

機械学習を用いた迅速な不確かさ付きガンマ線分析

高橋, 龍平
九州大学大学院総合理工学府先端エネルギー理工学専攻

<https://hdl.handle.net/2324/4795189>

出版情報 : Kyushu University, 2021, 修士, 修士
バージョン :
権利関係 :



令和3年度
九州大学大学院 総合理工学府
先端エネルギー理工学専攻

修士論文

論文名

機械学習を用いた迅速な不確かさ付きガンマ線分析

氏名

高橋 龍平

指導教員名

金 政浩

目次

第1章	序論.....	1
1.1	研究背景	1
1.2	機械学習	7
1.3	先行研究	13
1.4	研究目的	13
第2章	データ作成	15
2.1	放射性核種.....	15
2.2	シミュレーション	16
2.2.1	ゲルマニウム検出器のシミュレーション	16
2.2.2	NaI(Tl)シンチレーション検出器のシミュレーション	18
2.3	データ条件.....	23
2.3.1	ゲルマニウム検出器のデータ条件	23
2.3.2	NaI(Tl)検出器のデータ条件.....	29
第3章	解析手法	34
3.1	従来法によるスペクトル解析.....	34
3.1.1	コベル法による放射能導出.....	34
3.1.2	逆マトリックス法	36
3.2	機械学習によるスペクトル解析	38
3.3	従来法との比較方法	43
第4章	結果及び考察	44
4.1	ゲルマニウム検出器のシミュレーショ	44
4.1.1	コベル法.....	44
4.1.2	機械学習.....	45
4.1.3	機械学習とコベル法の比較.....	52
4.2	NaI(Tl)シンチレーション検出器のシミュレーション	55
4.2.1	逆マトリックス法	55
4.2.2	機械学習.....	56
4.2.3	機械学習と逆マトリックス法の比較.....	60
4.3	実測スペクトルの解析	63
4.3.1	用いた実測スペクトル.....	63
4.3.2	機械学習及び逆マトリックス法の適用.....	65
第5章	まとめと今後の展望.....	69
5.1	まとめ	69
5.2	今後の展望.....	69

参考文献..... 70

謝辭..... 73

第1章 序論

本研究では機械学習を用いて、放射性物質が出す放射線のスペクトルデータからその放射能を推定する手法の開発を行った。これにより、計測に必要な時間の短縮を目指す。また、機械学習モデルでは統計的不確かさのような決定論的な値は出力されないため、不確かさについても推定できるモデルの開発を目標とした。本章では、放射線計測の概要と、本研究で用いた解析手法である機械学習について説明したのち、研究目的について述べる。

1.1 研究背景

東日本大震災が2011年3月11日に発生し、それに起因して福島第一原子力発電所で事故が起こった。その後、大量の放射性物質(Cs-134,137 や I-130 など)が大気中へと放出された。放射性物質は風雨などの気象条件により拡散し、土壌や海、建築物などが汚染された。人体が放射線を大量に浴びると健康に悪影響が生じる。そのため、公衆の被ばく線量に関する研究が盛んに行われている⁽¹⁻³⁾。被ばくには内部被ばくと外部被ばくの二種類がある。外部被ばくは人体の外部にある放射性物質からの被ばくであり、皮膚を貫通するベータ線や、臓器にまで達するガンマ線を放出する核種が重要となる。一方、内部被ばくは人体の内部に取り込まれた放射性物質からの被ばくであり、臓器などが直接被ばくするため、透過力の高いガンマ線、ベータ線放出核だけでなく、透過力の低いアルファ線放出核も考慮する必要がある。本研究では広範囲に影響を及ぼし、外部被ばくと内部被ばくの両方で問題となるガンマ線に着目する。

放射線計測

ガンマ線は物質中で主に次のような相互作用をおこす。

- ・光電効果 光子と軌道電子の相互作用のひとつ。光子はすべてのエネルギーを失い、消滅する。光子と相互作用を起こした軌道電子は、光子がもともと持っていた運動エネルギーから軌道電子の結合エネルギー分だけ小さいエネルギーを受け取る。この電子を光電子と呼ぶ。光電子の初期運動エネルギーを式[1-1]に示す。

$$T_e = h\nu - I \quad [1-1]$$

ただし、 T_e は光電子の初期運動エネルギー、 $h\nu$ は光子のエネルギー

ギー、 I は軌道電子の結合エネルギーである。

- ・コンプトン散乱 光子と電子の弾性散乱による相互作用のこと。散乱後、光子の波長は長くなり、エネルギーが減少する。その減少量に応じたエネルギーを電子が受け取る。光子がその進行方向と真逆の方向に散乱されるとき、軌道電子に与えるエネルギーは最大となる。コンプトン効果によりエネルギーを受け取った電子をコンプトン電子と呼ぶ。コンプトン散乱の原理を Fig. 1-1 に示す。




Fig. 1-1 コンプトン散乱現象の概要図

この時以下の式が成り立つ。

$$h\nu' = \frac{h\nu}{1 + \frac{h\nu}{m_0c^2}(1 - \cos\theta)} \quad [1-2]$$

ただし、 $h\nu$ は散乱前の光子エネルギー、 $h\nu'$ 散乱後の光子エネルギー、 m_0c^2 は電子の静止質量エネルギー(0.511 MeV)である。

- ・電子対生成 光子とクーロン場の相互作用によって起こる現象のこと。光子が、核の作るクーロン場中で消滅し、陽電子と電子が対になって生成される。電子陽電子対を生成するには $2m_0c^2$ 以上のエネルギーが必要なので、1.02 MeV を超える光子が必要になる。入射光子がこの値を超えると、超過エネルギーは運動エネルギーの形で電子と陽電子に付与される。

$$E_{e^-} + E_{e^+} = h\nu - 2m_0c^2 \quad [1-3]$$

ただし、 E_{e^-} は電子の運動エネルギー、 E_{e^+} は陽電子の運動エネルギー、 m_0c^2 は電子の静止質量エネルギー(0.511 MeV)である。また、陽電子のエネルギーが物質の通常の電子の熱エネルギー程度まで小さくなると、陽電子は物質中の電子と結合し消滅する。この消滅点でエネルギーが m_0c^2 の 2 個の消滅ガンマ

線光子に置換され、正反対の方向に放出される。

ガンマ線検出器はこのような相互作用を利用してガンマ線を測定する。なお、相互作用を起こす物質のことを検出素子と呼ぶ。

次に、ガンマ線検出器の応答について説明する。本論文では次の応答関数の定義を用いた。

応答関数：単一エネルギー線源に対して、検出器から得られたパルス波高分布を、そのエネルギーの放射線に対する検出器の応答関数という。

エネルギー $h\nu$ のガンマ線が入射した際の応答関数の例を Fig. 1-2 に示す。ただし、エネルギー分解能は考慮しない。




Fig. 1-2 エネルギー $h\nu$ のガンマ線が検出器に入射した際の応答関数の例

光電子に対応した狭いピークを光電ピークと呼ぶ。コンプトン電子に対応した部分はコンプトン連続部と呼び、式[1-2]において $\theta = \pi$ の場所をコンプトン端と呼ぶ。コンプトン端よりエネルギーの高い成分は多重コンプトン事象と呼ばれる。これは、検出器内で複数回コンプトン散乱を起こすとき、複数のコンプトン電子がエネルギーを与えることで、単一の散乱の場合より大きなエネルギーを付与する現象のことである。入射ガンマ線エネルギーが十分高い場合には電子対生成の結果もスペクトルに現れる。電子対生成では、生成された電子と陽電子の運動エネルギーが検出器に付与される。その後生成された2個の消滅放射線のうち一つが検出器外へ逃げる現象をシングルエスケープ、2個とも逃散する現象をダブルエスケープと呼ぶ。実際には、検出器のエネルギー分解能によりスペクトルは全体的になだらかになってしまう。

一般的に、検出素子には半導体やシンチレータなどが使われる。半導体としては高純度ゲルマニウム(HPGe)、シンチレータとしてはNaI(Tl)結晶がよく用いられる。それぞれの検出器の特徴を次にまとめる。

ゲルマニウム検出器

ゲルマニウム検出器とは、ゲルマニウムの単結晶を検出素子として用いる半導体検出器のことである。ゲルマニウム結晶はバンドギャップが約 0.67 eV と小さい。また、常温では暗電流が大きすぎるため、冷却して使用する必要があり、液体窒素 (-196°C) などを用いて冷却して使用されるのが一般的である。一方、ほかの検出器と比べて、放射線との相互作用により得られる電子正孔対(キャリア数)は多い。そのため、半導体検出器は、他の検出器に比べて分解能が優れている。また、一般的に、半導体検出器の価格は他の検出器に比べて高い。

ゲルマニウム検出器を用いて Cs-137 から放出されるガンマ線を実測したスペクトルの例を Fig. 1-3 に示す。光電ピークやコンプトン連続部、多重コンプトン散乱などが確認できる。一方、Cs-137 から放出されるガンマ線は 662 keV のエネルギーを持っているため、シングルスエスケープピークやダブルエスケープピークは見られない。また、実測においては壁などの検出器以外の物質とコンプトン散乱した後、検出器に入射するガンマ線も存在する。このガンマ線が図中の後方散乱ピークを作る。




Fig. 1-3 Ge 検出器による Cs-137 のスペクトル例

ゲルマニウム検出器で得られたスペクトルの解析法として、光電ピークのみを用いるコベル法⁽⁴⁾が主に用いられている。光電ピークの検出効率(ピーク検出効率)は Fig. 1-4 に示すようにガンマ線のエネルギーが高くなると、急激に減少する。そのため、コベル法では、計測するガンマ線が高エネルギーになるほど、放射能を精度よく決定するのに時間がかかる。一方、スペクトル全体の検出効率(全検出効率)はピーク検出効率に比べ、ガンマ線のエネルギーが高くなってもあまり減少しない。




Fig. 1-4 ゲルマニウム検出器のピーク検出効率及び全検出効率⁽⁵⁾

NaI(Tl)シンチレーション検出器

検出素子が微量のタリウム (Tl) を含むヨウ化ナトリウム (NaI) の結晶である放射線検出器を NaI(Tl)シンチレーション検出器と呼ぶ。この結晶にガンマ線が入射するとガンマ線の相互作用により、シンチレーション光と呼ばれる光子を放出する。その発光量と付与エネルギー（結晶がガンマ線との相互作用により吸収するエネルギー）には比例関係がある。そのため、シンチレーション光を測定することで、結晶への付与エネルギーを測定することができる。なお、一つのシンチレーション光を生成するのに必要なガンマ線のエネルギーは約 25 eV である。

ヨウ化ナトリウムには潮解性があるため大気中で使用できず、密閉容器内に封入する必要がある。一方、常温でも使用できるため、取り扱いが容易である。また、一般的に全検出効率が同等のゲルマニウム検出器と比べて安価である。

NaI(Tl)シンチレーション検出器の最も顕著な特性はすべての無機シンチレータの中で最高の光吸収率を示すことである。そのため、検出効率は半導体検出器と比べて大きいものになっている。一方、分解能は半導体検出器に比べて悪い。これはシンチレーション光（キャリア）を測定する際に生じる統計的な広がりによるとこ

ろが大きい。

次に NaI(Tl)シンチレーション検出器を用いて Cs-137 を測定した例を Fig. 1-5 に示す。ゲルマニウム検出器の場合と同様に、光電ピークやコンプトン連続部、多重コンプトン散乱、後方散乱ピークなどが確認できる。また、ゲルマニウム検出器に比べてピークがなまっており、分解能が悪いことも確認できる。




Fig. 1-5 NaI(Tl)シンチレーション検出器による Cs-137 のスペクトル例

Fig. 1-6 にヨウ化ナトリウムの質量減弱係数を示す。質量減弱係数とは物質中を通過する光子が単位質量、単位長さあたりに相互作用する確率を表したものである。ゲルマニウム検出器と同様に、主要なガンマ線のエネルギー範囲である 300 keV～2000 keV においては、光子のエネルギーが大きくなるにつれて全減衰に比べ、光電効果が生じる確率が急激に減少しているのが確認できる。




Fig. 1-6 ヨウ化ナトリウムにおける質量減弱係数⁽⁶⁾

NaI(Tl)検出器で得られるスペクトルの解析においてもゲルマニウム検出器と同様に、逆マトリックス法⁽⁷⁾と呼ばれる光電ピークのみを用いた解析法が適用できる。一方、スペクトル全体を用いて解析する逐次近似法⁽¹⁷⁾と呼ばれる手法も適用されることがある。この逐次近似法とは測定スペクトルから線源スペクトルを求める手法であるが、検出器の正確な応答関数が必要になるため、一般的ではない。

