 33^\circ$ の範囲を観測する。
- 荷電粒子が大気と相互作用した際に発生する大気蛍光を球面鏡でカメラに集光し観測。
- 測定したデータから宇宙線の**エネルギー**や**到来方向**などを求める。

研究目的


- 従来のFDにおける宇宙線空気シャワー再構成手法。
 - 信号の入ったPMTの選別
 - シャワー軸とFDを含む平面(SDP)の決定
 - SDPから空気シャワージオメトリの再構成
 - 数値計算による宇宙線のエネルギー決定
 - モンテカルロシミュレーションと観測データの比較
- PMTの選別や数値計算、大量のシミュレーションが必要になるため、解析に時間がかかる。



新たな解析手法として**深層学習**を用いた空気シャワー解析手法を**開発**する。

→ それにより、観測を行いながらも空気シャワーの解析が可能になる。

FDイベントディスプレイ




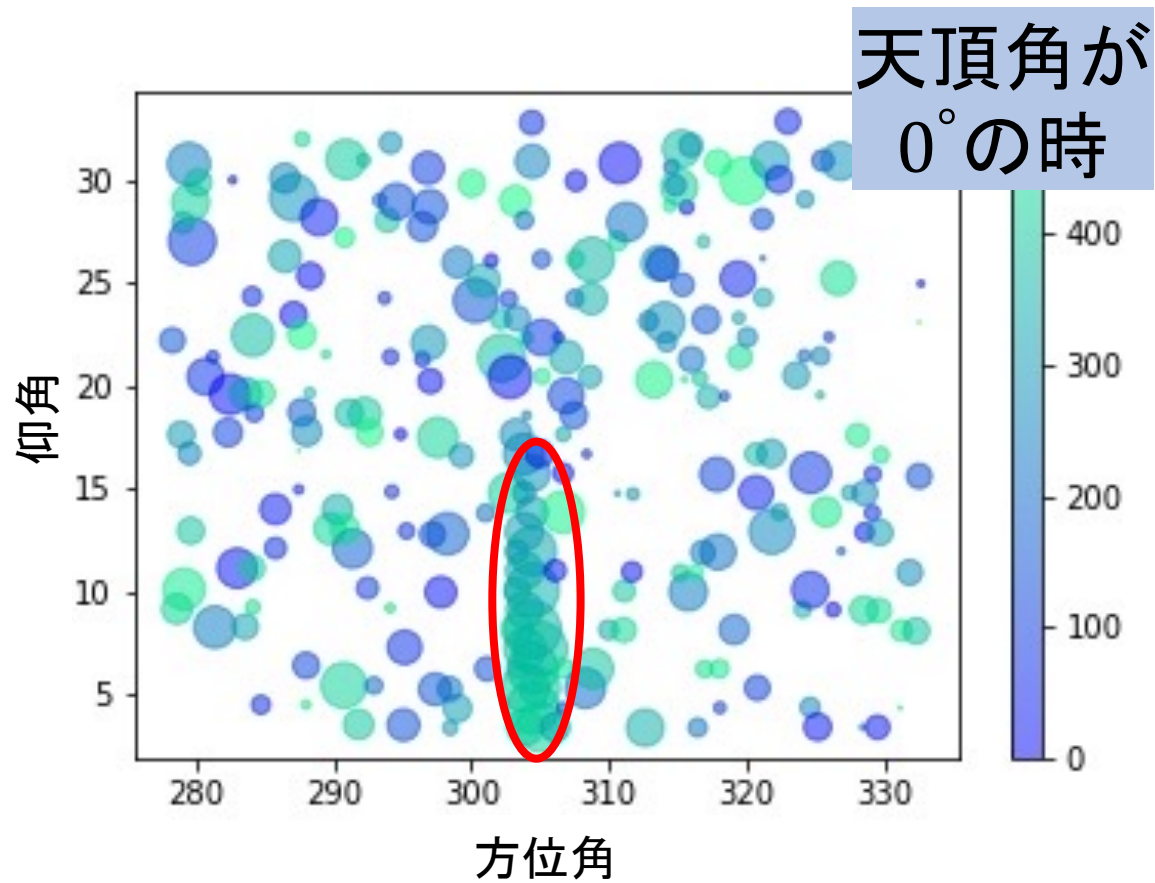
シミュレーションデータから作成した
イベントディスプレイ



深層学習にはTA Softのシミュレーションデータで作成した
イベントディスプレイを**学習データ**として使用する。

- FDからは各PMTに入ってきた蛍光量と入射した時間の情報が得られる。
- イベントディスプレイはFDで観測されたデータを使って空気シャワーを**可視化**した画像。
- 点の大きさが各PMTに入ってきた**光電子数**、点の色が各PMTに入ってきた**タイミング時間**の情報。

