

# ILC衝突点ビーム形状モニターへの 機械学習の応用研究

理学研究科 物理学専攻 素粒子実験研究室

博士課程前期2年 小林 陽介


2019年2月6日 修士論文発表会

# 目次

1. 国際リニアコライダーについて
2. ペアモニターの原理
3. ビームシミュレーション設定
4. ペアモニターヒット分布解析
5. 機械学習を用いたビームサイズ再構成

# 国際リニアコライダー について

# ILC概要



- 全長約20km、重心系エネルギー250GeV
- 電子・陽電子衝突型の線形加速器  
→衝突機会が1度

## ILC250の最重要課題

ヒッグス粒子の精密測定

### 必要なことは...

統計量を貯める。

→単位時間あたりのルミノシティ $\mathcal{L}$ を上げる

$$\mathcal{L} = \frac{f_{rep} n_b N^2}{4\pi \sigma_x \sigma_y} H_D H_G [cm^{-2} s^{-1}]$$

IP点でビームサイズを測定して小さく絞る。

ビーム測定のためにペアモニターが考案。

$f_{rep}$ : 単位時間あたりのビーム衝突回数

$n_b$ : バンチ数

$N$ : 粒子数

$\sigma_x, \sigma_y$ : IP点でのビームサイズ


$H_D$ : ルミノシティ増大係数

$H_G$ : 実質的なビーム衝突の度合い

# ペアモニターの原理

# 散乱の様子


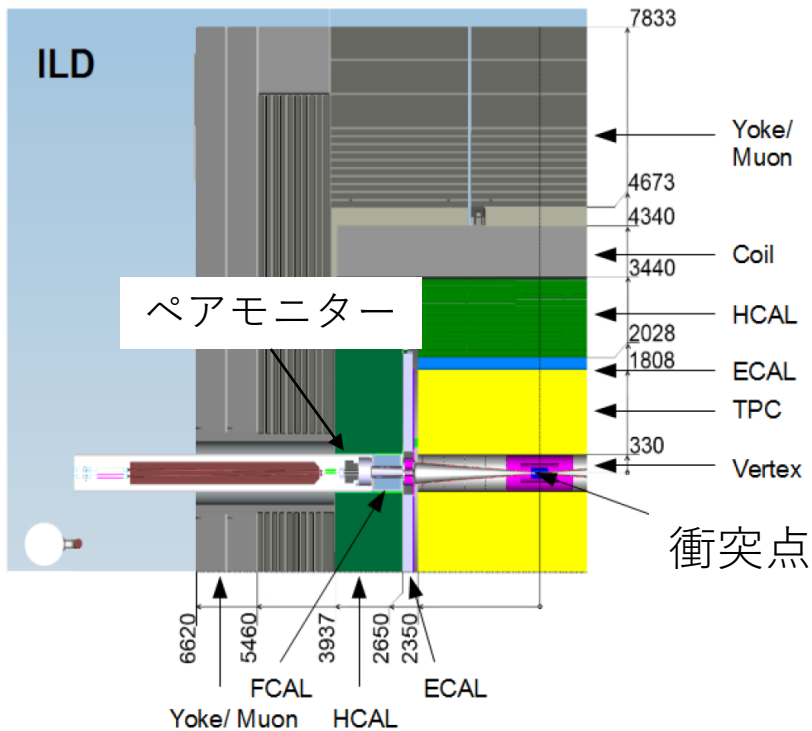
ビーム衝突によって発生する電子・陽電子を利用する。



# ペアモニター

## 利点

- 衝突点に置かなくても良い(衝突点周りの検出器に干渉しない)
- 衝突後に発生する粒子を利用するためビームに影響を与えない
- 1回のビーム衝突で十分な測定が可能





# ビームシミュレーション設定

# シミュレーション設定

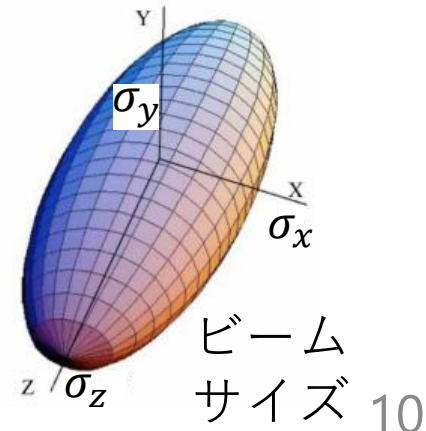
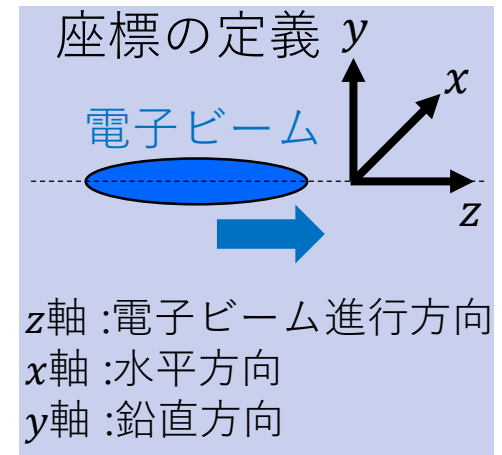
シミュレーションソフトウェアは次のソフトを使用。

## - CAIN24.2

高エネルギーの電子・陽電子などの相互作用をシミュレーションするソフトウェア。


Technical Design Report(TDR)のパラメータ

重心系エネルギー $E_{CM}$	250 GeV
バンチ中の粒子数 $N$	$2.0 \times 10^{10}$
<b>ビーム長さ<math>\sigma_z</math></b>	<b>0.3 mm</b>
水平方向エミッタンス $\gamma\epsilon_x$	10 $\mu\text{m}$
鉛直方向エミッタンス $\gamma\epsilon_y$	35 nm
IPの水平方向 $\beta$ 関数 $\beta_x^*$	13.0 mm
IPの鉛直方向 $\beta$ 関数 $\beta_y^*$	0.41 mm
<b>水平方向ビームサイズ<math>\sigma_x</math></b>	<b>729.0 nm</b>
<b>鉛直方向ビームサイズ<math>\sigma_y</math></b>	<b>7.7 nm</b>



# ビーム衝突

開始




終了

以上の設定でシミュレーションを行う

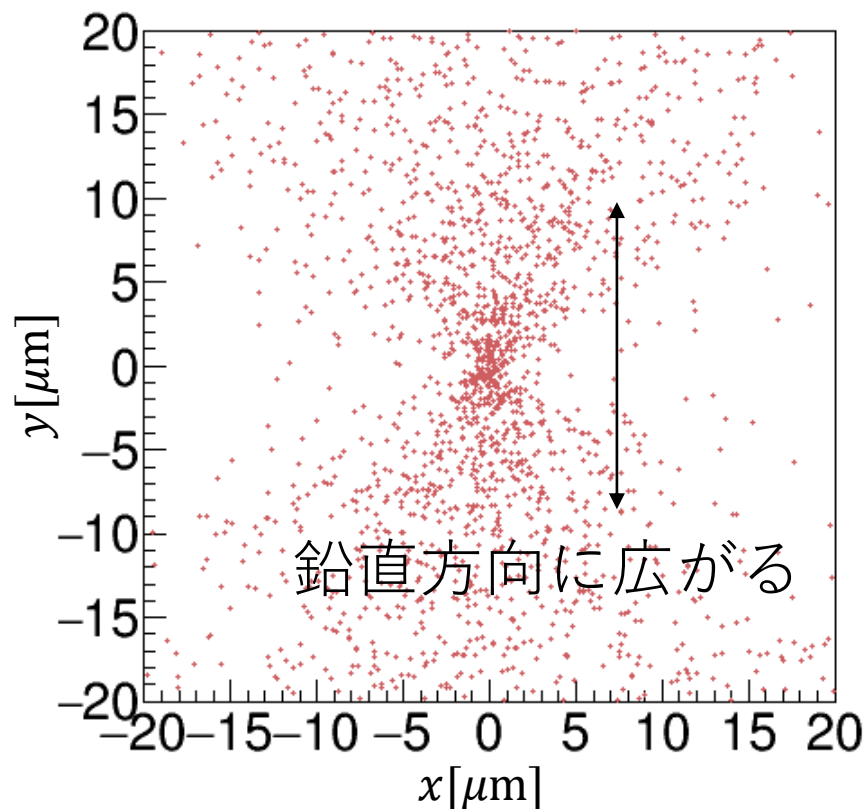
# シミュレーション結果

シミュレーション直後、+4mのペアモニターから衝突点方向を見たときの粒子の位置

電子




陽電子



# ペアモニターヒット分布解析

# トラッキング

磁場中の螺旋運動をシミュレーション





- 3.5Tのソレノイド磁場
- 衝突点から+z方向4mに設置
- 他のDetectorやビームパイプは考慮しない

# 1. 解析


(ビームがTDR設計値通り)