1.2 機械学習

この節では、本研究で用いた機械学習の概要を説明する。

機械学習

機械学習とは、データから確率統計、線形代数、微分積分学、情報理論、および最適化などの数学を駆使して、ある目的のもと定義された関数 $f(x)$ を獲得するための技術の総称である⁽²⁹⁾。人工知能の研究から派生して生まれ、2000年頃から盛んに研究が行われてきた。そのため、人工知能の研究分野の一つとして位置づけられている。Fig. 1-7に人工知能の概念図を示す。




Fig. 1-7 人工知能の概念図

本論文では機械学習の一種であるニューラルネットワーク（教師あり学習）を用いて解析を行った。以下ニューラルネットワークについて詳細を述べる。

ニューラルネットワーク

ニューラルネットワークとは、動物の脳の神経細胞ニューロンにおける情報伝達のメカニズムを参考に作られた関数 $f(x)$ のモデルである。ニューロンは Fig. 1-8 のような構造をしている。人間の場合、脳の中で 100 億から 1,000 億個のニューロンが回路網を形成している。このニューロンは、樹状突起と呼ばれる場所で他のニューロンから情報を受け取る。受け取った情報（電気信号）はシナプスと呼ばれる場所で増減され、それらを足し合わせた値がある値（閾値）を超えるとスイッチがオン（発火）になり、別のニューロンに新たな電気信号を軸索終末から伝送する仕組みとなっている。




Fig. 1-8 ニューロンの模式図

ニューラルネットワークの歴史は、このようなニューロンの仕組みを、数理モデル

で再現しようと 1943 年に McCulloch と Pitts が考案した形式ニューロン⁽⁸⁾から始まる。形式ニューロンの概要図を Fig. 1-9 に示す。




Fig. 1-9 形式ニューロンの概要図⁽²⁹⁾

形式ニューロンは円と四角で表されるノードと矢印で表現されるエッジから構成される有向グラフで表現できる。形式ニューロンにおいて、入力 $\mathbf{x}_i$ を出力 p_i に変換する処理は以下の手順で行われる。

1. 入力層の各ノードに入力ベクトル $\mathbf{x}_i$ を入れる。また、入力層の最後には1を入れる
2. 各エッジに割り当てられた重み係数 $w_1, w_2, \dots, w_D, b$ とエッジの始点のノードの値 $x_1, x_2, \dots, x_D, 1$ の積和を計算する
3. 求めた積和をステップ関数に通したものを出力 p_i とする。

このように、エッジに w や b が割り当てられた状態で、入力層から出力層へ向けて入力情報を伝搬し、出力を求める処理をフォワードプロパゲーションと呼ぶ。また、ステップ関数は、ニューロンの発火を再現していることがわかる。このように、あるニューロンから次のニューロンへ出力する際に、その入力値を別の数値に変換する関数を活性化関数と呼ぶ。

形式ニューロンの改良

形式ニューロンは入力およびモデルパラメータ(w および b)に対して線形の表現力しかもっていない。これに活性化関数をもつ中間層を追加して非線形な表現力を持つよう拡張する。また、活性化関数を変更することで、出力を離散値だけでなく、実測値もとれるように拡張する。このように形式ニューロンを改良したモデルをニューラルネットワークと呼ぶ。

形式ニューロンではステップ関数が活性化関数として使われる。一方、ニューラルネットワークでは、シグモイド関数や ReLU⁽⁹⁾などを使う。シグモイド関数を式[1-4]、ReLU を式[1-5]に示す。

$$\sigma(x) = \frac{1}{1 + e^{-\alpha x}} \quad (a > 0) \quad [1-4]$$

$$\begin{aligned} \text{ReLU}(x) &= x \quad (x \geq 0) \\ &= 0 \quad (x < 0) \end{aligned} \quad [1-5]$$

Fig. 1-10 に 3 層のニューラルネットワークのモデルを示す。フォワードプロパゲーションは以下の手順で行われる。

1. 入力層の各ノードに入力ベクトル $\mathbf{x}_i$ を入れる。また、入力層の最後には 1 を入れる
2. 次式を用いて $\mathbf{s}_i = (s_{i1}, s_{i2}, \dots, s_{iD})$ を求める。

$$\mathbf{s}_i = (x_1, x_2, \dots, x_D, 1) \begin{pmatrix} w_{11}^1 & w_{12}^1 & \cdots & w_{1L}^1 \\ w_{21}^1 & w_{22}^1 & \cdots & w_{2L}^1 \\ \vdots & \vdots & \ddots & \vdots \\ w_{D1}^1 & w_{D2}^1 & \cdots & w_{DL}^1 \\ b_1^1 & b_2^1 & \cdots & b_L^1 \end{pmatrix}$$

3. 活性化関数がシグモイド関数の場合 $h_{ij} = \sigma(s_{ij})$ 、ランプ関数の場合、 $h_{ij} = \text{ReLU}(s_{ij})$ とする。ただし、 $j = 1, 2, \dots, L$ である。
4. 各エッジに割り当てられた重み係数 $w_1^2, w_2^2, \dots, w_D^2, b^2$ とエッジの始点のノードの値 $h_{i1}, h_{i2}, \dots, h_{iL}, 1$ の積和を計算する
5. 計算した積和をシグモイド関数やランプ関数などの活性化関数に渡し、出力 $\hat{y}$ を求める。




Fig. 1-10 3 層のニューラルネットワークにおけるフォワードプロパゲーション⁽²⁹⁾

現代のニューラルネットワークではバックプロパゲーション（誤差逆伝播法）⁽¹⁰⁾と呼ばれる手法を用いて w や b を最適化する。バックプロパゲーションの概略図をFig. 1-11に示す。図中の平均二乗誤差は損失値と呼ばれる値である。これはモデルの出力と正解値を用いて算出される値で、出力と正解の離れ具合（損失）を表現する。バックプロパゲーションでは、この損失の勾配情報を出力層から入力層に伝搬し、最急降下法を用いてモデルパラメータを更新する。なお、損失値はモデルの目的に合わせ様々なものが開発されている。




Fig. 1-11 3層のニューラルネットワークにおけるバックプロパゲーション⁽²⁹⁾

このように、ニューラルネットワークでは、入力と出力がペアになったデータセットを用いて、モデルパラメータを最適化することで、データセットの特徴を掴み、識別や予測を行う。モデルパラメータを最適化することを学習といい、学習に使われるデータセットを学習用データと呼ぶ。また、最適化されたパラメータを評価するために用いるデータセットを検証用データと呼ぶ。このデータセットを用いることで、ニューラルネットワークが未知のデータに対してどの程度正しく識別や予測ができるか評価できる。

過学習とドロップアウト

過学習とは、「学習用データの損失値は学習を繰り返す中で小さくなっていく」が、「検証用データの損失値が上昇し続けてしまう」現象のこと。学習を繰り返す中で、学習用データに適しすぎたモデルパラメータになってしまい、未知のデータに関して機械学習がうまく推測できないことが原因で起こる。

ドロップアウト⁽¹¹⁾とは過学習を防ぐため、広く用いられている正則化の一種である。学習の際、ランダムでいくつかのユニットを消すことで、過学習が起こるの

を防いでいる。

畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (convolutional neural network, CNN) は神経細胞の視覚に関するネットワークをヒントに誕生したニューラルネットワークのことで、1958年にHubelとWieselが階層仮説⁽¹²⁾と呼ばれる、視覚野に関する仮説を発表したことからその歴史が始まる。それをもとに、福島がネオコグニトロンと呼ばれる多層ニューラルネットワークを提唱した⁽¹³⁾。そのネオコグニトロンにLeCunらが誤差逆伝播法を適用したLeNet⁽¹⁴⁾と呼ばれるニューラルネットワークが、現在畳み込みニューラルネットワークと呼ばれるモデルとほぼ等しい。

この畳み込みニューラルネットワークは、「畳み込み層」と「プーリング層」と呼ばれる2種類の層とニューラルネットワークで構成されている。

・畳み込み層

畳み込み層とは入力 x に対して重みフィルタ W をスライドさせながら適用させ、入力 x の特徴を抽出する層のことである。また、この操作を畳み込みという。5×5ピクセルの画像データに畳み込みを適用する例をFig. 1-12に示す。

78	38	29	28	28
37	26	62	60	34
20	49	10	53	23
32	35	52	79	26
23	77	81	76	93

入力 x

$\otimes$

0	1	0
1	1	1
0	1	0

フィルタ W

$=$

212	187	237
140	226	225
245	257	286

Fig. 1-12 畳み込みの計算例

・プーリング層

プーリング層とは畳み込み後の特徴マップを縮小する層のことである。また、この操作をプーリングという。最大値のみを取り出し抽出する最大プーリングなどがある。操作の例をFig. 1-13に示す。




Fig. 1-13 マックスプーリングの計算例

1.3 先行研究

ガンマ線検出器で得られるスペクトルには、Fig. 1-3 や Fig. 1-5 に示したように、従来法の解析に用いられる光電ピークだけでなく、コンプトン成分や後方散乱ピークなども含まれる。このことから、ガンマ線スペクトルの分析において、スペクトル全体を用いると、光電ピークのみの場合と比べ、より迅速に行えると考えられる。そこで、本研究室ではスペクトル全体を用いた分析手法として機械学習を提案してきた。その研究内容を簡単にまとめる。

まず、ゲルマニウム検出器を利用して得られる単核種のスペクトルを機械学習で解析し、核種の同定を行う研究を行ってきた⁽¹⁵⁾。ゲルマニウム検出器は分解能が良いため、スペクトル分析における機械学習の有用性を判断できると考え採用した。この研究により、機械学習を用いてガンマ線スペクトルの分析を行えることを確認した。

次にゲルマニウム検出器を利用して得られる複数核種のスペクトルを機械学習にて解析し、その放射能を推定する学習モデルの開発を行った⁽¹⁶⁾。この研究により、機械学習を用いて分析を行うことで、従来法に比べより迅速に放射能を推定できるとわかった。

1.4 研究目的

これまでの先行研究では、高精度測定に広く用いられるゲルマニウム検出器を用いてきた。一方、農作物などの全数検査でよく用いられるのは比較的安価な NaI(Tl) シンチレーション検出器である⁽¹⁷⁾。また、先行研究の機械学習モデルでは、放射能推定値に不確かさを付けることができなかった。そこで、本研究では以下の点を目的とした。

1. NaI(Tl)シンチレーション検出器にも機械学習を用いたガンマ線スペクトル解析手法が適用可能か調査する
2. 損失関数を改良し、不確かさも推定可能な学習モデルを作成する。その性能を光電ピークのみを用いる従来法と比較する

第2章 データ作成

教師あり機械学習では大量のデータセットが必要となる。しかし、ガンマ線スペクトロメトリにおいて、これらを実測から得ることは現実的でない。そこで、実測データを模擬するよう開発されたシミュレーション手法を用いてデータセットを作成した。本章では対象とした放射性物質や使用したシミュレーション、作成したシミュレーションスペクトルの条件について述べる。

2.1 放射性核種

本研究では測定試料に含まれる放射性核種として Cs-137,Cs-134,K-40 を想定した。Cs-137,Cs-134 は事故から 11 年経った現在も残る主要な核種のため選出した。また K-40 は自然界に常に一定量存在する放射性物質であるため妨害核種として選出した。各核種の崩壊図⁽¹⁹⁾を Fig. 2-1～Fig. 2-3 に示す。




Fig. 2-1 Cs-134 の崩壊図⁽¹⁹⁾




Fig. 2-2 Cs-137 の崩壊図⁽¹⁹⁾




Fig. 2-3 K-40 の崩壊図⁽¹⁹⁾

2.2 シミュレーション

この節では、放射線スペクトル作成に使用したシミュレーションの詳細について述べる。

2.2.1 ゲルマニウム検出器のシミュレーション

ゲルマニウム検出器を想定した学習用データや検証用データを作成するための

シミュレーション体系⁽¹⁸⁾は、新潟大の後藤らが以下のようにして決定した。なお、シミュレーションには **Geant4**⁽²⁰⁻²²⁾と呼ばれる、物質中を移動する粒子の物理的相互作用をシミュレーションするツールキットを使用している。

