

Environment Research and Technology Development Fund

## 環境研究総合推進費 終了研究成果報告書

1RF-1901 AI技術の活用による除去汚染土壌モニタリングシステムの開発  
(JPMEERF20191R01)

令和元年度～令和3年度

Development of a Monitoring System Utilizing Artificial Intelligence Technology for Removed  
Contaminated Soil

<研究代表機関>  
東京都立大学

<研究協力機関>  
徳島大学  
香川大学

○図表番号の付番方法について

「Ⅰ. 成果の概要」の図表番号は「0. 通し番号」としております。なお、「Ⅱ. 成果の詳細」にて使用した図表を転用する場合には、転用元と同じ番号を付番しております。

「Ⅱ. 成果の詳細」の図表番号は「サブテーマ番号. 通し番号」としております。なお、異なるサブテーマから図表を転用する場合は、転用元と同じ図表番号としております。

令和4年5月

## 目次

I. 成果の概要	1
1. はじめに（研究背景等）	
2. 研究開発目的	
3. 研究目標	
4. 研究開発内容	
5. 研究成果	
5-1. 成果の概要	
5-2. 環境政策等への貢献	
5-3. 研究目標の達成状況	
6. 研究成果の発表状況	
6-1. 査読付き論文	
6-2. 知的財産権	
6-3. その他発表件数	
7. 国際共同研究等の状況	
8. 研究者略歴	
II. 成果の詳細	9
II-1 AI技術の活用による除去汚染土壌モニタリングシステムの開発 （東京都立大学）	
要旨	
1. 研究開発目的	
2. 研究目標	
3. 研究開発内容	
4. 結果及び考察	
5. 研究目標の達成状況	
6. 引用文献	
III. 研究成果の発表状況の詳細	27
IV. 英文Abstract	30

## I. 成果の概要

課題名 1RF-1901 AI技術の活用による除去汚染土壌モニタリングシステムの開発  
 課題代表者名 井上一雅 (東京都立大学人間健康科学研究科教授)

重点課題 主：【重点課題④】災害・事故に伴う環境問題への対応に貢献する研究・技術開発  
 副：【重点課題③】環境問題の解決に資する新たな技術シーズの発掘・活用

行政要請研究テーマ（行政ニーズ）（1-5）災害廃棄物のリサイクルシステムの強靱化に関する研究

研究実施期間 令和元年度～令和3年度

### 研究経費

17,903千円（合計額）

（各年度の内訳：令和元年度：5,980千円、令和2年度：5,951千円、令和3年度：5,972千円）

### 研究体制

（サブテーマ1）AI技術の活用による除去汚染土壌モニタリングシステムの開発（東京都立大学）

### 研究協力機関

徳島大学  
 香川大学

本研究のキーワード 放射能深度分布、放射性セシウム、In-situ測定、福島第一原子力発電所、ディープラーニング

## 1. はじめに（研究背景等）

福島第一原子力発電所事故により生じた土壌汚染問題に対して、「除去汚染土壌の減容化」と「仮置場・中間貯蔵施設での適正管理」が求められている。IAEA専門家会合のレポートでは、今後の除去土壌の管理という主要課題が残っていると報告されている。除去汚染土壌の減容化については、除染対象面積が1,800平方キロメートルと推定されており、表土5 cmを剥ぐとした場合、除去汚染土壌量は4億立方メートルと概算できる。そのため、相当な減容化がされない限り保管スペース等の問題から長期的な継続が困難となる。仮置場・中間貯蔵施設での適正管理については、定期的な地下水の測定により管理されているが、空間線量率測定用モニタリングシステムのように連続的な計測がされておらず、かつ実際に土壌中濃度を計測していないため放射性セシウムの沈降を直接的に管理することは困難である。

本問題解決のため、環境研究総合推進費（2016年度－2018年度）において放射能深度分布測定器の開発を行い、10分程度で表層より40 cmまでの深度で各層（2 cm間隔）の放射性セシウム濃度を計測可能とした。また、各層に設置された計測部においてエネルギースペクトルを計測することができ、天然放射性核種と放射性セシウムを区別して計測可能である。本装置を仮置場・中間貯蔵施設のニーズに合致した形で実用化できれば、現場で深度分布調査を完結させることができ、除染対象区域ごとに適正な表土剥ぎ取り厚の決定ができ除去汚染土壌の減容化に寄与する。仮置場・中間貯蔵施設にお

いては、放射性セシウムの沈降を連続的にかつ直接計測できるため、適正な管理を実現することが可能になる。

## 2. 研究開発目的

本研究では、中間貯蔵施設向けの「除去汚染土壌用のモニタリングシステム」および一般市民レベルで取り扱いが容易な「可搬型深度分布測定器」の開発を目指す。具体的な研究開発の目標として、「①AIの学習精度（測定精度）の向上」については、校正場の設置、本研究実施期間を通してPHITSシミュレーション精度の向上と高速化および多種多量の学習データの収集とニューラルネットワークの改良を実施し、目標とする測定精度を±10%以下となることを目指す。除去汚染土壌の仮置場および中間貯蔵施設に設置を想定した「②除去汚染土壌用のモニタリングシステムの開発」では、既存の装置をベースとして、完全防水化、リアルタイム計測結果表示装置、電源装置およびデータ転送部の搭載を行う。本システムの構築においては、実用化を図るために空間線量率測定用モニタリングシステムの設置費用の半分以上の費用で設置可能な仕様を検討する。避難指示解除準備区域の復旧・復興のための環境整備の加速化・効率化を図るために開発を行う「③可搬型深度分布測定器」では、既存の装置は、棒状の計測部とデータ解析・表示部が独立した構造となっているが、これらを一体型の装置とし、かつ軽量化を図ることにより可搬型装置の開発を行う。本装置開発では、除染作業、行政機関の貸出しによる一般市民の利用を想定して、取扱いが容易な仕様とする。

## 3. 研究目標

全体目標	本研究では、種々の社会的ニーズに対応する放射能濃度深度分布を計測可能な計測システムの開発を目指し、次の段階的な研究目標を設定した。①AI技術を利用して構築した機械学習システムの精度向上を目的とした多種多量の実測およびシミュレーションデータの収集、機械学習システムの構造の最適化と計測精度の定義化により、最終的な測定精度を±10%以下とした。②除去汚染土壌モニタリングシステムおよび可搬型汚染土壌計測システムの設計およびプロトタイプシステムの構築、③実証実験の結果を踏まえたプロトタイプシステムの改良により、これまでに提案のない除去汚染土壌モニタリングシステムと装置容積が既存の装置の1/2程度、かつ重量が5 kg程度の可搬型汚染土壌計測システムを構築する。
------	--

サブテーマ1	AI技術の活用による除去汚染土壌モニタリングシステムの開発
サブテーマリーダー/所属機関	井上一雅/東京都立大学
目標	全体目標と同一

## 4. 研究開発内容

平成28年度～平成30年度に実施した環境研究総合推進費（多チャンネル放射能深度分布測定器の実用化とIn-situ測定法の確立）において開発した放射能深度分布測定器をベースとして、任意の場所で計測が可能な可搬型汚染土壌計測システムおよび中間貯蔵施設向けに中長期間の設置を想定した除去汚染土壌モニタリングシステムの開発を実施した。加えて、土壌中放射能濃度の計測においてAI

技術（ニューラルネットワーク）を活用し、現場、実験室およびモンテカルロシミュレーションにより得られた多種多量の学習データを用いてニューラルネットワークの精度を向上させた。研究開発の全体像は図4.1に示す通りである。



図4.1 研究開発の全体像

#### 4. 1 可搬型汚染土壌計測システムおよび除去汚染土壌モニタリングシステムの開発

可搬型汚染土壌計測システムおよび除去汚染土壌モニタリングシステムの開発において、既存の装置は計測結果が計測器本体内に設置された液晶画面に表示される仕様となっていたが、複数箇所での計測結果を一元管理できるシステムを構築した。可搬型および設置型深度分布測定器の概要を図4.1.1に示す。また、検出部および接続ケーブルは完全防水化を行い、検出部を任意の深さに設置可能とする。これにより、土壌・地下水のモニタリングを可能とした。可搬型汚染土壌計測システムで