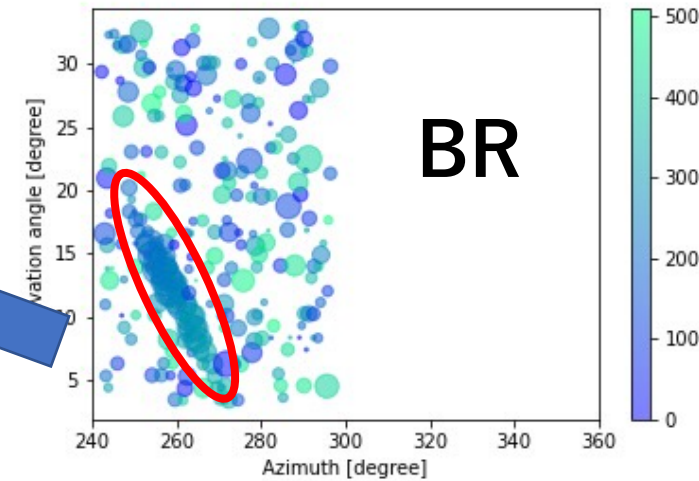
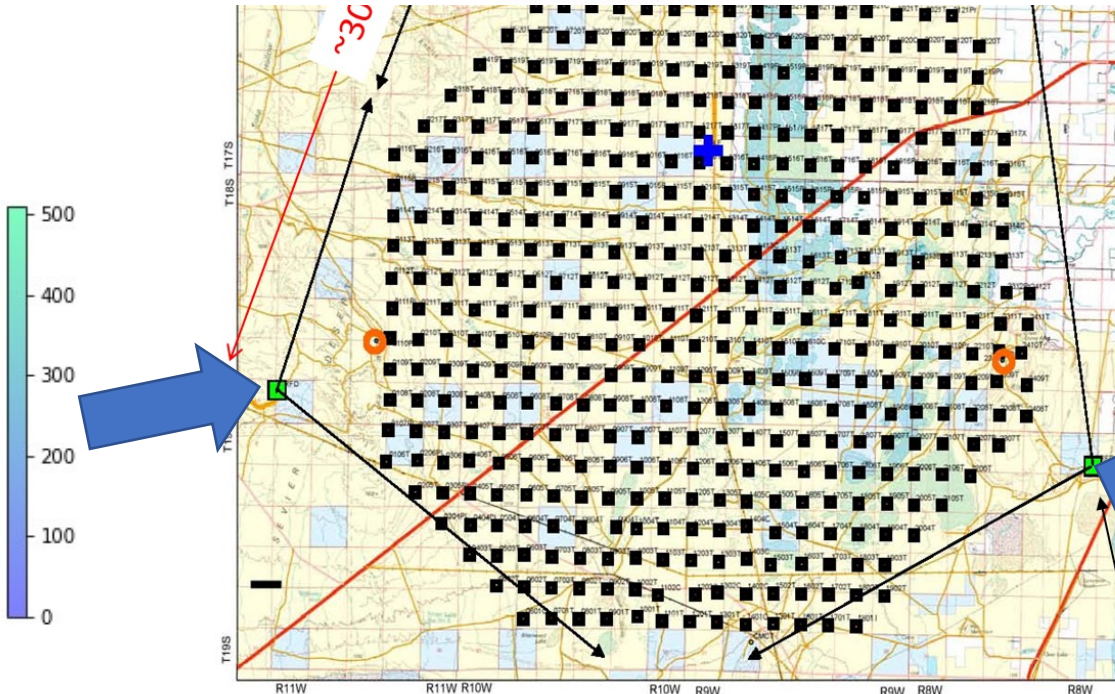
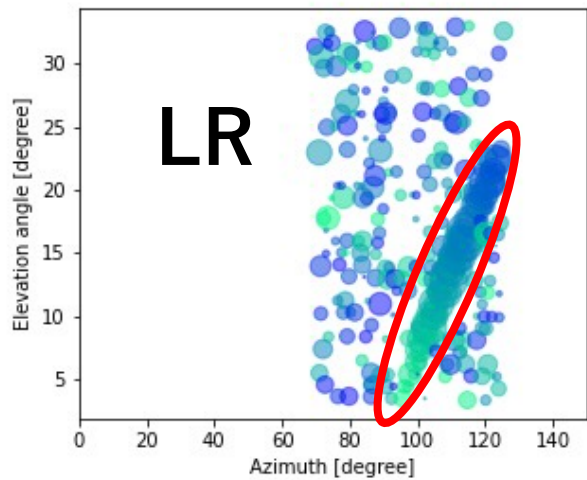
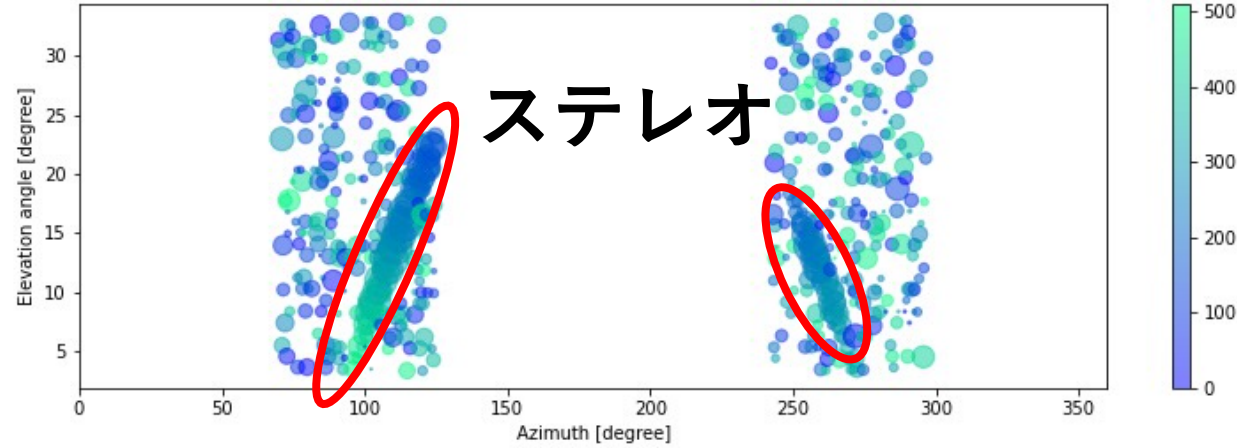
イベントディスプレイの例