①点線源の実測

Co-60 の標準線源をゲルマニウム検出器 (NaI 相対検出効率 40%) (ORTEC 社製 GEM-40190-P 型) のヘッドの中心軸上に配置した。検出器ヘッドと線源の距離が 10, 20, 30 cm の 3 パターンの条件で測定を行った。Co-60 は Ni-60 へ崩壊する際に 2 つのガンマ線 (1.17 MeV と 1.33 MeV) を放出するため、実測との比較がしやすいと考え選出した。

②点線源シミュレーション

上記の点線源測定を再現するよう、シミュレーションにおける Ge 結晶の表面不感層の厚さと電極の挿入されているホールサイズを調整し、各々 2.8、3.0 mm に決定した。また、散乱体として PC デスクを模擬した $100 \times 100 \times 5 \text{ cm}^3$ の木の板を挿入した。Co-60 の点線源を①と同じ条件で配置し、シミュレーションを行った。実測データと、最終的に決定された体系におけるシミュレーションスペクトルを Fig. 2-4 に示す。




Fig. 2-4 Ge 検出器を用いた、Co-60 線源の実測及びシミュレーションによるスペクトル

光電ピーク、コンプトン端、後方散乱を上手く再現できている。しかし、低エネルギー部においては、シミュレーションデータが実測データを下回る傾向がみられる。この部分はノイズによる影響が大きいため、本研究では 0~100 keV の領域は除去した。

本研究では、決定された体系で粒子輸送を行うことで、機械学習に用いるスペクトルを作成する。

2.2.2 NaI(Tl)シンチレーション検出器のシミュレーション

NaI(Tl)シンチレーション検出器を想定したシミュレーション体系の構築⁽¹⁷⁾は、三菱電機によって実施された。この体系は三菱電機が開発した食品用検出器を想定している。また、このシミュレーションでは、ガンマ線とシンチレータの相互作用だけではなく、構造材によるガンマ線の散乱・減衰、シンチレーション光の発光及び輸送、測定回路系のゆらぎによるパルス波高分布の広がりを考慮し、検出器応答の再現性を高めている。以下開発手法について述べる。

粒子の輸送は EGS5⁽³⁰⁾ (Electron Gamma Shower Version5)を用いて計算された。EGS5 とは、任意の元素、化合物および混合物中で電子・陽電子および光子の輸送をシミュレーションすることができるコードである。シミュレーションには実際の測定で用いられる鉛遮蔽体とアクリル製マリネリ容器を含んでいる。具体的なシミュレーション体系を Fig. 2-5 に示す。マリネリ容器に充填する測定試料は玄米とした。なお、玄米については粒を考慮せず、玄米と同組成の材質がマリネリ容器内に均一に分布するモデルとした。玄米の組成は文部科学省の食品データベース (<http://fooddb.mext.go.jp/>) に記載されている一般的な玄米のものをもとに Table 2-1 通り定義し、密度を 0.9 g/cm³ とした。




Fig. 2-5 NaI(Tl)シンチレーション検出器のシミュレーション体系

Table 2-1 一般的な玄米の組成

元素	質量分率
H	43.101
C	31.802
O	22.208
N	1.700
Na	0.002
K	0.427
Ca	0.017
Mg	0.204
P	0.539

次にシミュレーションにより得られた応答関数と実測スペクトルを比較した結果を Fig. 2-6 に示す。両者は概ね一致していることが確認できる。ゲルマニウム検出器の場合と同様に、低エネルギー領域はノイズによる影響が大きいため、本研究では 0～100 keV の領域は除去した。




Fig. 2-6 NaI(Tl)シンチレーション検出器を用いた、Cs-137 線源の実測及びシミュレーションによるスペクトル⁽³⁵⁾

応答関数から実測スペクトルを模擬する方法

NaI(Tl)シンチレーション検出器で取得されるスペクトルは、上記の手法で作成された応答関数からサンプリングすることで生成した。NaI(Tl)シンチレーション検出器を模擬した EGS5 シミュレーションが手元にないためこの方法を採用したが、直接粒子輸送を行い、スペクトルを模擬する方法と本質的な違いはない。

例として、 A [Bq]の Cs-137 が含まれている試料を t [sec]計測したスペクトルを模擬する方法について説明する。また、概要図を Fig. 2-7 に示す。

- A-1. 計測時間 t [sec]の間に Cs-137 が崩壊する回数は、 tA を平均とするポアソン分布に従う。この分布からサンプルした値を、Cs-137 が崩壊した数とする。
- A-2. Cs-137 が 1 回崩壊した場合、約 85.1%の確率で 662 keV のガンマ線が放出される。そこで、A-1 で求めた崩壊のうち、662 keV のガンマ線を放出した崩壊を、一様乱数を用いて決定する。具体的には、A-1 で決定した崩壊数だけ 0~1 の一様乱数を生成し、その乱数が 0.851 を下回っていた回

数を放出されたガンマ線の数とした。

- A-3. 応答関数を全範囲にわたって積分した値は、全検出効率と等しい。これを用いて、A-2 で求めたガンマ線のうち、検出器と相互作用するガンマ線の数（検出数）を一様乱数から決定する。具体的には、A-2 で決定したガンマ線の数だけ 0~1 の一様乱数を生成し、その乱数が応答関数の積分値を下回っている数を検出器と相互作用するガンマ線の数とした。
- A-4. 応答関数の面積を 1 に規格化し、付与エネルギーに対する確率密度関数として扱う。この確率密度関数から A-3 で決定した検出数だけサンプリングを行い、検出器内に付与するエネルギーを決定する。




Fig. 2-7 応答関数から放射線スペクトルを作成する手法の概略図

上記の方法で応答関数からスペクトルを作成できる。K-40 などの 1 度の崩壊で 1 つのガンマ線のみを放出する核種のスペクトルも同様に模擬できる。一方、Cs-134 のような 1 度の崩壊で複数のガンマ線を放出する核種の場合、次の手順でスペクトルを作成する。例として、 A [Bq] の Cs-134 が含まれている試料を t [sec] 計測したスペクトルを模擬する方法について説明する。

- B-1 Cs-134 の崩壊数を平均 tA のポアソン分布から決定する。
- B-2 各崩壊は Fig. 2-8、Fig. 2-9、Table 2-2 に示すいずれかの過程を経る。各崩壊が、どの過程の崩壊か一様乱数を用いて決定する。
- B-3 各過程で生じるガンマ線が検出器に付与するエネルギーをそれぞれ A-3、A-4 の手法を用いて求める。このエネルギーの合計値を最終的な付与エネルギーとして採用する。




Fig. 2-8 Cs-134 の崩壊過程(1365keV→604 keV, 801 keV →1167 keV, 795 keV →604 keV, 1038 keV →604 keV, 475 keV →1167 keV)




Fig. 2-9 Cs-134 の崩壊過程(475 keV →563 keV →604 keV, 569 keV →795 keV →604 keV, 801 keV →563 keV →604 keV)

Table 2-2 Cs-134 の各崩壊過程が生じる割合と放出されるガンマ線エネルギー

No.	放出されるガンマ線のエネルギー (keV)	過程が生じる割合 [%]
1	1365, 604	3.03
2	801, 1167	1.53
3	795, 604	70.23
4	1038, 604	1.00
5	475, 1167	0.26
6	475, 563, 604	1.23
7	569, 795, 604	15.48
8	801, 563, 604	7.19

なお、この方法では一つの原子核から同時に放出されるガンマ線がともに検出されることによって生じる、カスケードイベントは再現できる。一方、高放射能の時に問題になる、別々の原子核から放出されたガンマ線が偶然同時に検出されるアクシデンタルイベントは再現できない。ただし、今回の体系は環境回復を目的として、低放射能の試料を測定することを想定しているため、アクシデンタルイベントは考慮しなくてよい。

2.3 データ条件

この節では、2.2 節で決定したシミュレーション体系を用いて、実測データを模擬した放射線スペクトルを作成する際のデータ条件（放射能や計測時間など）について述べる。また、作成した放射線スペクトルの特徴についても述べる。

2.3.1 ゲルマニウム検出器のデータ条件

本研究で用いるゲルマニウム検出器の放射線スペクトルの作成は、Fig. 2-10 に示すような体系で行った。ゲルマニウム検出器は 2.2.1 項で定義したものを使用し、放射性物質は U8 容器(直径 55 mm、高さ 65 mm の円柱容器)に点線源を均等に入れた。ゲルマニウム検出器と U8 容器は 1 cm 離して置く。




Fig. 2-10 ゲルマニウム検出器のシミュレーション体系

このようなシミュレーション体系で 100 keV から 2,000 keV の範囲の 20 通りの単一エネルギーガンマ線のスペクトルを作成し、各々におけるピーク検出効率、全検出効率を求めた。そして、そのデータを次のような経験式でフィッティングした。

$$\varepsilon(E_\gamma) = N \times \exp[(A + BX + CX^2)^{-G} + (D + EY + FY^2)^{-G}]^{\frac{1}{G}} \quad [2-1]$$

$$X = \ln\left(\frac{E_\gamma}{100}\right), \quad Y = \ln\left(\frac{E_\gamma}{1000}\right)$$

ただし、 $\varepsilon(E_\gamma)$ は検出効率、 E_γ はガンマ線エネルギーであり、A、B、C、D、E、F、G、Nはフィッティングパラメータである。導出した全検出効率とピーク検出効率のパラメータを Table 2-3 に、2つの検出効率曲線を Fig. 2-11 に示す。ただし、C=0 の条件のもとフィッティングを行った。

Table 2-3 Ge 検出器における、決定した式[2-1]のフィッティングパラメータ

	全検出効率	ピーク検出効率
A	2.55×10^{-7}	1.6514
B	2.0587	2.9139
C	0	0
D	0.40189	0.4988
E	-0.1749	-0.7602
F	-0.04212	0.0584
G	1.4925	2.3326
N	0.0246	0.00497




Fig. 2-11 シミュレーションによるゲルマニウム検出器の検出効率曲線

検出効率はゲルマニウム検出器によって異なるため、Fig. 1-4 の結果と検出効率の数値は異なるが、ガンマ線のエネルギーが大きくなるにつれピーク検出効率が全検出効率に比べ急激に減少している特徴は再現できている。

次に、Fig. 2-12 に光電比を示す。光電比とは応答関数における、光電ピークの面積と全面積の比のことである。エネルギーが高くなるにつれて、光電吸収が生じる確率が減少しているのが確認できる。




Fig. 2-12 シミュレーションによるゲルマニウム検出器の光電比

Cs-134、Cs-137 における各ガンマ線の、ガンマ線放出率⁽²³⁾と Table 2-3 の結果をもとに導出した全検出効率、ピーク検出効率をそれぞれ Table 2-4、Table 2-5 に示す。

Table 2-4 Cs-134 から放出される γ 線のエネルギー及び、その放出率、Ge 検出器のピーク検出効率、全検出効率

γ 線エネルギー (keV)	563	569	605	796	802	1365
放出率	0.0836(3)	0.1539(6)	0.9763(6)	0.854(3)	0.0869(3)	0.03016(11)
ピーク検出効率	0.0129	0.0127	0.0121	0.0098	0.0097	0.0065
全検出効率	0.0394	0.0394	0.0391	0.0378	0.0378	0.0346

Table 2-5 Cs-137 から放出される γ 線のエネルギー及び、その放出率、Ge 検出器のピーク検出効率、全検出効率

γ 線エネルギー(keV)	662
放出率	0.851(2)
ピーク検出効率	0.0113
全検出効率	0.0387

食品衛生法により定められている食品中の放射能基準値は 100 Bq/kg である。U8 容器に入れる物質の平均的な重さを 0.2 kg とすると、この放射能基準値は 20 Bq となる。そこで、放射能推定の対象核種である Cs-137 と Cs-134 の放射能を次のような確率密度関数で決定した。低放射能のデータはばらつきが大きく、その特徴を学習するのにより多くのデータが必要と考えたため、確率密度関数に指数関数を採用している。

$$\begin{aligned} f(x) &= 0 & (x < 0) \\ &= \lambda e^{-\lambda x} & (x \geq 0) \end{aligned} \quad [2-2]$$

放射能 x の単位は kBq とし、小数第 4 位を四捨五入した。係数 λ は放射能の基準値である 0.02 kBq における累積分布関数の値が 0.5 となるよう 0.03456 に決定した。