# ペアモニター上のヒット分布


陽電子ビーム側の  
ペアモニター



陽電子のみ



電子のみ







## 2. ヒット分布の $\sigma_x, \sigma_y$ 依存性

# ビームサイズ $\sigma_x, \sigma_y$






ビームサイズ( $\sigma_x, \sigma_y$ )の値を変えてシミュレーションした。

	ビームサイズ $\sigma_x$
1.0倍	729.0 nm $\equiv \sigma_x^{TDR}$
1.5倍	1093.5 nm
3.0倍	2187 nm
5.0倍	3645 nm

	ビームサイズ $\sigma_y$
1.0倍	7.7 nm $\equiv \sigma_y^{TDR}$
1.5倍	11.55 nm
3.0倍	23.1 nm
5.0倍	38.5 nm



# ペアモニター上ヒット分布の比較



ヒット分布の傾向は  
 $\sigma_x$ と $\sigma_y$ で異なる

# 機械学習を用いた ビームサイズ再構成

# 機械学習

手書き文字




認識


5



0



$$\sigma_x = 1.0\sigma_x^{TDR}$$

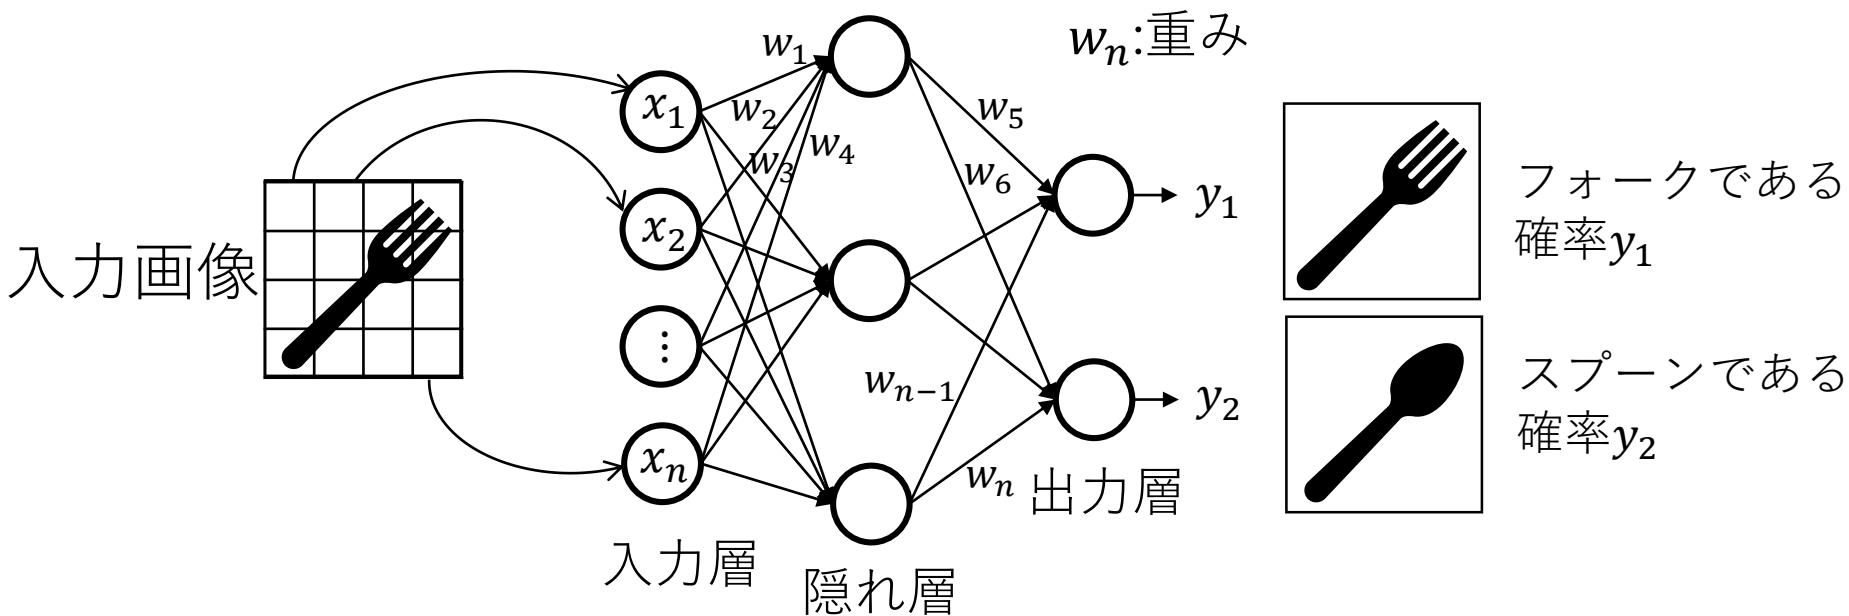


$$\sigma_x = 1.5\sigma_x^{TDR}$$

認識

- ビームサイズ再構成は文字認識問題と同様に扱える。
- 近年大量の画像を入力として利用し文字認識や物体検知などを機械学習によって行う手法が発展している。

# ニューラルネットワーク



- 神経細胞を模したパーセプトロンを層状に並べた構造を持つ
- 隠れ層が複数ある場合、ディープニューラルネットワークと定義

# 損失関数

ニューラルネットワークの出力がどれだけラベル (目標値)に近いかを測る尺度

$d_{nk}$  : 目標値


$y_{nk}$  : ニューラルネット出力

$N$  : 画像数

$K$  : ラベル数

$$L = - \sum_n^N \sum_k^K d_{nk} \log y_{nk}$$

例



画像の目標値はラベルと対応する要素が1、他は0で表現

$$d_n = [0 \quad 0 \quad 0 \quad 0 \quad 1 \quad 0 \quad \dots \quad 0]$$

$$\sigma_x / \sigma_x^{TDR} \quad \begin{matrix} \uparrow & \uparrow & \uparrow & \uparrow & \uparrow & \uparrow & \uparrow \\ 0.2 & 0.4 & 0.6 & 0.8 & 1.0 & 1.2 & \dots & 3.8 \end{matrix}$$

出力=目標値となるようにwを調整する。  $y_n = \sim$ であれば...

