

令和 6 年 6 月 13 日現在

機関番号：16201

研究種目：基盤研究(C)（一般）

研究期間：2020～2023

課題番号：20K11991

研究課題名（和文）光子飛跡計算と深層学習による放射線強度分布推定の高精度化とIoT機器への実装

研究課題名（英文）Development of Radiation-Distribution Estimation-System with Higher Precision Using Deep Neural Networks and Photon Transport Simulator and Its Implementation on Edge Device

研究代表者

藤本 憲市 (Fujimoto, Ken'ichi)

香川大学・創造工学部・教授

研究者番号：20300626

交付決定額（研究期間全体）：（直接経費） 3,300,000 円

研究成果の概要（和文）：効率的な土壤除染計画を立案するために必要となる簡易的放射能測定装置の基礎技術確立を目指し、土壤内の放射線強度深度分布を高精度に推定する深層学習システムを開発した。土壤内にある放射性物質の仮想的配置に対する放射線測定データをPHITS（光子飛跡シミュレータ）によって再現し、学習に必要となるシミュレーションデータを、敵対的生成ネットワークを用いて大量に生成（拡張）した。拡張したシミュレーションデータを深層学習システムに学習させ、高精度に推定できる放射線強度深度分布推定システムを構築した。更に構築システムをエッジデバイスへ実装することで、簡易的放射能測定装置の基礎技術を確立した。

研究成果の学術的意義や社会的意義

本研究では、放射線計測分野における標準的ツール（光子飛跡シミュレータ）を用いて推定した放射線センサの応答特性に基づいて、土壤内の放射線強度深度分布を高精度に推定できる深層学習システムを構築した。本研究成果は、ソフトコンピューティングの立場から放射線計測技術の高度化に寄与する点において重要である。また、放射能汚染土壤の除染計画や安全評価の効率化に寄与できるだけでなく、仮置場・中間貯蔵施設における放射性物質の適正な管理など、社会全体の放射線リスク管理技術の向上にも貢献できる。

研究成果の概要（英文）：This study aims to establish the basic technology for a portable radioactivity monitoring device for planning an efficient soil decontamination plan. We developed a machine learning system (deep neural network) that estimates the distribution of radioactive soil contaminants in the depth direction with high accuracy. We assumed a virtual situation in which radioisotopes are placed in the soil and simulated typical cases using a PHITS (Particle and Heavy Ion Transport code System). According to the data sets generated by the PHITS, a large amount of training data for the deep neural network was generated using generative adversarial networks. We created a deep neural network that can make high-precision estimates for the training data and implemented it on an edge device. These indicated that the basic technology for a soil radioactivity monitoring device with high-precision estimation was established.

研究分野：数理工学

キーワード：放射線強度分布推定 光子飛跡シミュレータ 深層学習システム 敵対的生成ネットワーク データ拡張 エッジデバイス実装

1. 研究開始当初の背景

放射性物質（ラジオアイソトープ：RI）を含む土壌の深度方向に対する放射線強度分布測定にスクレーパープレート法が使用される[1-3]。しかしながら、スクレーパープレート法は高精度な測定が可能なものの、採取した土壌を大型分析器が設置されている施設へ持ち込んで測定するため現場において測定を完結させることができず、放射線強度深度分布の経時変化を現地で常時測定することはできない。汚染土壌の除染作業や安全管理を効率化する観点から、土壌内の放射線強度深度分布を現地で常時モニタリングできるシステムの開発が急務となっている。

2. 研究の目的

図1に示すとおり、土壌を深さ方向に N 分割し、各層に1個の放射線センサを配置した棒状放射線測定器を用いて土壌内の放射線強度深度分布を推定する問題を考える。問題を簡単化するため、各層においてRIは一様に分布しており放射線強度は均一であると仮定する。すなわち、第 j 層におけるRIの放射線強度を s_j とする。各放射線センサは、測定できるエネルギー範囲に対して C 個のチャネルで光子を計数する。いま、第 i 層に配置した放射線センサの第 c チャネルにおいて、第 j 層における放射線強度 s_j のRIから放出された光子数 x_{ic} を観測するという過程を a_{ijc} とすれば、 $\mathbf{X} = [x_{ic}]_{N \times C}$, $\mathbf{A} = [a_{ijc}]_{N \times N \times C}$, 及び $\mathbf{S} = [s_j]_{N \times 1}$ として、土壌内の放射線強度深度分布推定問題を

$$\mathbf{X} = \mathbf{AS} \quad (1)$$

のとおりに定式化できる。

この問題に対し、光子飛跡シミュレータ（PHITS: Particle and Heavy Ion Transport code System）[4]から得られる仮想RIの強度分布 \mathbf{S} と仮想放射線センサで測定される放射線エネルギースペクトルデータ \mathbf{X} との関係 \mathbf{A} の逆写像を学習する深層学習システムを構築することによって、土壌内の放射線強度深度分布 \mathbf{S} を高精度に推定するシステムを開発することが本研究の目的である。