妨害核種の K-40 の放射能は次のような確率密度関数で決定した。

$$\begin{aligned} f(x) &= 0 & (x < 0, 0.4 < x) \\ &= \frac{1}{0.4} & (0 \leq x \leq 0.4) \end{aligned} \quad [2-3]$$

放射性セシウムと同じく、放射能 x は小数第 4 位を四捨五入し、単位は kBq とした。放射能の最大値である 0.4 kBq は、放射能を多く含むことで知られる干し昆布 200 g の放射能と等しい。また、計測時間は 60 秒で固定した。この条件のデータセットを 200,000 個作成した。作成したデータセットの特徴を調べるため、各スペクトルの総カウント数のヒストグラムを Fig. 2-13 に示す。




Fig. 2-13 本研究で用いた放射線スペクトル(Ge 検出器)の総カウント数のヒストグラム

総カウント数が 150 付近のスペクトルが最も多いとわかる。

次に、 x 軸にチャンネル数、 y 軸にカウント数をとったとき、データセットのスペクトルが (x,y) に現れる頻度を表した図を Fig. 2-14 に示す。




Fig. 2-14 ゲルマニウム検出器を想定したシミュレーションスペクトル。x 軸に ch 数、y 軸にカウント数をとったとき、データセットのスペクトルが(x,y)に現れる頻度をプロット。

コンプトン端が明瞭なスペクトルは少なく、またコンプトン成分がスペクトルの大部分を占めていることが分かる。

2.3.2 NaI(Tl)検出器のデータ条件

NaI(Tl)シンチレーション検出器を想定した放射線スペクトルは 2.2.2 項で示したものと同一体系を用いて作成した。このようなシミュレーション体系で 300 keV から 2,800 keV まで 10 keV 刻みの単一エネルギーガンマ線のスペクトルを作成した。そして、各々におけるピーク検出効率、全検出効率を求めた。ゲルマニウム検出器の場合と同様に、その結果を式[2-1]でフィッティングした。フィッティング結果を Table 2-6 に、検出効率曲線を Fig. 2-15 に示す。ただし、 $C=0$ の条件のもとフィッティングを行った。

Table 2-6 NaI(Tl)シンチレーション検出器における、決定した式[2-1]のフィッティングパラメータ

	全検出効率	ピーク検出効率
A	2.163	0.933
B	19.937	0.588
C	0	0
D	0.893	0.876
E	-0.274	-0.781
F	0.03196	-0.0678
G	68.001	15.713
N	0.03667	0.00840




Fig. 2-15 シミュレーションによる NaI(Tl)シンチレーション検出器の検出効率曲線

ゲルマニウム検出器の場合と同様に、ガンマ線のエネルギーが大きくなるにつれピーク検出効率が全検出効率に比べ急激に減少していることがわかる。

次に Fig. 2-16 に光電比を示す。エネルギーが高くなるにつれて、光電吸収が生じる確率が減少しているのが確認できる。




Fig. 2-16 シミュレーションによる NaI(Tl)シンチレーション検出器の光電比

Cs-134、Cs-137 における各ガンマ線の、ガンマ線放出率⁽¹⁹⁾と Table 2-6 の結果をもとに導出した全検出効率、ピーク検出効率をそれぞれ Table 2-7、Table 2-8 に示す。

Table 2-7 Cs-134 から放出される γ 線のエネルギー及び、その放出率、NaI(Tl)シンチレーション検出器のピーク検出効率、全検出効率

γ 線エネルギー (keV)	563	569	605	796	802	1365
放出率	0.0836(3)	0.1539(6)	0.9763(6)	0.854(3)	0.0869(3)	0.03016(11)
ピーク検出効率	0.0309	0.0307	0.0294	0.0240	0.0239	0.0157
全検出効率	0.1059	0.1056	0.1036	0.096	0.095	0.082

Table 2-8 Cs-137 から放出される γ 線のエネルギー及び、その放出率、NaI(Tl)シンチレーション検出器のピーク検出効率、全検出効率

γ 線エネルギー(keV)	662
放出率	0.851(2)
ピーク検出効率	0.0275
全検出効率	0.1001

ゲルマニウム検出器の場合と同じく、計測時間は 60 秒、Cs-134,Cs-137 の放射能は式[2-2]で、K-40 の放射能は式[2-3]で与えた。ただし、2L のマリネリ容器に玄米を詰めるとその重さは 1.8 kg となるため、法律による放射能基準は 180 Bq となる。この放射能を中心とした放射能分布とするため、式[2-2]の $\lambda = 0.00385$ とした。データセットもゲルマニウム検出器と同じく 200,000 個用意した。

作成したデータセットの特徴を調べるため、各スペクトルの総カウント数のヒストグラムを Fig. 2-17 に示す。総カウント数が 3,000 付近のものが最も多いとわかる。




Fig. 2-17 本研究で用いた放射線スペクトル(NaI(Tl)シンチレーション検出器)の総カウント数のヒストグラム

次に、x 軸にチャンネル数、y 軸にカウント数をとったとき、データセットのスペクトルが(x,y)に現れる頻度を表した図を Fig. 2-18 に示す。




Fig. 2-18 NaI(Tl)シンチレーション検出器を想定したシミュレーションスペクトル。x 軸に ch 数、y 軸にカウント数をとったとき、データセットのスペクトルが(x,y)に現れる頻度をプロット。

ゲルマニウム検出器と比較して、光電ピークが広がっているため、分解能が低いことがわかる。また、60 ch~80 ch 付近ではピークが重なっていることが確認できる。

第3章 解析手法

この章では、スペクトル解析における従来の手法と提案手法について述べた後、両手法を比較する方法について説明する。

3.1 従来法によるスペクトル解析

3.1.1 コベル法による放射能導出

・ 光電ピークのカウント数から放射能を導出する方法

光電ピークのための情報を用いて放射能を求める方法について説明する。光電効果による正味のカウント数を N_{net} とする。半減期に対して計測時間 t が十分長い核種の場合、この値を用いて次式より放射能を導出することができる。

$$A = \frac{N_{net}}{t \cdot I_{\gamma} \cdot \varepsilon_{\gamma}} \quad [3-1]$$

ただし、 A は放射能 (Bq)、 I_{γ} はガンマ線放出率、 ε_{γ} はピーク検出効率である。

・ コベル法によるピーク領域の計数方法

光電効果によるイベントが有意に存在する領域をピーク領域と呼ぶ。ピーク領域には光電効果によるカウントだけでなく、他核種によるバックグラウンド成分（コンプトン成分が主成分）も含まれている。コベル法⁽⁴⁾とは、このピーク領域のカウント数からバックグラウンド成分を簡易的に取り除き、 N_{net} を推定する手法のことである。具体的な推定方法について Fig. 3-1 のスペクトル例を用いて説明する。




Fig. 3-1 コベル法適用におけるスペクトル例⁽²⁸⁾

N_P はピーク領域全体のカウント数、 N_L と N_R は N_P に含まれるバックグラウンド成分を見積もるのに利用する領域である。 N_P 、 N_L 、 N_R はそれぞれ次の式で計算できる。

$$N_P = \sum_{i=L_0}^{R_0} n_i \quad [3-2]$$

$$N_L = \sum_{i=L_2}^{L_1} n_i \quad [3-3]$$

$$N_R = \sum_{i=R_1}^{R_2} n_i \quad [3-4]$$

ただし、 n_i は各チャンネルにおけるカウント数である。この時、 N_{net} は次式で計算される。

$$N_{net} = N_P - \beta_L N_L - \beta_R N_R \quad [3-5]$$

この式における β_L 、 β_R は次で定義される値である。

$$\beta_L = \frac{(R_1 + R_2 - L_0 - R_0)(R_0 - L_0 + 1)}{(L_1 - L_2 + 1)(R_1 + R_2 - L_2 - L_1)} \quad [3-6]$$

$$\beta_R = \frac{(L_0 + R_0 - L_1 - L_2)(R_0 - L_0 + 1)}{(R_2 - R_1 + 1)(R_1 + R_2 - L_2 - L_1)} \quad [3-7]$$

・コベル法によって導出される放射能

N_{net} に付随する不確かさは次の式で示される。

$$\delta N_{net} = \sqrt{N_P + \beta_L^2 N_L + \beta_R^2 N_R} \quad [3-8]$$

よってコベル法によって導出した放射能は次のようにあらわされる。

$$A = \frac{N_{net}}{t \cdot I_\gamma \cdot \varepsilon} \pm \frac{\sqrt{N_P + \beta_L^2 N_L + \beta_R^2 N_R}}{t \cdot I_\gamma \cdot \varepsilon} \quad [3-9]$$

3.1.2 逆マトリックス法

試料中に含まれる主な核種が数核種に限定され、かつ核種があらかじめ同定できる場合、逆マトリックス法⁽⁷⁾により含まれる核種それぞれの放射能を定量することができる。この方法は、既知の核種の標準線源を用いて、それぞれの核種の主領域（主要ガンマ線のピーク領域）を定め、その領域に含まれる他核種の寄与を、逆行列を用いて求める方法である。試料に Cs-134, Cs-137, K-40 が含まれている場合のスペクトル例を Fig. 3-2 に示す。




Fig. 3-2 測定試料に Cs-134, Cs-137, K-40 が含まれている場合の NaI(Tl)シンチレーション検出器を用いたスペクトル例

領域*i* (*i* = 1,2,3) のグロス計数値 N_i は次式で表される。

$$N_i = \sum_j N_{Xj} e_{ij} + B_i \frac{t_f}{t_b} \quad [3-10]$$

B_i は領域*i* (*i* = 1,2,3) のバックグラウンド計数値、 N_{Xj} は領域*j* (*j* = 1,2,3) を主領域とする核種 X_j による領域*j* の計数値、 t_f は対象試料の測定時間、 t_b はバックグラウンドの計測時間である。 e_{ij} は核種 X_j の標準線源を用いて、主領域*j* に対する寄与領域*i* の計数率の比として求める。例として e_{23} の求め方を、K-40 の標準線源における Cs-134 と K-40 の主領域を示した Fig. 3-3 を用いて説明する。




Fig. 3-3 K-40 の標準線源における Cs-134 と K-40 の主領域

K-40 の主領域における K-40 のカウント数を b 、Cs-134 の主領域における K-40 のカウント数を a とおくと、 e_{23} は次式で示される。

$$e_{23} = \frac{a}{b} \quad [3-11]$$

ここで[3-10]より、以下の関係が成り立つ。

$$N_{X1} e_{11} + N_{X2} e_{12} + N_{X3} e_{13} = N_1 - B_1 \frac{t_f}{t_b} \quad [3-12]$$

$$N_{X1} e_{21} + N_{X2} e_{22} + N_{X3} e_{23} = N_2 - B_2 \frac{t_f}{t_b} \quad [3-13]$$

$$N_{X1} e_{31} + N_{X2} e_{32} + N_{X3} e_{33} = N_3 - B_3 \frac{t_f}{t_b} \quad [3-14]$$

式の右辺は測定により得られる。行列表現は次のようになる。

$$\begin{bmatrix} e_{11} & e_{12} & e_{13} \\ e_{21} & e_{22} & e_{23} \\ e_{31} & e_{32} & e_{33} \end{bmatrix} \begin{bmatrix} N_{X1} \\ N_{X2} \\ N_{X3} \end{bmatrix} \equiv M \begin{bmatrix} N_{X1} \\ N_{X2} \\ N_{X3} \end{bmatrix} = \begin{bmatrix} N_1 - B_1 \frac{t_f}{t_b} \\ N_2 - B_2 \frac{t_f}{t_b} \\ N_3 - B_3 \frac{t_f}{t_b} \end{bmatrix} \quad [3-15]$$

行列 M について逆行列 M^{-1} を求めると N_{Xj} は次で与えられる。ただし、逆行列 M^{-1} の i 行 j 列の要素を $\bar{e}_{ij}$ とする。

$$N_{Xj} = \bar{e}_{j1} \left(N_1 - B_1 \frac{t_f}{t_b} \right) + \bar{e}_{j2} \left(N_2 - B_2 \frac{t_f}{t_b} \right) + \bar{e}_{j3} \left(N_3 - B_3 \frac{t_f}{t_b} \right) \quad [3-16]$$

$$\sigma_{N_{Xj}} = \sqrt{\bar{e}_{j1}^2 \left(N_1 - B_1 \frac{t_f}{t_b} \right)^2 + \bar{e}_{j2}^2 \left(N_2 - B_2 \frac{t_f}{t_b} \right)^2 + \bar{e}_{j3}^2 \left(N_3 - B_3 \frac{t_f}{t_b} \right)^2} \quad [3-17]$$

