

P4前期実験

低エネルギー荷電粒子 識別の新手法の開発

2018年10月11日

荒川結, 延與紫世, 金剛亮太, 坂梨公亮, 高木周,
土方佑斗, 松本凜子, 三神拓哉, 宮里慶子

目次

1. 導入
2. 全体の実験装置
3. 実験①
 - Si検出器を用いた粒子識別実験
4. 実験②
 - ホスウィッチ検出器を用いた粒子識別実験

1. 導入

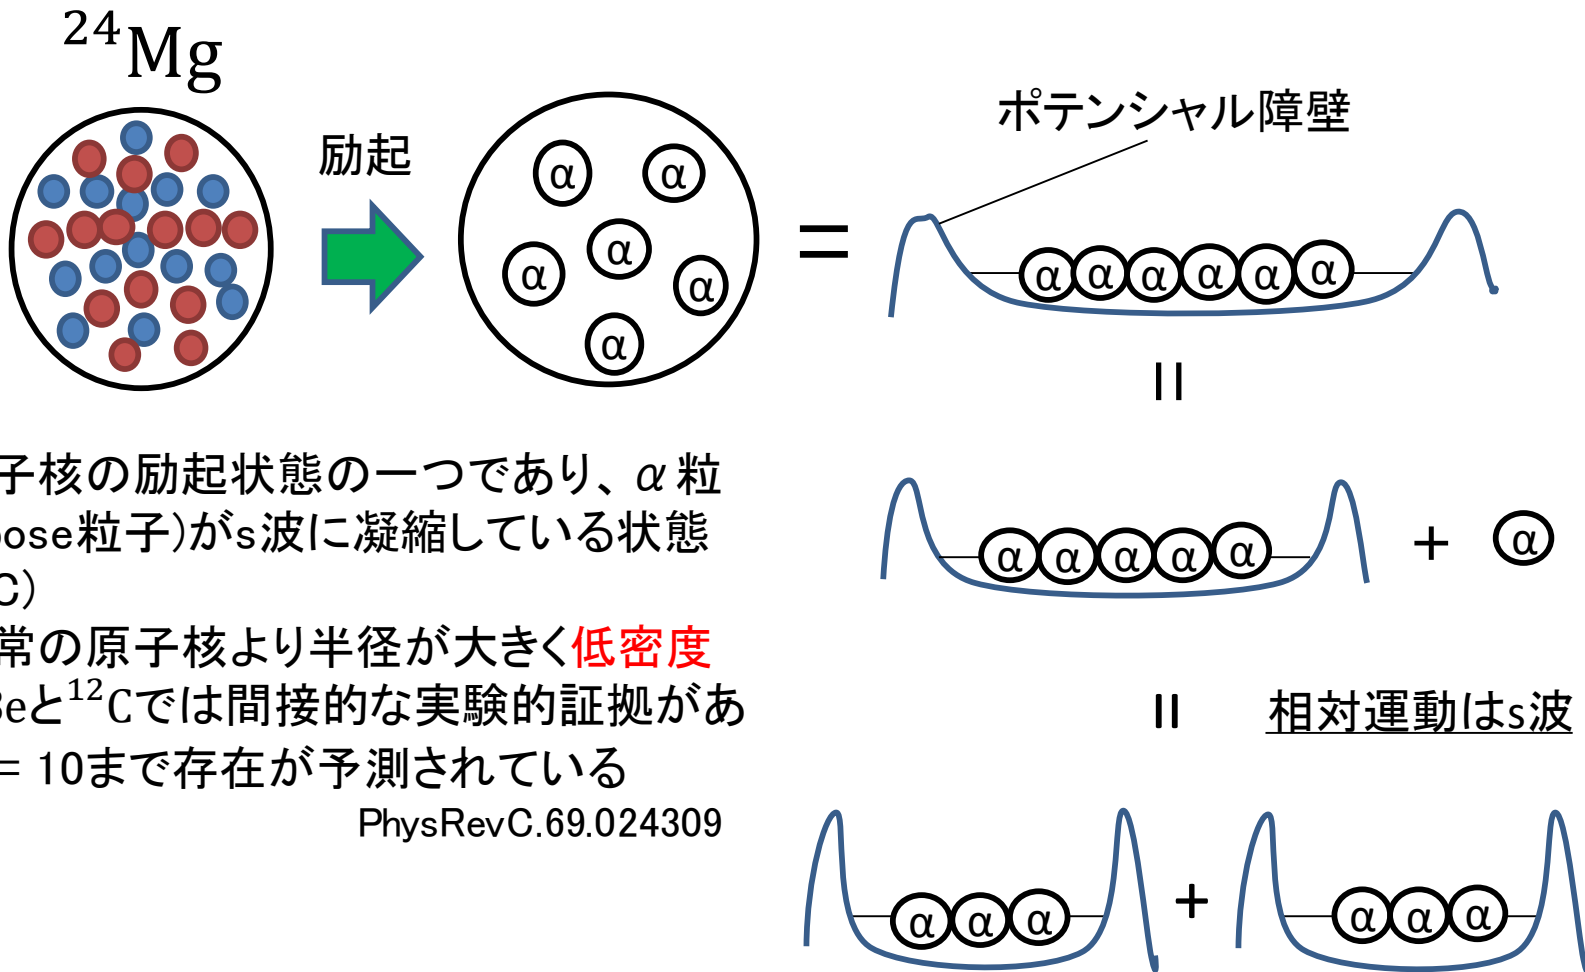
I. 背景と目的

II. 既存の方法とその問題点

III. 解決策

I. 背景と目的 - 原子核の α 凝縮状態

目標: $A = 4N$ ($N \geq 3$) の原子核で α 凝縮することの確認



- ・原子核の励起状態の一つであり、 α 粒子(bose粒子)がs波に凝縮している状態 (BEC)
- ・通常の原子核より半径が大きく**低密度**
- ・ ^8Be と ^{12}C では間接的な実験的証拠があり $N = 10$ まで存在が予測されている


PhysRevC.69.024309

I. 背景と目的 - α 凝縮状態の観測

放出確率 = 行列要素 \times クーロン透過確率 \times 状態密度

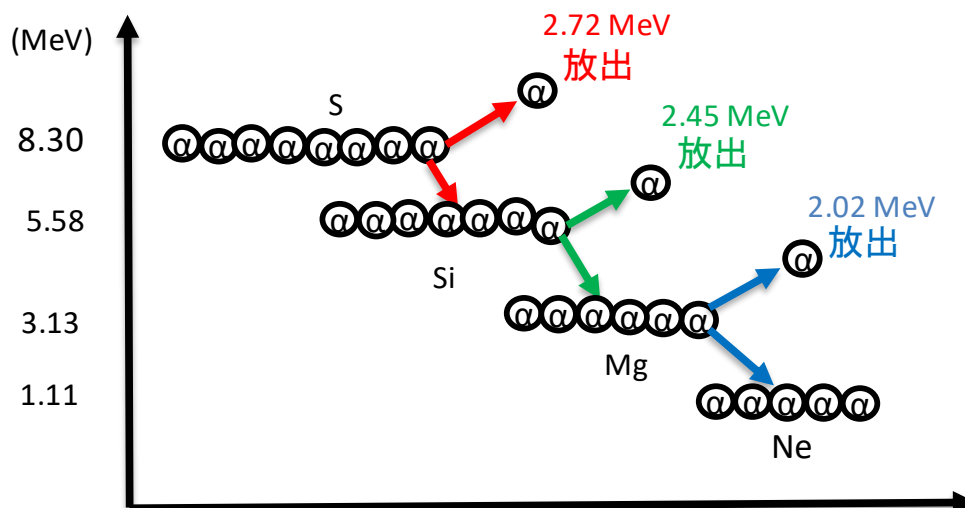
$$T = |\langle i | H | f \rangle|^2 \times P \times \rho$$

6 α 状態が1 α 放出した時の反応



波動関数の重なりが大きいと行列要素も大きい

α 凝縮状態と思われる状態と閾値とのエネルギー差




PhysRevC.69.024309



低エネルギー α 粒子の観測はBEC状態の特異な特徴

I. 背景と目的—実験目的



α粒子だけでなく、陽子や重陽子といった粒子も観測されるので低エネルギー(1から3 MeV)の荷電粒子の識別方法を確立するのは重要。

II. 既存の方法とその問題点

現状の識別方法

TOF法

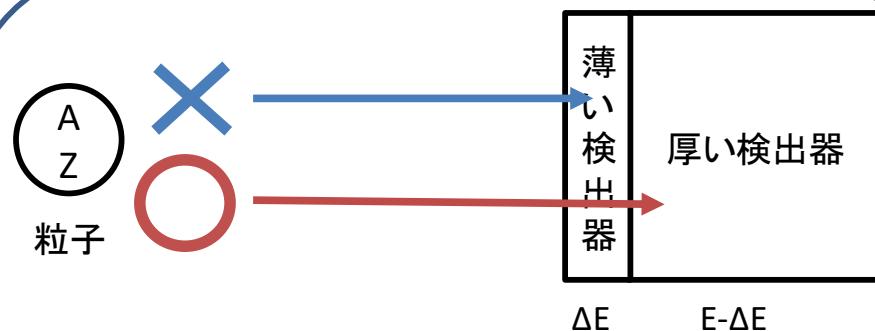


飛行時間 $t = \frac{L}{v}$ の違いを用いて粒子を識別する

問題点

- ・粒子の質量しかわからない
- ・高質量分解能のためLを大きくする必要
- ・高統計実験を行うためには、大面積化が必要

E- ΔE 法



$\Delta E \propto AZ^2/E$ を用いて粒子を識別する

問題点

- ・最初の検出器を透過する以上のエネルギーの粒子しか識別できない
- ・シリコン検出器では最も薄いもので $20 \mu\text{m}$

新手法の開発が必要

III. 解決策

- 解決策として


- ① Si検出器でとったデータによる波形解析(さらにそれを機械学習させる)
(実験①)
- ② ホスウィッチ検出器を用いた実験データの解析(実験②)

を行った。

III. 解決策—①Si検出器で波形解析

- Si検出器を2枚用意し様々な粒子を当てる
- 1枚目と2枚目のデータよるE- ΔE 法で粒子識別(2枚目の波形データの正解を得る)
- 識別した粒子それぞれにおいて2枚目の波形データを解析しそのデータのみで粒子を識別する
- さらにそれを機械学習させる

➡ 1枚のSi検出器だけで識別できるのでエネルギーの低い粒子も識別できる



III. 解決策—①Si検出器で波形解析

- 荷電粒子のエネルギー損失

$$\text{阻止能} : -\frac{dE}{dx} \propto \frac{AZ^2}{E}$$

Z: 電荷 A: 質量数

→粒子の種類によって波形が変わる


- 従来の波形解析

・波高 ・傾き ・立ち上(下)がり時間
などの違いを予想し、解析する

- 今回は、低エネルギー粒子 (1~3MeV)

→波高が小さく、従来の解析では識別が困難

粒子の波形データ

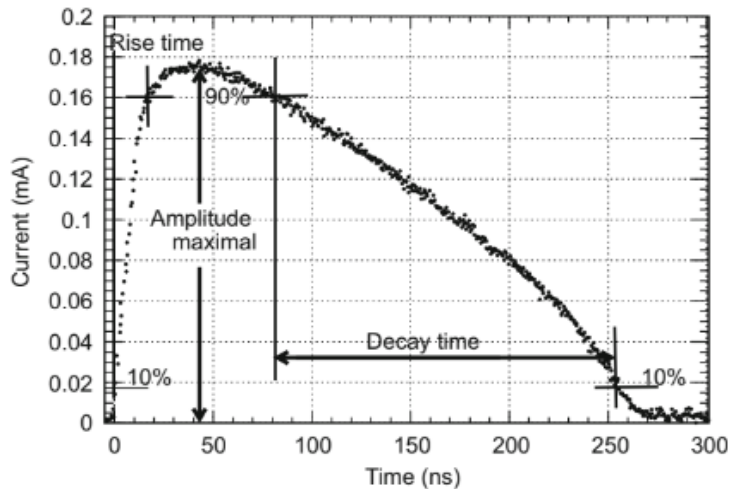


機械学習化

特徴を複合的に判断
→識別精度の向上


III. 解決策—①Si検出器で波形解析

先行研究: 先に引用した論文では、 ^{12}C と ^{13}C 、 ^{36}Ar と ^{40}Ar 、 ^{80}Kr と ^{84}Kr に対してそれぞれ波形解析で粒子を識別するに至っている。

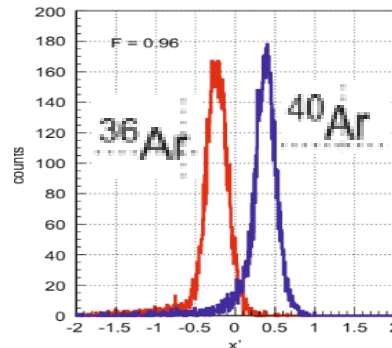


Method	100 MeV ^{12}C , ^{13}C	312 MeV ^{36}Ar , ^{40}Ar	682 MeV ^{80}Kr , ^{84}Kr
Amplitude max. (mA)	$M = 1.42$	$M = 0.81$	$M = 0.54$
Risetime (ns)	$M = 0.62$	$M = 0.36$	$M = 0.26$
Decay time (ns)	$M = 0.81$	$M = 0.48$	$M = 0.07$
Slope (mA/ns)	$M = 1.35$	$M = 0.73$	$M = 0.11$
m_2 (ns)	$M = 0.91$	$M = 0.64$	$M = \sim 0$

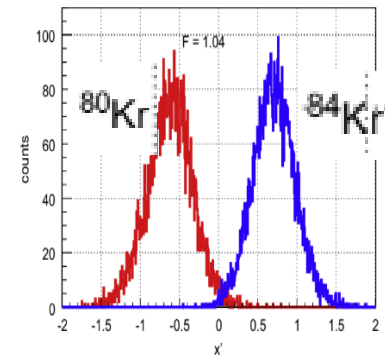
M: 2つのガウス分布の離れ具合を表す値
一般に0.75以上だと十分分離しているといえる。



Arにおける m_2 : m_3



Ar: $M = 0.96$

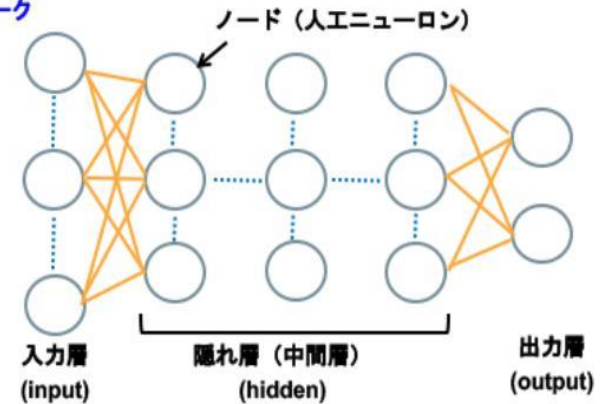


Kr: $M = 1.04$


Neural network とは

- 人間の脳神経系のニューロンの仕組みをモデル化したネットワーク構造
- 入力層・中間層・出力層が存在し、ニューロンは隣接する層の全てのニューロンと接続
- 入力信号に、重み・バイアス・活性化関数を用い、出力信号に変換