は、電源バッテリーを搭載した小型・軽量タイプのシステムを構築した。さらに、除染作業員および一般市民の使用を想定し、取扱い方法および計測結果の表示方法を外部有識者の意見を参考に検討した。実証実験に際しては、国民と対話する機会を設けながら開発を行った。




図4.1.1 可搬型および設置型深度分布測定器の概要

#### 4.2 多種多量の実測およびシミュレーションデータの収集

深度分布測定器に装備されている20個の検出器で得られる情報はカウントである。そのため、検出器の応答特性を考慮してカウントから放射能濃度 (Bq/kg) に換算する必要がある。これは換算係数を導入することで問題は解決するが、問題点として、2.0 cm間隔に設置した検出器間に遮蔽体等を設置していないため、各深度における正確な計測情報を得るためには検出器に対して斜入する放射線の影響を除去する必要がある。放射線は物理的な特性（衝突と輸送の繰り返し）に従って透過・減衰していくため、斜入した放射線の出力信号はガンマ線スペクトル（応答関数）において異なるものとなる。そこで、この変化を後述するニューラルネットワークに学習させて、斜入する放射線の影響を除去することを検討した。

ニューラルネットワークの構築には、多種多量の学習データが必要である。そこで、実測データの取得に際しては、福島県内の帰還困難区域において、可搬型測定器を用いて学習データの収集を行った。これと同時に、従来から深度分布調査に使用されていたスクレーパープレートを用いて1 cm毎に表層より深度30 cmまでの土壌を採取して、高純度ゲルマニウム半導体検出器を用いて放射性セシウムの濃度 (Bq/kg) を計測して教師データを取得した。これにより、ニューラルネットワークの入力データ（可搬型測定器で得られた結果）と出力データ（スクレーパープレートで得られた結果）を取

得でき、ニューラルネットワークの学習データとして利用した。上記に加えて、現場で得られた実測結果のみでは、学習に必要なデータ数を確保できないため、実験室内に現場環境を可能な限り模擬した校正場を設置して実測データの収集を実施した。校正場は、Cs-137点線源用のアクリル製のトレイ（35 × 10 × 2 cm）を20段積層したものと、Cs-137面線源用にドーナツ状のトレイを20段積層したものを作成した。これらの校正場は、線源の位置や強度を任意に変更できる仕様とし、多種多量のデータを計測できる体系を構築した。

上記の実測に加えて、放射線挙動解析に使用されるモンテカルロ・シミュレーションを用いて、実測では再現が困難な条件下での計測結果を得られる計算体系を構築した。具体的には、(1)可搬型深度分布測定器の放射線検出プローブ設計図からのPHITS計算空間へのジオメトリー記述、(2)点線源用校正場におけるPHITS計算のためのジオメトリー記述、(3)PHITS計算パラメータ条件の最適化、(4)実測データと比較したPHITSシミュレーション計算試行回数の最適化、(5)多量のPHITS計算結果を創出することを目的とした計算機ハードウェアの改善、(6)ジオメトリー体系記述の四面体構造メッシュ化による計算精度の向上、(6)計算時間の短縮を目的としたdumpデータベース化を順次実施した。これらの取組みにより多種多量の学習データの取得を行った。

#### 4.3 ニューラルネットワークの最適化

構築を目指すニューラルネットワークの精度を向上させるためには、実測データを忠実に再現した良質な多種多量の学習データが必要不可欠である。そこで、モンテカルロシミュレーションにより作成した学習データと実測データとの類似度について数学的指標を用いて検討し、モンテカルロシミュレーションを用いた学習データの生成にフィードバックさせた。次に、シミュレーションによる学習データの作成には膨大な時間を要することから、2つの深層ニューラルネットワークから構成される条件付き敵対的生成ネットワークを用いてデータ拡張（データの水増し）することを検討した。これにより、実測、シミュレーションおよびデータ拡張により作成した多種多量の学習データをニューラルネットワークの学習データに用いて、機械学習システムの精度向上を行った。これに加えて、ニューラルネットワークの構造について検討を行った。これまでの構造は計5層で構成された深層ニューラルネットワークを利用していたが、畳み込み型深層ニューラルネットワークを使用できるように改良し、学習精度の向上を目指した。

## 5. 研究成果

### 5-1. 成果の概要

#### 可搬型汚染土壌計測システムおよび除去汚染土壌モニタリングシステムの開発

試作段階の測定器をベースとして可搬型および設置型深度分布測定器の開発を行った。計測システムは、検出器部（47×3 cmφ）、解析部（24×16×9 cm）、データ表示部（汎用型PC）および接続ケーブル（2 m）から構成されている。実際の計測では、接続ケーブルを介さずに検出器部と解析部を直接接続でき、解析部内に設置されている小型PCとデータ表示させるためのPCをWi-Fi接続できる仕様となっている。これにより、計測機器が複数あった場合においても計測結果を一カ所に集約管理できる体制を構築した。加えて、本改良により従来の装置と比較して重量を半分以下の4.4 kgまで軽量化させることが可能であった。さらに、防水仕様とすることで雨天時の測定も可能とした。

設置型タイプの開発では、中長期間の連続測定に耐えられるようにステンレススチール製の筐体（53×47×94 cm）を設計し、その内部に産業用PC、モニターおよび解析部を設置可能な仕様とした。

電源については、電源アダプタを新たに設置してAC100Vに対応する仕様とした。これにより、中間貯蔵施設等に設置されている電源設備から電源を確保することにより、中長期的な測定を可能とした。実際に福島県内において一ヶ月間の実証実験を行い、地下水の上昇による計測結果の変化を計測することに成功し、目的とする設置型モニタリングシステムの要件に達したことを確認した。

### 多種多量の実測およびシミュレーションデータの収集

実験室内にCs-137点線源および面線源用の校正場を設置した。線源と検出器間の距離、線源の設置場所および線源強度を可変させてニューラルネットワーク用の学習データの収集を行った。

これと同時に、上記の校正場を仮想空間上に再現し、PHITS計算空間へのジオメトリー体系を構築した。その後、実測データに類似した結果が得られるようにパラメータの最適化を行い、実測の光電ピークのエネルギー分解能に一致したデータ収集が行える計算体系を構築した。しかし、現状の計算体系では、1セットデータ（20層分のデータ）を得るために約50時間を有することから、計算器システムの再構築と、PHITS計算における四面体構造メッシュ化およびdumpデータベース化を試み、計算速度の高速化を行った。これにより、ヒストリー数を1億と設定した場合において、計算時間を50時間から1.5時間に短縮することが可能であった。これにより、精度と計算速度を両立したPHITS計算体系を用いて400個（20層×20セット）作成してニューラルネットワークの学習データとした。

### ニューラルネットワークの最適化

構築を目指すニューラルネットワークの高精度化には、シミュレーションに作成されたデータが現場で計測された実測データを忠実に再現していることが求められる。そこで、二つの確率分布間の類似度を表すカルバック・ライブラー・ダイバージェンス（Kullback-Leibler divergence: KL divergence）を用いて、シミュレーションデータ $P$ と実測データ $Q$ との類似度を定義してモンテカルロシミュレーションにおけるヒストリー数の最適化を検討した。ヒストリー数が多くなるにしたがいシミュレーションデータが実測データにより近づくことが例証されたが、シミュレーション時間を勘案し、PHITSにおけるヒストリー数を100,000,000（1億）に設定した。

次に、深層ニューラルネットワークをベースとした条件付き敵対的生成ネットワーク（Conditional Generative Adversarial Networks: CGAN）を用いたデータ拡張（水増し）を検討した。本研究では、放射線源のある単一層にのみ仮想配置した200個（10種類×20層）のデータに対して加算平均をとってガウスノイズを重畳した計20,000個のデータを条件付き敵対的生成ネットワークに学習させた。更に、ある単一層に強度1.0の放射線源が存在する条件ラベルを学習後の条件付き敵対的生成ネットワークに与え、1層ごとに6,000個、計120,000個の疑似データを作成した。