赤い丸で囲ったところが空気シャワーの軌跡
空気シャワーのジオメトリが変化すると、軌跡も変化する。

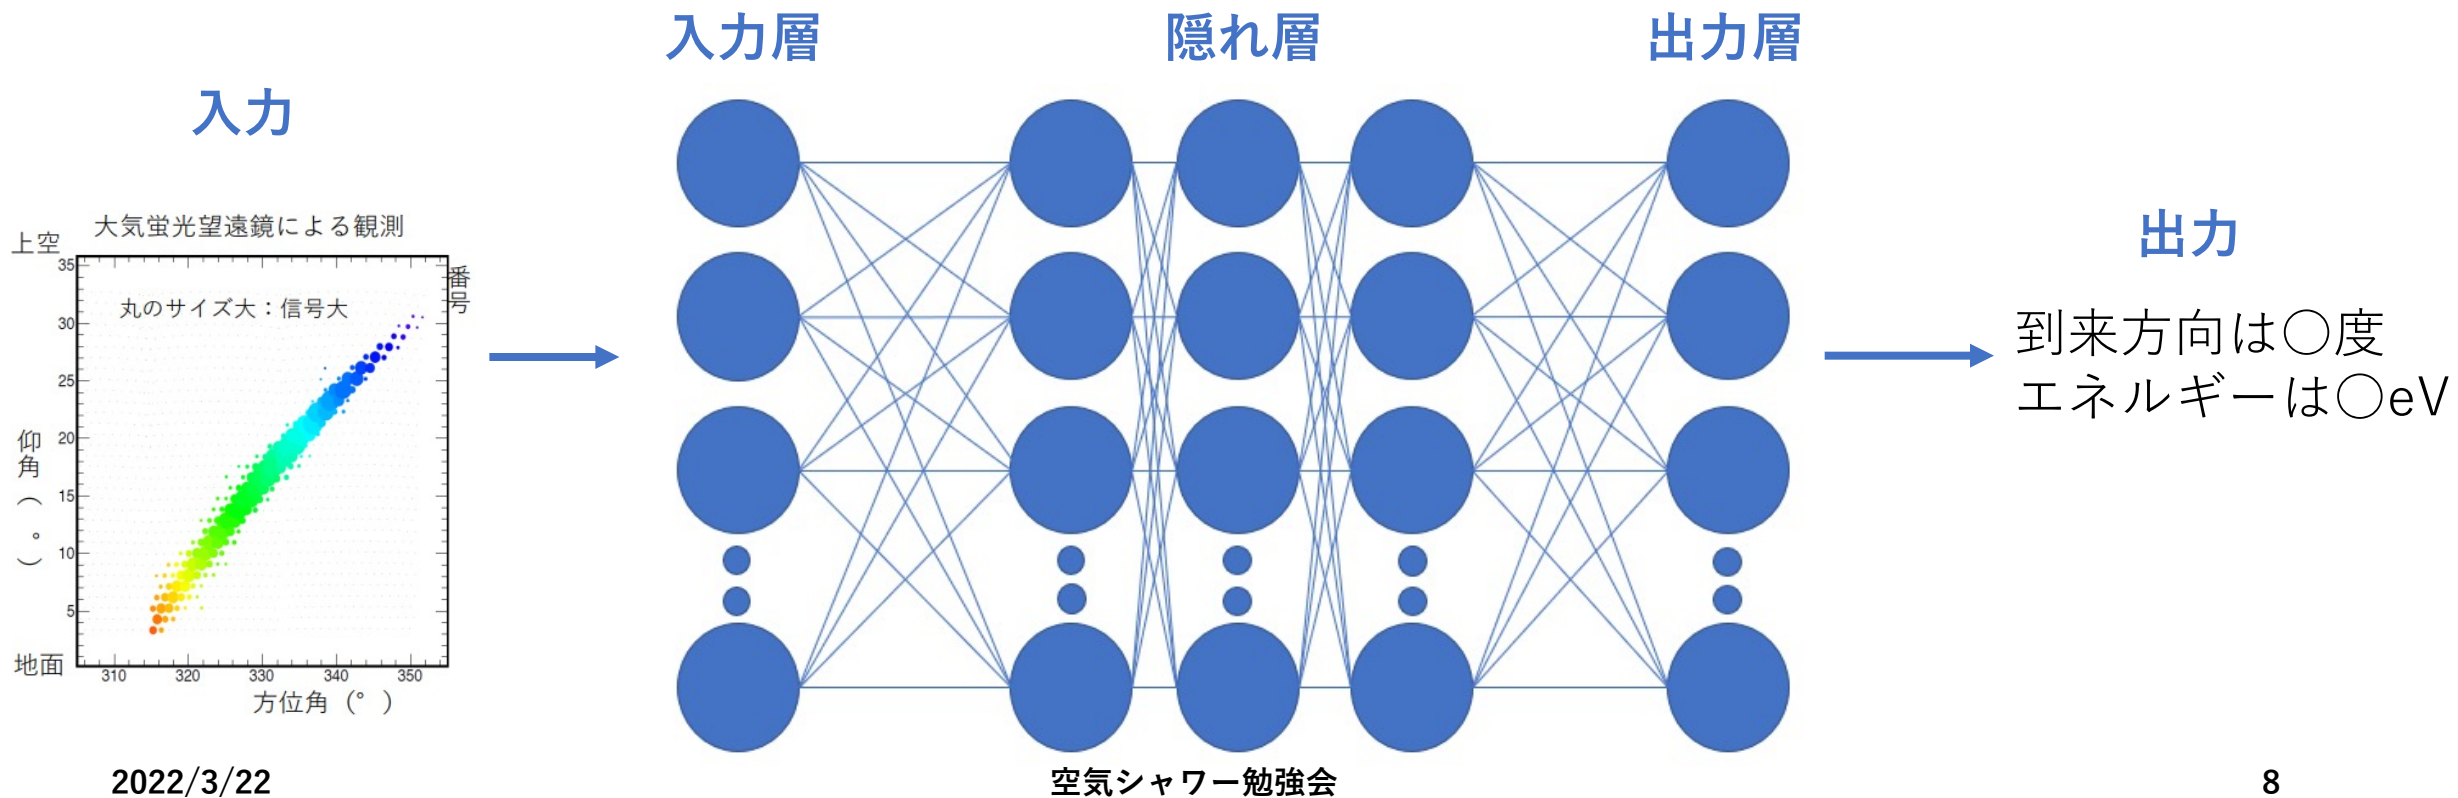
イベントディスプレイの例

同じ空気シャワーでも
ステーションによって
見え方が変わる。



深層学習(ディープラーニング)

- 人間の脳の仕組みを再現したニューラルネットワークを用いた機械学習の手法の一つ。
- 従来の機械学習の手法との違いは、データ量が十分にあればマシンが**自動的に**データの特徴を抽出することができる点である。
- 層が**多層**になれば、データに含まれる特徴もより**深く学習を行える**。



深層学習の学習手順

1. 学習用データセットの作成。
 - 本研究のデータセットには**イベントディスプレイ**を使用する。
2. 分類するクラスを決める。
 - 例:犬か猫の判別の場合は「犬」と「猫」の2クラス。
3. データセットをクラスごとに分類(ラベリング)する。
4. データセットを訓練データと検証データに分ける。
 - 学習に使わないデータを用意することで、学習モデルの**汎用性能**を確かめる事が出来る。
5. 訓練データをマシンに入力し学習させる。
6. 訓練データで検証する。
7. 検証データで検証する。
8. 5～7までを自分で決めた学習回数分繰り返す。

クラス分類学習

- 空気シャワーの軌跡が「垂直」か、「傾いているか」を判定する二値分類を行い、イベントディスプレイで深層学習が行えるかを確認する。
- 天頂角が 0° から 30° までの空気シャワーを「垂直」、 30° から 70° までの空気シャワーを「傾いている」と定義し、それぞれの空気シャワーのイベントディスプレイをマシンに学習させ判定させた。

シミュレーションの条件

エネルギー	$\log(E/eV) = 19$
天頂角	$0 \sim 70^\circ$
方位角	$0 \sim 360^\circ$
coreX	$-10 \sim 10$ km
coreY	$-10 \sim 10$ km

深層学習の環境

使用マシン



- MacBook pro(13-inch,M1,2020)

ライブラリ

- python : 3.8.12
- numpy : 1.19.5
- matplotlib: 3.4.3
- tensorflow: 2.6.0
- keras : 2.6.0