ニューラルネットワーク



入力: p_i
重み: w_i
バイアス: b
 $\rightarrow n = \sum_i (w_i p_i + b)$



活性化関数: $f = \frac{1}{1+e^{-n}}$ (シグモイド関数) など
出力: $y = f(n)$



Neural network の学習

○波形を入力すると粒子の種類が出力されるネットワークを作りたい
→ 訓練データで重み w_i の最適化

- ・誤差 $E(w_i)$... 性能の悪さを表す
- ・勾配法 ... 誤差 E の極小値を探す

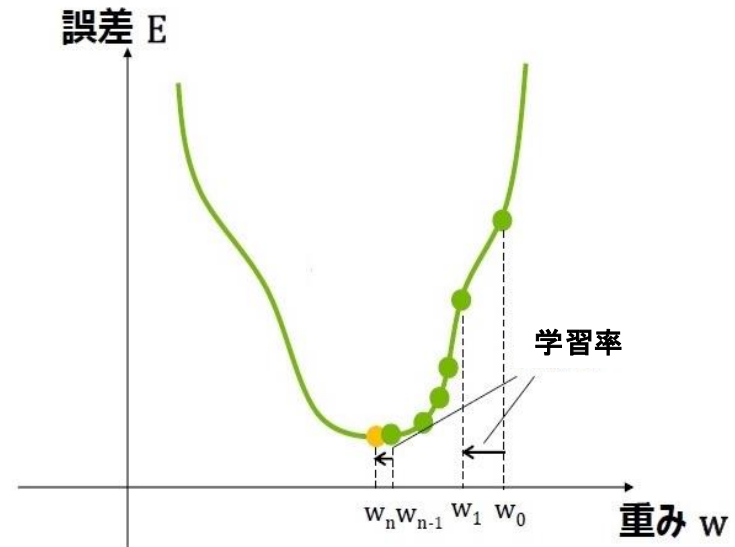
$$w_{i+1} = w_i - \mu \frac{\partial E}{\partial w_i}$$

μ : 学習率

○ 検証データを用いて性能評価

※過学習

学習データに特化しすぎて、検証データの正答率が悪くなる現象
サンプルデータが少ないときやパラメータが多い時によく生じる



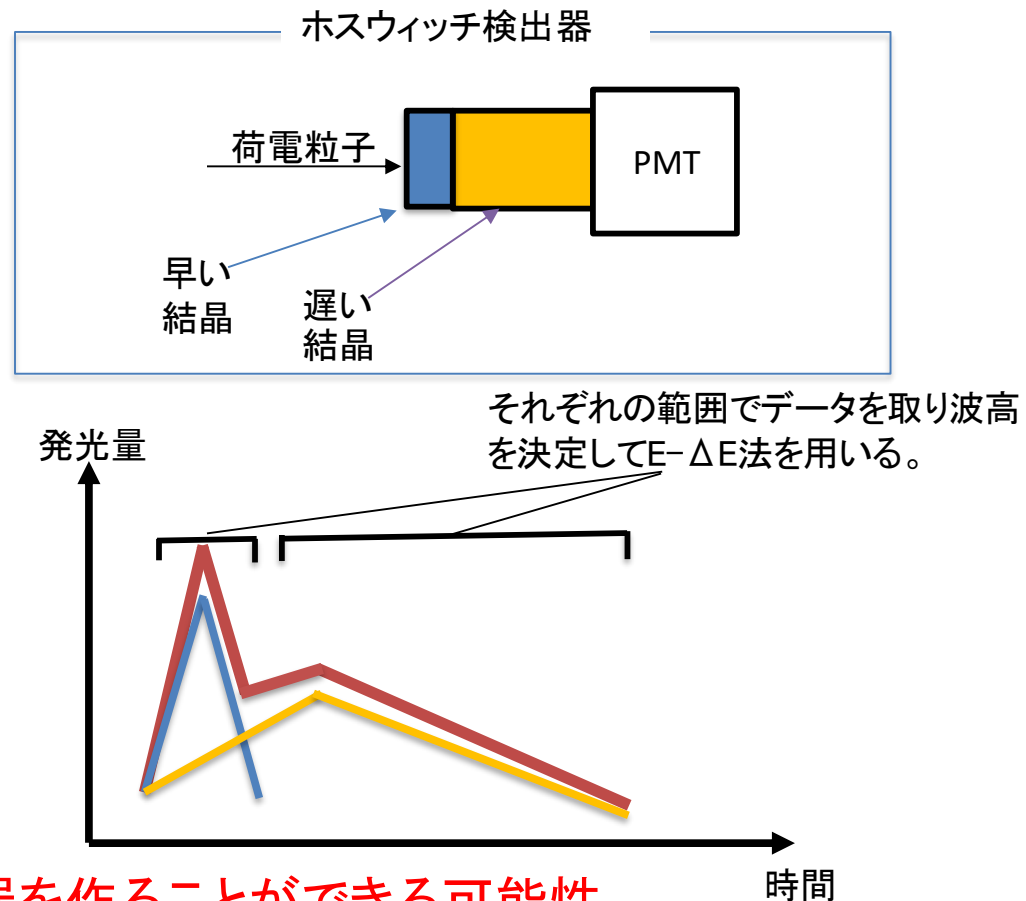
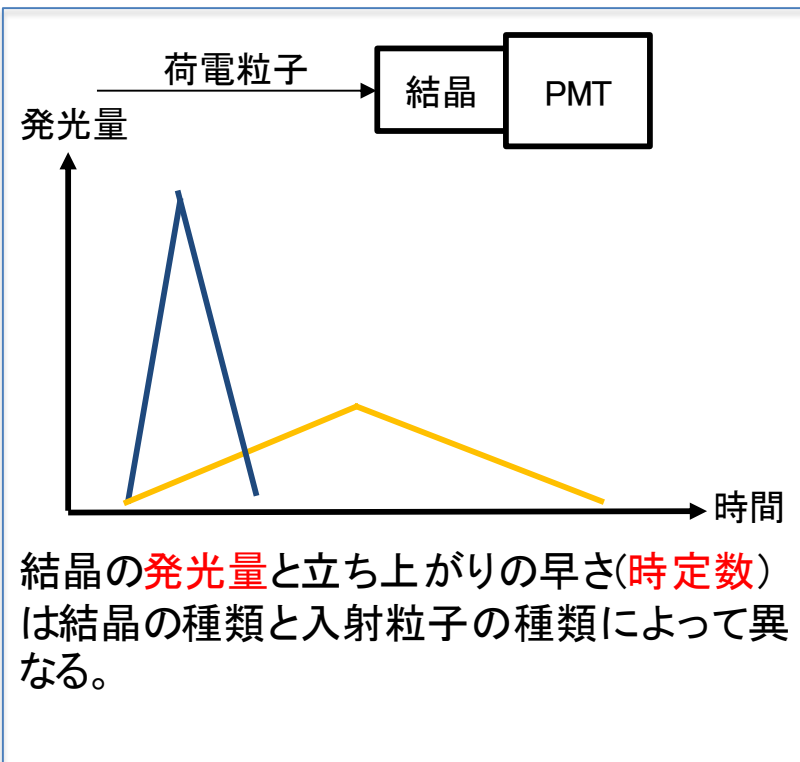
III. 解決策—②ホスウィッチ検出器

ホスウィッチ検出器：時定数が異なる結晶を組み合わせた検出器。

ある結晶表面に異種の結晶を育てることで原理的には厚さ数 μm の結晶を育成可能。

(今回用いたのは $100\ \mu\text{m}$)

東北大学金属材料研究所と共同研究。作って頂いた。



メリット

- ΔE 層の薄い検出器を作ることができる可能性
- 低エネルギー粒子の識別が可能

2. 全体の実験装置

準備日程

7月24日(火)～7月28日(土)