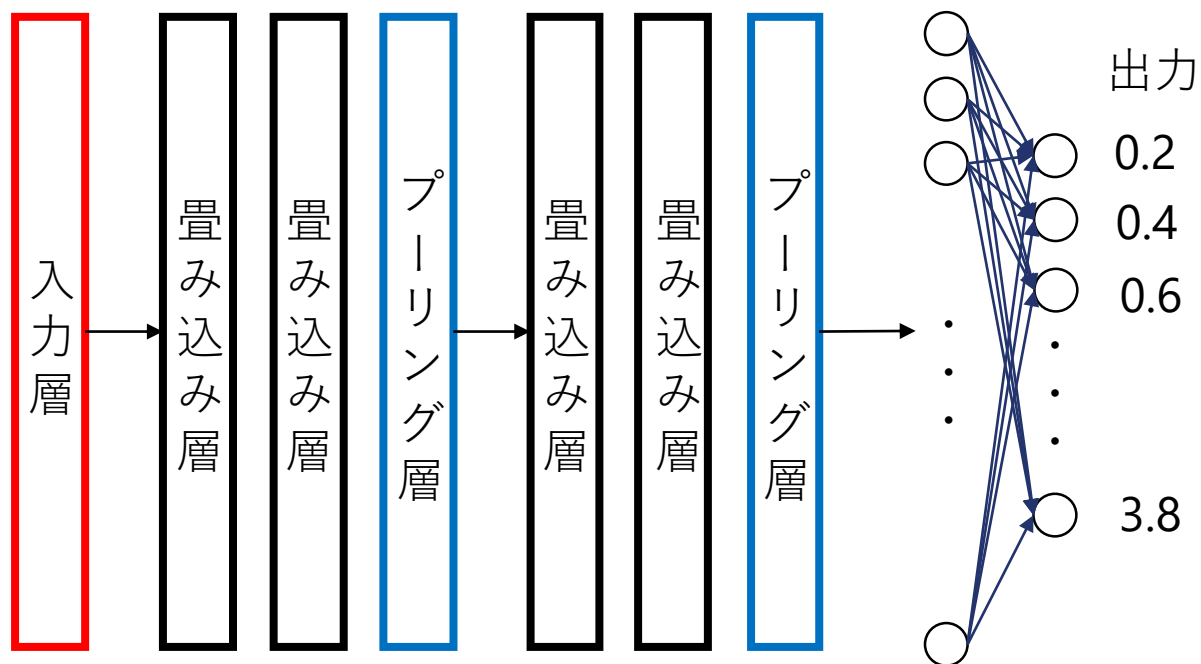
$$y_n = [0 \quad 0 \quad 0 \quad 0.01 \quad 0.98 \quad 0.01 \quad \dots \quad 0]$$