クラス分類学習

- 空気シャワーの軌跡が「垂直」か、「傾いているか」を判定する二値分類を行い、イベントディスプレイで深層学習が行えるかを確認する。
- 天頂角が 0° から 30° までの空気シャワーを「垂直」、 30° から 70° までの空気シャワーを「傾いている」と定義し、それぞれの空気シャワーのイベントディスプレイをマシンに学習させ判定させた。



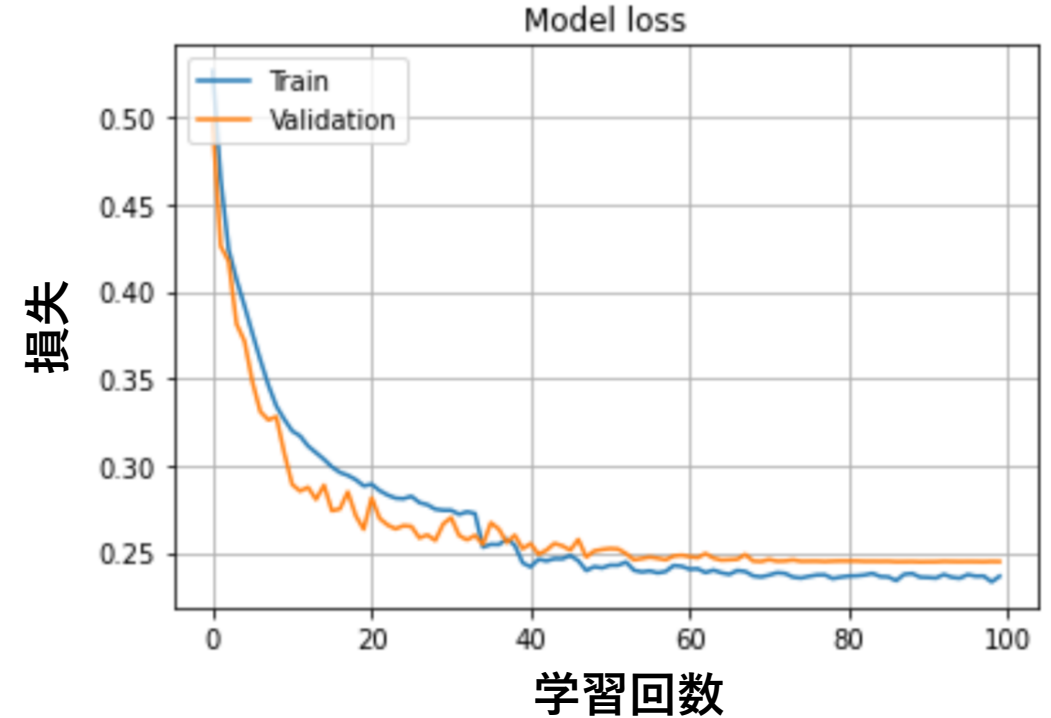

大きさ:各PMTに入ってきた**光電子数**
色:各PMTに入ってきた**タイミング**



計30000イベント分の
画像を使用した。

学習結果


- 学習を100回行った結果、学習精度は88.9%、損失は0.24となった。



結果から、イベントディスプレイを使って学習することは
可能であると期待できる。

天頂角の分類学習

- 次に天頂角が $0^{\circ} \sim 70^{\circ}$ の範囲を 10° 刻みで判別できる学習モデル作成を行った。
- シミュレーションからは、BRとLRの二つのステーションの観測データを得ることができる。そのため、データセットもBRのみ、LRのみ、ステレオと3種類作成しそれぞれ学習を行った。




各クラス10000枚、合計70000枚のイベントディスプレイをそれぞれ使用し、学習を40回行った。

学習結果


学習を40回行った。横軸が学習回数、縦軸が学習精度である。



BR
精度:58.4%
損失: 1.027
学習時間:約12分



ステレオ
精度:58.1%
損失:1.040
学習時間:約12分



LR
精度:57.9%
損失:1.030
学習時間:約12分

天頂角を 10° 刻みで判別する学習モデルの作成をすることはできた。
→しかし、最初の分類学習に比べると思うように精度が上がらなかった。


改良点

- FD従来の空気シャワー解析では、モノ観測が約5度、ステレオ観測が2度以下と高水準の決定精度で求めることができる。
→学習モデルの**精度向上**は必須となる。
- ここまでで使用したイベントディスプレイは、シミュレーションデータから、夜光などのノイズデータを取り除かずに使用している。
→学習に大きく影響している可能性がある。