核種 X_j の放射能 A_j とその標準偏差 σ_{A_j} は次式で与えられる。

$$A_j = \frac{N_{Xj}}{\varepsilon_{Xj} \cdot t_f} \pm \frac{\sigma_{N_{Xj}}}{\varepsilon_{Xj} \cdot t_f} \quad [3-18]$$

なお、本研究では標準線源は 2.2.2 項で述べた応答関数を用いた。

3.2 機械学習によるスペクトル解析

1.2 節に示したように、中間層に畳み込み層を採用した学習モデルのことを畳み込みニューラルネットワーク(CNN)と呼ぶ。今回は一次元の CNN を使用した学習モデルを開発した。畳み込みではスペクトルのエネルギー依存性を考慮することができる。そのため、ニューラルネットワークの場合と比較して、入力データである放射線スペクトル形状を扱えることができたと考えた。本研究で用いたモデルの概要図及び決定したハイパーパラメータの一例をそれぞれ Fig. 3-4、Table 3-1 に示す。ハイパーパラメータとは、学習モデル選択時に決めなければならないパラメータのことである。なお、ハイパーパラメータの最適化はベイズ最適化⁽³²⁻³⁴⁾と呼ばれる手法を用いて行った。

Table 3-1 決定した学習モデルのハイパーパラメータ

中間層	Table 3-2
学習方法	Adam ⁽²⁴⁾
活性化関数	出力層:linear、それ以外:ReLU ⁽⁹⁾
損失関数	MSE or GaussianNLLLoss ^(25,26,31)
初期値設定方法	Xavier ⁽²⁷⁾
ドロップアウト率	なし
Epoch 数	50
Batch 数	128




Fig. 3-4 開発した畳み込みニューラルネットワークによるモデルの概要図

まず、入力層には検出器で得られるスペクトルのデータを与える。次に畳み込みと Max プーリングを 2 回 Fig. 3-4 に示す順に行う。なお、畳み込み及び Max プーリングに関するハイパーパラメータは Table 3-2 に示す通りである。

Table 3-2 決定した畳み込み及び Max プーリングに関するハイパーパラメータ

	フィルタの長さ	フィルタ数	ストライド	パディング
畳み込み 1 (A1)	8	64	1	ゼロパディング
畳み込み 2 (A2)	4	32	1	ゼロパディング
プーリング 1 (B1)	2	-	1	-
プーリング 2 (B2)	2	-	1	-

※ゼロパディングとは、畳み込みの前後でデータの次元数が同じになるよう 0 を追加すること。

その後データを Fig. 3-4 に示すように一次元化し、ユニット数が 1 の出力層につなげる。出力層では推定したい核種の放射能を出力させる。

損失関数には次の 2 種類を試した。それぞれについて説明する。

A) 平均二乗誤差 (mean square error ; MSE)

式[3-19]に示すのが MSE と呼ばれる損失関数である。

$$E(\mathbf{w}) = \frac{1}{N} \sum_{n=1}^N (\hat{y}(\mathbf{x}_n; \mathbf{w}) - y_n)^2 \quad [3-19]$$

$\mathbf{x}_n$: n 番目の放射線スペクトル

$\mathbf{w}$: 機械学習のモデルパラメータ

$\hat{y}(\mathbf{x}_n; \mathbf{w})$: モデルに n 番目のデータを入力して得られる予測値

y_n : n 番目のデータに対応した正解値

N : 学習に用いたデータ数

この損失関数は最尤法の考え方をを用いて、次のように導出できる。

まず、入力値と独立なノイズ成分 ε_n は以下の式でモデル化される。

$$y_n = \hat{y}(\mathbf{x}_n; \mathbf{w}) + \varepsilon_n \quad [3-20]$$

ここで、 ε_n は次のような平均 0、分散 σ^2 の正規分布に従っていると仮定する。

$$\varepsilon_n \sim \mathcal{N}(\varepsilon_n | 0, \sigma^2) \quad [3-21]$$

よって、正規分布の再生性より、正解値 y_n の確率分布は以下の式で定式化される。

$$\begin{aligned} p_n(y_n | \mathbf{x}_n, \mathbf{w}) &= \mathcal{N}(y_n | \hat{y}(\mathbf{x}_n; \mathbf{w}), \sigma^2) \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[-\frac{(\hat{y}(\mathbf{x}_n; \mathbf{w}) - y_n)^2}{2\sigma^2} \right] \end{aligned} \quad [3-22]$$

この確率分布の対数尤度は以下のように計算できる。

$$\begin{aligned}\sum_{n=1}^N \ln(p_n) &= -\sum_{n=1}^N \frac{(\hat{y}(x_n; \mathbf{w}) - y_n)^2}{2\sigma^2} + \text{const.} \\ &\propto -\sum_{n=1}^N (\hat{y}(x_n; \mathbf{w}) - y_n)^2 + \text{const.}\end{aligned}\quad [3-23]$$

2行目の変形は誤差の分布が独立かつ同一であることを利用した。この対数尤度を最も大きくするには、 $\sum_{n=1}^N (\hat{y}(x_n; \mathbf{w}) - y_n)^2$ を最小化すればよい。この値が MSE の形になっている。

B) GaussianNLLLoss (Gaussian negative log likelihood loss)

式[3-24]に示すのが、GaussianNLLLoss^(25,26,31)と呼ばれる損失関数である。

$$E(\mathbf{w}) = \frac{1}{N} \sum_{n=1}^N \frac{(\hat{y}(x_n; \mathbf{w}) - y_n)^2}{\hat{\sigma}_n^2(x_n; \mathbf{w})} + \ln \hat{\sigma}_n^2(x_n; \mathbf{w}) \quad [3-24]$$

$\hat{\sigma}_n(x_n; \mathbf{w})$: モデルに n 番目のデータを入力して得られる新たな予測値

MSE で用いたノイズ ε_n は、 n によらず同一の分布であることが仮定されていた。しかし、放射線スペクトルの場合、ゆらぎ成分は統計的な不確かさであり、ノイズ ε_n は係数やバックグラウンド成分に応じた Fig. 3-5 に示すような値となる。




Fig. 3-5 放射線スペクトル解析時に考慮すべき統計誤差

左のスペクトルは、放射能推定対象の核種 A のみ含まれているスペクトルである。このスペクトルのカウント数を C_A とおく。この時、 C_A の誤差は $\sqrt{C_A}$ となる。推定したい値である放射能は C_A に比例するため、ノイズ ε_n は n によって形状が変化す

ることがわかる。右のスペクトルのように、妨害核種として核種 B が存在している場合も同様に、 C_A の誤差は $\sqrt{C_A + C_B}$ となるため、ノイズ ε_n は n によって形状が変化する。

そのため、ノイズ ε_n の分布を、次のように変更した。

$$\varepsilon_n \sim \mathcal{N}(\varepsilon_n | 0, \hat{\sigma}_n^2(\mathbf{x}_n; \mathbf{w})) \quad [3-25]$$

$$\begin{aligned} p_n(y_n | \mathbf{x}_n, \mathbf{w}) &= \mathcal{N}(y_n | \hat{y}(\mathbf{x}_n; \mathbf{w}), \hat{\sigma}_n^2(\mathbf{x}_n; \mathbf{w})) \\ &= \frac{1}{\sqrt{2\pi\hat{\sigma}_n^2(\mathbf{x}_n; \mathbf{w})}} \exp\left[-\frac{(\hat{y}(\mathbf{x}_n; \mathbf{w}) - y_n)^2}{2\hat{\sigma}_n^2(\mathbf{x}_n; \mathbf{w})}\right] \end{aligned} \quad [3-26]$$

これにより、入力データ（放射線スペクトル） $\mathbf{x}_n$ に依存したノイズ ε_n を定義できる。対数尤度は式のようになる。

$$\sum_{n=1}^N \ln(p_n) = -\sum_{n=1}^N \frac{(\hat{y}(\mathbf{x}_n; \mathbf{w}) - y_n)^2}{\hat{\sigma}_n^2} + \ln \hat{\sigma}_n^2(\mathbf{x}_n; \mathbf{w}) + \text{const.} \quad [3-27]$$

よって損失関数 GaussianNLLLoss が導出できた。

この損失関数を使用するには出力層のユニットを一つ追加する必要がある。追加されたユニットの値が $\hat{\sigma}_n^2(\mathbf{x}_n; \mathbf{w})$ に相当する。モデルを図に示す。




Fig. 3-6 損失関数に GaussianNLLLoss を使用する際のニューラルネットワークの概略図

なお、実際に損失関数として用いるときは式[3-24]右辺第一項における 0 除算をなくすため、次のように式変形して用いる。

$$E(\mathbf{w}) = \sum_{n=1}^N \frac{1}{2} \exp(-s_i) \times (\hat{y}(\mathbf{x}_n; \mathbf{w}) - y_n)^2 + \frac{1}{2} s_i \quad [3-28]$$

$$\log \hat{\sigma}^2 = s_i$$

3.3 従来法との比較方法

この節では、従来法と機械学習モデルの性能を評価する指標として用いた計測時間増倍係数について説明する。これは両手法の標準偏差を用いて計算される簡便な手法だが、定量的評価が可能であり、性能の差も直感的にとらえやすという特徴がある。

まず、光電効果によるカウント数(N_{net})から推定される放射能の標準偏差 σ_t は次式で表される。

$$\sigma_t = \frac{\sqrt{N_{net}}}{t \varepsilon I_\gamma} \quad [3-29]$$

ただし、 t は計測時間(sec)、 ε ピーク検出効率、 I_γ はガンマ線放出率である。この時、計測時間を k 倍にした標準偏差 σ_{kt} は次式のように書ける。

$$\sigma_{kt} = \frac{\sqrt{k N_{net}}}{k t \varepsilon I_\gamma} \quad [3-30]$$

よって、式[3-29]、[3-30]より次の関係が成り立つ。

$$k = \frac{\sigma_t^2}{\sigma_{kt}^2} \quad [3-31]$$

つまり、2つの標準偏差から k を求めることで、計測時間を指標として性能を比較できる。この k を、計測時間増倍係数(Multiplication factor)と呼ぶ。この値は放射能の正解値ごとに算出される。

第4章 結果及び考察

この章では、3章で述べた各手法を Cs-137, Cs-134, K-40 混合放射線スペクトルに対して適用し、最も重要な Cs-137 の放射能を推定した結果についてまとめる。推定したスペクトルは

- ・ゲルマニウム検出器で測定したシミュレーションスペクトル
- ・NaI(Tl)シンチレーション検出器で測定したシミュレーションスペクトル
- ・NaI(Tl)シンチレーション検出器で測定した実測スペクトル

の3種類である。

導出した放射能を評価するため、各データセットの正解値ごとに、各手法において次のような値を計算した。

- ・導出した放射能の平均
導出した放射能の平均を計算する。この値と正解値を比較することで、導出した放射能分布の正確度がわかる。
- ・導出した放射能の標準偏差
導出した放射能の標準偏差を計算した。この値は放射能分布の精度に対応する。

4.1 ゲルマニウム検出器のシミュレーション

この節では、ゲルマニウム検出器を模擬したシミュレーションから得られた、スペクトルの解析結果についてまとめる。なお、シミュレーション条件は2.3.1項と同様である。

4.1.1 コベル法

ゲルマニウム検出器を用いて得られるスペクトルは分解能が良いため、光電ピークが明瞭に見える。そのため、解析には3.1.1項で述べたコベル法がよく用いられる。そこで、スペクトルに本手法を適用し、Cs-137 の放射能を導出した。その平均値と標準偏差を計算した結果を Fig. 4-1 に示す。




Fig. 4-1 コベル法により Ge 検出器から得られる放射線スペクトルを解析し、Cs-137 の放射能を導出した結果。横軸は正解値、縦軸は導出した放射能である。図中の丸は各正解値における放射能の平均値、またエラーバーはその標準偏差を示す。

次の式を用いて平均値を線形フィッティングした。

$$y = ax + b \quad [4-1]$$

ただし、 x は放射能の正解値、 y は推測値の平均、 a 、 b はフィッティングパラメータである。結果は $a = 0.98$, $b = 0.19 \times 10^{-5}$ となった。