$$L = - \log 0.98 = 0.020$$

出力=目標値のとき  $L = 0$

$L = 0$ となるように学習

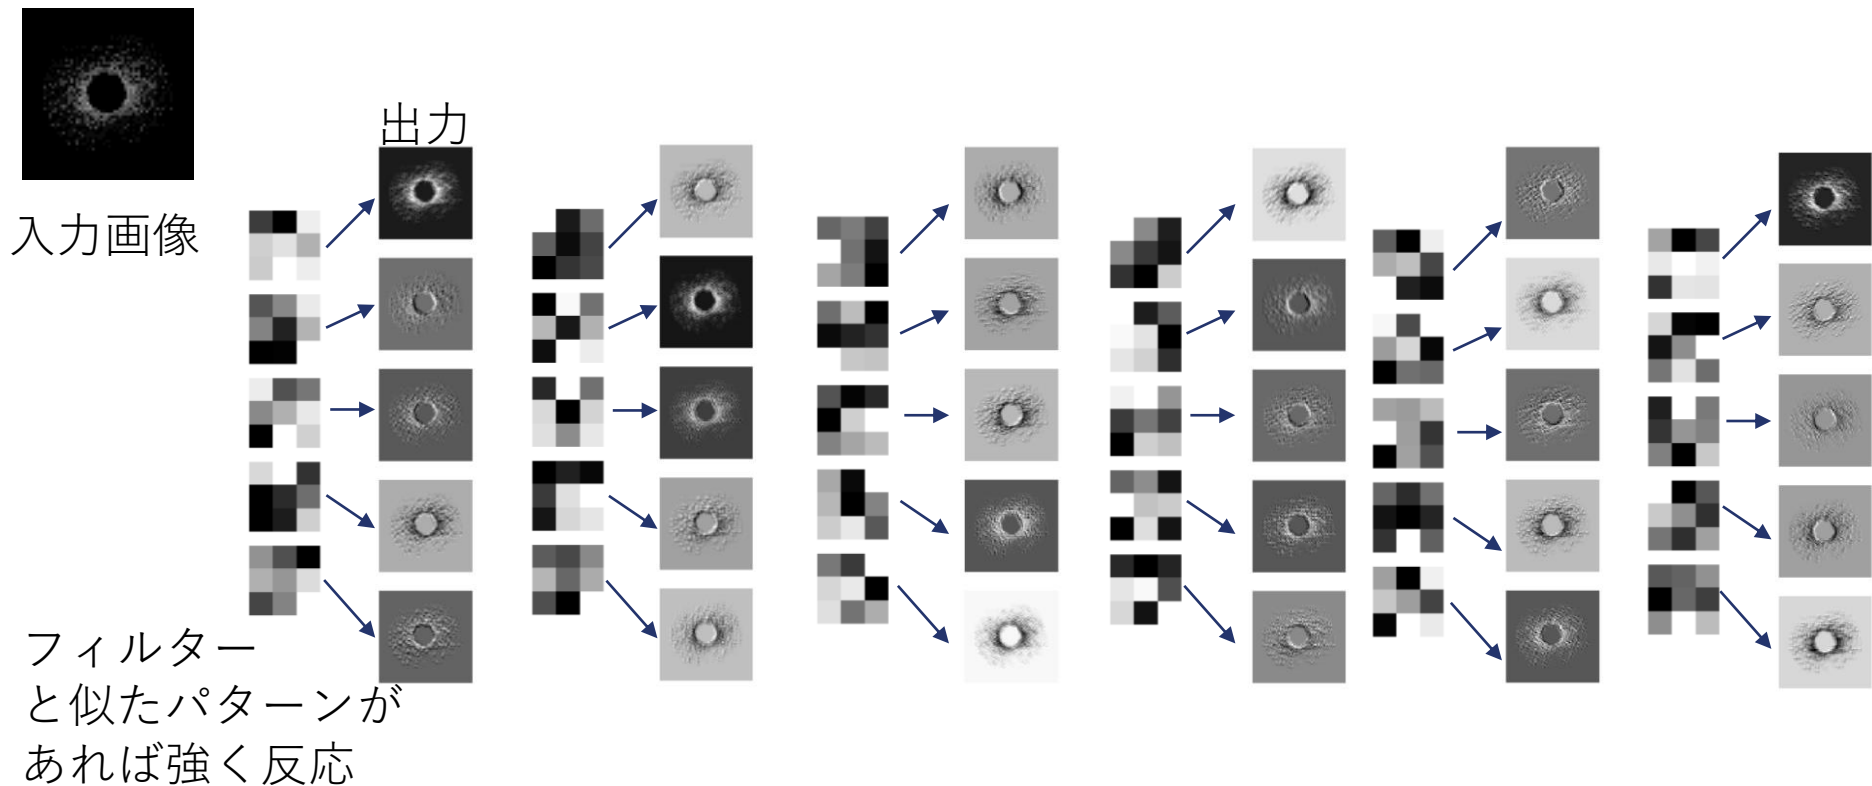
# 畳み込みニューラルネットワーク



畳み込み層(Convolution)とプーリング層(Pooling)を含む  
ディープニューラルネットワーク




# 畳み込み層(Convolution layer)



機能: フィルターによってある画素周りの特徴を抽出する。

# プーリング層 (Pooling layer)

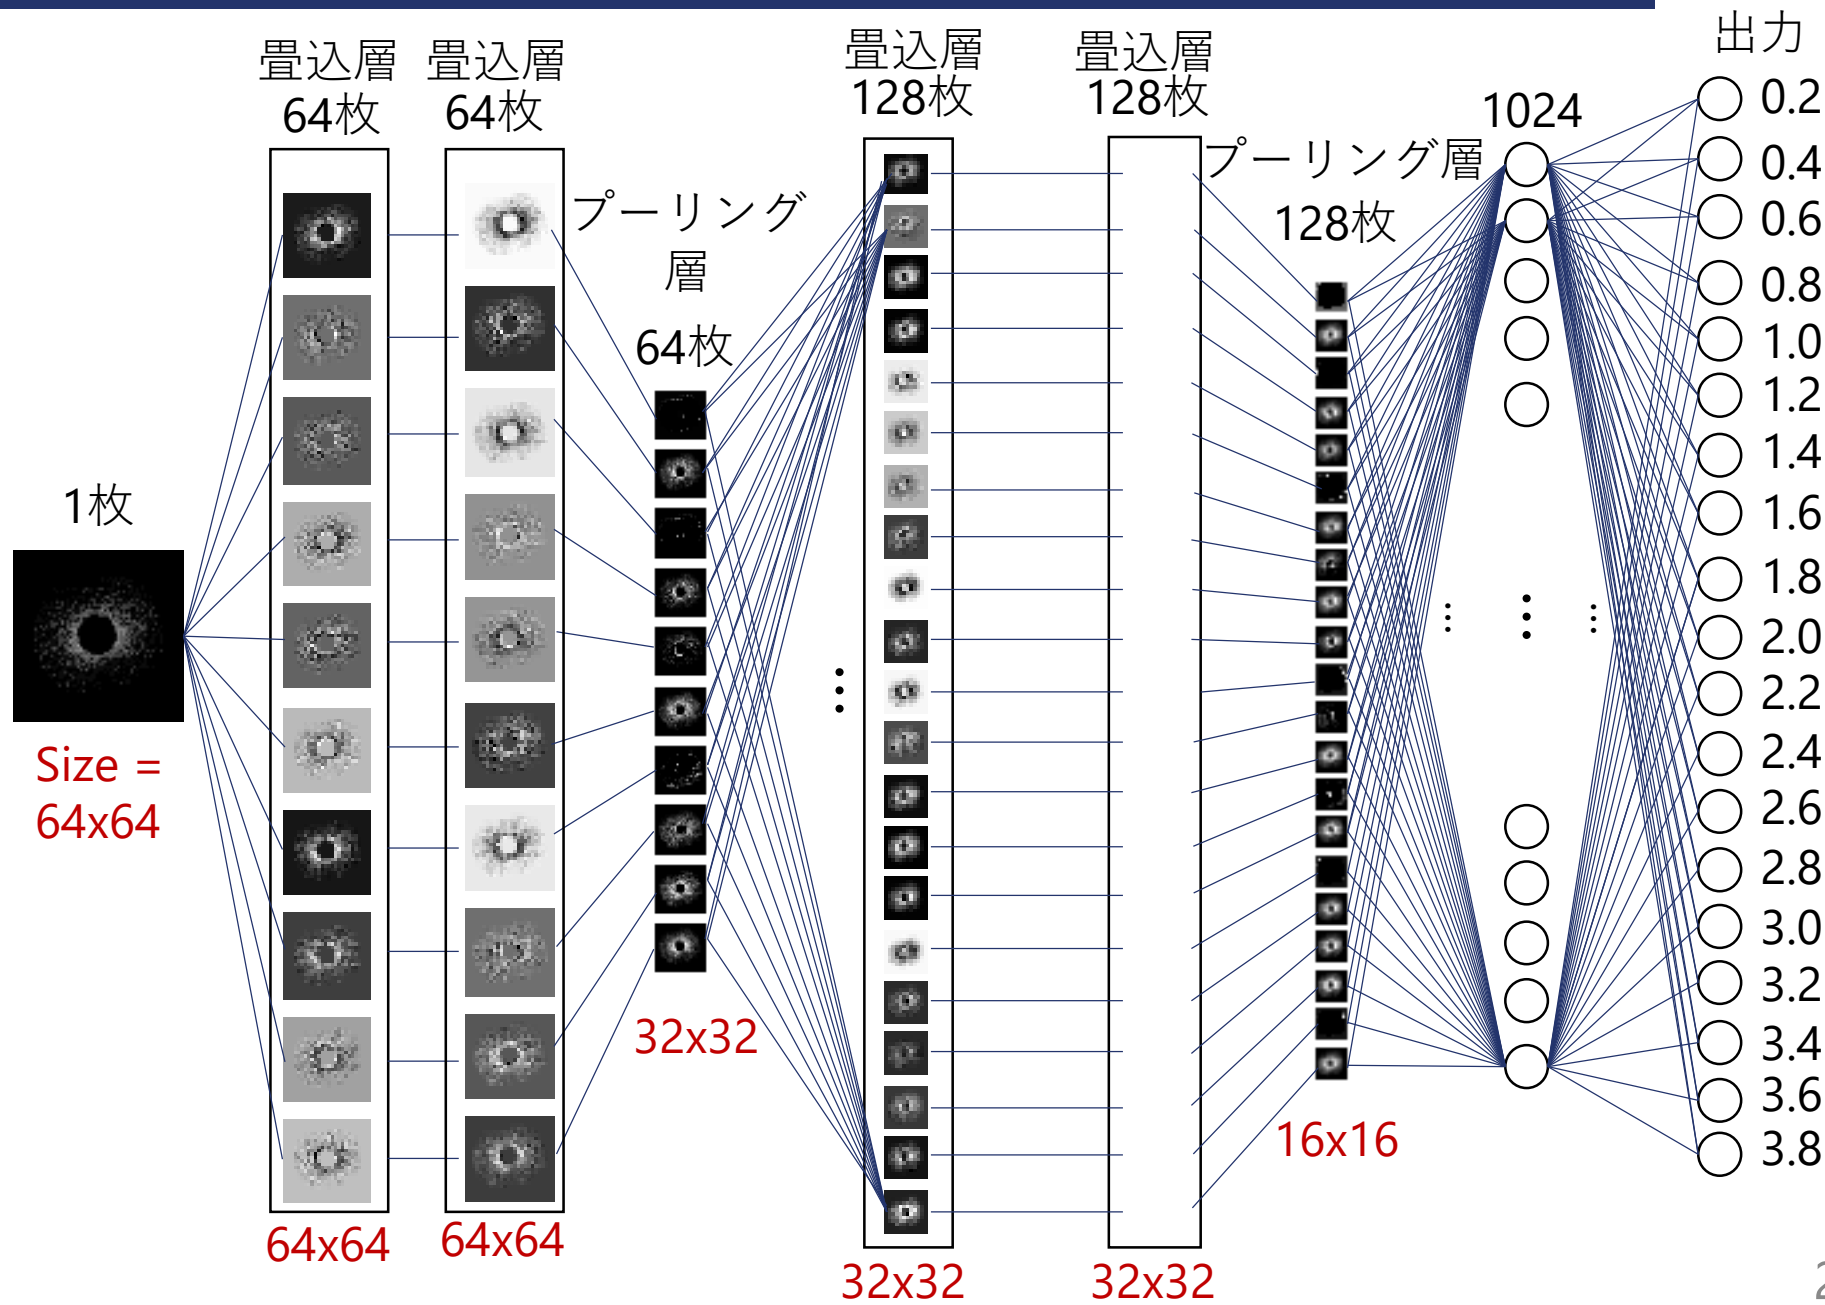
Pooling前



- 畳み込み層の後に実行される
- ある範囲内で最も特徴のある要素を抽出し画像サイズを小さくする。
- 利点:画像によって特徴の位置が多少異なる場合でもその特徴を抽出できる