3. 研究の方法

土壌内の放射線強度深度分布推定のための深層学習システムとして、畳み込みニューラルネットワーク（CNN: Convolutional neural network）[5]を用いる。CNNの高精度化には膨大な数の良質な学習データが必要となるため、土壌の放射線強度深度分布の実測データに酷似したデータを大量に作成しなくてはならない。そこでまず、3次元CADを用いて測定現場及び棒状放射線測定器（センサ）を模擬した仮想実験空間を作成し、そのCADデータをPHITSに読み込ませることで、土壌内の任意の層に埋め込まれたRIから放出される光子（放射線）の測定をシミュレーションできる環境を整備する。次に、PHITSシミュレーションから得られる仮想測定器による放射線エネルギースペクトルが実測データに近づくように、PHITSにおけるシミュレーションパラメータ値を調整する。モンテカルロ法に基づいたPHITSは1回のシミュレーションに数日間という時間を要するため、一通りのRI配置パターンについてのみシミュレーションを実行し、それらに類似した放射線エネルギースペクトルデータを敵対的生成ネットワーク（GAN: Generative Adversarial Networks）[6]に拡張（大量生成）させることで学習データ作成にかかる時間の短縮を図る。大量生成したシミュレーションデータをCNNに学習させながらCNNの構造を改良することにより、放射線強度深度分布を高精度に推定できるCNNを構築する。可搬型の放射線強度深度分布推定システムを実現するために、構築したCNNを小型IoT機器（エッジデバイス）へ実装する。

4. 研究成果

CNNの推定精度（正解率）を向上させるためには実測データをほぼ忠実に再現した良質な学習データを用意する必要がある。そこで、シミュレーションデータと実測データとの類似度をKullback-Leibler divergence（KL divergence）により定義し、PHITSのパラメータ調整に利用した。図2(a)は、スクレーパープレート法に基づいて高性能な放射能分析器で測定した1層分の実測データ、同図(b), (c)は、PHITSでシミュレートする総光子数を5億又は1千万とした場合のシミュレーション結果である。総光子数を5億とした場合のシミュレーション結果と実測データとのKL値は0.90、総光子数を1千万

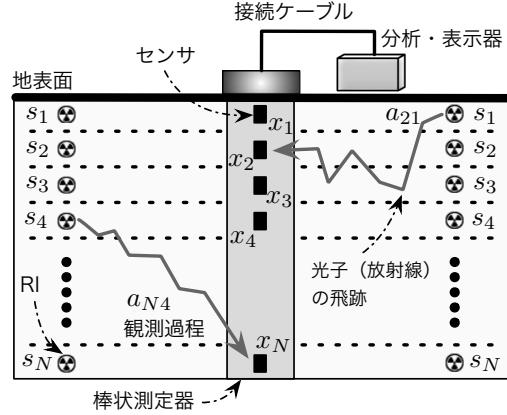


図1 土壌の放射線強度深度分布推定問題（センサ及び観測過程におけるチャネルの添字は省略）

とした場合との KL 値は 1.20 となり、総光子数を 5 億としたシミュレーションデータの方がより実測データに近い。しかしながら総光子数を多くすれば PHITS シミュレーション時間は増大するため、これらの結果及び研究期間におけるシミュレーション割り当て可能時間を勘案して、PHITS における総光子数を 1 億に設定した。その他、PHITS の dump 機能の有効化が、1 回あたりのシミュレーション時間の短縮化に効果的であることもわかった。

総光子数を 1 億に設定しつつ dump 機能を有効化したとしても、PHITS によるシミュレーションにはかなりの時間を要する。そこで、図 3 に示す条件付き敵対的生成ネットワーク (CGAN: Conditional Generative Adversarial Networks) [7] を用いて、CNN の学習・テスト用データを拡張した。本研究では、RI をある単一層のみに仮想的に配置した 400 個 (20 種類 × 20 層分) のデータを PHITS で作成し、ノイズ重畠処理を施すことによって、CGAN に学習させるための放射線エネルギースペクトルデータを各層 1000 種類ずつ合計 2 万個作成した。なお実際の放射線センサには 1024 チャネル搭載されているが、本研究における想定核種がセシウム 134 と 137 (Cs-134, Cs-137) であることから、それら核種が主に放出するエネルギー帯に相当するチャネル (265 ~ 433ch の 168ch 分) のみに着目することで、CGAN の学習時間短縮のみならず、放射線強度深度分布推定用の CNN のダウンサイジングも図った。