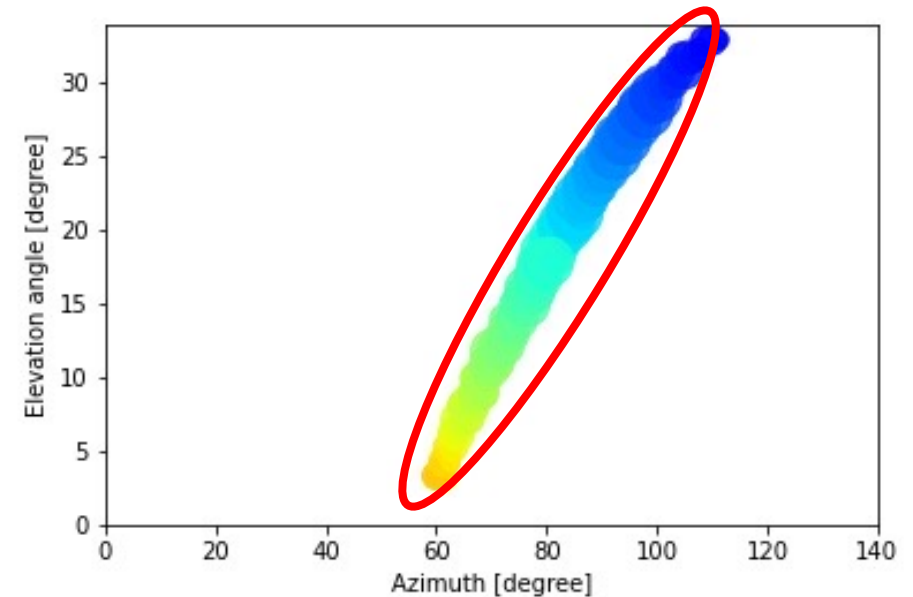



イベントディスプレイを**改良**することで、**学習精度の向上**が考えられる。

イベントディスプレイの改良



改良前



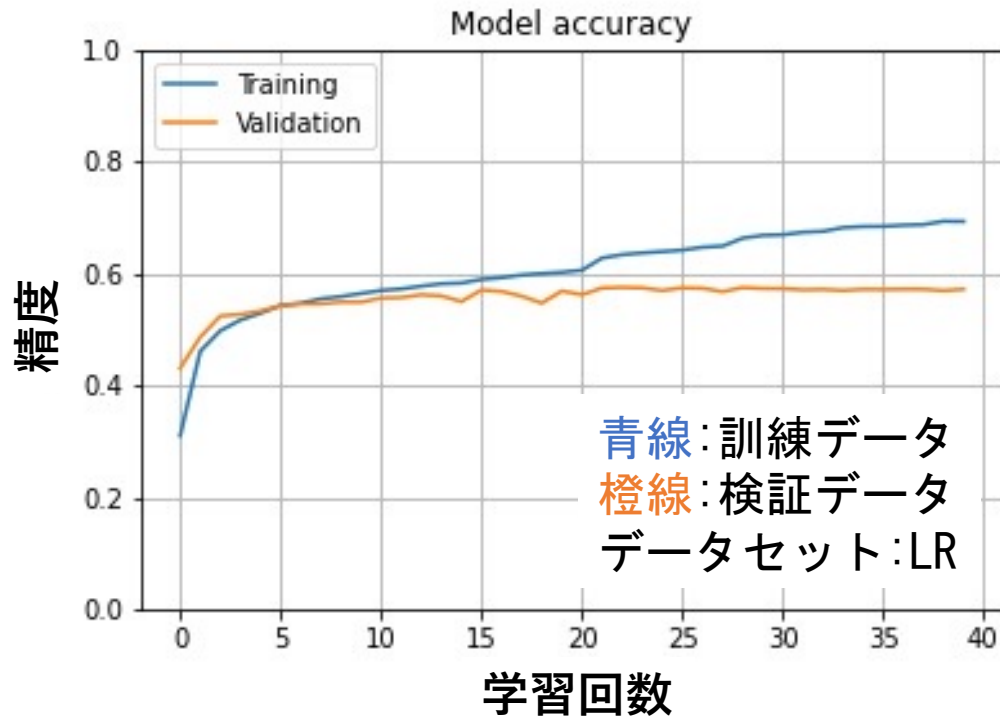
改良後

改良点

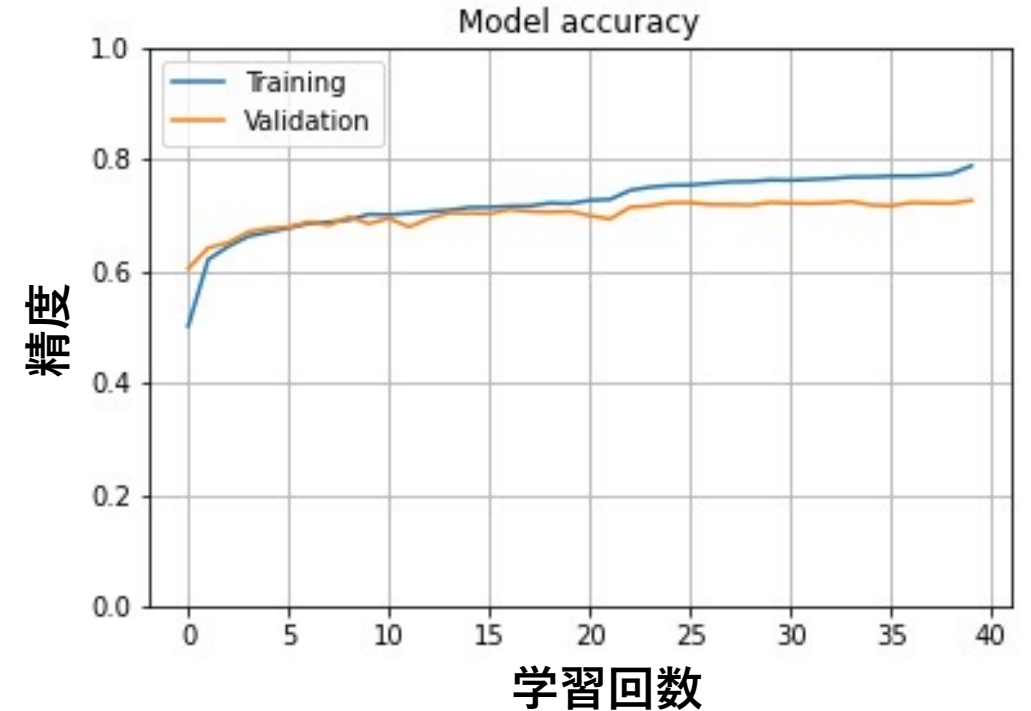
- ・夜光等のノイズデータの排除。
- ・色の変化を七色に変化させる。
- ・カラーバーの排除。

改良前と改良後の結果比較

- 改良後の画像でイベントディスプレイを作成し、 10° 刻みの判別学習を行った。



改良前
精度:57.1%
損失:1.071



改良後
精度:72.6%
損失:0.670

改良後の方が、学習結果が**良くなった**。

まとめと今後

まとめ

- 空気シャワーシミュレーションで作成したイベントディスプレイを使用して、深層学習による宇宙線空気シャワージオメトリの識別を行った。
- 二値分類学習の結果、学習精度は88.9%となった。