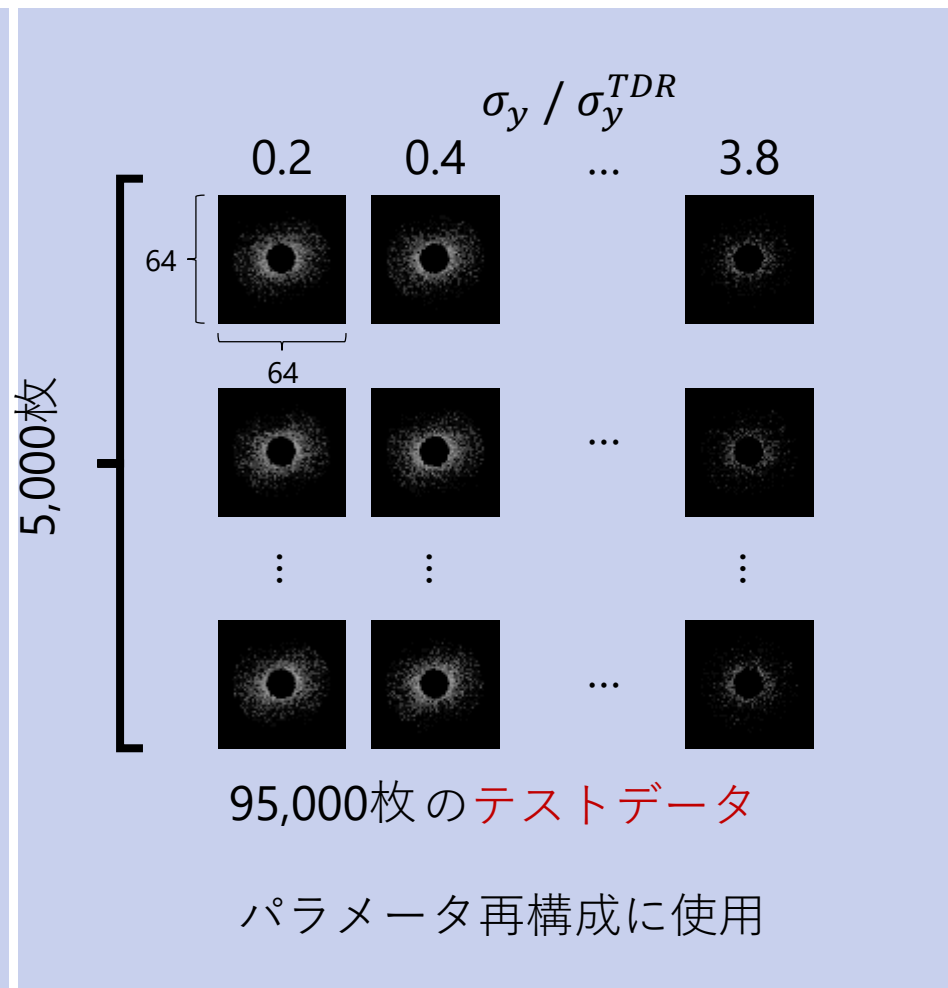
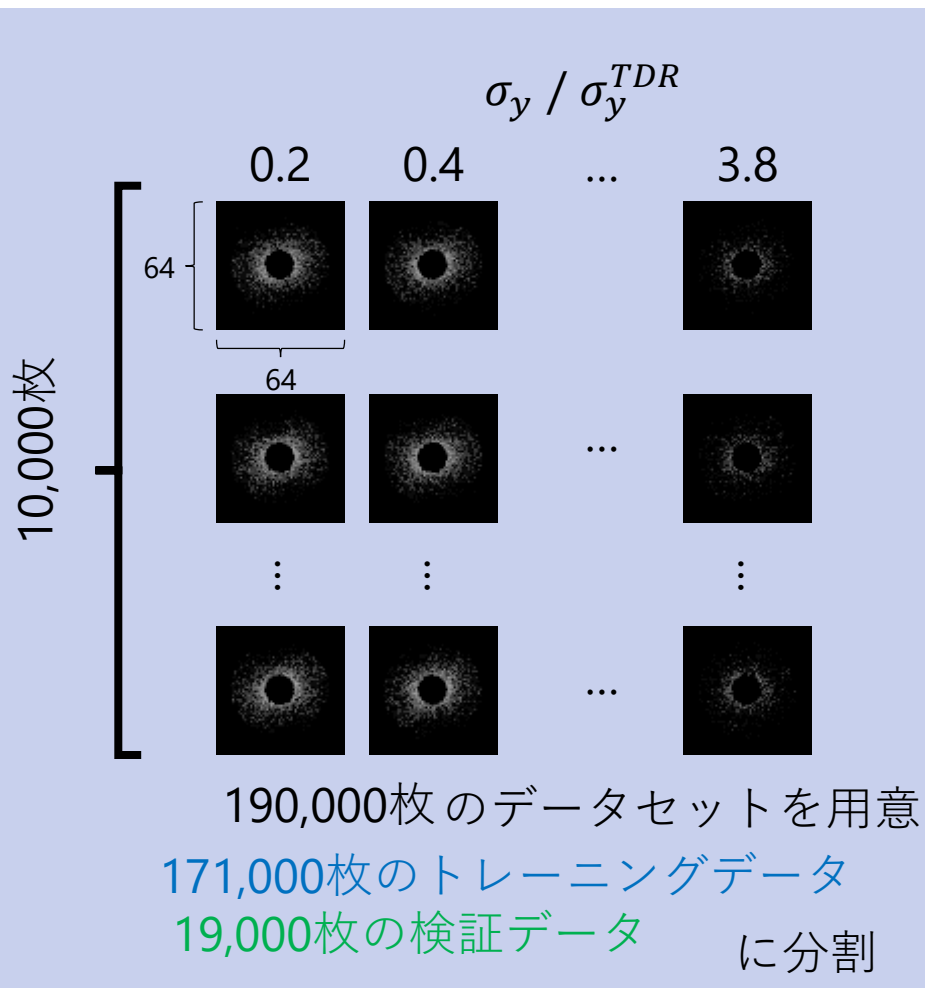
# 1. ビームパラメータ $\sigma_y$ 再構成

# ニューラルネットワーク構成



# 学習用データセット

- $\sigma_y = 0.2\sigma_y^{TDR}, \dots, 3.8\sigma_y^{TDR}$  ( $0.2\sigma_y^{TDR}$  ずつ変化)

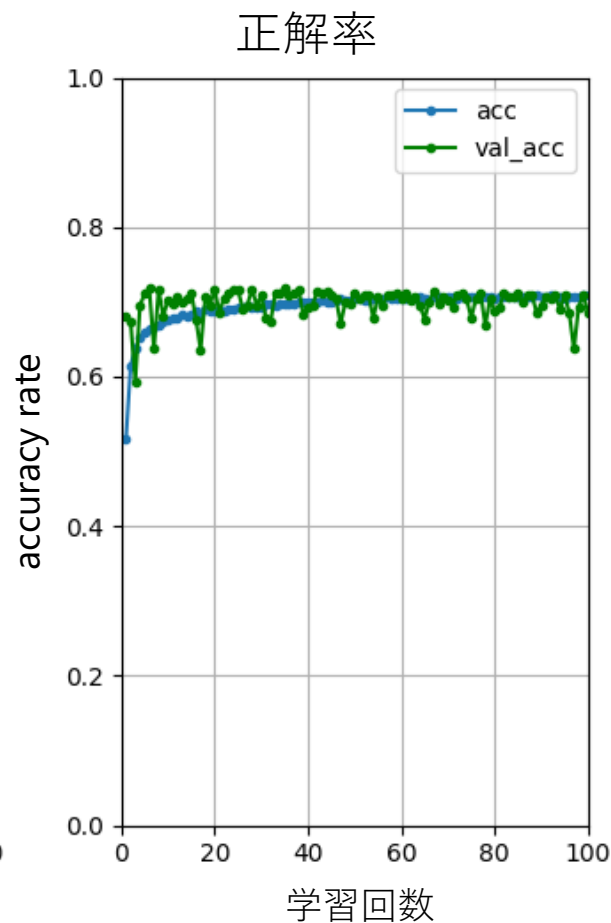



# 結果

損失関数の値がトレーニングと検証データで共に0.7で収束


学習回数が50回以降から  
トレーニングデータの正  
解率は7割をキープ

検証データも7割の正解率



# ビームサイズ確率分布


不正解となった3割の中  
であるデータを見ると...