作成した 2 万個のデータを CGAN へ学習させた結果の一例を図 4 に示す。学習データ (青色) に酷似した放射線エネルギースペクトル (オレンジ色) が生成されていることが見てとれる。学習済みの CGAN に対し、ある単一層に強度 1.0 の RI が存在するという条件ラベルを与えることで、1 層ごとに 6 千個で 20 層分の合計 12 万個の放射線エネルギースペクトルデータを作成した [8,9]。

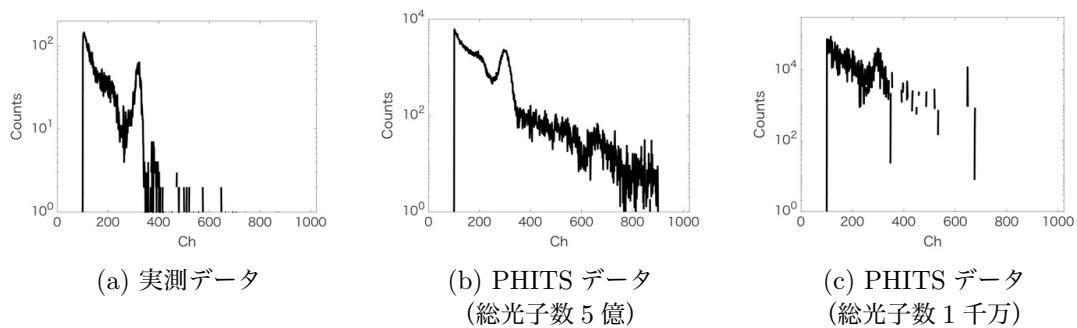


図 2 PHITS シミュレーションデータと実測データの比較 (1 個の検出器における例)

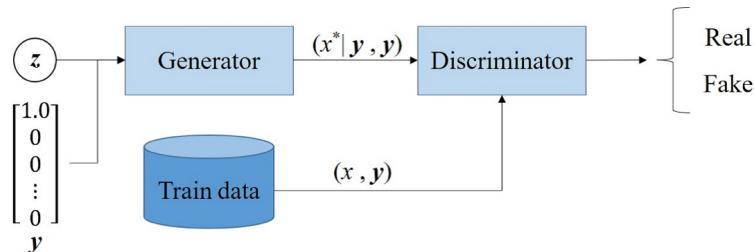


図 3 データ拡張のための条件付き敵対的生成ネットワーク (CGAN)