- 天頂角が $0^\circ \sim 70^\circ$ の範囲を 10° 刻みで判別する学習を行った結果、BRのみの精度は58.4%、LRのみが57.9%、ステレオが58.1%となった。
- イベントディスプレイを改良した結果、学習結果が良くなった。

今後の課題

- 学習精度の向上
- 宇宙線のエネルギーや方位角、シャワー軸も判別することが可能な学習モデルの作成。
- 実際にTA実験で観測データを使って、宇宙線の解析ができるかを調査する。

Back UP

データの種類

- 訓練データ：学習に使用するデータ
- 検証データ：学習の最中に汎用性があるかどうかを確かめるため、検証を行うデータ

活性化関数の決定

学習を行う際に、活性化関数を決める必要がある。どの活性化関数を使用するのがいいかを判断するため、活性化関数の比較を行った。

深層学習の条件



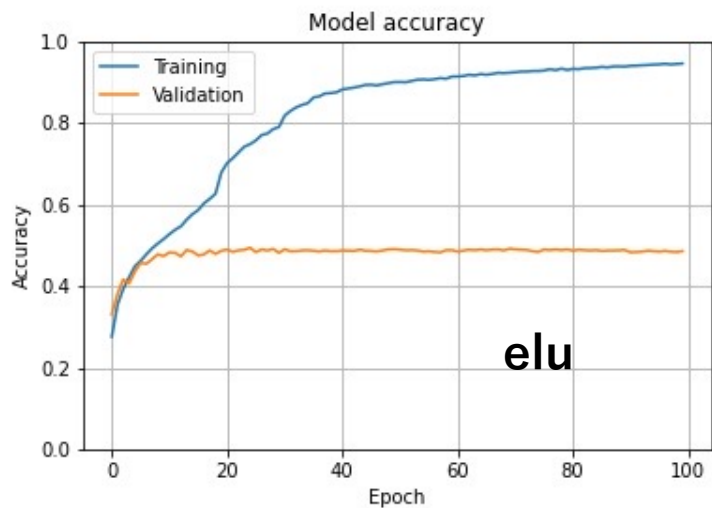
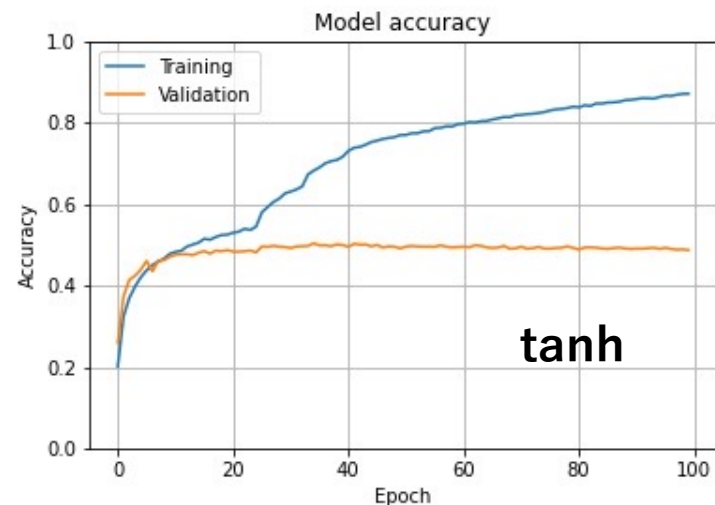
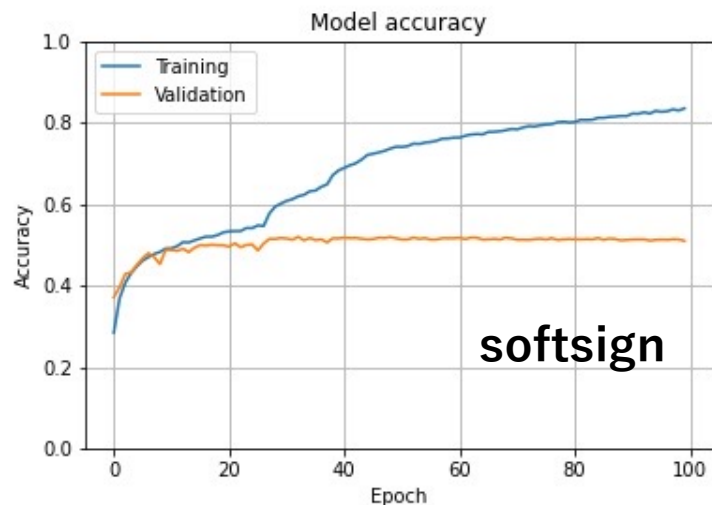