4.1.2 機械学習

コベル法と同様に機械学習を用いてスペクトルを解析し、放射能を推定した。機械学習には 3.2 節で述べた MSE および GaussianNLLLoss の 2 種類の損失関数を採用した。それぞれの損失関数に関して順に解析結果を述べる。

A. MSE

まず、120,000 個の学習用データを用いて学習を行い、モデルパラメータを決定した。Fig. 4-2 に学習回数(Epochs)と損失値(Loss)の結果を示す。




Fig. 4-2 MSE を用いた学習モデルを用いて、Ge 検出器の放射線スペクトルを学習した際の損失値変化。学習用データを青、検証用データをオレンジで示す。

学習用データの損失値の変化が収束しているため、学習は十分行えているとわかる。また、検証用データの損失値が学習とともに増加していないため、過学習を起こしていないことがわかる。

次に、決定したモデルパラメータを用いて放射能の推定を行った。推定には検証用データ 50,000 個を使用し、それらについて推定した放射能の平均値と標準偏差を求めた。結果を Fig. 4-3 に示す。




Fig. 4-3 MSE を用いた学習モデルにより Ge 検出器から得られる放射線スペクトルを解析し、Cs-137 の放射能を推定した結果。横軸は正解値、縦軸は推定した放射能である。図中の丸は

各正解値における放射能の平均値、またエラーバーはその標準偏差を示す。

$y = x$ の直線から大きくはずれていないため、正しく学習できているのが確認できる。また、放射能の正解値が大きくなるにつれて標準偏差も大きくなるのがわかる。これは放射能が大きいと、計数が増えるため、絶対誤差が大きくなることに起因している。

次に、コベル法と同様に、式[4-1]を用いて平均値のフィッティングを行った。結果は結果は $a = 0.94, b = 0.16 \times 10^{-3}$ となった

B. GaussianNLLLoss (Gaussian negative log likelihood loss)

まず、120,000 個の学習用データを用いて学習を行い、モデルパラメータを決定した。Fig. 4-4 に学習回数(Epochs)と損失値(Loss)の関係を示す。




Fig. 4-4 GaussianNLLLoss 学習モデルを用いて、Ge 検出器の放射線スペクトルを学習した際の損失値変化。学習用データを青、検証用データをオレンジで示す。

MSE と同様に、学習用データの損失値の変化が収束しているため、学習は十分行っているとわかる。また、検証用データの損失値が学習とともに増加していないため、過学習を起こしていないことがわかる。

次に、決定したモデルパラメータを用いて放射能の推定を行った。推定には検証用データ 50,000 個を使用した。推定した放射能の平均値と標準偏差を求めた。Fig. 4-5 に示す。




Fig. 4-5 GaussianNLLLoss を用いた学習モデルにより Ge 検出器から得られる放射線スペクトルを解析し、Cs-137 の放射能を推定した結果。横軸は正解値、縦軸は推定した放射能である。図中の丸は各正解値における放射能の平均値、またエラーバーはその標準偏差を示す。

ほとんどの放射能領域において Cs-137 の放射能を正しく推定できていることがわかる。ただし、0 Bq 付近の推定値は、正解値より大きな値となった。これは機械学習が放射能の正解値に 0 Bq 以下のものがないことを学習してしまったためと考えられる。これまでと同様に、式[4-1]を用いて平均値をフィッティングした結果は $a = 1.01, b = 0.13 \times 10^{-3}$ である。

最後に、式[3-24]に示した、GaussianNLLLoss の損失関数を用いて放射能を推定した際に、同時に推定される s_i について解析を行う。 s_i は正規分布の標準偏差に相当する変数なので、推定値の信頼度となっていることを期待した。つまり、正解値を y 、推定値を $\hat{y}$ 、不確かさを $\hat{\sigma} = \exp(s_i)$ とした際、次式が成り立つことを期待した。

$$P(\hat{y} - Z_{\alpha/2} \cdot \hat{\sigma} \leq y \leq \hat{y} + Z_{\alpha/2} \cdot \hat{\sigma}) = 1 - \alpha \quad [4-2]$$

ただし、 Z_{α} は Fig. 4-6 に示すように平均 0、標準偏差 1 の標準正規分布においてその点より上側の確率が α となる点であり、パーセント点と呼ばれる。核種の崩壊過程はランダム現象であり、その回数は正規分布で近似できることから、上記が成り立つことが期待される。




Fig. 4-6 標準正規分布とパーセント点 $Z_{\alpha/2}$ の関係図

式[4-2]が成り立つことを確認するため、式[4-3]と式[4-4]（誤差関数）の結果を比較した。

$$P(\hat{y} - \alpha \times \hat{\sigma} < y < \hat{y} + \alpha \times \hat{\sigma}) \quad [4-3]$$

$\hat{y}$ ：放射能の予測値、 $\hat{\sigma}$ ：不確かさ、 y ：放射能の正解値、 α ：正の定数

$$\text{erf}\left(\frac{\alpha}{\sqrt{2}}\right) = \frac{2}{\sqrt{\pi}} \int_0^{\frac{\alpha}{\sqrt{2}}} e^{-t^2} dt \quad [4-4]$$

比較のため、全検証用データセットに対して、式中の α を 0.2~3 まで 0.03 刻みで変化させ、式[4-3]と式[4-4]を計算した。この結果を Fig. 4-7 に示す。




Fig. 4-7 Ge 検出器を想定した、機械学習による不確かさと誤差関数の比較。赤点は不確かさを用いて算出した値、黒線は誤差関数である。

比較のため、コベル法の結果を Fig. 4-8 に示す。ただし、コベル法では Cs-137 の正解値が 10 Bq 以上のデータを用いている。これは、10 Bq 以下のデータではピーク領域の統計量が少なく、推測誤差が正規分布で近似できないためである。




Fig. 4-8 Ge 検出器を想定した、コベル法による推測誤差と誤差関数の比較。赤点は推測誤差を用いて算出した値、黒線は誤差関数である。

コベル法・機械学習の両者ともガウスの誤差関数と良い一致を示すことがわかる。そのため、機械学習が推定した不確かさは、正規分布に従う誤差を表現できているとわかる。

バックグラウンド成分が不確かさに与える影響の確認

本研究では、Cs-137 の放射能を明示的に学習した。そのため、機械学習の推定値に Cs-134 や K-40 の影響があるかどうか定かではない。ここでは、Cs-134 や K-40 の放射能が不確かさ $\hat{\sigma}$ にどのような影響を与えるか調べることで、影響の有無を確認した。

まず、Cs-137 の放射能を固定したときに、Cs-134 の放射能または、K-40 の放射能を変化させ、それぞれの放射能の正解値と $\hat{\sigma}^2$ の相関係数を求めた。不確かさ $\hat{\sigma}$ ではなく $\hat{\sigma}^2$ 用いたのは式[3-8]より、不確かさとスペクトルのカウント数は平方根で関係づけられているためである。結果を Table 4-1 に示す。

Table 4-1 Cs-137 の正解値を固定したデータを用いた際の Cs-134 及び K-40 における $\hat{\sigma}^2$ との相関係数

固定した Cs-137 の放射能の正解値	データ数	$\hat{\sigma}^2$ と Cs-134 の放射能の 正解値の相関係数	$\hat{\sigma}^2$ と K-40 の放射能の正 解値の相関係数
-------------------------	------	---	---

0	967	0.573	0.220
10	748	0.549	0.132
20	527	0.549	0.168
30	365	0.785	0.233
40	256	0.785	0.153
50	184	0.861	0.181
60	123	0.861	0.00674

σ^2 と Cs-134 の相関係数は 0.54～0.86 の値であり、両者に正の相関があることがわかる。よって、不確かさ σ には Cs-134 の影響が反映されていることがわかる。

一方、 σ^2 と K-40 の相関係数は 0.0067～0.23 の値となった。よって両者には相関は見られない結果となった。

次に、この結果について、放射能が同じ Cs-134, Cs-137, K-40 を長時間測定した際の、Cs-137 のピーク領域を示した Fig. 4-9 を用いて考察する。機械学習ではスペクトル全体を用いて解析を行っているが、Cs-137 のピーク領域が最も σ^2 に影響を与えると考えたため、この領域を考察に採用した。




Fig. 4-9 Ge 検出器を想定したスペクトルにおける、Cs-137 のピーク領域。各放射性物質の放射能は等しい。

Cs-137 のピーク領域には Cs-134 と K-40 がバックグラウンドとして存在することが確認できる。また、その強度は Cs-134 のほうが K-40 より 14.6 倍あることがその面積比より計算できる。K-40 が Cs-137 のピーク領域に与える影響は Cs-134 に比べて相対的に小さいため、K-40 における相関係数が小さくなってしまったと考えられる。

そこで、Cs-137 のピーク領域に対する Cs-134 と K-40 からの寄与の大きさを考

慮したうえで、2つの妨害核種が $\hat{\sigma}^2$ に与える影響を調査した。ここで、 $\hat{\sigma}^2$ と" $y_{\text{Cs-134}} + x \times y_{\text{K-40}}$ "の相関係数を、 x を0.01~0.2まで0.01刻みで変化させて算出した。なお、 $y_{\text{Cs-134}}$ はCs-134の放射能の正解値、 $y_{\text{K-40}}$ はK-40の放射能の正解値を表す。結果をFig. 4-10に示す。Cs-137の正解値を20 Bqで固定したデータセットを用いた結果を示したが、どの放射能でも同じような結果となった。




Fig. 4-10 x を0.01~0.2まで0.01刻みで変化させた際の $\hat{\sigma}^2$ と $y_{\text{Cs-134}} + x \times y_{\text{K-40}}$ の相関係数

$x = 0.07$ のとき、最も相関が強くなることがわかる。この値はCs-134とK-40の面積比 $\frac{1}{14.6} = 0.068$ と近い値になっている。したがって、機械学習が推定した不確かさはCs-134に加え、K-40のバックグラウンドも同時に考慮した結果になっていることがわかる。

4.1.3 機械学習とコベル法の比較

ここまでに、機械学習とコベル法の両手法を用いて、ガンマ線スペクトルからその放射能の導出を行った。本項では、3.3節で述べた計測時間増倍係数（式[3-31]）を利用して両手法の性能を比較した。ゲルマニウム検出器を使用した場合における、「MSEを用いた機械学習」とコベル法の比較をFig. 4-11に示す。




Fig. 4-11 コベル法に対する機械学習(MSE)の計測時間増倍係数(Ge 検出器から得られる放射線スペクトル)

MSE を用いた場合には、放射能が 10 Bq 以上で計測時間増倍係数が大きく、機械学習が有利であることが分かった。一方、10 Bq 以下では、計測時間増倍係数が小さく、コベル法のほうが短時間でスペクトルを分析できる結果となった。

次に、「GaussianNLLLoss を用いた機械学習」とコベル法の比較を Fig. 4-12 に示す。




Fig. 4-12 コベル法に対する機械学習(GaussianNLLLoss)の計測時間増倍係数(Ge 検出器から得られる放射線スペクトル)

GaussianNLLLoss の場合は、すべての放射能領域において計測時間増倍係数が 1

を超える結果となった。そのため、機械学習の方がコベル法に比べより短時間でスペクトルを分析できることがわかる。

次に、GaussianNLLLoss を用いた機械学習がコベル法と比べ良い性能となる理由を確かめるため、コベル法の解析領域のみのスペクトルを用いた学習を行い、計測時間増倍係数を算出した。これにより、光電ピーク以外のスペクトルがどのような影響を与えているか予測できると考えた。推定した放射能の平均値と標準偏差を Fig. 4-13 に示す。また、コベル法と比較した計測時間増倍係数を Fig. 4-14 に示す。




Fig. 4-13 GaussianNLLLoss を用いた学習モデルにより Ge 検出器から得られるピーク領域を解析し、Cs-137 の放射能を推定した結果。横軸は正解値、縦軸は推定した放射能である。図中の丸は各正解値における放射能の平均値、またエラーバーはその標準偏差を示す。




Fig. 4-14 コベル法に対する機械学習(GaussianNLLLoss)の計測時間増倍係数(Ge 検出器から得られるピーク領域)

放射能領域が 10 Bq 以上では、機械学習とコベル法に大きな差は見られなかった。よって、Fig. 4-12 の 10 Bq 以上の領域において、計測時間増倍係数が 1 を超える原因は、ピーク領域以外のスペクトルによる情報量の増加であると考えられる。一方、放射能領域が 10 Bq 以下の領域では、推定に同じスペクトルを用いているにも関わらず、計測時間増倍係数が 1 より大きくなった。これは、機械学習が放射能の正解値には 0 Bq 以下がないことを学習したためだと考えられる。このことは Fig. 4-5 や Fig. 4-13 において、0 Bq 付近の推定値が $y = x$ の軸より大きくなっていることから確認できる。