実験日時

7月28日(土)21:00～7月29日21:00

場所

大阪大学核物理研究センター一
東実験室




2. 全体の実験装置

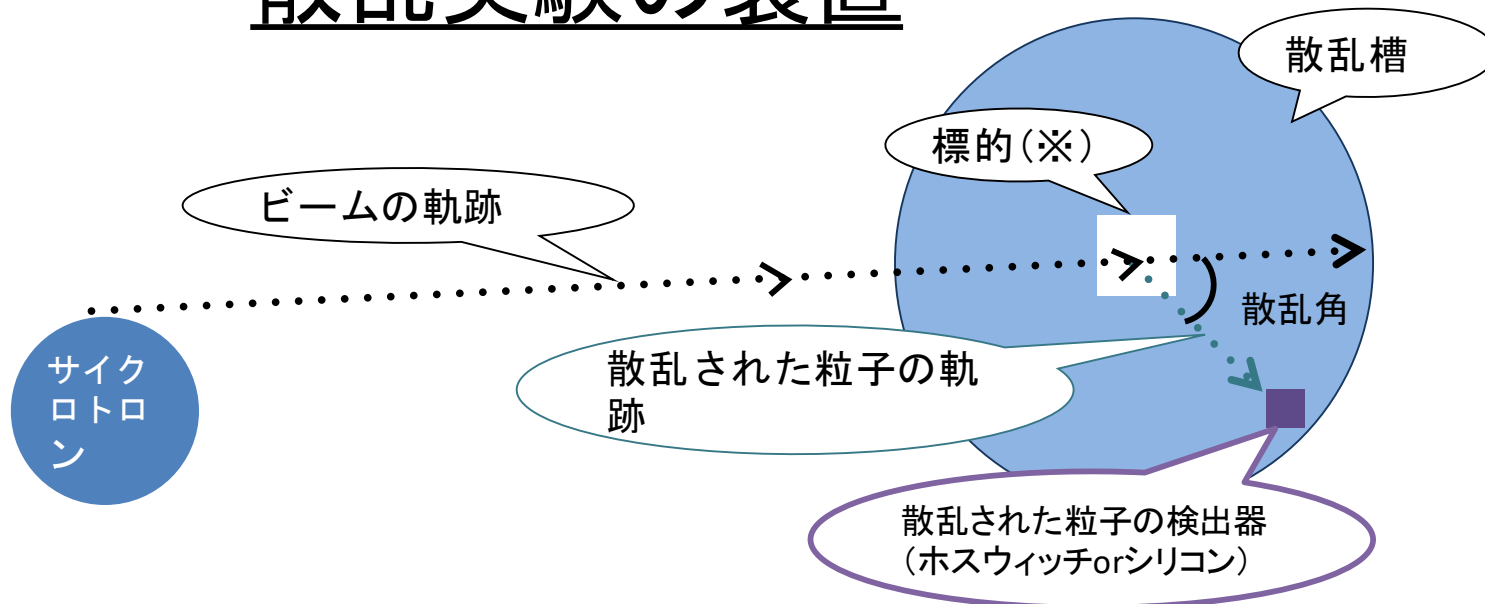
ビームの種類

入射粒子... ^4He

粒子のエネルギー...80MeV



散乱実験の装置




2. 全体の実験装置—※標的

- α線を標的に当てることでα粒子がターゲットの物質と相互作用し、様々な粒子(p, α, d, t, ^3He)を得られる。



図：実際に用いたターゲット



図：ターゲット模式図

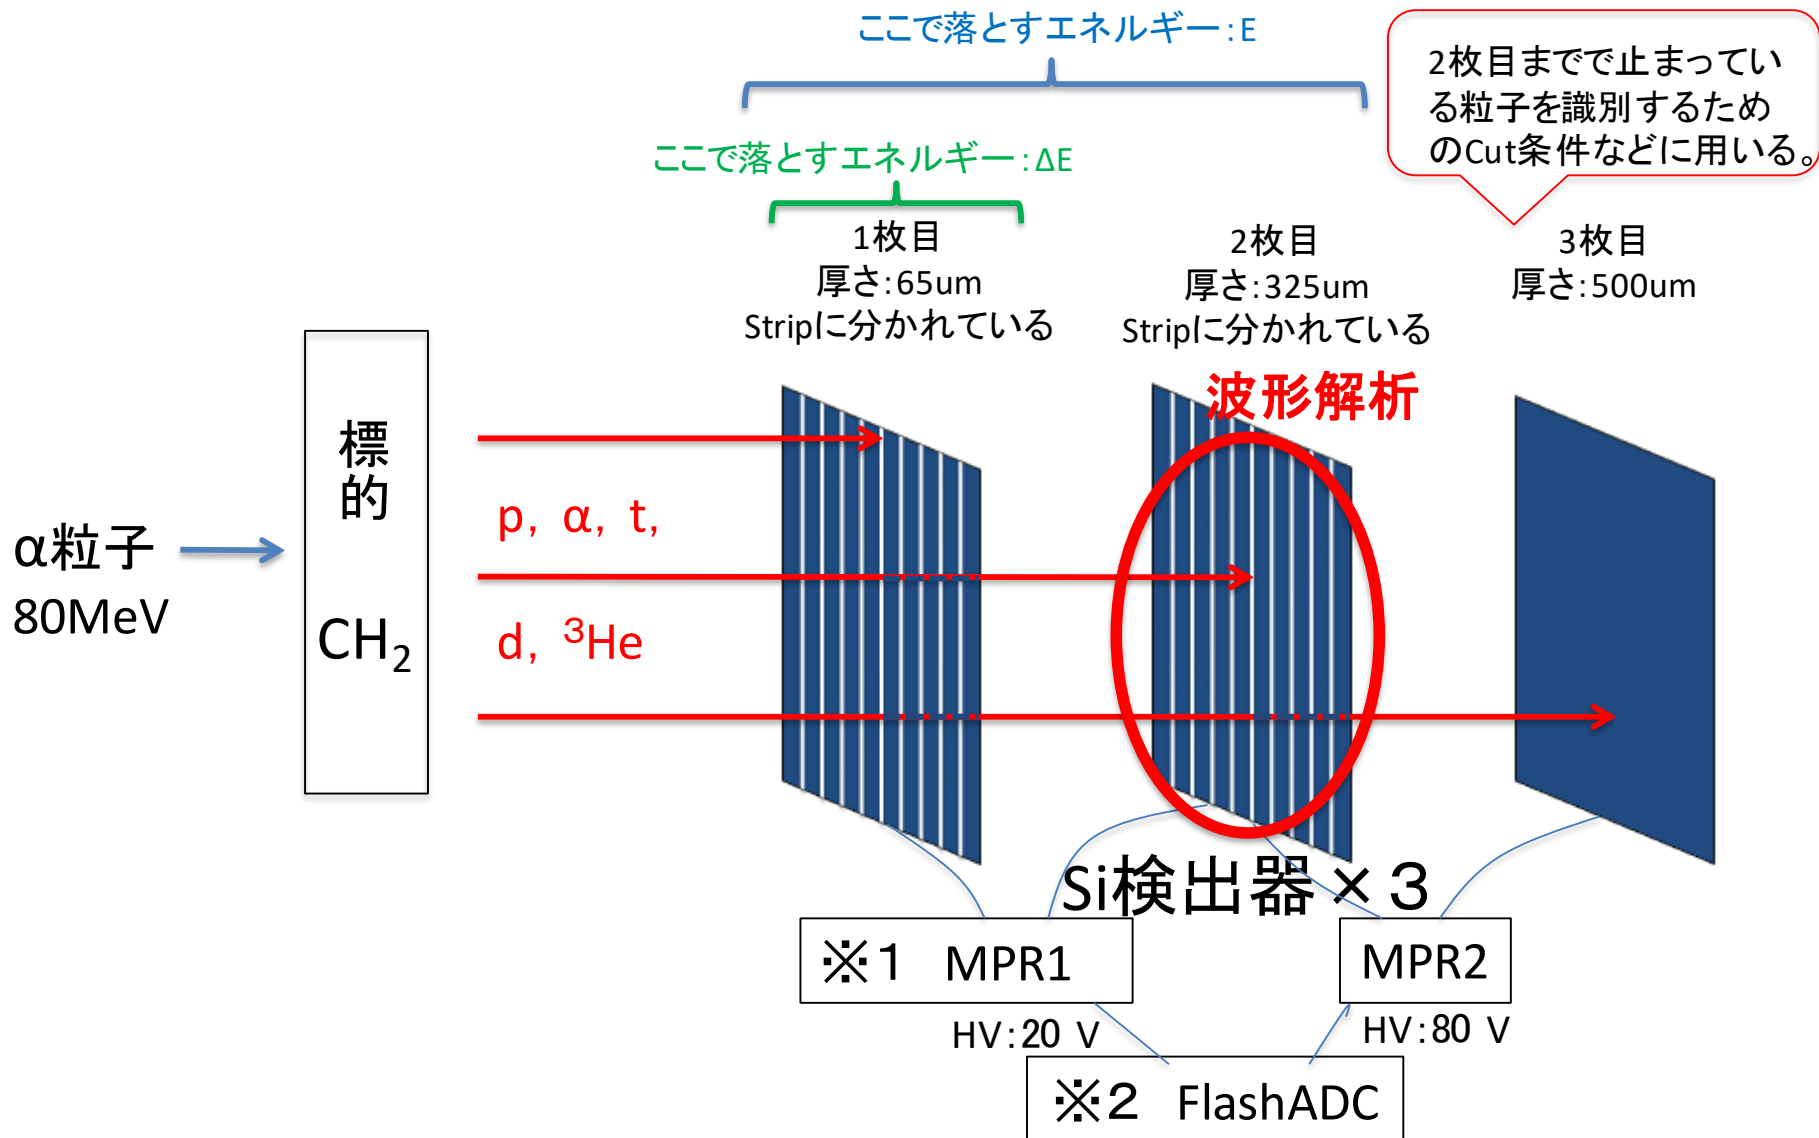
3. 実験①Si検出器で波形解析

I. 実験装置

II. 解析

III. まとめ

I. 実験装置




I. 実験装置 ※

• ※1 MPRとは

電荷積分型のプリアンプ。真空層に入れて使うことができる。

↳ 検出器からの電流信号をコンデンサーで積分した値を出力する



なぜ電荷積分型？

我々が扱おうとしている粒子は数MeV程度なのでそのままの電流信号だと波高が小さくノイズにまぎれてTriggerがうまくかけられない。

積分すればノイズはある程度キャンセルされる。


(先行研究では数100MeVの粒子を扱っているのでそのままの電流信号の波形を解析している)

1. 実験装置 ※


• ※2 FlashADCとは

アナログ信号の波高をデジタルデータとして時々刻々（今回は2nsごと）と出力できる装置（それゆえデータ量が非常に多い）

使う時は発熱するので扇風機で冷やしながら使用
値段は高い



苦労話



- ノイズ落としが大変だった。
 - ケーブルの金属部分を装置の金属部分とアルミホイール等で接地する
 - 実験中はパルスモーターの電源を切る(するとリアルタイムでターゲットの位置を調整できなくなる) など
- Flash ADCを用いたのでデータ量が非常に大きくなり扱いに手間取った。
- Flash ADCは扇風機で常に冷却し続けなければならなかった。

II. 解析

A) 生データ

B) E- ΔE 法で粒子識別（波形解析の準備）

- 従来のE- ΔE 法でこれから波形解析する粒子それぞれの波形データを抽出

C) 波形解析

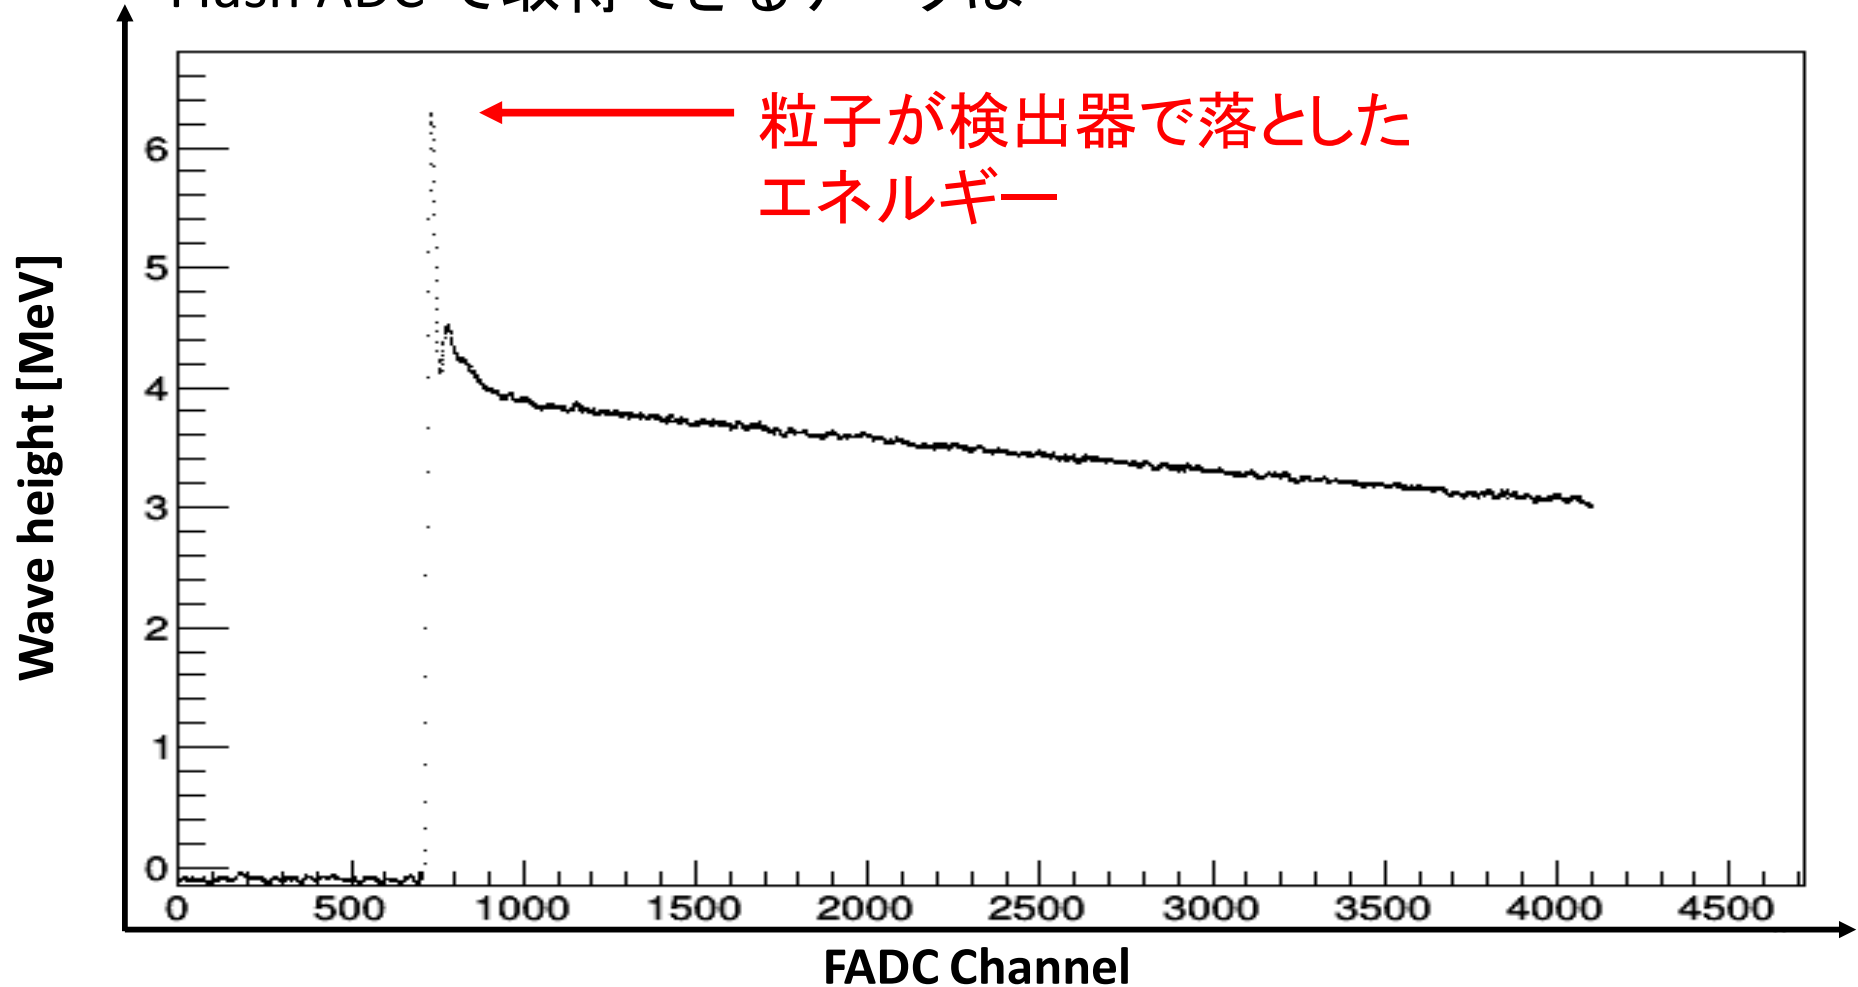
- 1枚の検出器の波形データだけで粒子が識別できるか？

D) Neural networkの構造

E) Neural networkによる学習

A) 生データ


Flash ADC で取得できるデータは



横軸は1 ch = 2nsec , 1event あたり 4100 ch 取得
プリアンプを通した出力なので、**最大波高が energy** に対応

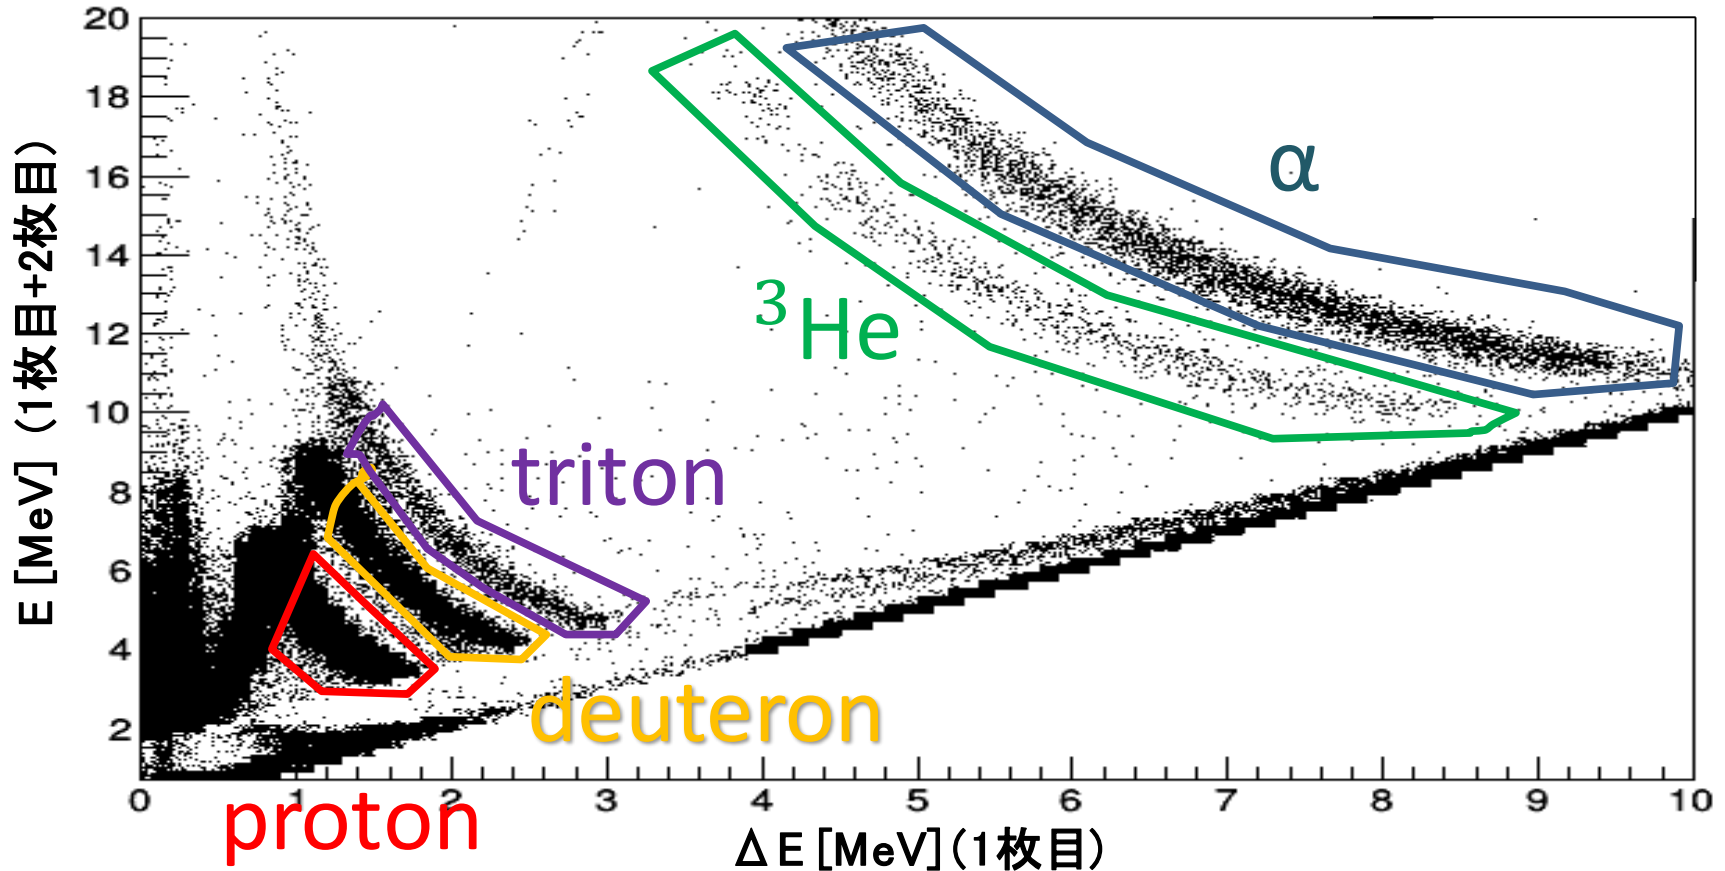
B) E- ΔE による粒子識別(波形解析の準備)