データセット	BR
学習用データ	36400 個
検証用データ	9100 個
層の数	10
学習回数	100 回

活性化関数の比較結果




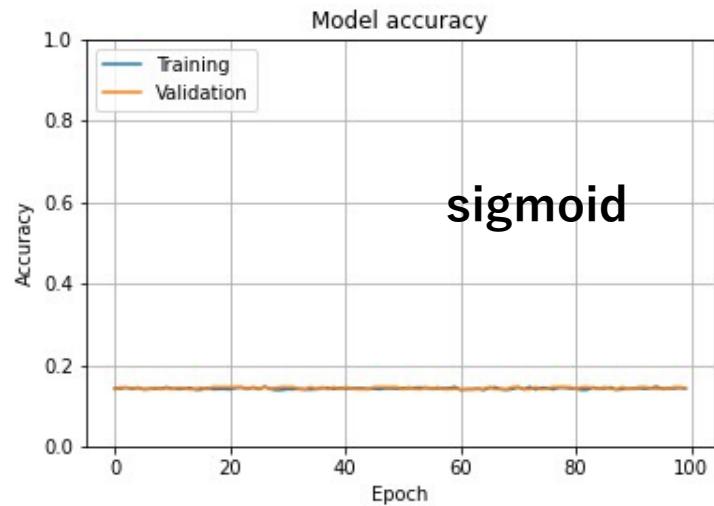
活性化関数	精度 (%)	学習時間 (分)
relu	55.5	約 27
softsign	50.9	約 50
tanh	48.7	約 27
elu	48.5	約 59
selu	47.8	約 59
linear	43.3	約 25
sigmoid	14.4	約 27
Hard-sigmoid	14.3	約 34
softmax	13.8	約 32
softplus	13.7	約 54

比較結果から学習には**relu関数**を使用する。

活性化関数の決定




活性化関数の決定




損失

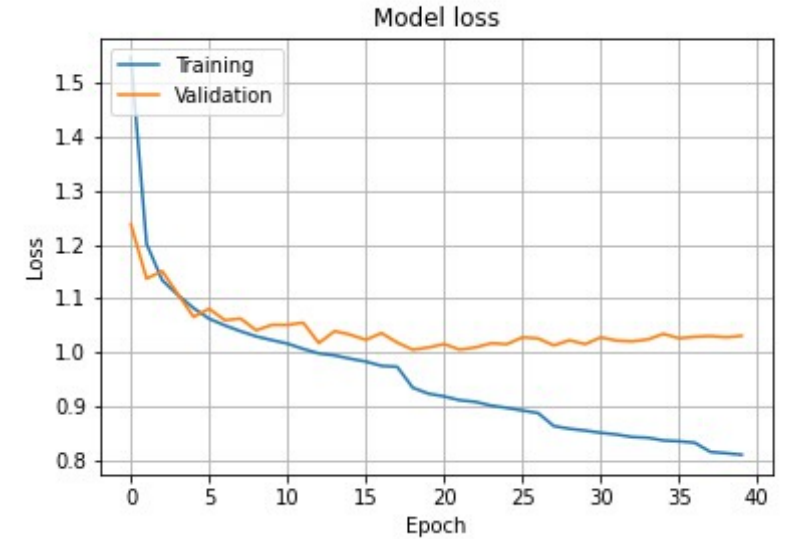
学習を40回行った時の損失の値。横軸が学習回数、縦軸が損失である。



BR
損失:1.027



ステレオ
損失:1.040



LR
精度:1.030