ある画像  
の場合



確率




ニューラルネットワークは  
正解は1.2と判定したため、  
不正解。

別の画像  
の場合



確率



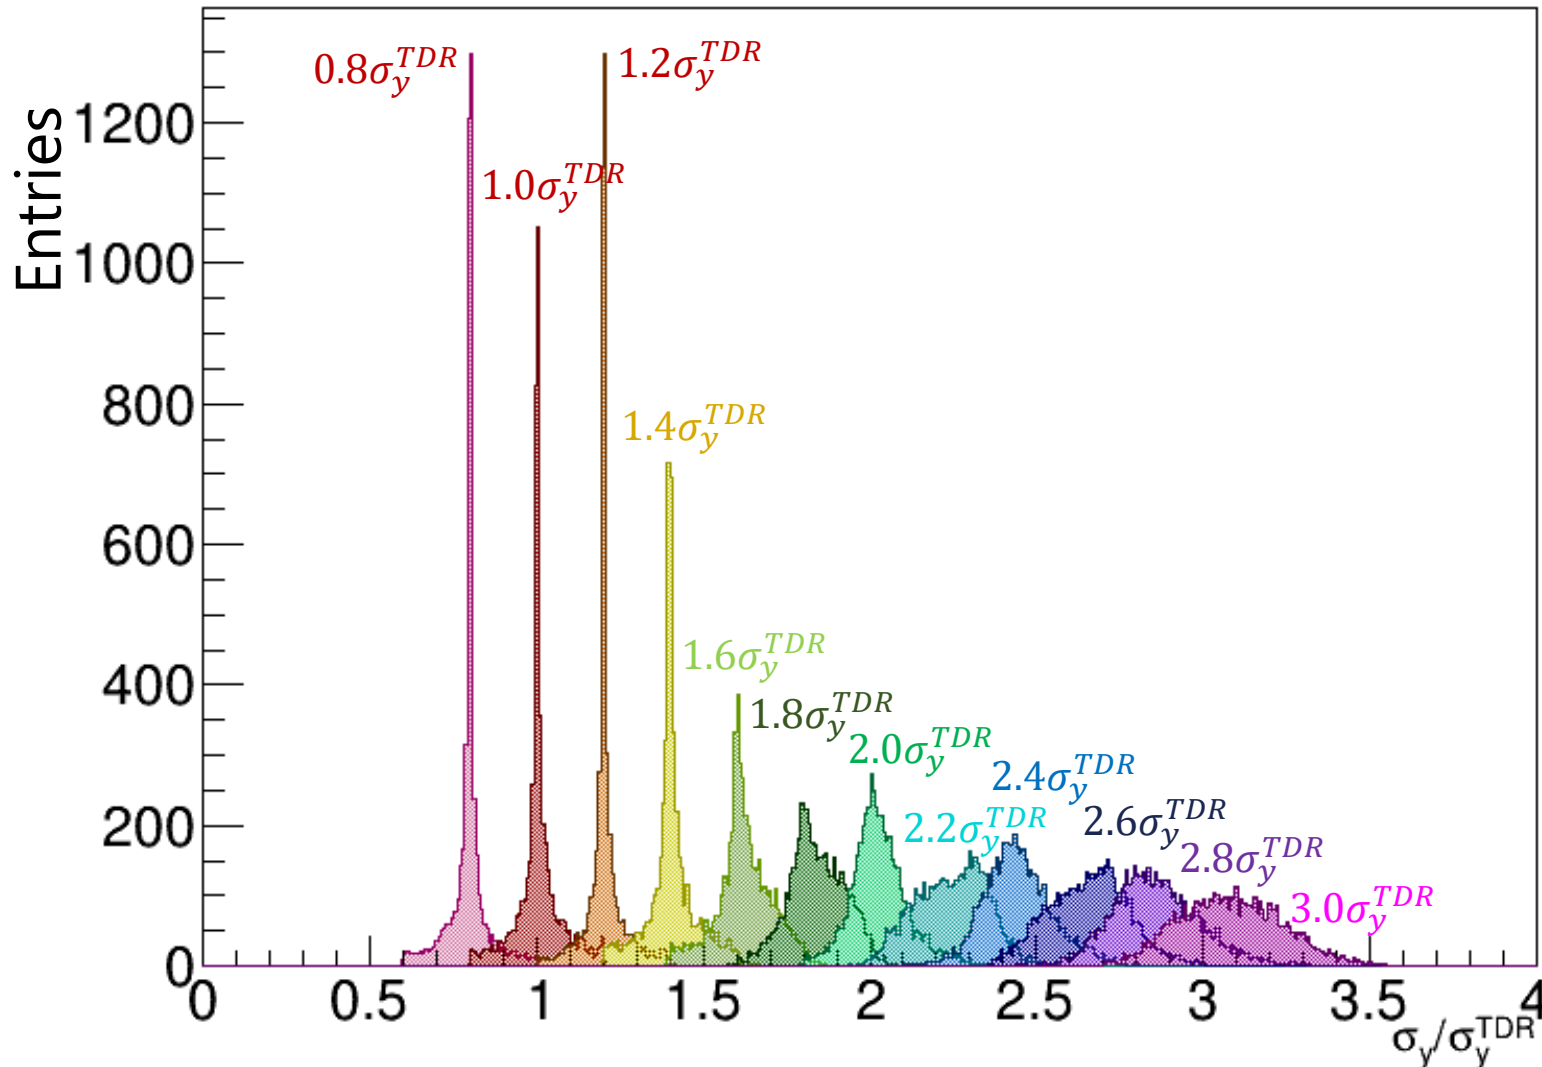
正解は1.2と判定したため、  
不正解。

これら以外の結果も似た  
傾向となった。

確率分布から得られる期待値をニューラルネットワークの予測値とする

# ビームサイズ再構成

- $\sigma_y = 0.8\sigma_y^{TDR}, 1.2\sigma_y^{TDR}, \dots, 3.0\sigma_y^{TDR}$  の確率分布から期待値を計算






## 2. 複数のビームパラメータ( $\sigma_x\sigma_y$ )再構成

# 複数のビームパラメータ再構成の検討


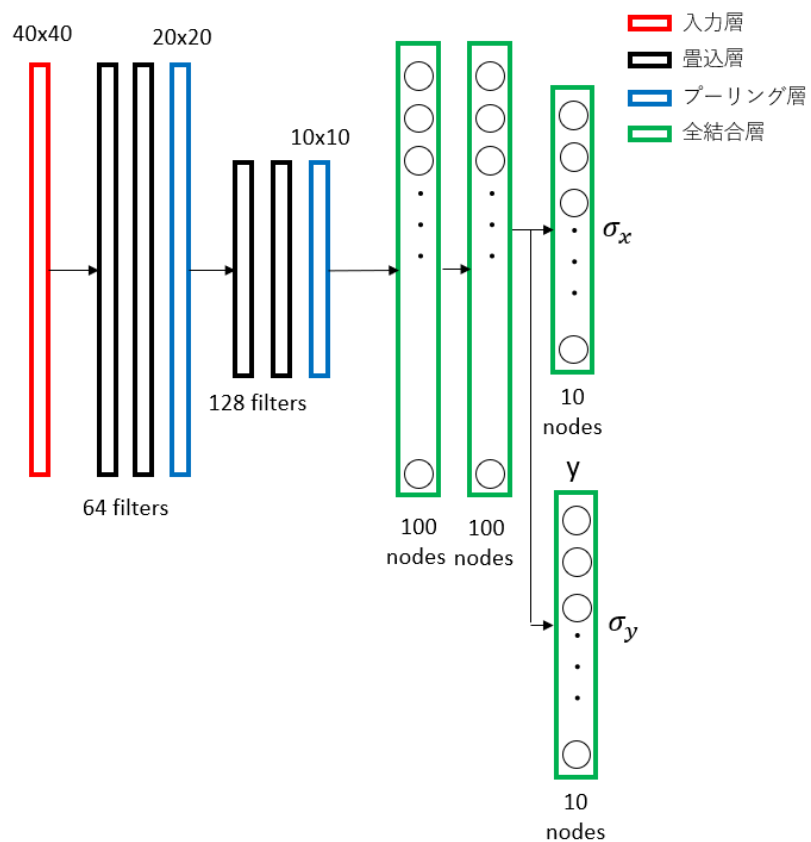
- $\sigma_x = 0.2\sigma_x^{TDR}, \dots, 2.0\sigma_x^{TDR}$  ( $0.2\sigma_x^{TDR}$  ずつ変化)
- $\sigma_y = 0.2\sigma_y^{TDR}, \dots, 2.0\sigma_y^{TDR}$  ( $0.2\sigma_y^{TDR}$  ずつ変化)