拡張データから放射線源の位置と強度を推測するための機械学習システムとして使用する深層ニューラルネットワーク（Deep Neural Network: DNN）の構造の最適化について検討した。これまでの深層ニューラルネットワークの構造は計5層で構成されていたが、合計で1,710個（総光子数1千万）のシミュレーションデータを学習させた場合、計測の精度は誤差10%としたときの学習用データに対する正解率は59.0%、検証用データに対する正解率は17.7%と、その推定精度はかなり低い結果であった。しかし、畳み込み型深層ニューラルネットワーク（Convolutional Deep Neural Network: CDNN）を使用できるように改良し、この畳み込み型深層ニューラルネットワークに対して条件付き敵対的生成ネットワークで作成した6,000個×20層分のデータのうちの5,000×20層分を学習させた結果、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%と大幅に向上した。



これを踏まえて、学習済みの畳み込み型深層ニューラルネットワークを組み込んだ可搬型深度分布測定器を用いて福島県内の帰還困難区域において実証実験を行った。スクレーパープレート法で得られた放射能濃度を正解として、最大放射能濃度を示す位置を同定し、かつその層における放射能濃度を誤差10%以内で計測することが可能であった。

## 5-2. 環境政策等への貢献

### <行政等が既に活用した成果>

特に記載すべき事項はない。

### <行政等が活用することが見込まれる成果>

除去汚染土壌用のモニタリングシステムを設置することにより、除去汚染土壌の直下にある土壌・地下水をリアルタイムに直接計測可能となり、かつ複数の測定地点で得られた計測データを無線化により1箇所を集約できるため、人員配置を含めた現場管理の効率化と適正化を図ることができる。また、計測結果を空間線量率モニタリング結果と同様にリアルタイムにホームページ等で公表可能となり、安心・安全な地域社会づくりに貢献できる。加えて、太陽光発電・蓄電システムを併設することにより、地震や近年多発している豪雨にともなう災害時の迅速な対応技術となる。

取扱いが容易な可搬型深度分布測定器を実用化することにより、任意の現場で深度分布調査を完結でき、除染作業で実施されている表土の剥ぎ取り厚の適切なコントロールが可能となり、過剰な剥ぎ取りや剥ぎ取り不足を抑止でき、除染の効率化や減容化を図ることができる。また、天地返し後の農地再開時および住民の帰還に際しては、適切に土壌の入れ替えが実施されているか、宅地内が適切に除染されているかを住民自身で確認することができ、住民の不安解消に寄与する。

## 5-3. 研究目標の達成状況

中長期的な土壌中放射性セシウムの動態をモニタリング可能な「除去汚染土壌用のモニタリングシステム」および従来比で約半分の重量まで軽量化した一般市民レベルで取扱いが容易な「可搬型深度分布測定器」の開発に成功した。測定精度については、校正場の構築、PHITSシミュレーションの高精度化と高速化の両立およびニューラルネットワークの最適化により、当初の目標値である±10%以下を達成した。

## 6. 研究成果の発表状況

### 6-1. 査読付き論文

#### <件数>

1件

#### <主な査読付き論文>

- 1) M. SAKAMA, K. FUJIMOTO, K. INOUE, M. FUKUSHI, Y. IMAJO, T. FUKUHARA, M. MATSUURA, M. YAJIMA, M. ENDO, M. FUJISAWA, E. MATSUMOTO: Radiation Protection Dosimetry, 184(1-3), 328-333 (2019) (IF:0.831) Feasibility study on the fusion of PHITS simulations and the DLNN algorithm for a new quantitative method of in-situ multiple-channel depth distribution spectrometer.

## 6-2. 知的財産権

- 1) 井上一雅、福土政広、阪間稔、藤本憲市：東京都立大学；「放射線測定器」、特許6889476号、令和3年5月25日

## 6-3. その他発表件数

査読付き論文に準ずる成果発表	0件
その他誌上発表（査読なし）	2件
口頭発表（学会等）	3件
「国民との科学・技術対話」の実施	1件
マスコミ等への公表・報道等	0件
本研究に関連する受賞	0件

## 7. 国際共同研究等の状況

特に記載すべき事項はない。

## 8. 研究者略歴

研究代表者

井上 一雅

首都大学東京大学院（現 東京都立大学大学院）修了、保健科学博士、現在、東京都立大学教授

研究分担者

特に記載すべき事項はない。

## II. 成果の詳細

### II-1 AI技術の活用による除去汚染土壌モニタリングシステムの開発

東京都立大学

人間健康科学研究科

井上 一雅

<研究協力者>

東京都立大学 人間健康科学研究科

福士 政広

徳島大学 医歯薬学研究部

阪間 稔

香川大学 創造工学部

藤本 憲市

#### [要旨]

福島第一原子力発電所事故により生じた汚染土壌に対する合理化が求められている。これまでの調査において、放射性セシウムの深度分布は土壌種や地形に依存して深度分布が異なるため、深度分布調査を実施することが必要となる。現在の深度分布調査方法は、スクレーパープレートを用いて土壌を採取して、採取土壌を実験室内に設置されている装置で計測が必要である。そのため、土壌を採取してから結果を得るまでに1週間程度の時間を要する。本研究では、中長期的に除去汚染土壌のモニタリングが可能な設置型深度分布測定器および一般市民が利用可能な可搬型深度分布測定器の開発を実施した。本測定器の計測精度は±10%以下となるように目標値を設定した。設置型深度分布測定器の開発では、約1ヶ月間の検証を行い、降雨等に起因した地下水の上昇など現場環境の変化を反映した計測結果が得られ、当初の目標を達成した。可搬型深度分布測定器の開発では、試作段階の測定器に対して約半分の重量に軽量化し、一般市民レベルで取り扱いが容易な測定器の開発に成功した。測定精度については、現場環境を可能な限り再現した深度分布測定器専用の校正場の構築、PHITSシミュレーションの高精度化と高速化の両立および深層ニューラルネットワークの最適化により、当初の目標値である±10%以下を達成することが可能であった。これらの成果により、深度分布調査を放射能濃度に依存して10～30分程度に短縮することが可能となった。今後、本研究成果を基盤として、除染作業の合理化と除去汚染土壌を管理する中間貯蔵施設などでの利用が期待できる。

#### 1. 研究開発目的

本研究では、「除去汚染土壌用のモニタリングシステム」および一般市民レベルで取り扱いが容易な「可搬型深度分布測定器」の開発を目指す。具体的な研究開発の目標として、「①AIの学習精度（測定精度）の向上」については、校正場の設置、本研究実施期間を通してPHITSシミュレーション精度の向上と高速化、および多種多量の学習データの収集とニューラルネットワークの改良を実施し、目標とする測定精度を±10%以下となることを目指す。除去汚染土壌の仮置場および中間貯蔵施設に設置を想定した「②除去汚染土壌用のモニタリングシステムの開発」では、既存の装置をベースとして、完全防水化、リアルタイム計測結果表示装置、電源装置およびデータ転送部の搭載を行う。本システムの構築においては、実用化を図るために空間線量率測定用モニタリングシステムの設置費用の半分以下の費用で設置可能な仕様を検討する。避難指示解除準備区域の復旧・復興のための環境整備の加速化・効率化を図るために開発を行う「③可搬型深度分布測定器」では、既存の装置は、棒状の計測部とデータ解析・表示部が独立した構造となっているが、これらを一体型の装置とし、かつ軽量化を図ることにより可搬型装置の開発を行う。本装置開発では、除染作業、行政機関の貸出しによる一般市民の利用を想定して、

取扱いが容易な仕様とした。

## 2. 研究目標

本研究では、種々の社会的ニーズに対応する放射能濃度深度分布を計測可能な計測システムの開発を目指し、次の段階的な研究目標を設定した。①AI技術を利用して構築した機械学習システムの精度向上を目的とした多種多量の実測およびシミュレーションデータの収集、機械学習システムの構造の最適化と計測精度の定義化により、最終的な測定精度を±10%以下とした。②除去汚染土壌モニタリングシステムおよび可搬型汚染土壌計測システムの設計およびプロトタイプシステムの構築、③実証実験の結果を踏まえたプロトタイプシステムの改良により、これまでに提案のない除去汚染土壌モニタリングシステムと装置容積が既存の装置の1/2程度、かつ重量が5 kg程度の可搬型汚染土壌計測システムを構築する。