1枚目と2枚目のシリコンによるE- ΔE



B) E- ΔE による粒子識別(波形解析の準備)

1枚目と2枚目のシリコンによるE- ΔE



- 識別すべき粒子がよく分離
- Eventごとに粒子を識別 → 手法の評価

なお、これ以降は proton と α のみについて報告


C) 波形解析 目論見

単位長さあたりに落とすエネルギーは $\Delta E \propto \frac{AZ^2}{E}$

A: 質量数
Z: 原子番号

⇒ AやZが大きい粒子の方が早く停止

Si 検出器



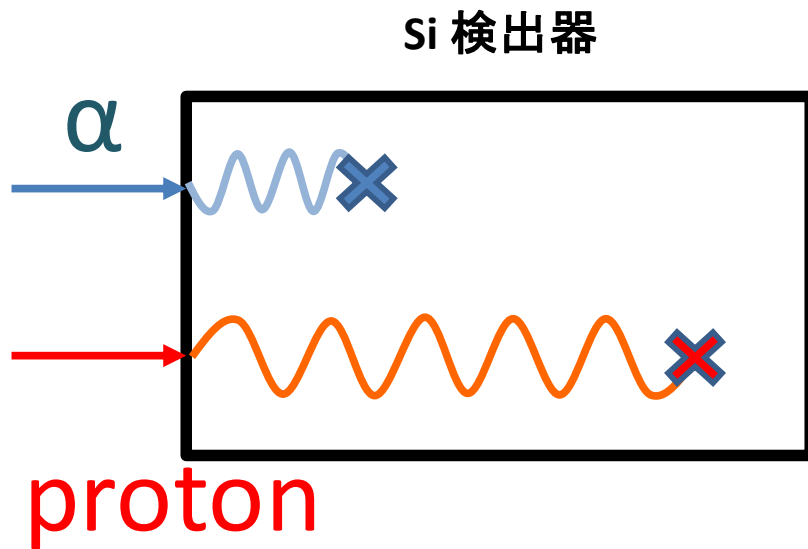
proton

C) 波形解析 目論見

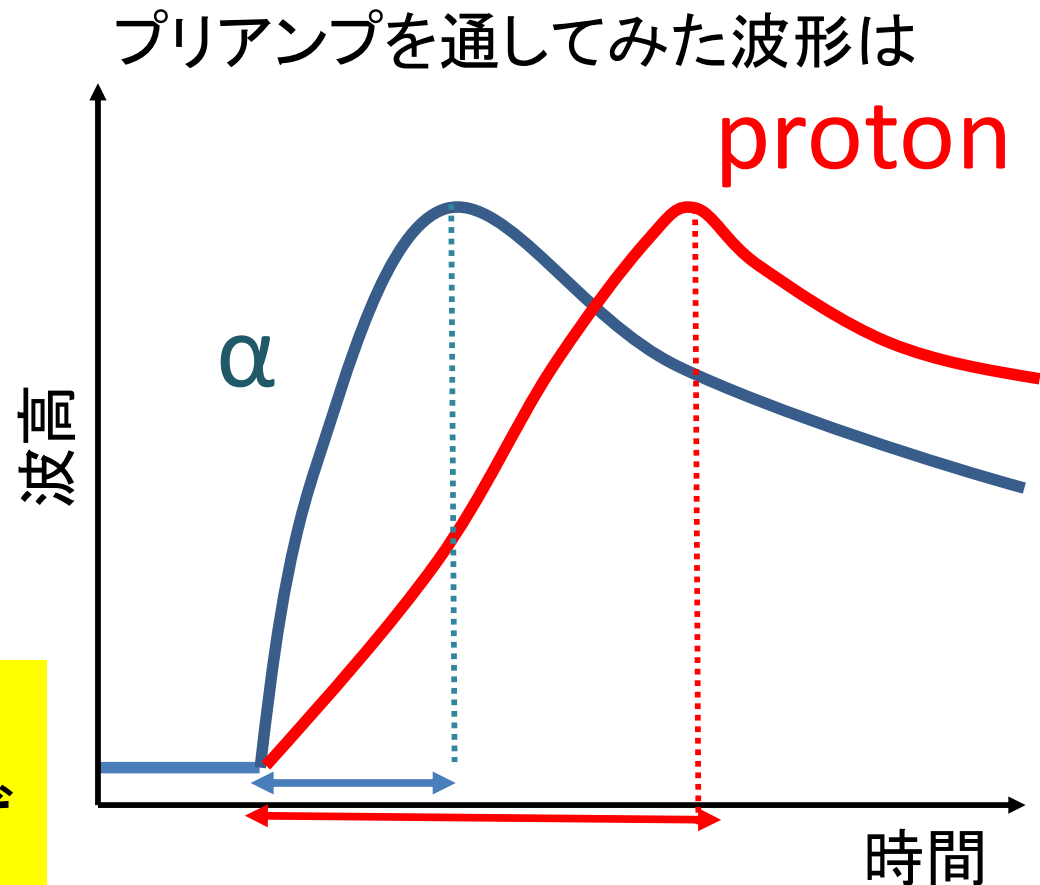
単位長さあたりに落とすエネルギーは $\Delta E \propto \frac{AZ^2}{E}$

A: 質量数
Z: 原子番号

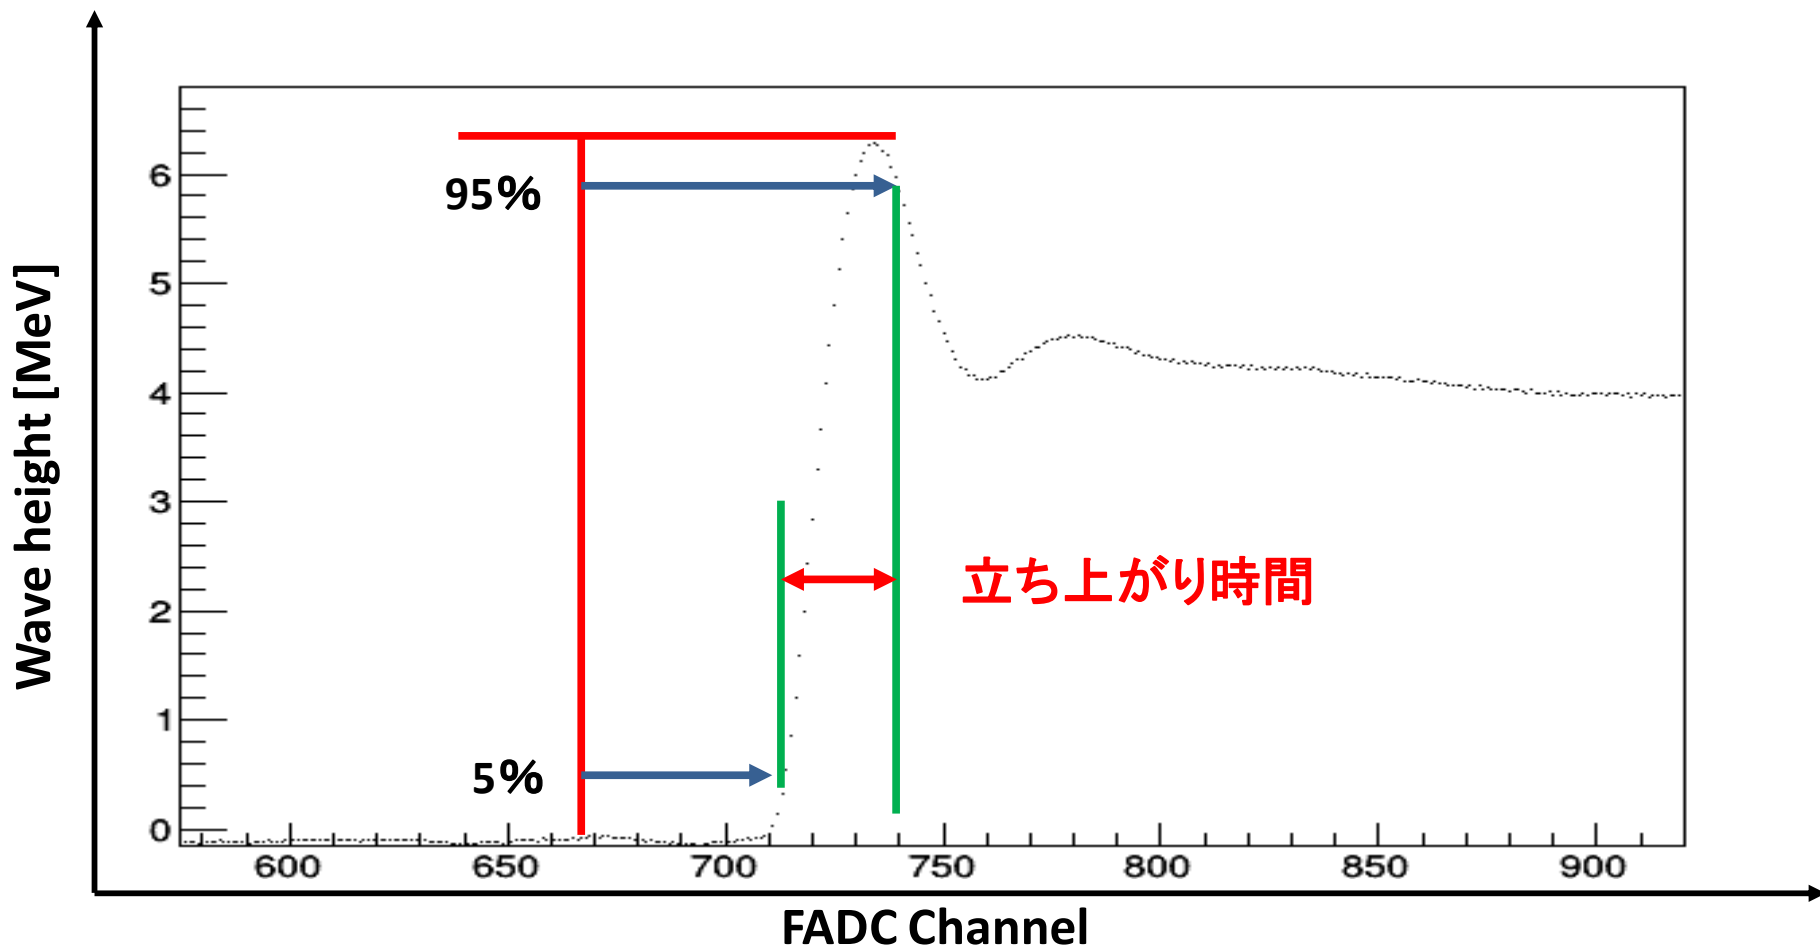
⇒ AやZが大きい粒子の方が早く停止



立ち上がり時間に
違いが表れるはず



C) 波形解析 立ち上がり時間の決定




立ち上がり時間の取り方を複数とって見たところ、
最大波高の5%から山の反対側での95%が最も分離が良い

2nsec ごとのデータであるが、spline 補完により立ち上がり時間は連続の値

C) 波形解析 エネルギーと立ち上がり

エネルギーと立ち上がりの相関

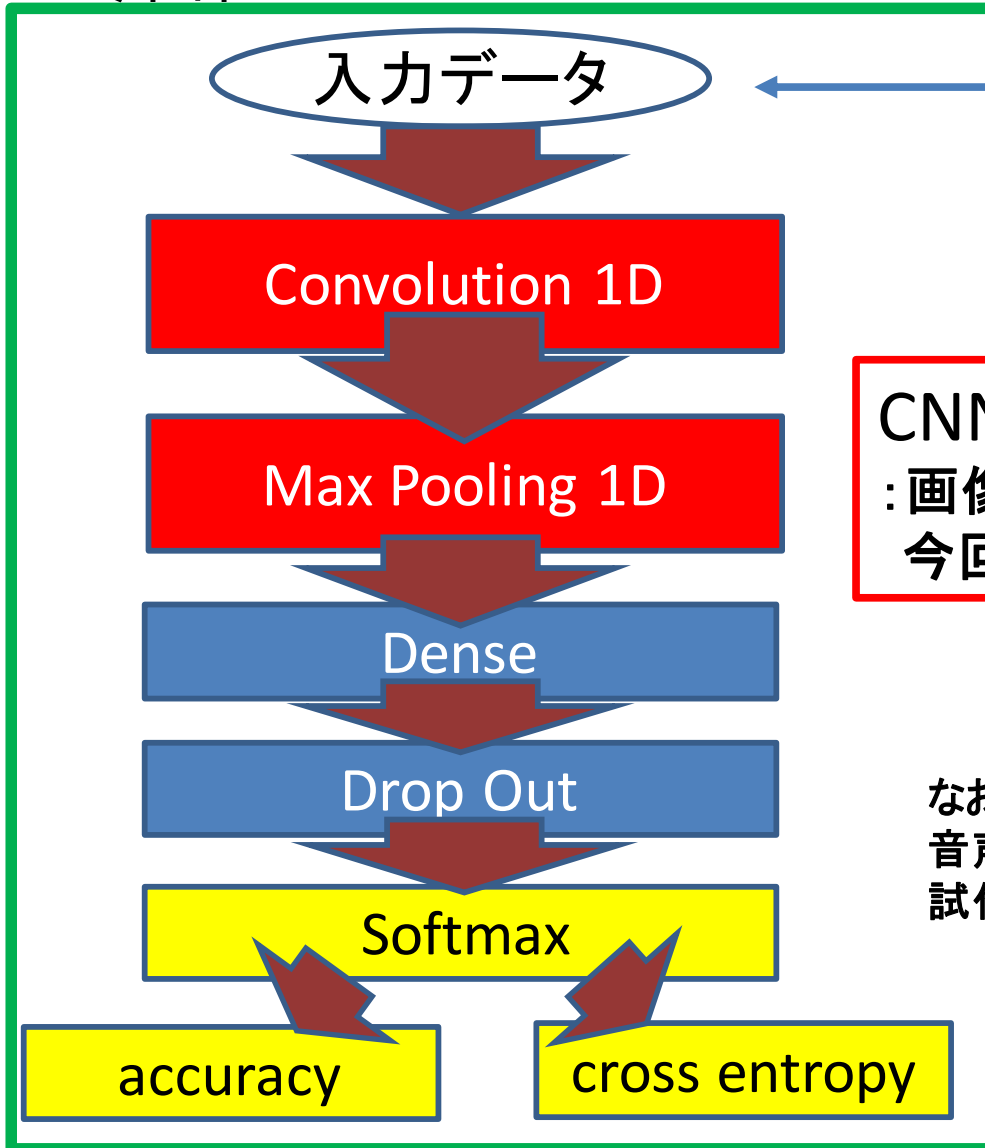


この図から二つの粒子を判別するのは不可能！！

⇒ neural networkにお任せ

D) Neural networkの構造

今回組んだneural networkはConvolution Neural Networkである。



Flash ADC で取得した1 event あたり
4100個のサンプリング点を使用
(ただしcalibrationしたもの)