- トレーニング+  
検証データとして  
約600,000枚
- テストデータとして  
約200,000枚


# 学習ネットワークの構成と結果

$\sigma_x$ と $\sigma_y$ を出力するために、出力層を2つにする




検証データの  
損失関数  
が収束せず

# ビームサイズ $\sigma_x$ 再構成



# ビームサイズ $\sigma_y$ 再構成



# まとめ

## • Incoherent Pairの解析

- ビーム衝突シミュレーションによって生成された電子・陽電子の解析を行った。
- ペアモニターにヒットする粒子は同電荷粒子であることが確かめられた。
- ビームパラメータを変えることでヒット分布も変化し、 $\sigma_x, \sigma_y$ のそれぞれで異なった変化をすることがわかった。


## • 機械学習を用いたビームパラメータ再構成の検討

- ヒット分布を画像として使用し畳み込みニューラルネットを使用した。
- 1種類のパラメータ( $\sigma_y$ )再構成は可能
- 複数のパラメータ( $\sigma_x, \sigma_y$ )の再構成は $\sigma_x$ に関して精度は良いが、 $\sigma_y$ は改善が必要


ニューラルネットワークの調整を行えば  
ビームパラメータの再構成に有効

- backup


# beamstrahlung



(a) Breit-Wheeler :  
( $\gamma\gamma \rightarrow e^+e^-$ )




(b) Bethe-Heitler  
( $e\gamma\gamma \rightarrow e^\pm e^+e^-$ )




(c) Landau-Lifshitz  
( $ee\gamma\gamma \rightarrow e^+e^-e^+e^-$ )