## 3. 研究開発内容

### 3.1 AI技術の活用による除去汚染土壌モニタリングシステムの開発

#### 除去汚染土壌モニタリングシステムの開発

本研究の目的を達成させるために、平成28年度～平成30年度に実施した環境研究総合推進費（多チャンネル放射能深度分布測定器の実用化とIn-situ測定法の確立）において開発した放射能深度分布測定器をベースとして除去汚染土壌モニタリングシステムの開発を実施した。研究開発実施前の放射能深度分布測定器は、CsI(Tl)シンチレータ（10 × 10 × 10 mm）、大面積Si PINフォトダイオードおよび電荷収集型プリアンプをそれぞれ20個装置した棒状の検出器、小型PCを搭載したデータ分析・表示部およびそれらを接続するケーブルで構成されていた（図3.1.1）。検出器部は20個のCsI(Tl)シンチレータを1 cm間隔に設置されており、深度40 cmまでの放射能濃度計測を1回の計測で可能である。実用化に向けた課題として、装置の完全防水化および電源バッテリーを搭載した小型・軽量タイプの可搬型放射能深度分布測定器の開発と、中間貯蔵施設等に設置することを想定した除去汚染土壌モニタリングシステムの開発が必要であった。本研究では、研究開始当初に計画をしていた完成イメージ図（図3.1.2）をベースとして、図3.1.3に示す2つの異なる放射能深度分布測定器を設計した。主な仕様を表3.1.1にまとめて示す。

可搬型放射能深度分布測定器では、電源バッテリーを搭載した小型・軽量タイプのシステムを目指し、不要な外部インターフェース等を取り除き、データ表示・分析部の大きさが従来と比較して約半分になるように設計をした。また、雨天時の測定を可能とするため検出器部を含めて完全防水仕様とし、計測結果の一元管理を可能とするためWi-Fiを利用して外部パソコンから制御・表示可能な仕様に設計した。除去汚染土壌モニタリングシステムでは、接続ケーブルを介して複数の検出器から得られたデータを一箇所に集約させることを可能とし、メンテナンスの効率性を重視して設計した。




図3. 1. 1 研究開発実施前の放射能深度分布測定器

可搬型汚染土壌計測システム  
(除染作業者・行政機関向け)

設置型除去汚染土壌モニタリング  
システム (仮置場等向け)




図3. 1. 2 研究開始当初に計画していた放射能深度分布測定器の完成イメージ図

可搬型汚染土壌計測システム

設置型除去汚染土壌  
モニタリングシステム




図3.1.3 放射能深度分布測定器の設計

表3.1.1 可搬型およびモニタリング型放射能深度分布測定器の主な仕様

部位	可搬型	モニタリング型
検出器	CsI(Tl)シンチレータ (10×10×10 mm) 20個 大面積Si-PINフォトダイオード20個 電荷収集型プリアンプ20個	CsI(Tl)シンチレータ (10×10×10 mm) 20個 大面積Si-PINフォトダイオード20個 電荷収集型プリアンプ20個
ロッド	ステンレススチール (厚さ：1.0 mm、直径：30 mmφ)	ステンレススチール (厚さ：1.0 mm、直径：30 mmφ)
検出器配置	表面から40 cm：2 cm間隔 (数量：20個)	表面から40 cm：2 cm間隔 (数量：20個)
波形整形アンプ	アクティブフィルタ型波形整形 (波形整形時定数：2 μs) 増幅率 2.0 keV/ch 測定可能レンジ 150 keV-1800 keV 入出力チャンネル 20 ch	アクティブフィルタ型波形整形 (波形整形時定数：2 μs) 増幅率 2.0 keV/ch 測定可能レンジ 150 keV-1800 keV 入出力チャンネル 20 ch
パルス波高分析	ピークセンシングADC コンバージョン分解能 1024 ch	ピークセンシングADC コンバージョン分解能 1024 ch
性能	エネルギー分解能 8.0% (Cs-137 662 keV) エネルギー校正 2.0 keV/ch (±5%)	エネルギー分解能 8.0% (Cs-137 662 keV) エネルギー校正 2.0 keV/ch (±5%)
制御プロセッサ	スタック型PC (BLKSTK2M364CC BLKSTK2M364CC) CPU：Intel® Core m3-6y30プロセッサ 64 GB eMMC OS：Windows10	産業用コンパクトPC (uIBX-250-BW-N3-R20) CPU：Intel® Celeron® N3160 (up to 2.24 GHz, quad-core, 2 MB cache, TDP=6W) OS：Windows10
表示部	Wi-Fiにて外部パソコンから制御・表示可能	8インチHDMIマルチ モニター (LCD-8000VH2B)
電源	大容量モバイルバッテリー： USB出力1 +5.0 V 2.1 A (max) (制御プロセッサ用) USB出力2 +5.0 V 1 A (max) 容量 23000 mAh 外部電源 AC電源アダプタ	AC100 V 外部蓄電池&ソーラー発電システム接続可能
データ記録	USBメモリ	内部HDD保存
インターフェイス	無	LAN、USB
GPS受信器	Bluetooth対応GPS (HOLUX社M-241)	GlobalSet社 (BU-353S4)
接続ケーブル	JIS-B-6015に準拠した防水丸型ワンタッチロックコネクタ ケーブル長 2 m	JIS-B-6015に準拠した防水丸型ワンタッチロックコネクタ ケーブル長 2 m

#### 実測実験による検出器応答特性の取得

検出器で得られる情報は、異なる深度に設置された個々の検出器で計測されるカウントである。そのため、個々の検出器の応答特性を考慮してカウントから放射能濃度 (Bq/kg) に換算する必要がある。問題点として、CsI(Tl)シンチレータ間に遮蔽体等を設置していないため、各深度における正確な計測情報

を得るためには検出器に対して斜入する放射線の影響を除去する必要がある。本問題の解決のために、後述するニューラルネットワークを構築することを計画したが、本研究項目では、ニューラルネットワーク用の学習データの取得を実測実験により実施した。予想される検出器応答特性の違いとして、例えば、表層に放射性セシウムが分布している場合、表層付近と深部で計測される波高分布は線源-検出器間距離に違いより異なることが予想される。この違いをニューラルネットワークで学習させることで、検出器に対して斜入する信号量を推定して除去することができる。

実測データの取得に際しては、福島県浪江町および大熊町の許可（公益一時立入り）を得て同町内の帰還困難区域において、改良した可搬型および設置型放射能深度分布測定器を用いて計測を行った。加えて、従来から深度分布調査に使用されていたスクレーパープレートを用いて1 cm毎に表層より深度30 cmまでの土壌を採取して、高純度ゲルマニウム半導体検出器を用いて放射性セシウムの濃度 (Bq/kg) を計測した。これらの調査により、放射能深度分布測定器で得られた計測結果とスクレーパープレートを用いて得られた真の放射能深度分布を取得した。これにより、ニューラルネットワークの入力データとなる深度分布測定器から得られた計測値と出力データ（正解）となる高純度ゲルマニウム半導体検出器から得られた放射能濃度を取得でき、ニューラルネットワークの学習データとして利用した。

上記に加えて、現地調査には多くの時間と費用を要し、かつ目標達成のために必要なデータ数を確保することが困難であることが予想されたため、実験室内に現場環境を可能な限り模擬した校正場を設置して実測データの収集を実施した。校正場の図面を図3.1.4に示すが、放射能深度分布測定器が挿入可能な直径30 mm φの穴の空いたアクリル製のトレイ (35 × 10 × 2 cm) を20個作成し、各トレイに土壌を充填し、それを回転テーブル上に積層した。校正用の線源には、市販されているCs-137点線源（線源強度：2.68 MBq）を使用した。点線源は、各層の土壌トレイに検出器中心から25、50、100、150および200 mmの位置に設置した。測定は、測定器のみを固定して、線源を設置した土壌トレイが回転する条件下で実施した。1回転に要する時間は27 sに設定した。これにより、検出器を中心として土壌トレイに設置したCs-137線源が一定の半径で回転してγ線が検出器側面より均等に入射される。これらの条件下で各層および異なる検出器-線源間距離において実測データを取得した。