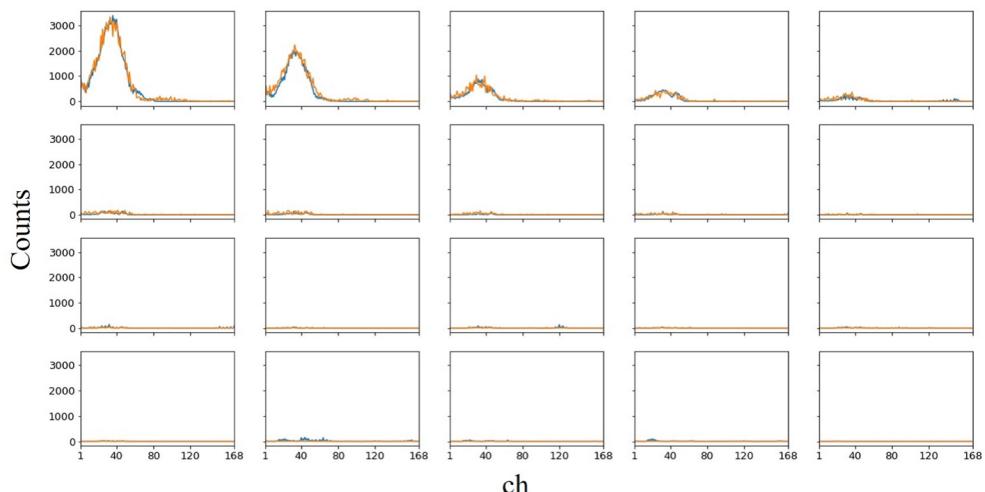


図 4 CGAN が生成した放射線エネルギースペクトルデータの一例

図5に示すとおり、放射線強度深度分布推定用CNNの入力層には20個のセンサから得られる168ch分の放射線スペクトルデータを入力するために 20×168 個のノードを用意し、出力層には、測定された放射線スペクトルデータから各層のRI強度分布を推定させるためのノードを20個を配置した。CGANで拡張した12万個(6千種類 \times 20層分)のデータのうち、10万個(5千種類 \times 20層分)を学習させ、残りの2万個(1千種類 \times 20層分)を評価用データとした。10万個のデータに対して標準化等の前処理を施した上でCNNに学習させた結果、学習用データに対して99.9%、評価用データについては100.0%の正解率を得た。なおCNNの20個の出力値に対し、「RIが存在する層において誤差率が±10%以内かつRIが存在しない層においてはCNNの出力値が0.1未満」であれば正解と定義した。

次に、RIが単一層に存在する場合の放射線エネルギースペクトルデータを組み合わせることにより、RIが複数層に存在する場合の放射線エネルギースペクトルデータを計17万1千個作成した。RIが複数層に存在する場合でも放射線強度深度分布を高精度に推定できるようCNNの構造を改良した結果、1万7千個の評価用データに対して98%以上の正解率を得ることができた[10]。最後に、構築したCNNを小型IoTデバイスの一つであるNVIDIA Jetson Nanoに実装した。

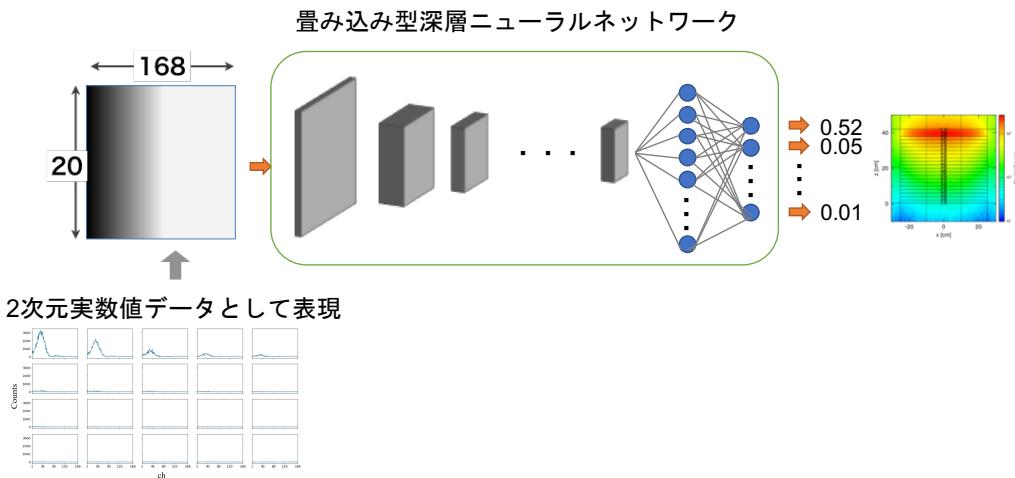


図5 放射線強度深度分布推定のための畳み込みニューラルネットワーク(CNN)

参考文献

- [1] 恩田 裕一, “試料採取法の確定,” *Radioisotopes*, vol. 62, no. 10, pp. 767–773, 2013.
- [2] F. Zapata (Editor), *Handbook for the Assessment of Soil Erosion and Sedimentation Using Environmental Radionuclides*, 1st ed., Springer, 2003.
- [3] N. Matsuda, S. Mikami, S. Shimoura, J. Takahashi, M. Nakano, K. Shimada, K. Uno, S. Hagiwara, and K. Saito, “Depth profiles of radioactive cesium in soil using a scraper plate over a wide area surrounding the Fukushima Dai-ichi Nuclear Power Plant, Japan,” *Journal of Environmental Radioactivity*, vol. 139, pp. 427–434, 2015.
- [4] T. Sato, K. Niita, N. Matsuda, S. Hashimoto, Y. Iwamoto, S. Noda, T. Ogawa, H. Iwase, H. Nakashima, T. Fukahori, K. Okumura, T. Kai, S. Chiba, T. Furuta, and L. Sihver, “Particle and Heavy Ion Transport code System, PHITS, version 2.52,” *Journal of Nuclear Science and Technology*, vol. 50, no. 9, pp. 913–923, 2013.
- [5] Y. LeCun and Y. Bengio, “Convolutional networks for images, speech, and time-series,” In M. A. Arbib (ed.), *The Handbook of Brain Theory and Neural Networks*, MIT Press, 1995.
- [6] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, “Generative Adversarial Nets,” *Proceedings of the 27th International Conference on Neural Information Processing Systems (NIPS’14)*, vol. 2, pp. 2672–2680, December, 2014.
- [7] M. Mirza and S. Osindero, “Conditional Generative Adversarial Nets,” arXiv:1411.1784, 2014.
- [8] 梅本 拓登, 鈴木 順也, 大林 史乃, 藤本 憲市, 阪間 稔, 井上 一雅, 福士 政広, 今城 裕介, 福原 隆宏, 遠藤 優崇, “放射能濃度深度分布推定のための深層学習データ生成法,” 日本放射線安全管理学会第19回学術大会, 2020.
- [9] 梅本 拓登, 藤本 憲市, 阪間 稔, 井上 一雅, 福士 政広, 今城 裕介, 福原 隆宏, 遠藤 優崇, “条件付き敵対的生成ネットワークによる放射線スペクトルデータの生成,” 令和3年度電気・電子・情報関係学会四国支部連合大会講演論文集, p. 65, 2021.
- [10] M. Azam, T. Umemoto, K. Fujimoto, M. Sakama, K. Inoue, M. Fukushi, Y. Imajyo, and M. Endo, “Development of Convolutional Neural Networks to Estimate Depth Distribution of Radioisotope in Soil Layers,” *Journal of Signal Processing*, vol. 27, pp. 103–106, 2023.