4.2 NaI(Tl)シンチレーション検出器のシミュレーション

この節では、NaI(Tl)シンチレーション検出器を模擬したシミュレーションから得られたスペクトルの解析結果についてまとめる。なお、シミュレーション条件は 2.3.2 項に示してある。

4.2.1 逆マトリックス法

NaI(Tl)シンチレーション検出器を用いて得られるスペクトルは、ゲルマニウム

検出器に比べて分解能が低い。そのため、Fig. 3-2 に示したように、Cs-137 が放出する 662 keV の光電ピークは、Cs-134 が放出する 604 keV の光電ピークと重なってしまい、コベル法による解析は困難である。そこで本項では、逆マトリックス法を用いて解析した。導出した Cs-137 の放射能の平均値と標準偏差を Fig. 4-15 に示す。




Fig. 4-15 逆マトリックス法により NaI(Tl)シンチレーション検出器から得られる放射線スペクトルを解析し、Cs-137 の放射能を導出した結果。横軸は正解値、縦軸は導出した放射能である。図中の丸は各正解値における放射能の平均値、またエラーバーはその標準偏差を示す。

推測した放射能の平均値は線形性が良いことがわかる。そこで、これまでと同様に、式[4-1]を用いてフィッティングを行った。結果は $a = 1.00$, $b = 0.20 \times 10^{-3}$ となった

4.2.2 機械学習

逆マトリックス法と同様に機械学習を用いてスペクトルを解析し、放射能を推定した。なお、損失関数には GaussianNLLLoss を適用した。

まず、700,000 個の学習用データを用いて学習を行い、モデルパラメータを決定した。Fig. 4-16 に学習回数(Epochs)と損失値(Loss)の関係を示す。




Fig. 4-16 GaussianNLLLoss 学習モデルを用いて、NaI(Tl)シンチレーション検出器を想定した放射線スペクトルを学習した際の損失値変化。学習用データを青、検証用データをオレンジで示す。

学習用データの損失値の変化が収束しているため、学習は十分行えているとわかる。また、検証用データの損失値が学習とともに増加していないため、過学習を起こしていないことがわかる。

次に、決定したモデルパラメータを用いて放射能の推定を行った。推定には検証用データ 200,000 個を使用した。推定した放射能の平均値と標準偏差を Fig. 4-17 に示す。




Fig. 4-17 GaussianNLLLoss を用いた学習モデルにより NaI(Tl)シンチレーション検出器から得られる放射線スペクトルを解析し、Cs-137 の放射能を推定した結果。横軸は正解値、縦軸は推定した放射能である。図中の丸は各正解値における放射能の平均値、またエラーバーはその標準偏差を示す。

$y = x$ の直線に沿っているため、正しく学習できているのが確認できる。これまでと同様に、式[4-1]を用いてフィッティングを行った。結果は結果は $a = 1.00, b = -0.92 \times 10^{-4}$ となった

ゲルマニウム検出器の場合と同様に、求めた不確かさを式[4-3]に適用し、式[4-4]と比較を行った。結果を Fig. 4-18 に示す。




Fig. 4-18 NaI(Tl)シンチレーション検出器を想定した、機械学習による不確かさと誤差関数の比較。赤点は不確かさを用いて算出した値、黒線は誤差関数による値である。

誤差関数とほぼ一致していることから、NaI(Tl)シンチレーション検出器によるスペクトルの場合においても、機械学習が正しく不確かさを推定できていることが確認できた。

また、逆マトリックス法によって導出した推測誤差についても、同様に誤差関数との比較を行った。結果を Fig. 4-19 に示す。なお、3.1.2 節で示したように、逆マトリックス法の精度はスペクトルの統計誤差のみによって決まるため、推測誤差が誤差関数と一致するのは自明である。




Fig. 4-19 NaI(Tl)シンチレーション検出器を想定した、逆マトリックス法による推測誤差と誤差関数の比較。赤点は推測誤差を用いて算出した値、黒線は誤差関数である。

4.2.3 機械学習と逆マトリックス法の比較

ここまでに、機械学習と逆マトリックス法の両手法を用いて、ガンマ線スペクトルからその放射能を求めた。本項では、3.3 節で述べた計測時間増倍係数を利用して両手法の性能を比較した。その結果を Fig. 4-20 に示す。




Fig. 4-20 逆マトリックス法に対する機械学習(損失関数 GaussianNLLLoss)の計測時間増倍係数。1 を超えると機械学習の方が良い性能となる。使用したスペクトルは NaI(Tl)シンチレーション検出器から得られるスペクトル。ただし、機械学習では各スペクトル全体を使用するのに対し、逆マトリックス法はピーク成分のみを使用した。

計測時間増倍係数が 1 を超えているため、連立方程式に比べ機械学習の方が良い性能を示すことがわかった。

機械学習が有利となる理由を調べるため、Table 4-2 に示す No.3 の学習・解析を新たに行った。ただし、No.1 と No.2 はそれぞれ 4.2.1 項と 4.2.2 項で示したものである。

Table 4-2 NaI(Tl)シンチレーション検出器のスペクトル解析一覧

	解析手法	使用したスペクトル
No.1	逆マトリックス法	光電ピークのためのスペクトル
No.2	機械学習	スペクトル全体
No.3	機械学習	光電ピークのためのスペクトル

No.1 と No.3 の解析結果から計測時間増倍係数を導出した。ただし、計測時間増倍

係数が1を超える場合、No.3 のほうが良い結果となるようにした。結果を Fig. 4-21 に示す。




Fig. 4-21 逆マトリックス法に対する機械学習(損失関数 GaussianNLLLoss)の計測時間増倍係数。1を超えると機械学習の方が良い性能となる。使用したスペクトルは NaI(Tl)シンチレーション検出器から得られるスペクトル。ただし、機械学習と逆マトリックス法ともにピーク成分のみを使用した。

逆マトリックス法と同じスペクトルを用いた場合でも、機械学習の方が良い結果となった。これは、スペクトルに見られるピークの重なりを機械学習がうまく分離し、解析を行えたためと考えられる。

次に、No.2 と No.3 の解析結果から計測時間増倍係数を導出した。ただし、計測時間増倍係数が1を超える場合、No.2 のほうが良い結果となるようにした。結果を Fig. 4-22 に示す。




Fig. 4-22 ピーク成分のみを用いた機械学習(損失関数 GaussianNLLLoss)に対する、各スペクトル全体を用いた機械学習(GaussianNLLLoss)の計測時間増倍係数。1 を超えると各スペクトル全体を用いた機械学習の方が良い性能となる。使用したスペクトルは NaI(Tl)シンチレーション検出器から得られるスペクトル。

比較した両手法の違いは、スペクトル中の光電ピークのみを用いたか、スペクトル全体を用いたかである。この違いが Fig. 4-22 の結果に表れたと考えられる。計測時間増倍係数は 1 を超えているため、スペクトル全体を用いることで、より早く解析を行えることを示せた。また、この結果は Fig. 4-12 の結果と傾向が似ている。これは両グラフとも光電ピーク以外のスペクトルの影響度を示したものであるためと考えられる。

最後に、Fig. 4-22 の形状について考察を加える。まず、0 Bq 付近の計測時間増倍係数が大きくなっているのが確認できる。今回の学習データには正解値が 0 Bq 以下のものが存在しないことを学習している。一方、コベル法などの従来の手法では、バックグラウンド成分を引くとき、統計的なゆらぎにより、0 Bq 以下の値をとることがある。この両者の違いが影響していると考えられる。次に、全体の傾向として、放射能が大きくなると計測時間増倍係数も大きくなることがわかる。これは放射能が大きくなるにつれて、コンプトン端などの成分の形状がはっきりとみえるようになり、この形状を機械学習がうまく解析できているためと考えられる。

4.3 実測スペクトルの解析

NaI(Tl)シンチレーション検出器の実測スペクトルに開発した学習モデルを適用することで、その性能を検証した。本節では、初めに使用した実測スペクトルについて述べた後、解析結果を示す。

4.3.1 用いた実測スペクトル

実測スペクトルは2014/6/24~25に九州大学筑紫地区D棟で測定されたもの⁽³⁵⁾を用いた。なお、検出器はNaI(Tl)シンチレーション検出器(EMF-211)を使用している。測定条件についてまとめたものをTable 4-3に示す。

Table 4-3 NaI(Tl)シンチレーション検出器を用いた実測スペクトルの測定条件

日時	2014/6/24~2014/6/25
場所	九州大学筑紫地区D棟
体系	Fig. 2-5
計測時間	3600 sec
測定試料	玄米認証標準物質
測定試料の重さ	1.822 kg
検出器	NaI(Tl)シンチレーション検出器

玄米認証標準物質とは、日本分析化学会が販売している放射能濃度が認証された粒状玄米試料のことである。この玄米認証標準物質(JSAC 0731)を複数用いてマリネリ容器を満たした。含まれる核種とその放射能についてTable 4-4にまとめる。ただし、基準日時は2012年6月1日0時0分0秒である。

Table 4-4 基準日時と測定日時における、玄米認証標準物質の放射能濃度

	Cs-134	Cs-137	K-40
放射能(校正時) [Bq/kg]	141.0	210.0	75.0
拡張不確かさ(校正時) [Bq/kg]	9.0	13.0	7.0
放射能(測定時) [Bq/kg]	75.0	200.2	75.0
拡張不確かさ(測定時) [Bq/kg]	4.8	12.4	7.0

※拡張不確かさとは、合成標準不確かさに包含係数 $k=2$ を乗じたもので、95%信頼区間に相当する。

バックグラウンド測定も同様の検出器を用いて行われた。測定条件をTable 4-5にまとめる。

Table 4-5 NaI(Tl)シンチレーション検出器を用いたバックグラウンドスペクトルの測定条件
実測スペクトルの測定条件

日時	2014/6/24~2014/6/25
場所	九州大学筑紫地区
体系	Fig. 2-5
計測時間	3600 sec
測定試料	バックグラウンド（非汚染玄米）
測定試料の重さ	1.822 kg
検出器	NaI(Tl)シンチレーション検出器

上記の条件で得られたスペクトルは計測時間が 3600 sec、チャンネル数は 1024 ch だった。一方、4.2.2 項で示した学習モデルは計測時間 60 sec、チャンネル数 300 ch を想定して作成された。そこで、玄米認証標準物質スペクトル（スペクトル A）とバックグラウンドスペクトル（スペクトル B）を用いて、学習モデルで想定している条件に合うスペクトル（スペクトル C）を作成した。スペクトル C（計測時間 60 sec、チャンネル数 300 ch）を作成する手順について以下に示す。ただし、統計によらないノイズは含まれないと仮定している。

1. スペクトル A および B のエネルギー校正を行い、0 から 3000 keV の範囲を 10 keV/ch となるようリビンした。なお、玄米認証標準物質は Cs-134 の 795 keV と K-40 の 1461 keV、バックグラウンドは K-40 の 1461 keV と 0ch で 0 keV となる点を用いてエネルギー校正を行った。
2. 300ch に変更したスペクトル A の総カウント数を C_{total} とする。また、
$$C_{\text{min}} = C_{\text{total}} \times \frac{60}{3600}$$
 とする
3. C_{min} を平均とするポアソン分布から乱数を取得。この乱数が新たに作成するスペクトル（スペクトル C）の総カウント数となる。
4. 3 で決定した乱数の数だけスペクトル A からイベントをランダムに取得し、これをスペクトル C とする。
5. 3 と 4 を任意の数だけ繰り返す。なお、4 で取得したイベントはもとに戻さない。

上記の方法でスペクトルを作成することで、計測時間 60 sec、チャンネル数 300 ch の放射線スペクトルを作成した。また、計測時間 10,20,30,40,50 sec の放射線スペクトルも同様に作成し、その計測時間を 60 sec とみなすことで、Table 4-6 に示す放射能の放射線スペクトルを作成した。

Table 4-6 作成した NaI(Tl)シンチレーション検出器を用いた実測スペクトルの放射能とそのデータ数

No.	Cs-134 の放射能[Bq]	Cs-137 の放射能[Bq]	K-40 の放射能[Bq]	データ数
1	21.1	60.8	22.8	2510
2	42.3	121.6	45.6	1250
3	63.5	182.4	68.3	840
4	84.6	243.2	91.1	620
5	105.8	304.0	113.9	430
6	127.0	364.8	136.7	480