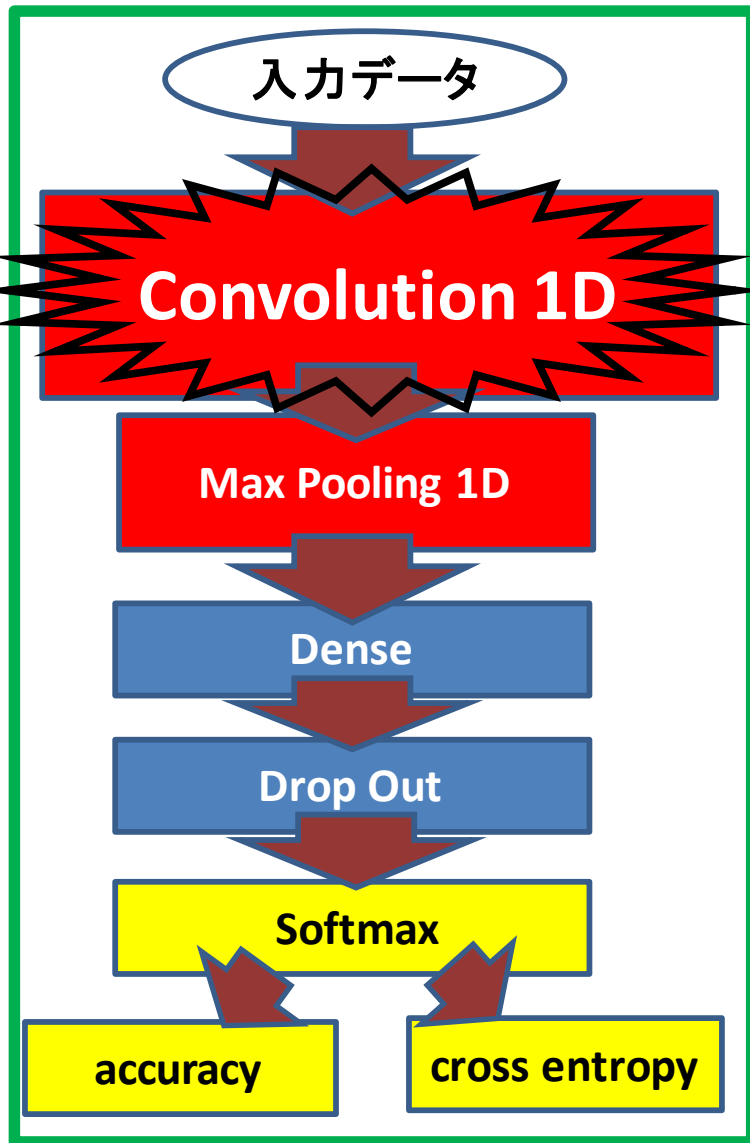
CNNとは？

: 画像解析に有用であるneural network
今回ものデータは画像のようなもの


なお、RNN(Recurrent Neural Network)という、
音声等の時系列データに有用なネットワークもあり、
試作してみたもののCNNの方がよい結果が得られた