# ヒット分布(電子)



ヒット分布を $p_t$ で  
分割してプロット↓




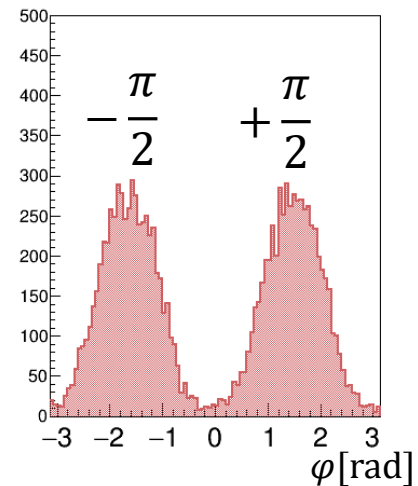


# ヒット分布(陽電子)






電子と比べて一様ヒット分布  
➤ 陽電子のピークは凸型の形状であるため



$\phi$ 分布



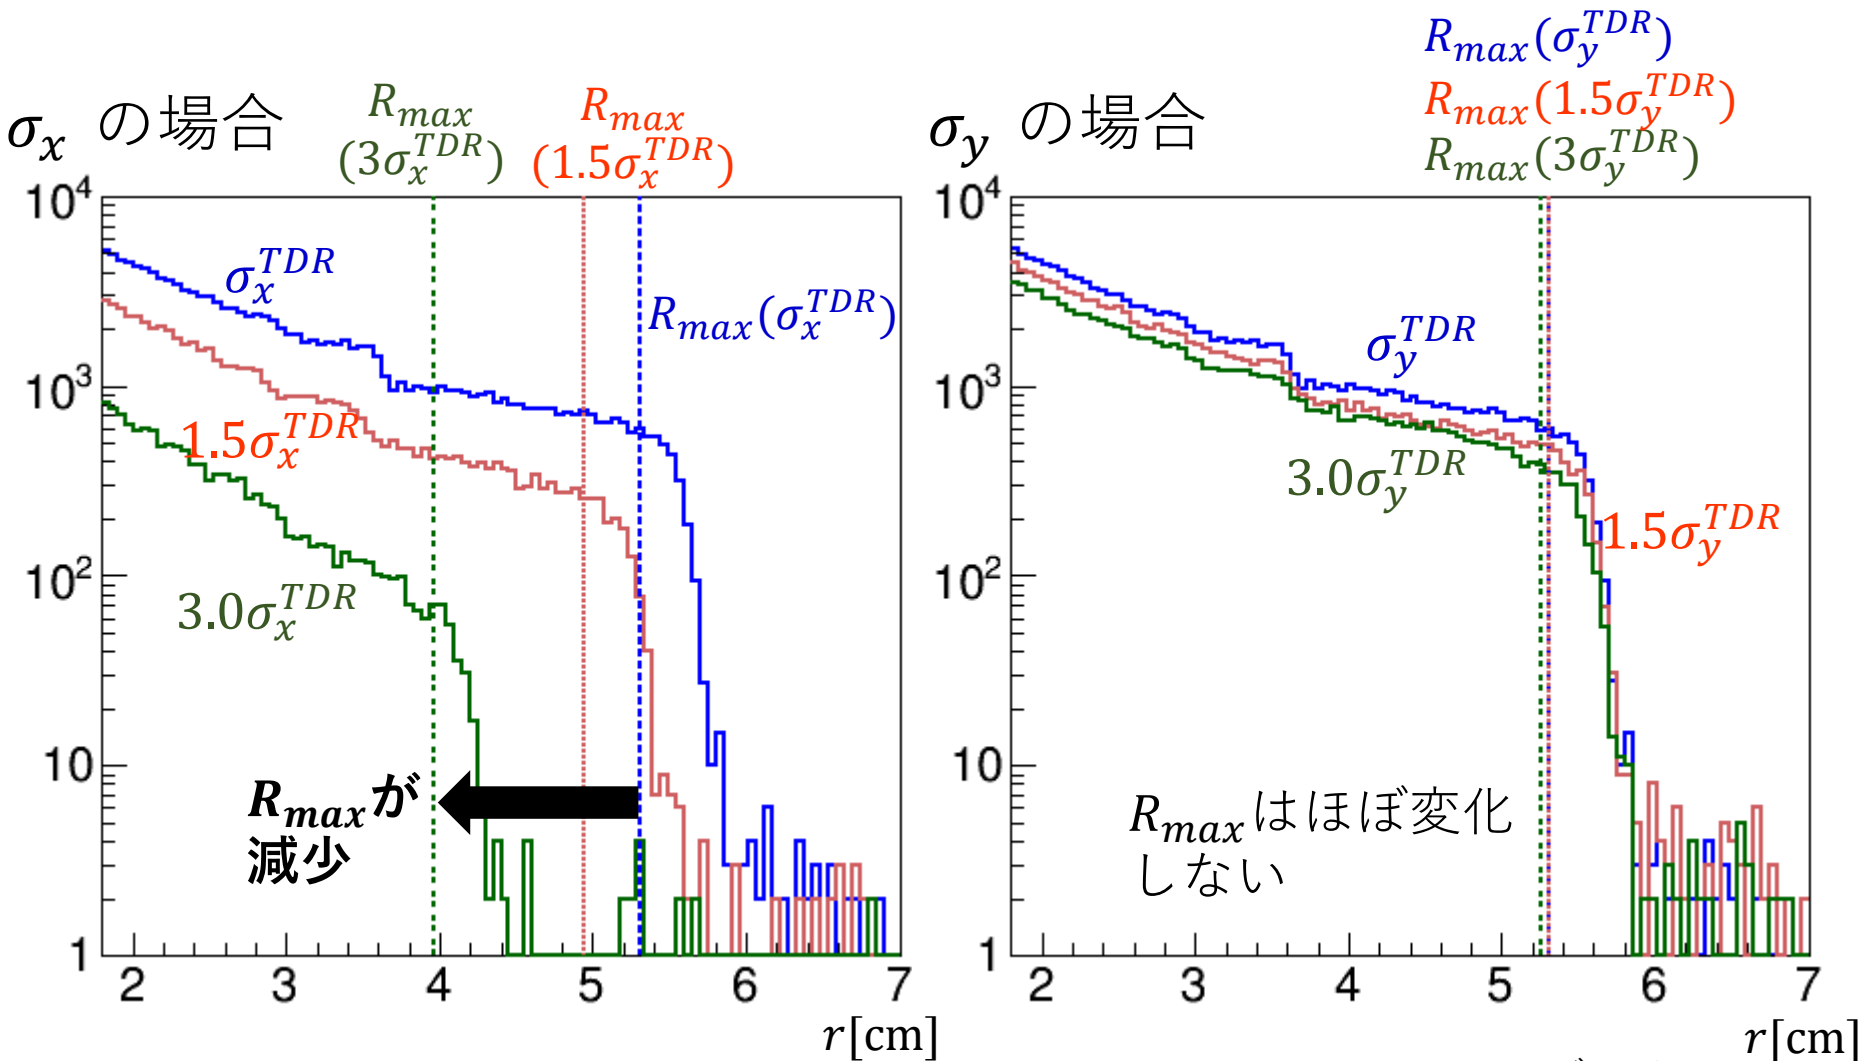
# ペアモニター上ヒット分布の比較



ヒットした総数の97.5%  
を含む最大半径を $R_{max}$   
と定義



# 最大半径 $R_{max}$ の比較




$R_{max}$  は  $\sigma_x$  に支配的

データは  
50バンチ分

# $\phi$ 分布の比較

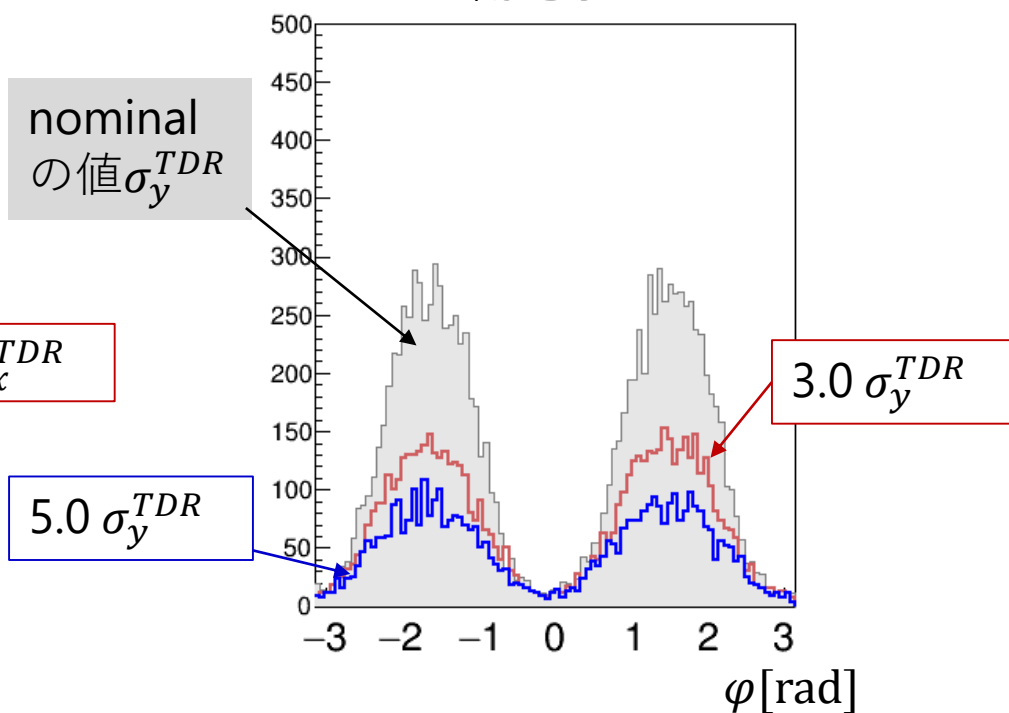
$\sigma_x^{TDR}$  との比較

陽電子



$\sigma_y^{TDR}$  との比較

陽電子




対向ビームによる電場が弱まったため生成数が減少

電場の水平成分による効果が見られるため  $\sigma_x$  と比べて減少が緩やか

# 学習ネットワークの構成要素

## パーセプトロン

- 生物の脳内神経細胞を模したアルゴリズム



総入力  $u$

$$u = w_1x_1 + w_2x_2 + b$$


出力  $z$

$$z = f(u)$$

$f$ : 活性化関数

## 活性化関数

- 神経細胞の電気信号のような役割を果たす関数
- 出力値は活性化関数の値となる



# 畳み込み層 (Convolution layer)

- 画像サイズ  $W \times W$ 
  - 画像のピクセルを  $(i, j)$  で表現  
( $i = 0, \dots, W - 1, j = 0, \dots, W - 1$ )



- フィルタ  $F \times F$ 
  - フィルタのピクセルを  $(p, q)$  で表現  
( $p = 0, \dots, F - 1, q = 0, \dots, F - 1$ )

畳み込み演算後の出力  $u_{i,j}$  は


$$u_{i,j} = \sum_{p=0}^{F-1} \sum_{q=0}^{F-1} x_{i+p,j+q} m_{p,q}$$

利点:

ある画素周りの特徴(例:斜線、縦線、横線)を学習に取り入れることができる。




⋮




⊗ 畳み込み演算

# プーリング層 (Pooling layer)

- もっとも特徴のある要素を抽出し画像サイズを小さくする。
- 畳み込み層の後に実行される処理層。
- サイズ  $W \times W$  の画像で領域  $F \times F$  を考える ( $W > F$ )



本研究は領域  $F \times F$  の中で最大値を選ぶMaxプーリング法を用いた。




利点:画像によって特徴の位置が多少異なる場合でもその特徴を抽出できる



# 先行研究との比較

- 今回求めた期待値と逆行列法によって求めた先行研究の結果を比較する。



逆行列法とほぼ同等な性能を持つ。


1バッチのデータから求めたため素早いフィードバックが可能

※逆行列法の誤差棒は最終的な結果の値を使用した。逆行列法は50バッチ分の結果を示している

# ビームパラメータ $\sigma_y$ 再構成

ビームパラメータ  $\sigma_y$  の再構成を試みる。

$$\sigma_y = 1\sigma_y^{TDR}, \dots, 10\sigma_y^{TDR} (1.0\sigma_y^{TDR} \text{ ずつ変化})$$



濃淡はヒットした粒子数を表現する

粒子数が少ない  粒子数が多い

256階調

5000



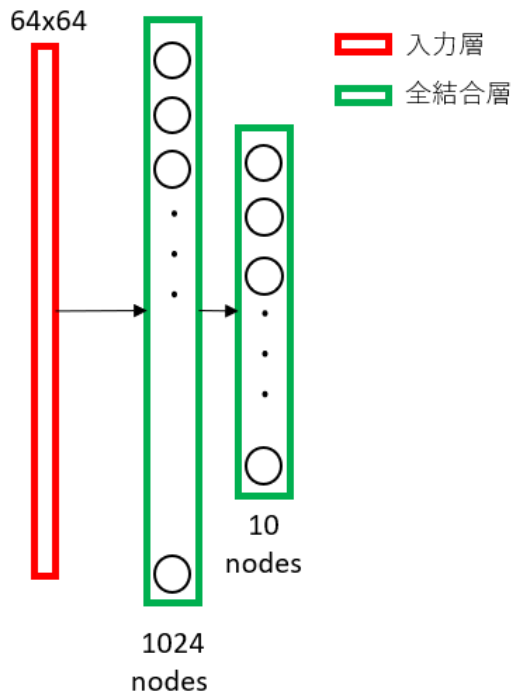
4500 トレーニングデータ

500 検証データ



50

# 結果

もっとも単純なニューラルネットワークで検証



入力層、隠れ層、出力層からなるニューラルネットワーク



検証データとトレーニングデータの損失関数値が乖離、しかし正解率は4割 51

# 散乱の様子