図3.1.4 点線源を用いた校正場実験の概要（赤領域：点線源設置位置）

ニューラルネットワークの精度向上に向けて、可能な限り現場環境を実験室内で模擬した校正場が必要となる。そこで、図3.1.4で示した点線源用の校正場に加えて、面線源の利用が可能な検出器の全周を



覆うドーナツ状の試料皿（直径15 cm）を3Dプリンタで製作して、それを多層（20層）にした校正場を構築した（図3.1.5）。実験では、1層にCs-137汚染土壌、残りの19層は放射性セシウムを含有しない土壌を設置して計測した。同様に、連続した2層および3層をCs-137汚染土壌とした場合においても計測し、合計で288パターンでの計測データを取得した。




図3.1.5 円形多層型校正場の作成

#### 多種多量の実測およびシミュレーションデータの収集

原子力災害由来の放射性セシウムにより生じた汚染土壌に対する除染作業の合理化の目的のため、任意の現場で汚染土壌中の放射能濃度深度分布調査を完結できる可搬型かつ小型の放射能濃度深度分布測定器を開発してきた。これまで報告では、汚染土壌の深度方向に対する各層での放射能濃度を決定する際に考慮が必要な近傍層からの妨害放射線の影響を除去する弁別技術に、AI技術（階層型ニューラルネットワーク：Feedforward Neural Network）を導入して解決の糸口を示した。本検討では、AI技術の導入に必要な不可欠な多種多量の学習データの取得のため、現場および校正場でのデータ収集に加えて、仮想空間でのモンテカルロシミュレーション計算（PHITS計算）を実施した。

一般的に放射線挙動解析に使用されるモンテカルロ・シミュレーション計算手法では、放射線計測の実測環境場と放射線計測機器、特に、検出器部分の体系を計算空間上に精密に再現できるかがニューラルネットワークの精度向上のカギとなる。仮想空間上での可搬型深度分布測定器の設計図は、初期段階で2次元のCADで制作していたが、シミュレーション精度を向上させるために3次元のCADへ変換し、その後、PHITS計算体系に取り込むことで放射線輸送計算を実施可能な体系を構築した。

PHITS計算の最適化では、現場でのガンマ線計測時に発生する光電ピークの揺らぎ、つまり、光電ピークのエネルギー分解能を再現することが必要となる。このため、PHITS計算コード上で関連するパラメータの最適化を実施した。加えて、シミュレーション計算の精度に直接的に関係するヒストリー数（放射線発生インベントリーの総数）の検討およびdumpデータベース化による計算時間の短縮を行い、シミュレーション計算の高精度化と計算時間の短縮を両立可能な計算体系の構築を行った。計算の高精度化では、PHITS計算を実行する計算機数を増設すること（MacPro201928 コア56スレッド IntelXeonW-3275M CPUを整備：図3.1.6）や、並行施策として、Azureによるクラウドコンピューティングサービスや中規模ワークステーション（東京都立大学教育研究用情報システム研究支援システム）を利用した。Dump

データベース化においては、これまで四面体構造メッシュ化やハードウェアの改善策および計算機の増強などを行ってきたが、目標値を達成させるに至らない状況であったため、抜本的な見直しを実施した。PHITS計算システム手法の改善として、2段階計算手法を基本としたdumpデータベース化を試みた。PHITS計算コードのバージョンアップに即して、dumpデータベース化が柔軟に適用できる体制が整ったので、1段階目の計算では、20連の縦列したCsI(Tl)シンチレーション検出器すべてのボリュームに対して、放射線輸送計算を行わない外部ボイド領域に設定し、それら検出器までに入射する放射線挙動をランダムに記録する。ここまでの統計条件では、1億ヒストリーとした。次に、2段階目の計算では、さきほど外部ボイド領域とした20連の検出器ボリューム全てを外部ボイドから外し、放射線輸送できる状態として検出器内でエネルギー付与されるエネルギースペクトルを取得した。これにより、仮想空間上で限定された狭い領域のみを対象としてシミュレーションを実施することが可能となるため、計算時間の短縮に寄与することが期待された。



図3.1.6 構築した計算機

### ニューラルネットワークの最適化

機械学習システムの推定精度（正解率）を向上させるためには、まず良質（実測データを忠実に再現した）な学習データを機械学習システムに与える必要がある。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数学的指標により定義し、シミュレータのパラメータ調整に利用した。また、これまで使用していた正解の定義についても見直し、より自然な形へ変更した。次に、これまでに構築した機械学習システム（深層ニューラルネットワーク）の改良を検討した。

二つの確率分布間の類似度を表す数学的指標として、カルバック・ライブラー・ダイバージェンス（Kullback-Leibler divergence: KL divergence）がある。いま、 $P$  と  $Q$  を離散確率分布とするとき、 $P$  の  $Q$  に対する KL divergence は以下のように定義できる。

$$D(P \parallel Q) = \sum_{n=0}^N P(n) \log_{10} \frac{P(n)}{Q(n)}$$

ここで、 $P(n)$ 、 $Q(n)$  はそれぞれ  $n$  の値が選ばれたときの確率である。KL divergence は常に非負の値をとり、 $P$  と  $Q$  が同じ分布のとき  $D = 0$  となる。本検討では、この KL divergence を用いて、シミュレーションデータと実測データとの類似度を定義した。総光子数を 10,000,000（1千万）及び 500,000,000

(5億) とした場合のシミュレーションデータ、並びに、実測データのスペクトルを図3.1.7に示す。これらは地表直下の層に配置した面線源から放出される光子を地表直下の層に配置した検出器 (#1) で計測した結果であり、便宜上、それぞれを $P_1$ 、 $P_2$ および $Q$ で表すこととする。 $P_1$ と $Q$ および $P_2$ と $Q$ それぞれのKL divergenceを計算すると、 $D(P_1||Q) = 1.20$ 、 $D(P_2||Q) = 0.90$ となり、総光子数を5億としたシミュレーションデータ ( $P_2$ ) のほうがより実測データに近いといえる。




図3.1.7 シミュレーションデータと実測データの比較 (検出器#1)

総光子数を多くすることによってシミュレーションデータが実測データにより近づくことが例証されたが、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。そこで、図3.1.7に示した結果およ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、PHITSにおける総光子数を100,000,000 (1億) に設定した。

総光子数が1億であってもPHITSシミュレーションにはかなりの計算時間を要するため、大量の学習用データを用意するためには他の方法によるデータ拡張 (データの増し) が必要となる。そこで、二つの深層ニューラルネットワークから構成される条件付き敵対的生成ネットワーク (Conditional Generative Adversarial Networks: CGAN) を用いたデータ拡張 (水増し) を検討した。その構成図を図3.1.8に示す。条件付き敵対的生成ネットワークは、生成器 (Generator) と判別器 (Discriminator) から構成され、これら二つはそれぞれ独立した深層ニューラルネットワークである。生成器はノイズ  $z$  と放射線源の位置と強度を表す条件ベクトル  $y$  から擬似スペクトルデータを生成し、判別器は正解とするシミュレーションデータ (学習用データ) と生成器から出力された擬似データとを比較することで擬似データの真贋を判定する。このように、条件付き敵対的生成ネットワークは、生成器と判別器を敵対的に学習させることによって、生成器が次第にシミュレーションデータに酷似したデータを生成できるようになるという機械学習システムの一つである。