Neural Network の構造

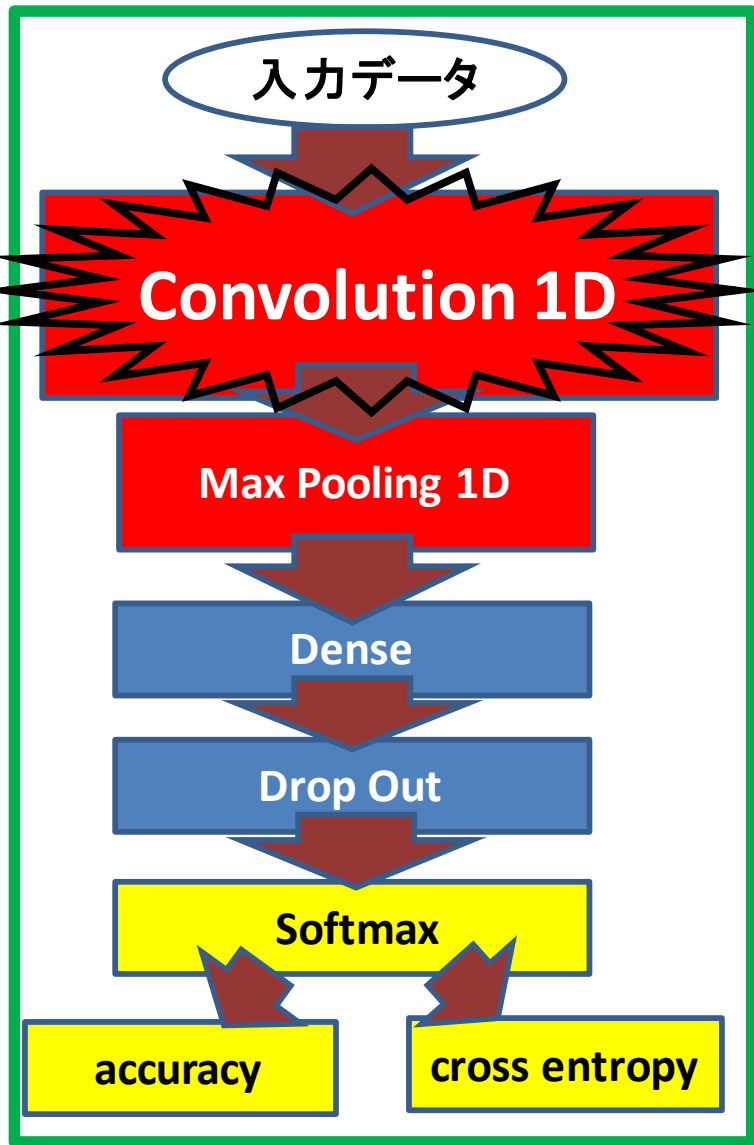
D) Neural networkの構造



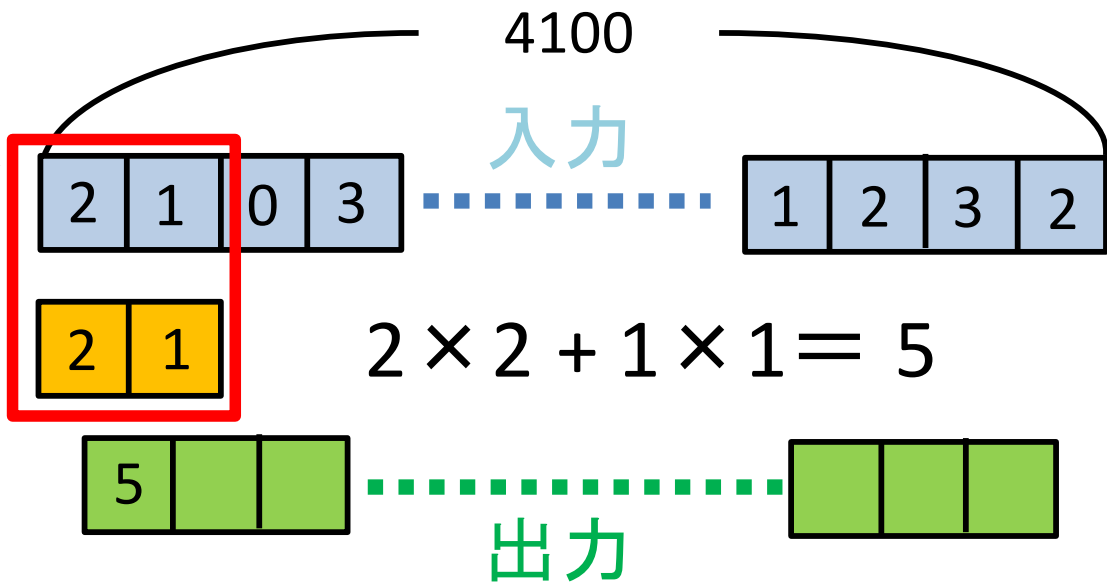
Convolution layer



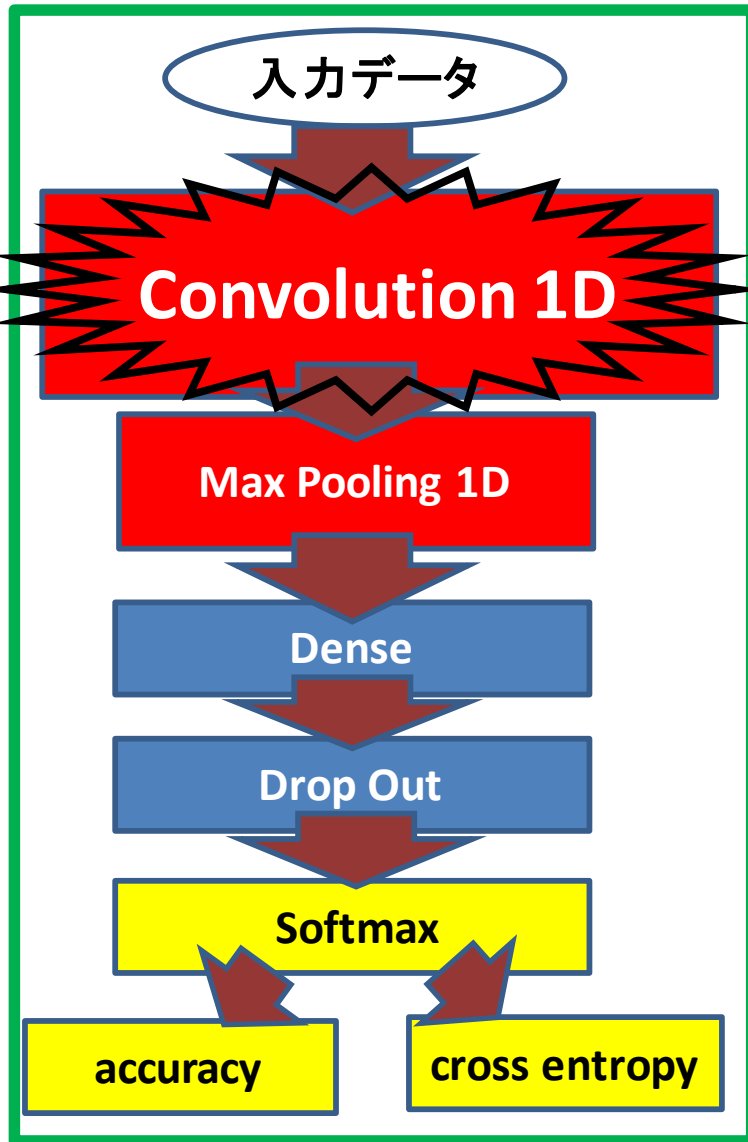
D) Neural networkの構造




Convolution layer



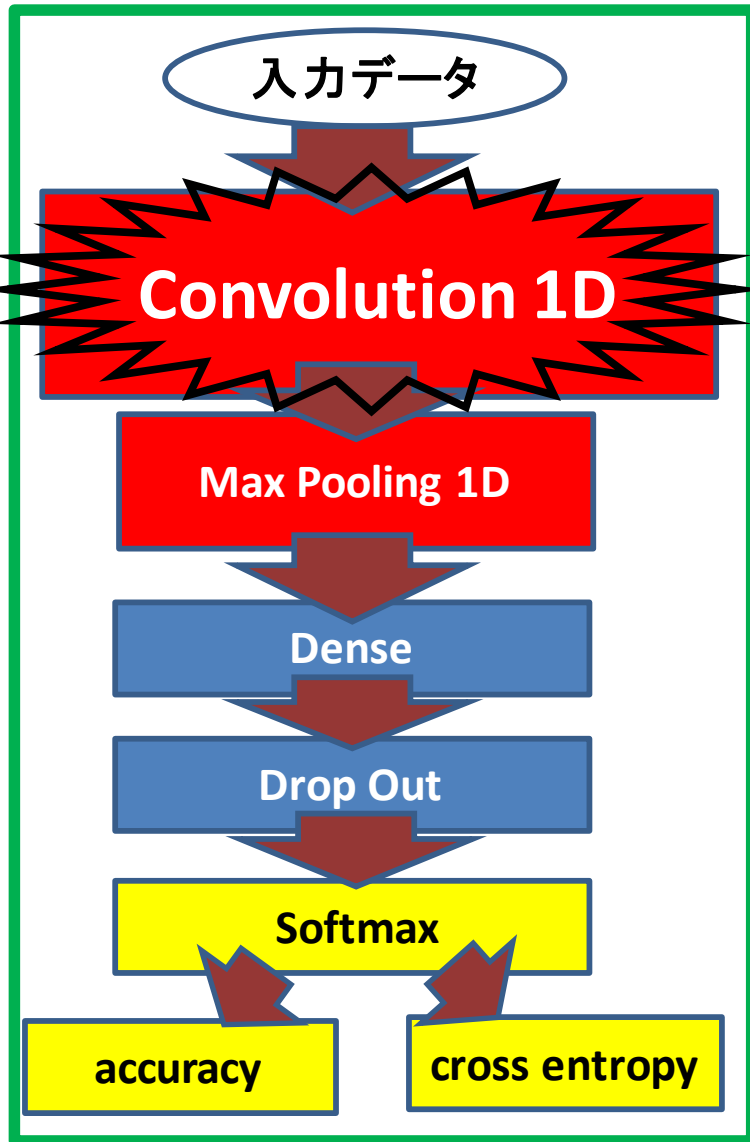
D) Neural networkの構造



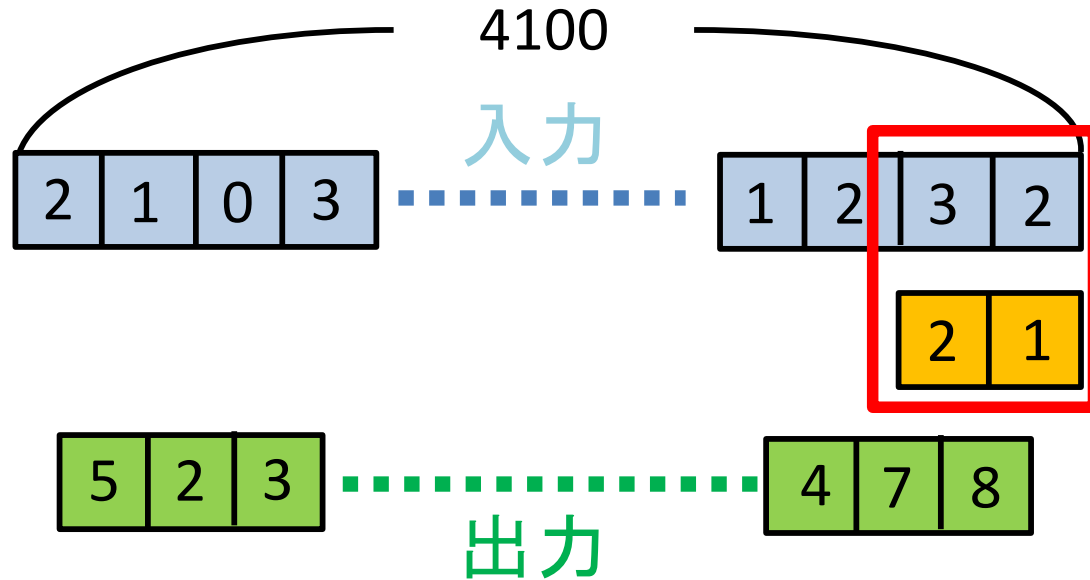
Convolution layer



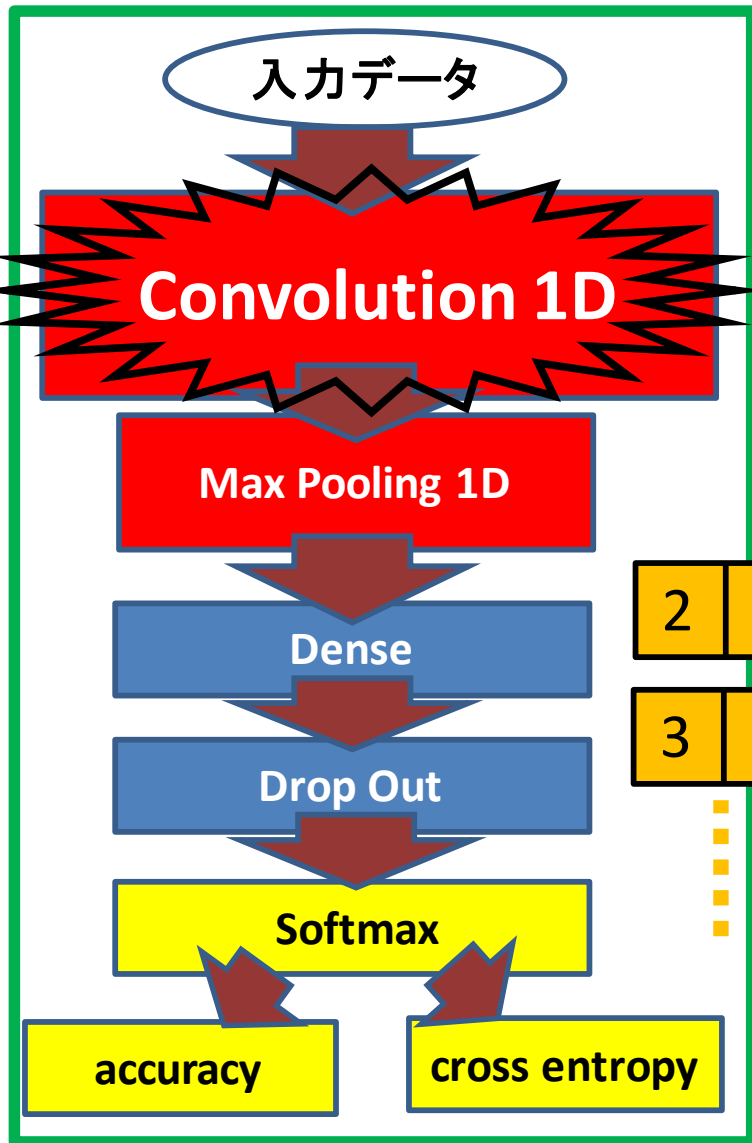
D) Neural networkの構造




Convolution layer



D) Neural networkの構造

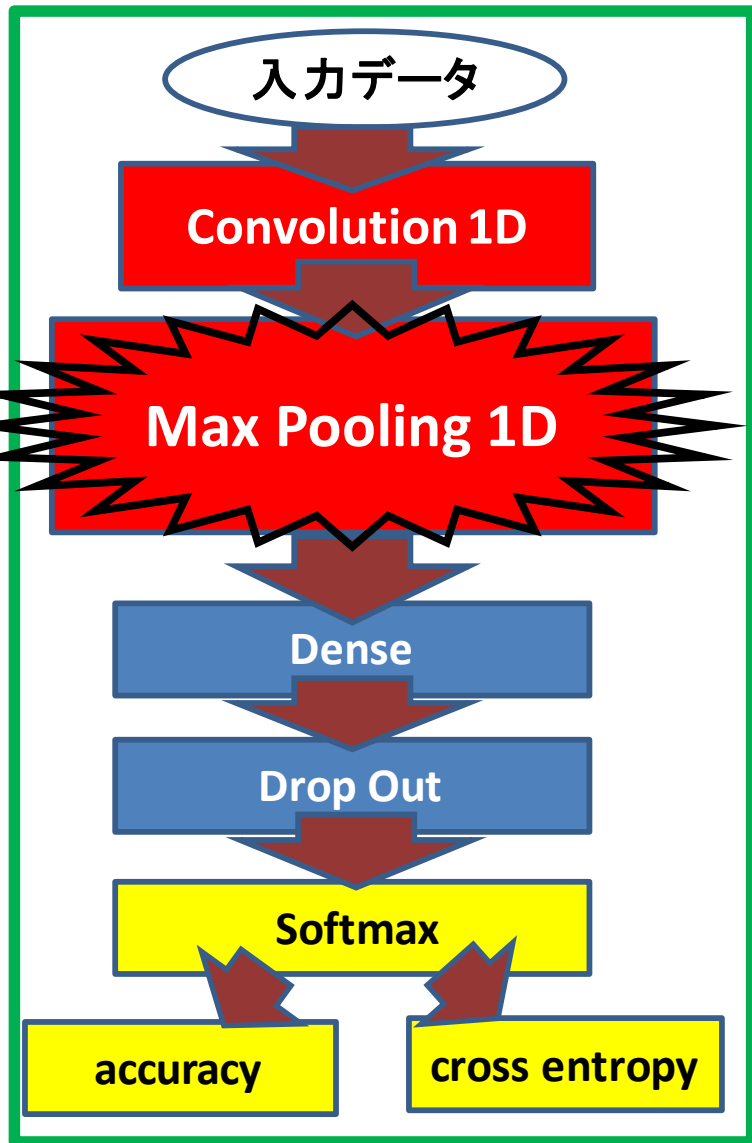


Convolution layer




 に様々な値を入れて反復

D) Neural networkの構造



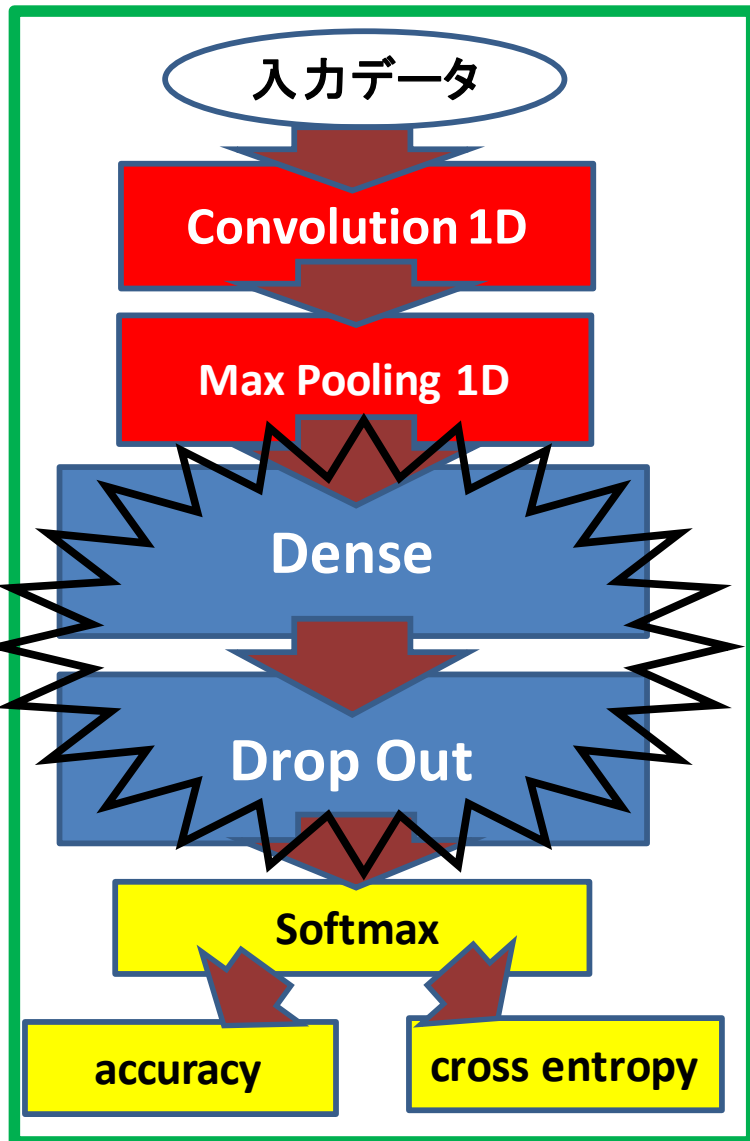
Max Pooling layer



三つの中から最大のデータを選択し、圧縮される


他にもAverage Poolingがあるが、
Max Poolingが結果が良いと報告されている
(A Sensitivity Analysis of (and Practitioners' Guide to)
Convolutional Neural Networks for Sentence
Classification, Ye Zhang and Byron C. Wallace
arXiv:1510.03820)

D) Neural networkの構造




Dense layer

全結合ネットワーク、おそらく一番一般的

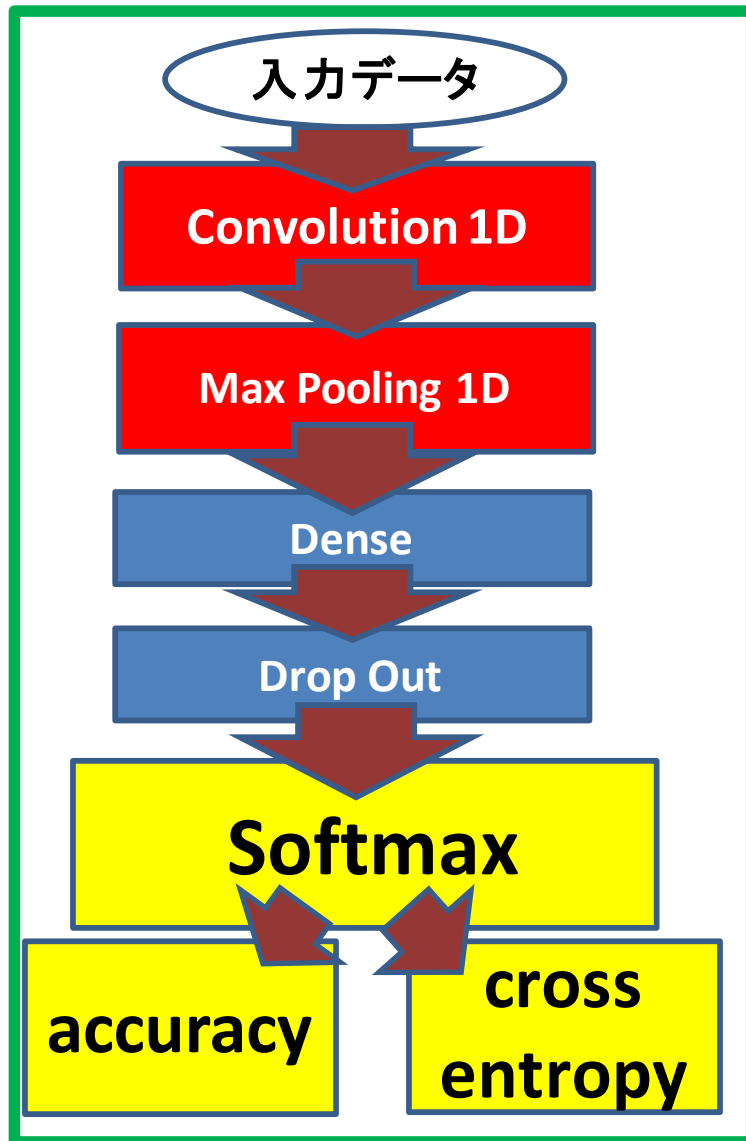


Drop Out

Denseでパラメータが大きくなりすぎた部分を
不使用にする、過学習防止に有効



D) Neural networkの構造



Softmax layer

- 分類問題において使用
- 各選択肢の確率が何%であるかを出力 (今回はprotonと α)

accuracy

Softmax からの出力のうち
最も確率の高いものを答えとしたときの正答率

cross entropy

$E = -\sum_k t_k \log y_k$ で定義

- k は粒子ごとのラベル
- t_k は正解のみ1、その他は0
- y_k はsoftmaxの出力
- この値が小さくなるようにパラメータが更新

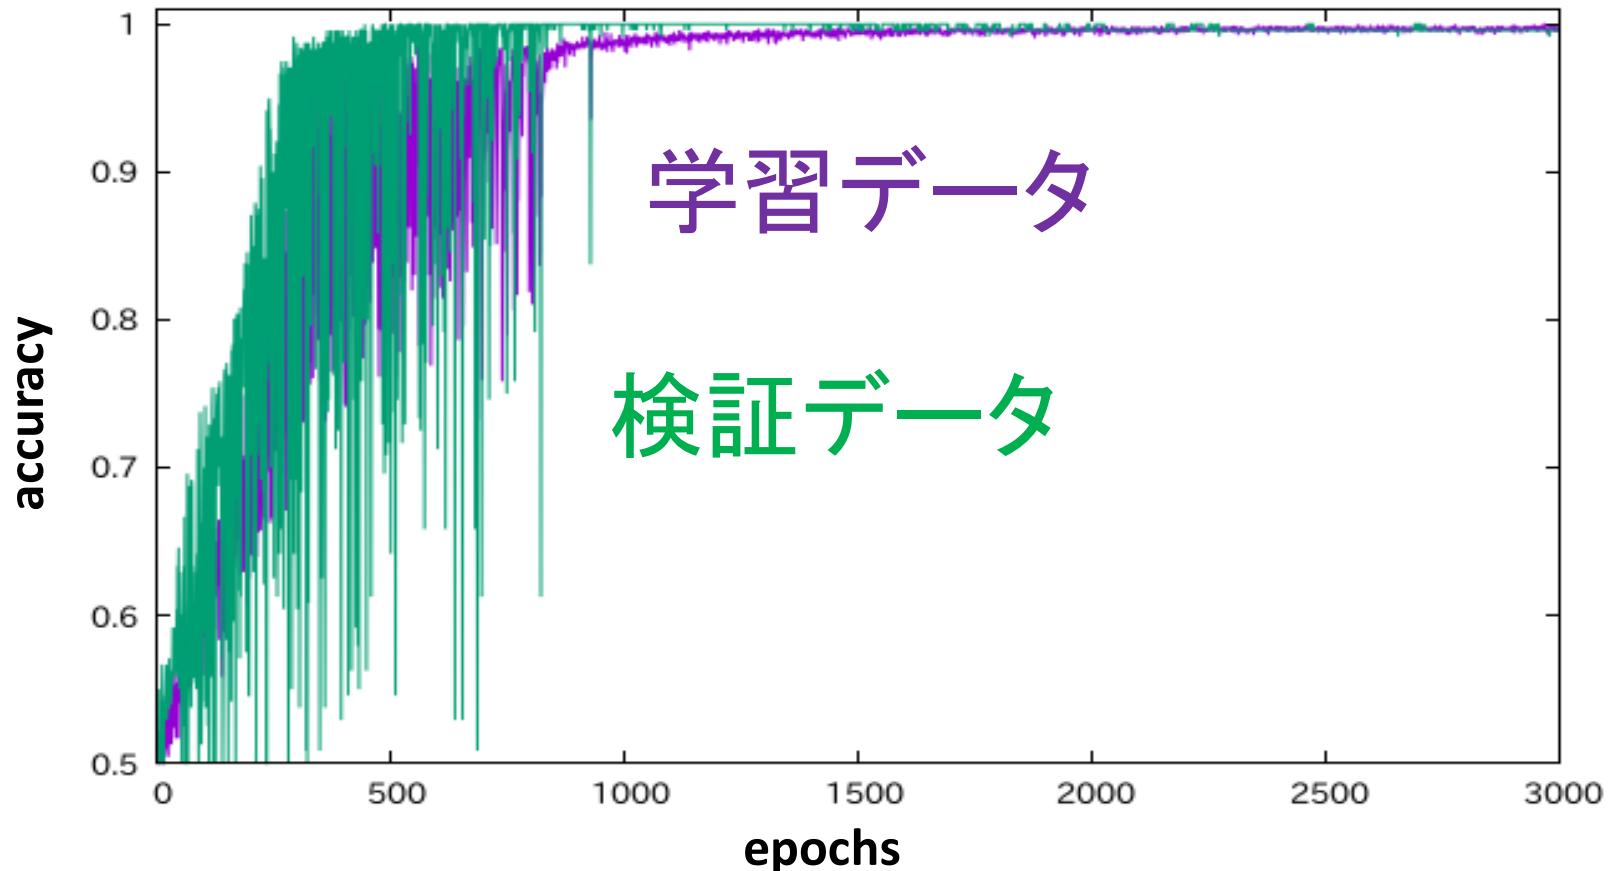
example) 正解が α , softmaxの出力がproton 0.2, alpha 0.8 なら $E = -\log 0.8$