4.3.2 機械学習及び逆マトリックス法の適用

Table 4-6 の放射線スペクトルに対して、機械学習を適用し、Cs-137 の放射能を推定した。ただし、機械学習の損失関数は GaussianNLLLoss であり、モデルパラメータは 4.2.2 項で決定したものである。また、同様に逆マトリックス法の適用も行った。推定結果について放射能、不確かさの順に述べる

放射能の推定値

Table 4-6 の放射線スペクトルに対する、推定値の平均値を求めた。その結果を Fig. 4-23 に示す。




Fig. 4-23 GaussianNLLLoss を用いた学習モデルにより NaI(Tl)シンチレーション検出器を用いた実測スペクトルを解析し、Cs-137 の放射能を推定した結果。図中の青点は推定値の平均値、赤線は $y = x$ 軸を示す。

この平均値を式[4-1]でフィッティングした。結果は $a = 1.04, b = -2.57$ となった。

よって、推定結果が線形にずれていることが確認できる。これは、Fig. 2-6 に示すように、実測とシミュレーションのズレに起因すると考えられる。具体的には、300 keV~600 keV において、シミュレーションが実測スペクトルを過大評価したため、機械学習の推定値が実測値を過大評価したと考えられる。

フィッティング結果をもとに平均値が $y = x$ の直線上に乗るように補正した。補正した放射能をヒストグラムで示したものを Fig. 4-24 に示す。なお、逆マトリックス法で示した結果も同時に示してある。ただし、機械学習の結果を CNN、逆マトリックス法の結果を MI とした。




Fig. 4-24 逆マトリックス法と GaussianNLLLoss を用いた学習モデルにより NaI(Tl)シンチレーション検出器を用いた実測スペクトルを解析し、Cs-137 の放射能を推定した結果

機械学習の方が逆マトリックス法に比べヒストグラムの幅が狭く、精度が高くなっていることがわかる。それぞれのデータセットに対して平均値と標準偏差を求め、計測時間増倍係数を求めた。結果を Table 4-7 に示す。

Table 4-7 NaI(Tl)シンチレーション検出器を用いた実測スペクトルにおける計測時間増倍係数

No.	計測時間増倍係数
1	2.60
2	2.38
3	2.33
4	2.51
5	2.64
6	2.60

すべてのデータセットに対して、計測時間増倍係数が1を超えたため、実測データにおいても、機械学習の方が逆マトリックス法より良い性能を示すことが分かった。

不確かさ

Table 4-6 の放射線スペクトルに対する、不確かさを求めた。求めた不確かさを式[4-3]に適用し、式[4-4]と比較を行った。結果を Fig. 4-25 に示す。




Fig. 4-25 GaussianNLLLoss を用いた学習モデルにより、NaI(Tl)シンチレーション検出器を用いた実測スペクトルを解析し、算出した不確かさと誤差関数の比較。

誤差関数と比較し多少のずれがみられるが、おおよそ一致しており、実測データにおいても、正しく不確かさが推定されていることがわかった。

第5章 まとめと今後の展望

5.1 まとめ

本研究では、機械学習を用いたガンマ線スペクトル分析において、損失関数として GaussianNLLLoss を使用する学習モデルを提案した。そして、この学習モデルをゲルマニウム検出器と NaI(Tl)シンチレーション検出器を用いて得られる低放射能領域のシミュレーションスペクトルに適用し、従来手法であるコベル法や逆マトリックス法と比較を行った。ゲルマニウム検出器、NaI(Tl)シンチレーション検出器の両方とも従来手法に比べ、より短時間で放射能を推定することができるとわかった。また、提案した学習モデルは、導出した放射能の不確かさも同時に推定できることを示した。

そして、NaI(Tl)シンチレーション検出器を用いた実測スペクトルに機械学習を適用した。結果として、従来法と比較して短時間で放射能を推定できること、その不確かさも同時に推定できることを示した。

5.2 今後の展望

本研究で用いたデータの分析対象核種は Cs-137 であり、妨害核種として Cs-134 と K-40 を選出した。今後は分析対象核種を増やすと共に、その他の自然放射性核種を考慮することで、より現実的な条件での学習をさせることが必要となる。また、同じくスペクトル全体の情報を用いて放射能を推定する手法であるアンフォールディング手法と性能を比較する。さらに、今回推定した統計に依存した不確かさだけではなく、モデル選択やデータ不足に起因した不確実性も推定できるような学習モデルの開発が研究課題となる。

参考文献

- (1) 関 勝寿, 福島原発事故による土壌の放射能汚染対策, 経営論集 **78** (2011) 13-26.
- (2) M. Hatch, *et al.*, The Chernobyl Disaster: Cancer following the Accident at the Chernobyl Nuclear Power Plant, *Epidemiologic Reviews* **27** (2005) 56-66.
- (3) S. Uchida and K. Tagami, Soil-to-plant transfer factors of fallout ^{137}Cs and native ^{133}Cs in various crops collected in Japan, *Journal of Radioanalytical and Nuclear Chemistry*, **273** (2007) 205–210.
- (4) D.F. Covell, Determination of gamma-ray abundance directly from the total absorption peak, *Analytical Chemistry* **31** (1959) 1785–1790.
- (5) Y. Mizumoto, *et al.*, Ratio of Peak to Total Efficiencies for Germanium Detectors, *Radioisotopes* **36** (1987) 20-23.
- (6) 日本アイソトープ協会. アイソトープ手帳. 丸善出版.(2020)
- (7) 公益社団法人日本アイソトープ協会”NaI(Tl)シンチレーションスペクトロメータによる γ 線スペクトロメトリガイドンス”, (2015)
- (8) W. McCulloch and W. Pitts, A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics* **7** (1943) 115 - 133.
- (9) V. Nair and G.E. Hinton, Rectified Linear Units Improve Restricted Boltzmann Machines, *Proceedings of 27th ICML '10* (2010) 807-814.
- (10) D.E.Rumelhart, *et al.*, Learning representations by back-propagating errors. *Nature* **323** (1986) 533-538.
- (11) N.Srivastava *et al.*, Dropout: A simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research* **15** (2014) 1929-1958.
- (12) D.H. Hubel, and T. N. Wiesel, Receptive fields of single neurons in the cat's striate cortex, *Journal of Physiology* **148** (1959) 574-591.
- (13) K. Fukushima, Neocognitron: A self-organizing neural network model for a mechanism of pattern unaffected by shift in position, *Biological Cybernetics* **36** (1980) 193-202.
- (14) Y.LeCun, *et al.*, Backpropagation applied to handwritten zip code recognition. *Neural computation* **1** (1980) 541-551.
- (15) T. Kin, J. Goto and M. Oshima, Machine Learning Approach for Gamma-ray Spectra Identification for Radioactivity Analysis, *2019 IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC)*, (2019) 1-2.
- (16) 高橋龍平. 機械学習を用いた環境中放射性セシウムの放射能推定. 九州大学. 卒業論文. (2020).
- (17) 林真照ら, アンフォールディング手法を用いた NaI(Tl)シンチレーション

- 式放射能分析装置の開発, 放射線(応用物理学会放射線分科会機関誌), **44**(2018)101-108.
- (18) J. Goto, *et al.*, Introduction of multiple γ -ray detection to charged particle activation analysis, *Journal of Radioanalytical and Nuclear Chemistry* **314** (2017) 1707–1714.
 - (19) R.B. Firestone, Table of Isotopes (eighth edition), John Wiley & Sons, Inc. (1996).
 - (20) S.Agostinelli, *et al.*, Geant4—a simulation toolkit, *Nuclear Instruments and Methods in Physics Research Section A* **506** (2003) 250-303.
 - (21) J.Allison, *et al.*, Geant4 developments and applications, *IEEE Transactions on Nuclear Science* **53** (2006) 270- 278.
 - (22) J.Allison, *et al.*, Recent developments in Geant4, *Nuclear Instruments and Methods in Physics Research Section A* **835** (2016) 186- 225.
 - (23) Evaluated Nuclear Structure Data File (ENSDF), From ENSDF database as of March, 2018 Version available at <http://www.nndc.bnl.gov/ensarchivals/>.
 - (24) D.P. Kingma and J. Ba., Adam : A method for stochastic optimization, arXiv:1412.6980 (2014).
 - (25) D. A. Nix and A. S. Weigend, Estimating the mean and variance of the target probability distribution, *Proceedings of 1994 IEEE International Conference on Neural Networks (ICNN'94)*, **1**(1994)55-60.
 - (26) arXiv:1703.04977
 - (27) X. Glorot and Y. Bengio, Understanding the difficulty of training deep feedforward neural networks. *Artificial Intelligence and Statistics*, **9** (2010) 249-256.
 - (28) 放射能測定シリーズ7「ゲルマニウム半導体検出器によるガンマ線スペクトロメトリー」, 文部科学省 (1992).
 - (29) 八谷大岳. ゼロからつくる Python 機械学習プログラミング入門. 講談社,(2020)
 - (30) H.Hirayama, *et. al.*,”The EGS5 code system”,SLAC-R-730 and KEK Report 2005-8(2005)
 - (31) Quoc V Le, Alex J Smola, and Stephane Canu. Heteroscedastic Gaussian process regression. In *Proceedings of the 22nd international conference on Machine learning, ACM*, (2005) 489–496.
 - (32) E. Brochu, V. M. Cora, and N. De Freitas. A tutorial on Bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. (2009)
 - (33) E. Contal, V. Perchet, and N. Vayatis. Gaussian process optimization with mutual information. In *International Conference on Machine Learning*, (2013) 252-253.
 - (34) B. Shahriari, K. Swersky, Z. Wang, R. P. Adams, and N. de Freitas. Taking the human out of the loop: A review of Bayesian optimization. In *Proceedings of the*

IEEE, **1**, (2016) 148-175.

- (35) 赤野竜斗. アンフォールディング手法を用いた NaI(Tl)シンチレーション放射能分析装置の性能評価. 九州大学. 修士論文. (2014).

謝辞

本研究は非常に多くの方の協力のもと仕上げることができました。直接感謝を申し上げますとともに、短いスペースではありますがこの場でも感謝を申し上げたいと思います。

まず、指導教員の金政浩准教授は、研究に関し全くの無知である私に対し、懇切丁寧に指導をしてくださいました。おかげさまで、研究者としての第一歩を踏み出すことができました。心より感謝申し上げます。

新潟大の後藤先生は、急なお願いにもかかわらず、本研究で用いたデータセットの作成を快く引き受けてくださいました。感謝申し上げます。

渡辺幸信教授には研究者としての所作や心構えなど、研究生活を送るうえで大切なことを教えていただきました。感謝申し上げます。

川瀬頌一郎助教とは研究内容の相談から政治経済の話題など、非常に楽しい時間を過ごさせて頂きました。感謝申し上げます。

研究室秘書の古賀留美子氏には、研究生活で疲れた私たちにいつも笑顔で接してくださいました。また、研究生活が滞りなく送れるよう環境を整えてくださいました。心より感謝いたします。

同研究室の先輩である、中野敬太氏、M Kawchar A Patwary 氏、佐藤俊輔氏、佐藤光流氏、真鍋征也氏、青木勝海氏、竹下隼人氏、亀井智子氏、黒田順也氏、小森智博氏、塩川圭一郎氏、馬原巧氏、吉浪皓亮氏、植松美由希氏、岡本直也氏、新城優治氏、寶来悠氏、宮武立彦氏、室田拓哉氏、Mar Alfonse 氏、山口真矢氏、Basiri hamid 氏、鄧亦凡氏、後輩である大石将也氏、芝洋斗氏、関口恒氏、竹本伊吹氏、田中裕貴氏、福永将太郎氏、李坤東氏、奥田歩夢氏、川田哲平氏、木原隆弘氏、中上直人氏は、私の日々の生活を色鮮やかなものとしてくださいました。本当にありがとうございます。

同期の福田宏哉氏、西津美咲氏には、難しい私の性格を広い心で受け入れてもらいました。本当に感謝しています。

そして、最もお世話になった家族はおそらくこの論文を見る機会はないので、直接お礼を伝えたいと思います。

最後に6年間の大学生活で関わったすべての人の幸せを祈って、この論文を締めくくらせていただきます。