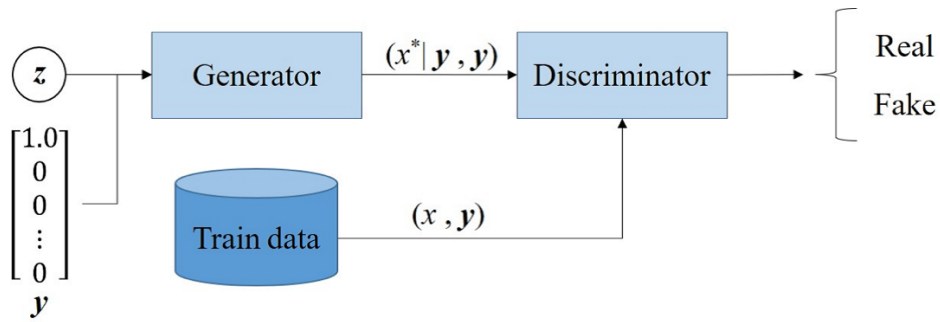


図3.1.8 条件付き敵対的生成ネットワークの構成図

本研究では、放射線源をある単一層にのみ仮想配置した400個（20種類×20層）のデータをPHITSで作成したあと、加算平均処理やガウスノイズ重畳処理を施すことによって、各層1,000種類で計20,000個のデータを作成した。この20,000個のデータを条件付き敵対的生成ネットワークに学習させる際に、計算効率化の観点から、敵対的生成ネットワークの規模をできる限り縮小させること、および想定核種の影響が多く現れるエネルギー帯のみに着目したデータを利用することとした。本研究における想定核種がCs-134とCs-137であることから、それらが発するエネルギー帯に相当するチャンネル265 ch～433 ch（計168 ch）のみに着目した。図3.1.9に、敵対的生成ネットワークに学習させたデータ（青色）と生成器からの出力（橙色）の一例を示す。敵対的生成ネットワークが学習データ（PHITSデータ）に酷似した擬似スペクトルデータを生成していることが見てとれる。

学習後、ある単一層に強度1.0の放射線源が存在する条件ラベルを条件付き敵対的生成ネットワークに与え、1層ごとに6,000個、計120,000個の疑似データを作成した。




図3.1.9 敵対的生成ネットワークの学習に用いるデータの一例

次に、機械学習システムの出力を正解とする定義について検討した。これまでの正解の定義を次に示す。

[旧定義] 線源が存在する層において誤差率が $\pm X\%$ 以内、かつ、その他の層においては、機械学習システムの出力が、線源の存在する層の許容範囲外であれば正解とする。

例えば、 $X = 20\%$ とし、上から2層目に強度0.5の線源を配置した場合に、機械学習システムが表3.1.2に示した値を出力したとする。この場合、検出器#2については誤差率(-10%)が $\pm 20\%$ 以内であり、他の検出器については $0.5 \pm 20\%$ の範囲外(つまり[0.4, 0.6]の範囲外)であるため、この例は正解と判定される。しかしながら、検出器#3をみれば、真値0に対して機械学習システムが検出器#2の真値よりも高い値(0.65)を出力しているにも関わらず、この例が正解とみなされることは不自然である。そこで、正解の定義を次のとおりに変更した。

[新定義] 線源が存在する層において誤差率が $\pm X\%$ 以内、かつ、線源が存在しない層においては機械学習システムの出力値が0.1未満であれば正解とする。

表3.1.2 機械学習システムの正解例

検出器#	真値 (教師データ) ( $t$ )	機械学習システム の出力 ( $y$ )	誤差率 [%] $((y-t)/t \times 100)$
1	0	0.005	$-\infty$
2	0.5	0.450	-10.00
3	0	0.650	$-\infty$
⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮
20	0	0.001	$-\infty$

次に、深層ニューラルネットワークの構造について検討した。これまでの深層ニューラルネットワークの構造を図3.1.10に示す。このニューラルネットワークは計5層で構成され、入力層は20,480個、中間層はそれぞれ1,024個、256個、500個、出力層は20個のノードをもつ。つまり、この深層ニューラルネットワークは、1,024 chをもつ20個の検出器におけるすべてのカウント値を深層ニューラルネットワークに入力すれば、第1層から第20層における線源濃度の推定値を出力する。学習させるデータは、単一層、連続する2層および3層に強度 $I = \{0.5, 1.0, 1.5\}$ の線源がある場合のシミュレーションデータ(計1,710個)であり、1つのシミュレーションにおける総光子数は1千万である。なお、学習結果を評価するために、学習用データと同様の検証用データを1,710個用意した。これら学習用データを学習させた結果、新定義において $X = 10\%$ としたとき、学習用データに対する正解率は59.0%、検証用データに対する正解率は17.7%であった。

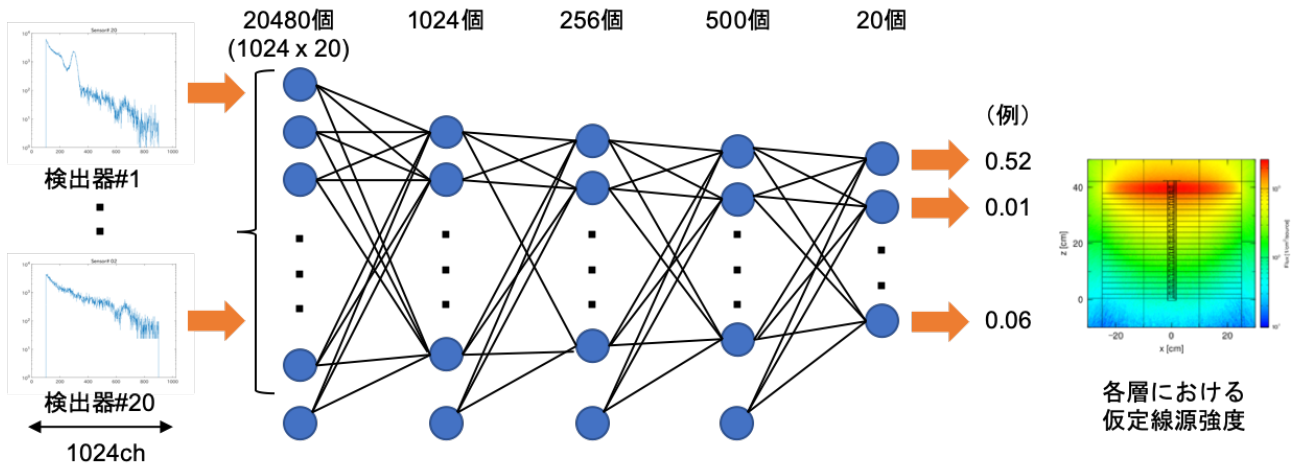


図3.1.10 旧システム（深層ニューラルネットワーク）の構造

この低正解率を改善すべく、まず前述のとおり、想定核種をCs-134とCs-137とすることで265 ch～433 ch（計168 ch）のみのデータを利用することにした。さらに、168 ch×20層分のデータを二次元データとして取り扱うことにより、図3.1.11に示す畳み込み型深層ニューラルネットワーク（Convolutional Deep Neural Network: CDNN）を使用できるように改良した。この畳み込み型深層ニューラルネットワークに対して、条件付き敵対的生成ネットワークで作成した6,000個×20層分のデータのうちの5,000×20層分を学習させた。