E) Neural network による学習

α 凝縮状態の探索に必要な1~3 MeV のデータの学習記録

E) Neural network による学習

α 凝縮状態の探索に必要な1~3 MeV のデータの学習記録




学習データ : 学習に利用 α , proton それぞれ 480 event

検証データ : 学習後に正答率を評価 それぞれ 120 event

epochs : 入力したデータを何周学習したか

E) Neural network による学習

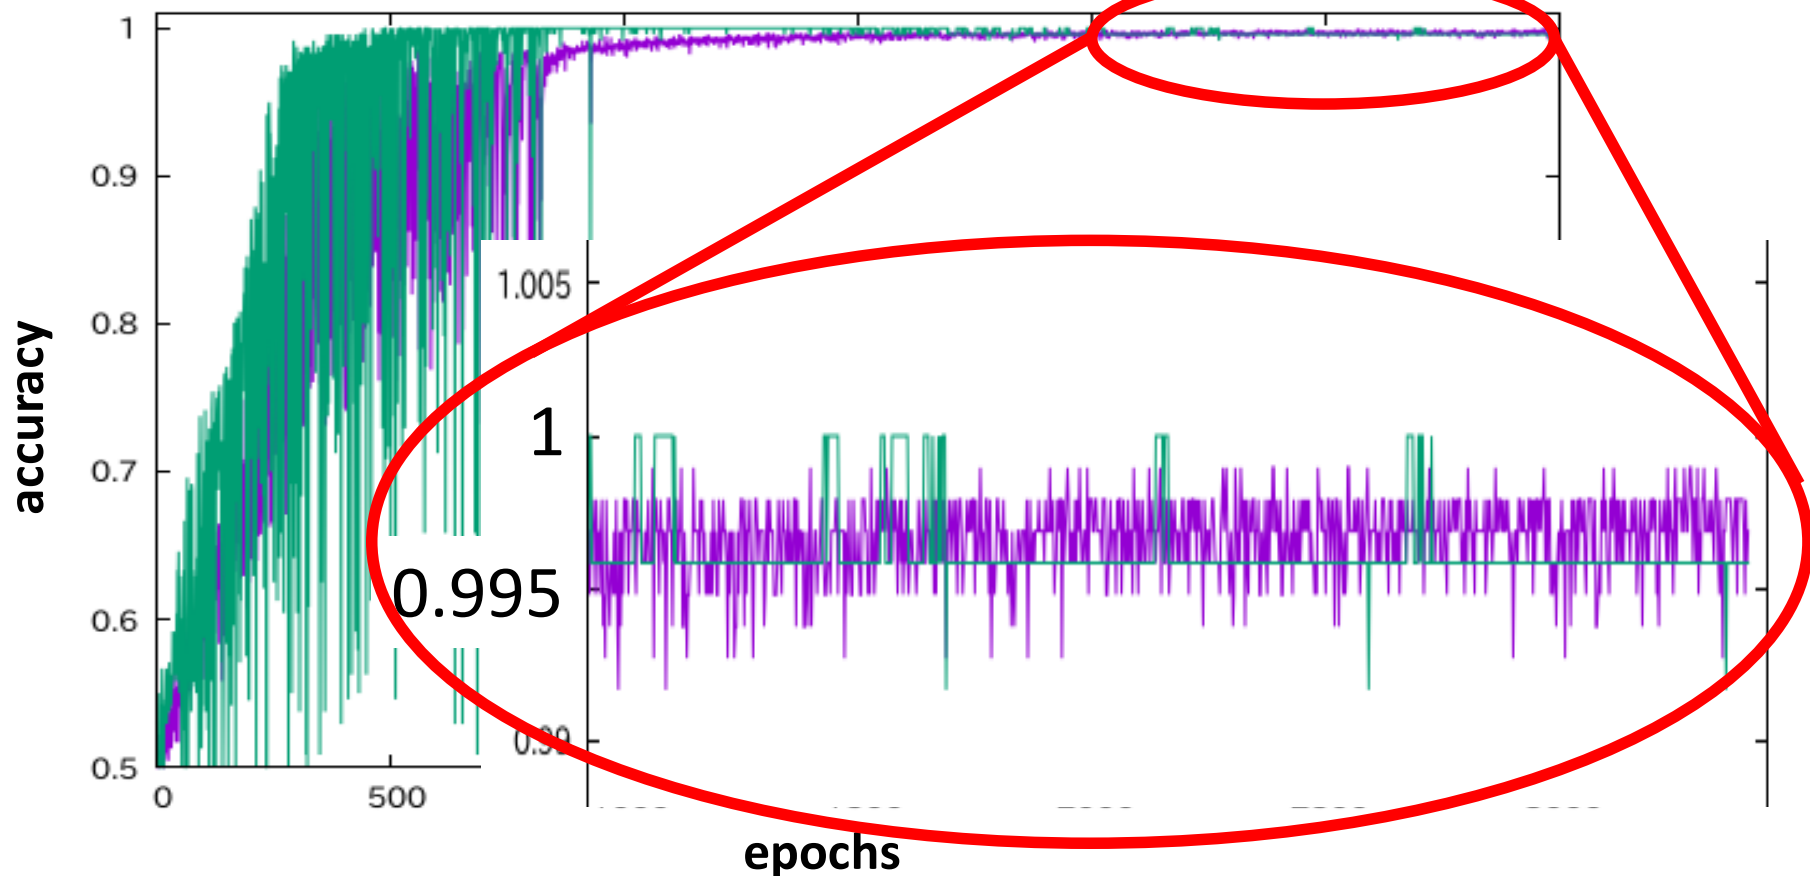
α 凝縮状態の探索に必要な1~3 MeV のデータの学習記録



激しく振動しながら学習していく

E) Neural network による学習

α 凝縮状態の探索に必要な1~3 MeV のデータの学習記録



1~3 MeV で99.8% 程度の高水準で判定！！


なぜ学習がうまくいったか？

Neural network が判別できるのならば、
人間が見ても見える違いがどこかに現れるのでは？

なぜ学習がうまくいったか？

Neural network が判別できるのならば、
人間が見ても見える違いがどこかに現れるのでは？

波形の高さを規格化して、立ち上がり時間をそろえてみると、



III. まとめ

現段階での成果

- **1 ~ 3 MeV** という低エネルギーで、protonか α 粒子であるかを **識別率99.8%** という高精度で判定するCNNを育成できた
- 1 ~ 3 MeV において、protonと α 粒子の波形の違いが表れる部分を少なくとも一部特定した

III. まとめ

現段階での成果

- **1 ~ 3 MeV** という低エネルギーで、protonか α 粒子であるかを **識別率99.8%** という高精度で判定するCNNを育成できた
- 1 ~ 3 MeV において、protonと α 粒子の波形の違いが表れる部分を少なくとも一部特定した

今後の解析

- deuteron や triton, ^3He を加えた場合にそれぞれの粒子を判定できるかを決定する
- 学習に用いない粒子を同定できるかを試してみる
ex) α , proton のみのデータで訓練して、deuteron を判定させる

4. 実験②ホスウィッチ検出器


I. 実験装置ーホスウィッチ検出器

II. 解析

III. まとめ


I. 実験装置ーホスウィッチ検出器

● ホスウィッチ型検出器



散乱角とエネルギーの相関

5mm角のGAGGで散乱粒子が止まるようなエネルギーとなる角度を計算により見つける。
断面積が大きく、かつ全ての粒子が検出できるエネルギー範囲となる角度を選ぶと、30°に。



5mm立方のGAGGシンチレータ
($Gd_3Ga_2Al_2O_{12}$ 1%Ce添加)

+

厚さ100 μm の1.5Yシンチレータ
($(Gd_{0.5}Y_{0.5})_3Ga_2Al_2O_{12}$ 1%Ce添加)

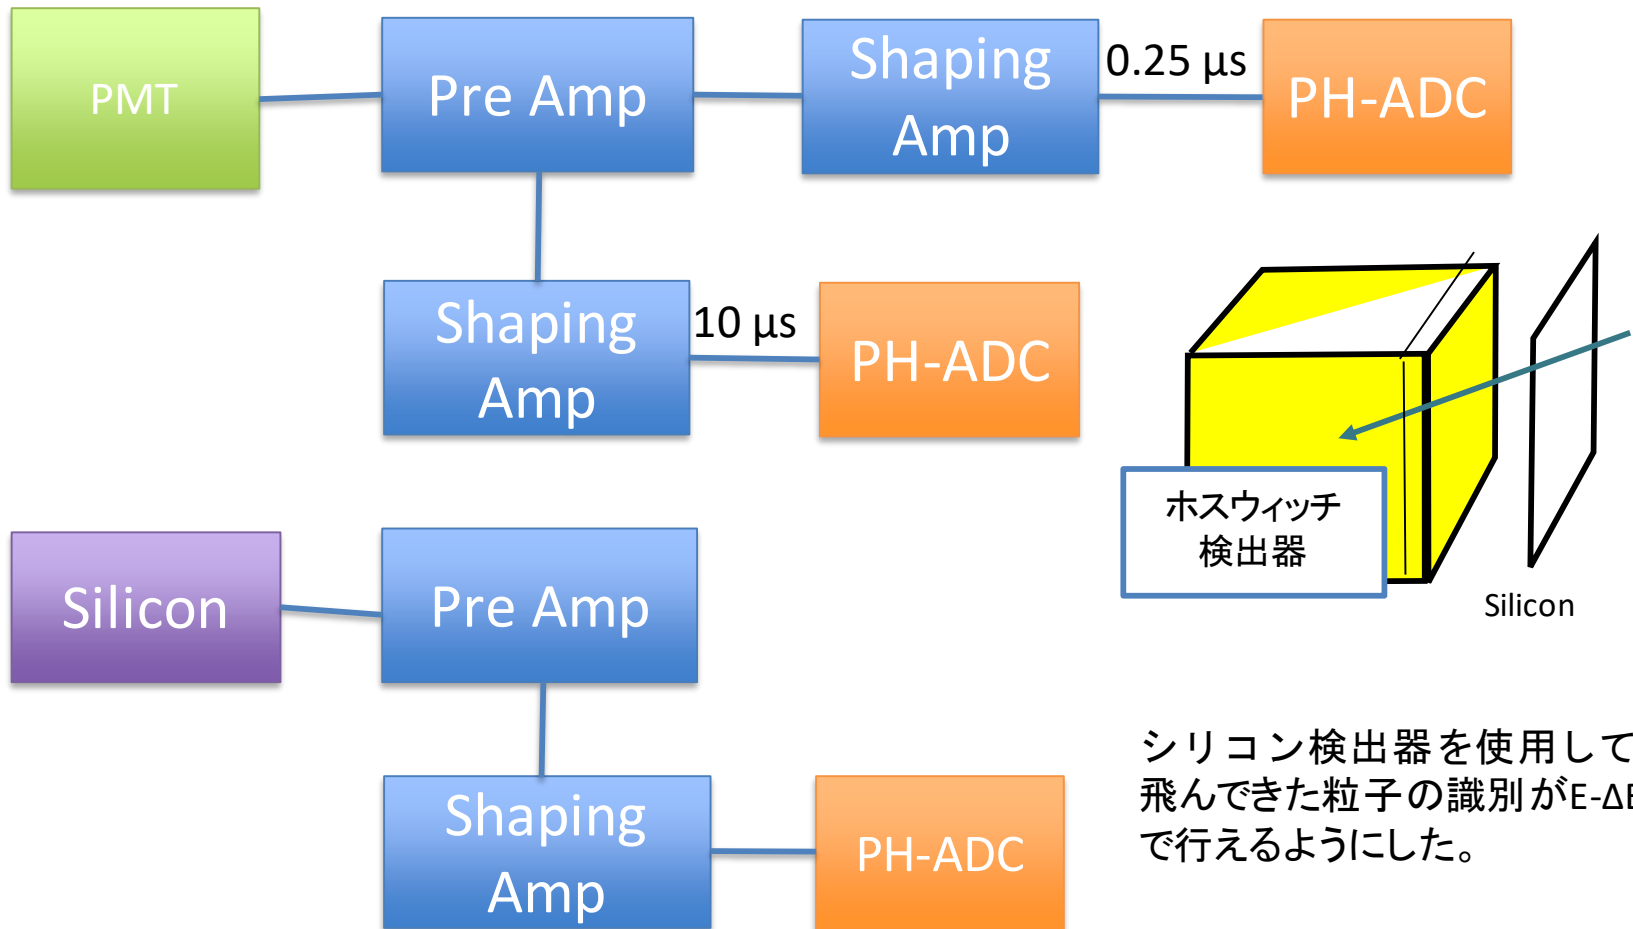


光電子増倍管
(PMT)

時定数

	実測	カタログ
GAGG	140 \pm 10 ns	140 \pm 10 ns
Y1.5	80 \pm 10 ns	61 \pm 10 ns

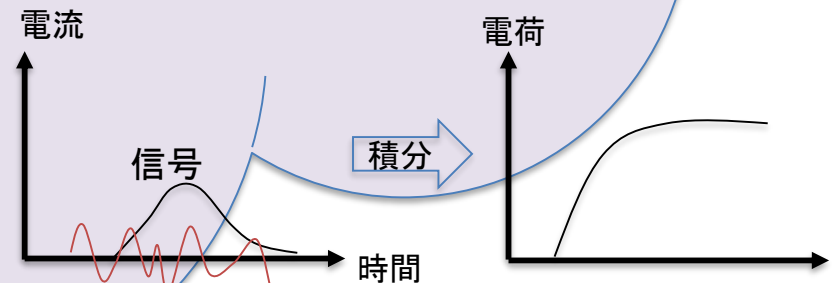
I. 実験装置－回路(ホスウィッチVer.)