5. 主な発表論文等

[雑誌論文] 計1件 (うち査読付論文 1件 / うち国際共著 0件 / うちオープンアクセス 1件)

| | |
|---|-------------------------|
| 1. 著者名 Mohd Azam Bin Mohd Pauzi, Takuto Umemoto, Ken'ichi Fujimoto, Minoru Sakama, Kazumasa Inoue, Masahiro Fukushi, Yusuke Imaijo, Michitaka Endo | 4. 巻 27 |
| 2. 論文標題 Development of Convolutional Neural Networks to Estimate Depth Distribution of Radioisotope in Soil Layers | 5. 発行年 2023年 |
| 3. 雑誌名 Journal of Signal Processing | 6. 最初と最後の頁 103 ~ 106 |
| 掲載論文のDOI(デジタルオブジェクト識別子) 10.2299/jsp.27.103 | 査読の有無 有 |
| オープンアクセス オープンアクセスとしている(また、その予定である) | 国際共著 - |

[学会発表] 計3件 (うち招待講演 0件 / うち国際学会 1件)

| |
|--|
| 1. 発表者名 Mohd Azam Bin Mohd Pauzi, Takuto Umemoto, Ken'ichi Fujimoto, Minoru Sakama, Kazumasa Inoue, Masahiro Fukushi, Yusuke Imaijo, Michitaka Endo |
| 2. 発表標題 Development of CNN to Estimate Depth Distribution Spectrometry of Soil |
| 3. 学会等名 RISP International Workshop on Nonlinear Circuits, Communications and Signal Processing 2023(国際学会) |
| 4. 発表年 2023年 |

| |
|--|
| 1. 発表者名 梅本 拓登, 藤本 憲市, 阪間 稔, 井上 一雅, 福士 政広, 今城 裕介, 福原 隆宏, 遠藤 倫崇 |
| 2. 発表標題 条件付き敵対的生成ネットワークによる放射線スペクトルデータの生成 |
| 3. 学会等名 令和3年度電気・電子・情報関係学会四国支部連合大会 |
| 4. 発表年 2021年 |

| |
|---|
| 1. 発表者名 梅本拓登, 鈴木順也, 大林史乃, 藤本憲市, 阪間 稔, 井上一雅, 福士政広, 今城裕介, 福原隆宏, 遠藤倫崇 |
| 2. 発表標題 放射能濃度深度分布推定のための深層学習データ生成法 |
| 3. 学会等名 日本放射線安全管理学会第19回学術大会 |
| 4. 発表年 2020年 |

〔図書〕 計0件

〔産業財産権〕

〔その他〕

-
6. 研究組織

| | 氏名 (ローマ字氏名) (研究者番号) | 所属研究機関・部局・職 (機関番号) | 備考 |
|-------|---------------------------------------|------------------------------------|----|
| 研究分担者 | 阪間 稔 (Sakama Minoru) (20325294) | 徳島大学・大学院医歯薬学研究部（医学域）・教授 (16101) | |

7. 科研費を使用して開催した国際研究集会

〔国際研究集会〕 計0件

8. 本研究に関連して実施した国際共同研究の実施状況

| 共同研究相手国 | 相手方研究機関 |
|---------|---------|
| | |