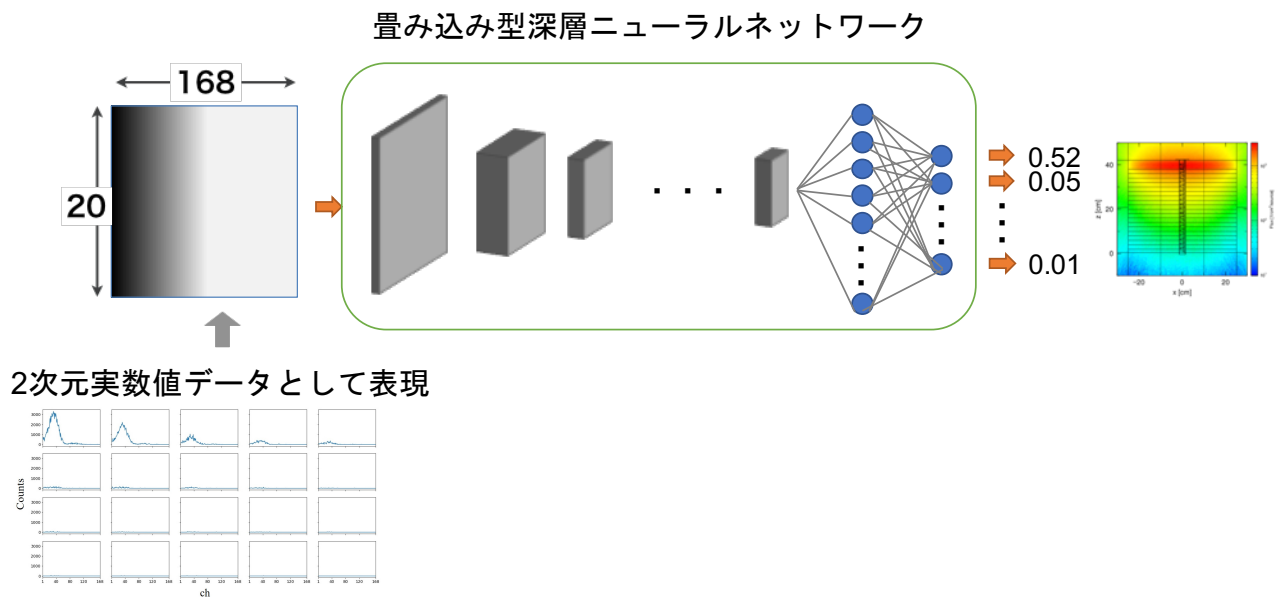


図3.1.11 新システム（畳み込み型深層ニューラルネットワーク）

## 4. 結果及び考察

### 4.1 AI技術の活用による除去汚染土壌モニタリングシステムの開発

#### 除去汚染土壌モニタリングシステムの開発

放射能深度分布測定器の実用化に向けて、図3.1.1に示した試作段階の測定器をベースとして可搬型および設置型深度分布測定器を開発した。図4.1.1に可搬型装置の外観を示すが、検出器部（47×3 cm

φ)、解析部(24×16×9 cm)、データ表示部(汎用型PC)および接続ケーブル(2 m)から構成されている。実際の計測では、接続ケーブルを介さずに検出器部と解析部を直接接続でき、解析部内に設置されている小型PCとデータ表示させるためのPCをWi-Fi接続できる仕様となっている。本改良により片手で携行できるほどの大きさおよび重量となった。また、防水仕様とすることで雨天時の測定も可能とした。

設置型タイプの開発では、中長期間の連続測定に耐えられるようにステンレススチール製の筐体(53×47×94 cm, 41.8 kg)を設計し、その内部に産業用PC、モニターおよび解析部を設置可能な仕様とした。電源については、電源アダプタを新たに設置してAC100Vに対応する仕様とした(図4.1.2)。これにより、中間貯蔵施設等に設置されている電源設備から電源を確保することにより、中長期的な測定が可能となる。福島県大熊町において1ヶ月間設置した代表的な結果を図4.1.3に示す。各検出器で得られた経時的な計測値の変化を示すが、計測期間内で計測値が一時的に低下した期間が2回観測された。気象庁の情報では、これらの期間の天候は雨であり、地下水の一時的な上昇により水による遮へい効果が高まり、結果として計測値が一時的に低下したと考えられた。これらの結果は、中長期的な測定において、地震や水害などの影響をモニタリングできることを示した結果である。

## データ表示




図4.1.1 可搬型放射能深度分布測定器の外観(左)と現場設置例(右)




図4.1.2 設置型放射能深度分布測定器（モニタリングポスト）の外観

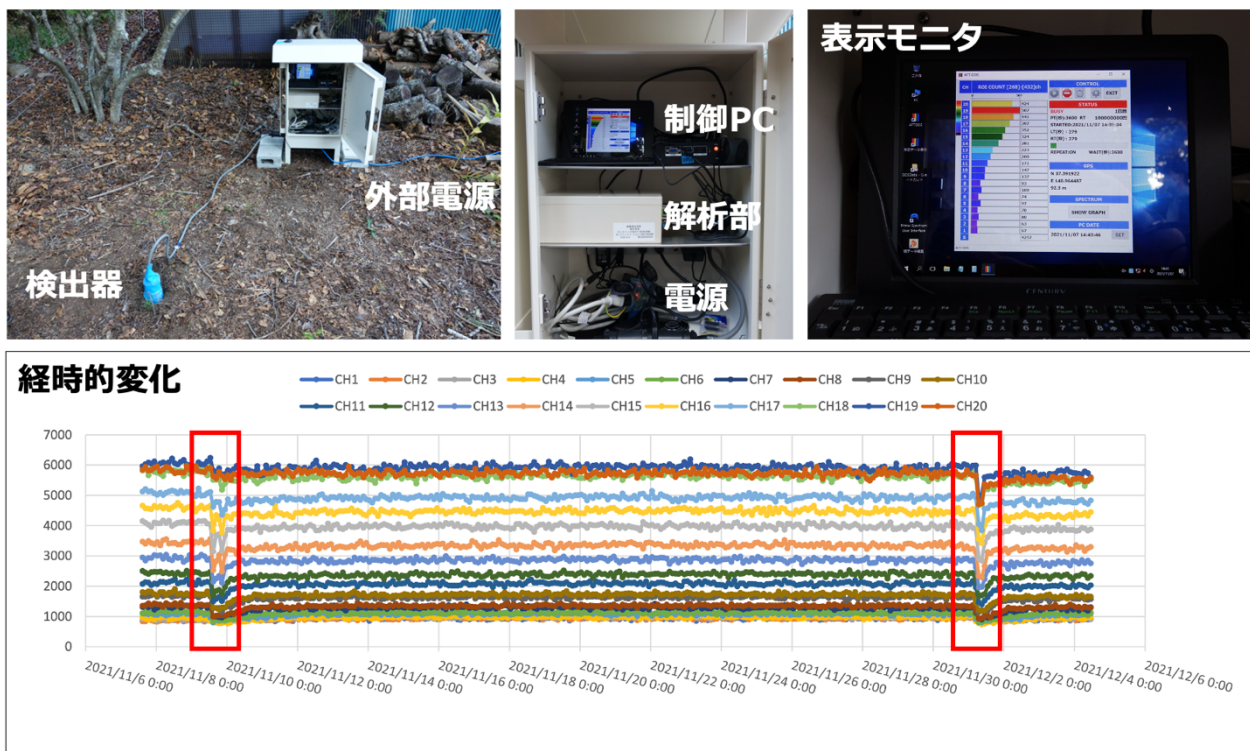


図4.1.3 設置型放射能深度分布測定器の設置例と代表的な計測結果

実測実験による検出器応答特性の取得

放射性セシウムによる汚染のないことを確認されている土壌（真砂土）をアクリル製トレイに入れ、積層（20段：40 cm）した校正場を用いて実測データを収集した。アクリル製トレイの大きさは、事前のPHITSを用いたシミュレーション実験の結果をもとにして35×10×2 cmとした。また、アクリル製トレイの端から10 cmの位置に直径3 cmの穴を開けて深度分布検出器を挿入できる仕様とした（図4.1.3）。実験では、<sup>137</sup>Cs点線源をトレイに設置して、検出器中心より25 mmから250 mmの位置に設置して計測を行った。加えて、ドーナツ状の校正場において、<sup>137</sup>Cs面線源を任意の段目に設置して計測を行った。いずれの場合においても、線源設置位置をピーク中心として正規分布に似た分布が得られた（図4.1.4、図4.1.5）。



波高分析により得られた各チャンネルのカウント数を比較した場合、例えば、1層目 (D1) に線源を配置して計測を行い、D1と10層目 (D10) で得られたデータを比較すると、放射性セシウムから放出された $\gamma$ 線に起因して生成された光電ピークの高さおよび形状に明確な違いを示した。これは、線源-検出器間距離の違いに起因し、結果として放射性セシウムから放出された $\gamma$ 線と土壌との相互作用の発生割合 (減弱) に差が生じるためである。これらの違いについて、実測データと答えとなる出力データをAI機械学習システムに入力することで学習させて、検出器に対して斜入する信号量を推定して除去することができる。本検討では、ニューラルネットワークに入力する学習データの収集を行った。