シリコン検出器を使用して、飛んできた粒子の識別がE- Δ E法で行えるようにした。

苦労話

- 結晶のどの面にY1.5シンチレータが貼り付けてあるのかがわからず、その確認に手間取った。
- ノイズ取りにはかなりの時間を要した。
- 結晶が光らなかった→アニールによる改良をお願い→実験間に合わないかも！手元にあった結晶とプラスチックで自分たちでLaGPSを作る→ギリギリに改良された検出器の到着
- 時間あたりの発光量が少なく、QDCでの計測に失敗。→プリアンプを組みこむ
- とにかく長時間、夜通しの実験で体力・精神力の限界を感じた



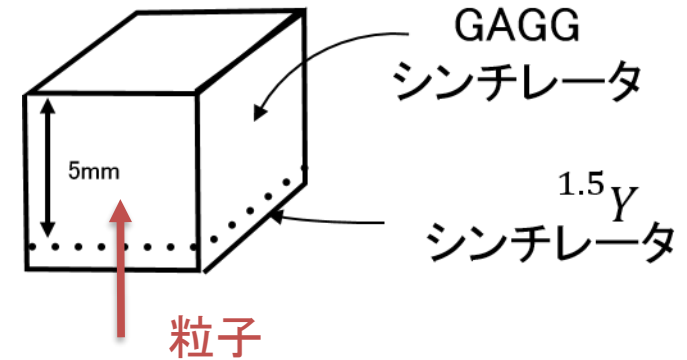

II. 解析

A) 周波数成分の違いで粒子識別

B) 波形解析で粒子識別

A) 周波数数の違いで粒子識別

- Phoswich型シンチレータの検出器は二重構造になっており, それぞれの結晶はシンチレーション光の発光時間が異なる.



粒子ごとでも違いが出る

整形アンプ(微積分回路)

異なる周波数成分のデータ

異なる周波数成分の比をとると粒子ごとに固有の傾向が得られる

0.25 μ s (4 MHz), 10 μ s (0.1 MHz)
成分をとった

粒子識別することができる

A) 周波数の違いで粒子識別(答えを知る)

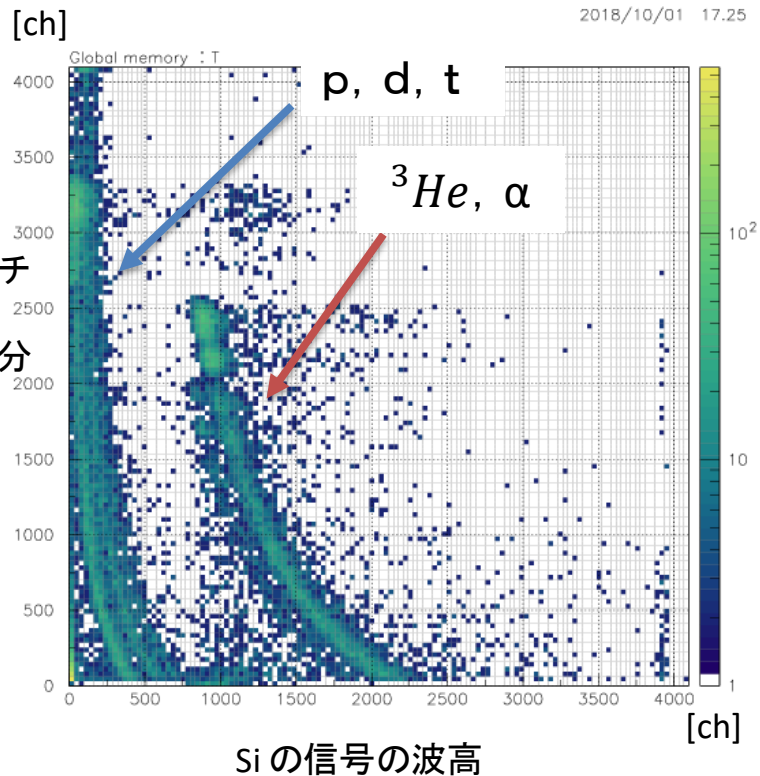
Si 検出器からの信号の波高を ΔE , GAGG結晶からの信号の波高を E とすれば $E-\Delta E$ 図より結晶に入射した粒子が何であったかの答えを知ることができる

※やりたいのはホスウィッチのみで粒子識別すること

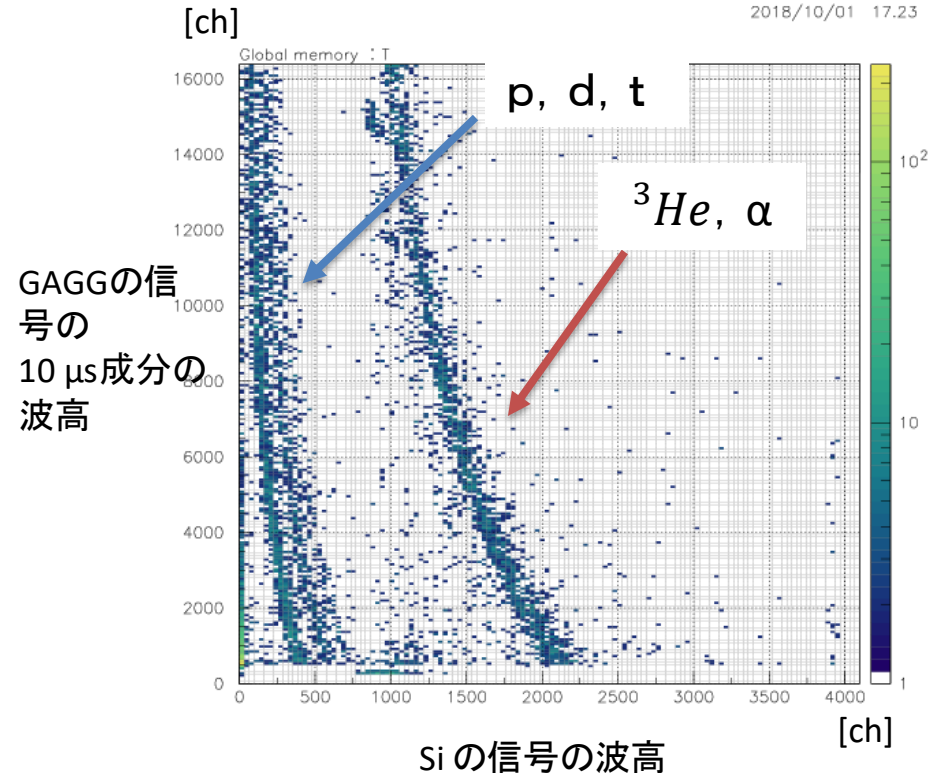


陽子と α 粒子のデータに分別する

ホスウィッチ 0.25 μs と Si による E- ΔE




ホスウィッチ 10 μs と Si による E- ΔE



A) 周波数の違いで粒子識別

縦軸を $R = (\text{時定数}10\mu\text{s成分の波高} / \text{時定数}0.25\mu\text{s成分の波高})$ としてプロット

2018/10/01 18.01



このままでは粒子の識別
ができていない

なぜ？

このR図で陽子と α 粒子
がどのように分布してい
るのかがわからない

陽子と α 粒子で別々に
R図を作る


この図をR図と呼ぶことにする

A) 周波数の違いで粒子識別

例として、 α 粒子のデータを取り出す

E- Δ E


2018/10/01 17.25



Siの信号の波高

α 粒子のR図

2018/10/09 18.49



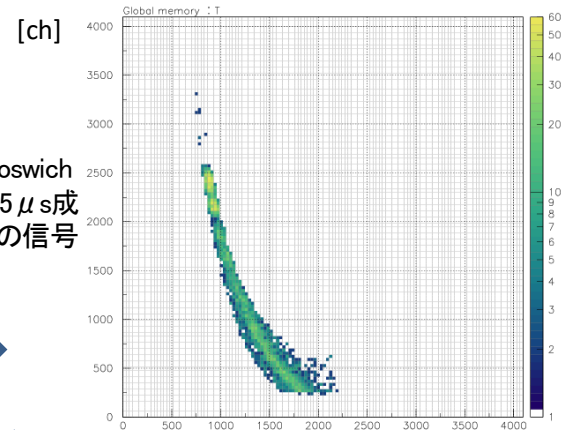
Phoswich0.25 μ s成分の信号

α 粒子の部分を取り出す



Phoswich
0.25 μ s成分の信号

2018/10/01 17.41



Siの信号の波高

[ch]

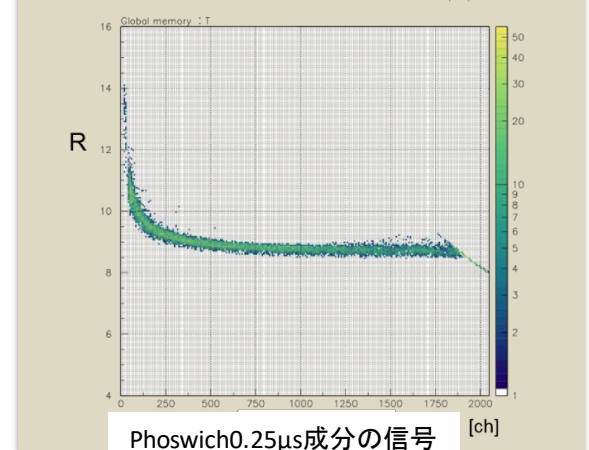
R図にする

α 粒子がR図でどう分布しているのかが分かる



縦軸をR=(時定数10 μ s/時定数0.25 μ s)としてプロット


2018/10/01 18.01



A) 周波数の違いで粒子識別


α粒子のR図

2018/10/09 18.49




縦軸に射影するとそれぞれの粒子がピークとして表れるような図にしたい

イメージ図



識別しやすくするために、ある関数fで fit し、R (= 時定数10μs/時定数0.25μs) と f との差(R-f と表記) を縦軸にする

R-f



GAGG0.25ns

[ch]

陽子についても同じ要領でR図を作り、α粒子で用いた関数fとの差 R-f の図を作る

Fに対して、粒子によって R-f に何らかの 違い が 出れば、粒子を識別することができる


A) 周波数の違いで粒子識別

2018/10/01 14:52

陽子のデータ, α 粒子の R-f データが得られたので, 粒子の違いがよく分かるように1次元に射影してカウントする.

陽子, α 粒子をそれぞれGaussian でfit

count



別々に描くと分かれるが, 1σ ほどしか分けない

取り出す周波数の違いで粒子識別するには
分解能が悪かった

B) 波形解析による識別

- 周波数による解析では識別できなかった




- Silicon班と同様の波形解析では？


B) 波形解析 ① E- ΔE 法で粒子を識別

Flash ADCのデータから
最大波高を取得

プリアンプ(ホスウィッチ型検出器)の出力




Silicon検出器の出力





全イベントを二次元にプロット

E- ΔE (Si vs GAGG結晶)



B) 波形解析 ② Proton と α の波形の差で識別


protonと α の波形



わかりにくいので、

1. protonの最頻値を四次関数でfit



protonの波形(z軸射影) 2018/10/07 10.22



2. α と p の分布がどのくらい fitting 関数からずれているか調べる


B) 波形解析 ②Protonと α の波形の差で識別

protonと α の波形



P: 広く分布
 α : 狭く分布

3. (各時間tの波高) - $f(t)$
を横軸にして一次元にプロット




頂点はずれているが
分離しているとは言えない

B) 波形解析 ③Neural network を用いた識別

Silicon 班と同様のnetworkを用いて波形解析
protonと α の識別を試みた

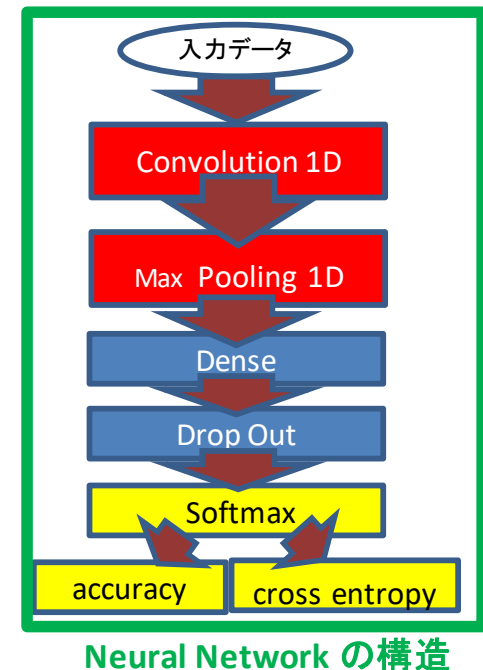
学習させた訓練データの正答率



⇒学習率の向上は見られない
neural network の育成が十分ではない

訓練データ

Proton, α : 500イベントずつ




III. 結論

時定数による識別


およそ 1σ の分離

⇒ 粒子識別するには
分解能が悪い



波形解析による識別

Proton と α の波形の間には差があるとは言えない



III. 考察と課題

時定数による識別

時定数

予定 : GAGG ~140 ns Y1.5 ~61 ns

実際 : GAGG ~140 ns Y1.5 ~80 ns



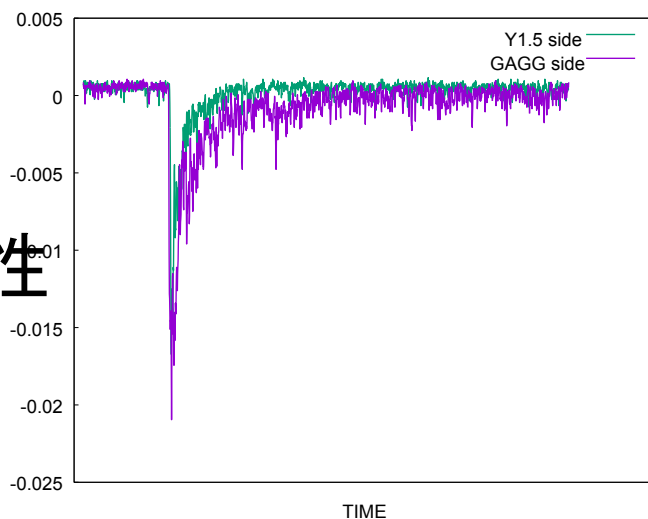
時定数の差が

小さかった可能性

今後

シミュレーション等

でも分析



波形解析による識別

実験途中で回路を
変更


⇒プリアンプを通す



波形の差が、
より小さくなった
可能性。

Neural network の向上

III. まとめ



ホスウィッチ Silicon


目的: 粒子識別のためのE- Δ E法の適用範囲を広げたい
⇒ 新たな技術であるホスウィッチ検出器の性能評価を行う

結果: 今回の検出器では粒子識別に十分な分解能が得られなかった

今後: ・今回のデータを基にどのような結晶であれば分解能が良くなるか調べる

例) 時定数、発光量、組成の違いによるエネルギーロスの差など

・Y1.5の平坦度、一様性を調べる必要性



今回結晶を作っていたいただいた、東北大学金属材料研究所の黒澤俊介さん、山路晃弘さん、FADCを貸してくださった理化学研究所の松崎禎市郎さん、東京大学理学部の新倉潤さんに御礼申し上げます。

ご清聴ありがとうございました！