図4.1.3 点線源用の校正場を用いた実測データ収集

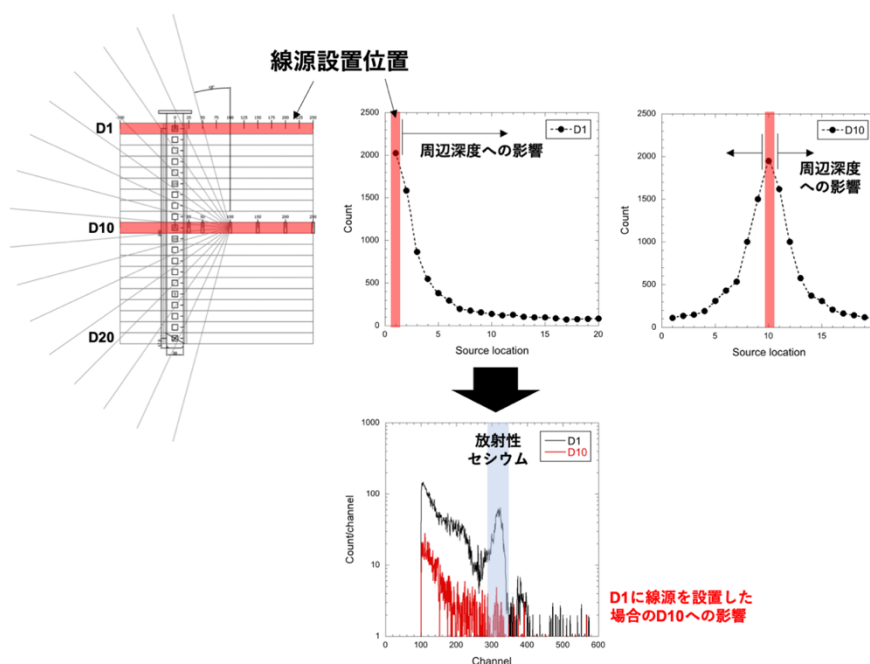


図4.1.4 点線源用の校正場を用いた実測データの代表例




図4.1.5 面線源用の校正場を用いた実測データの代表例

#### 多種多量の実測およびシミュレーションデータの収集

多種多量のシミュレーションデータの収集に向けて、図4.1.4に示した校正場を仮想空間上で再現させるため、PHITS計算空間へのジオメトリ体系の記述を実施した。特に、当該ジオメトリ体系の記述は比較的大型であったので、設計上の問題となる干渉が発生しないように繰り返しPHITSコード記述を実践することで、複雑な形状への対応を行った（図4.1.6）。




図4.1.6 校正場を再現したモンテカルロシミュレーション計算体系

PHITS計算におけるパラメータの最適化について、光電ピークのエネルギー分解能をシミュレーション計算でのパラメータに関するポイントが、PHITS計算コード上の「dresol」と「dfano」のパラメータとなる。ここで、 $dresol = \sigma$ 、 $dfano = F$ とした場合、本研究開発で対象となるCs-137のガンマ線ピーク（662 keV）では、シミュレーション計算においてCsI(Tl)シンチレーション結晶内でそのエネルギーが付与されると、スペクトル上に表示される光電ピークのエネルギー分解能（標準偏差）は、

$\sqrt{\sigma^2 + F \times 662}$ で評価される。このため、これらパラメータを関数値として繰り返し計算を実施することで、実測の光電ピークのエネルギー分解能に一致させることが可能であった。

四面体構造メッシュ化とdumpデータベース化によるシミュレーションの高速化について、図4.1.7に示すように計算体系の最適化を行った。Dump1段目の計算では、CsI(Tl)検出器（20個）自体を外部ボイドとして、それらの中に入るまでの情報を生成する。次に、Dump2段目では、放射線のランダム性は維持しつつ、20個の検出器内だけで計算を行う。初回の計算のみ、1億ヒストリー数のデータセット（20層）を1セット計算するために50時間を要するが、2セット目以降の計算時間を従来比で約34倍の高速化が可能であった。具体的には、図3.1.6に示した計算機を利用した場合、従来の50時間から1.5時間に短縮された。これらの手法を用いて、ヒストリー数を1億と設定して400個（20層×20セット）作成した。

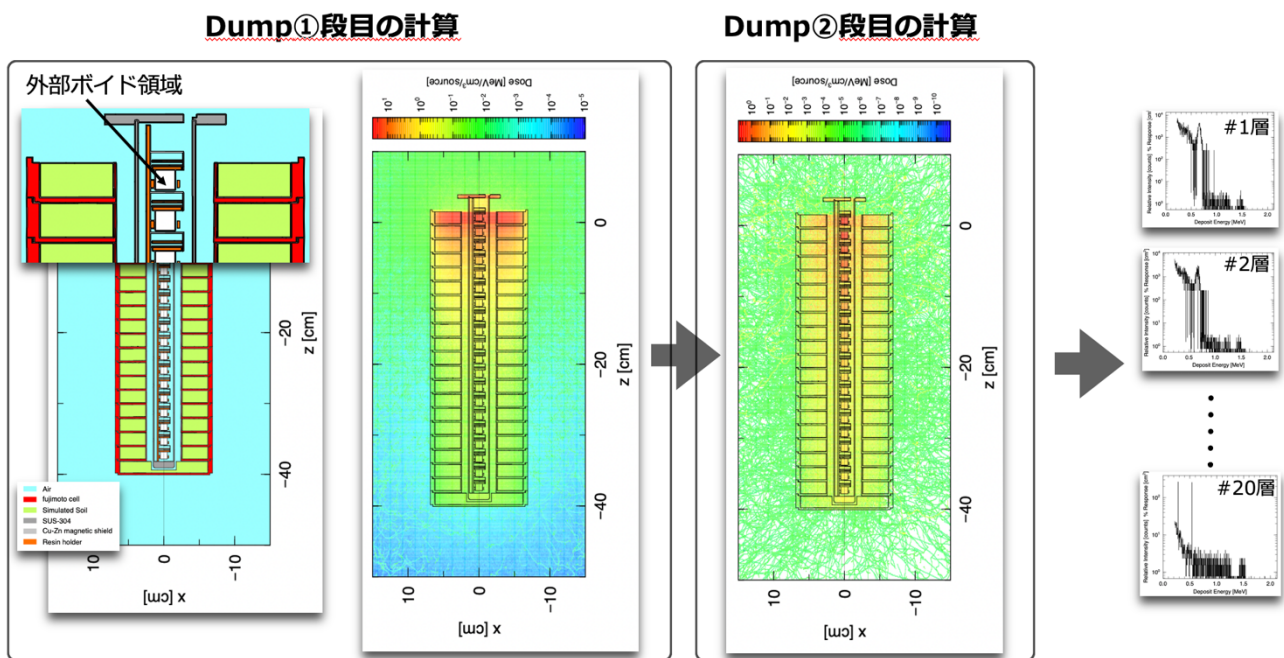


図4.1.7 PHITS 計算システム手法における dump データベース化の手順

### AI機械学習システムの最適化

AI機械学習システムの正解率を向上させるため、入力データの前処理や深層ニューラルネットワークの構造について検討した。まず、検出対象とする線源をCs-134とCs-137に限定することから、検出器で得られる全1024 chにROIを設置して265 ch～433 ch（計168 ch）とした。これにより、入力層のノード数が3,360（= 20×168）個となる。また、中間層の層数を10とし、各層の構造については、学習用及び検証用データに対する正解率を見ながら試行錯誤的に図4.1.8に示すとおりに決定した。ここで、第2層から第8層は畳み込み層であり、これらの層で入力データの特徴マップを得つつランプ関数（Rectified Linear Unit: ReLU）によって活性化させて次の層に順に伝播させる。第9層は2次元データを1次元データに変換するためのFlatten層である。第10層目は20個のノードを有する全結合層であり、各層における線源強度の推定結果を出力する。

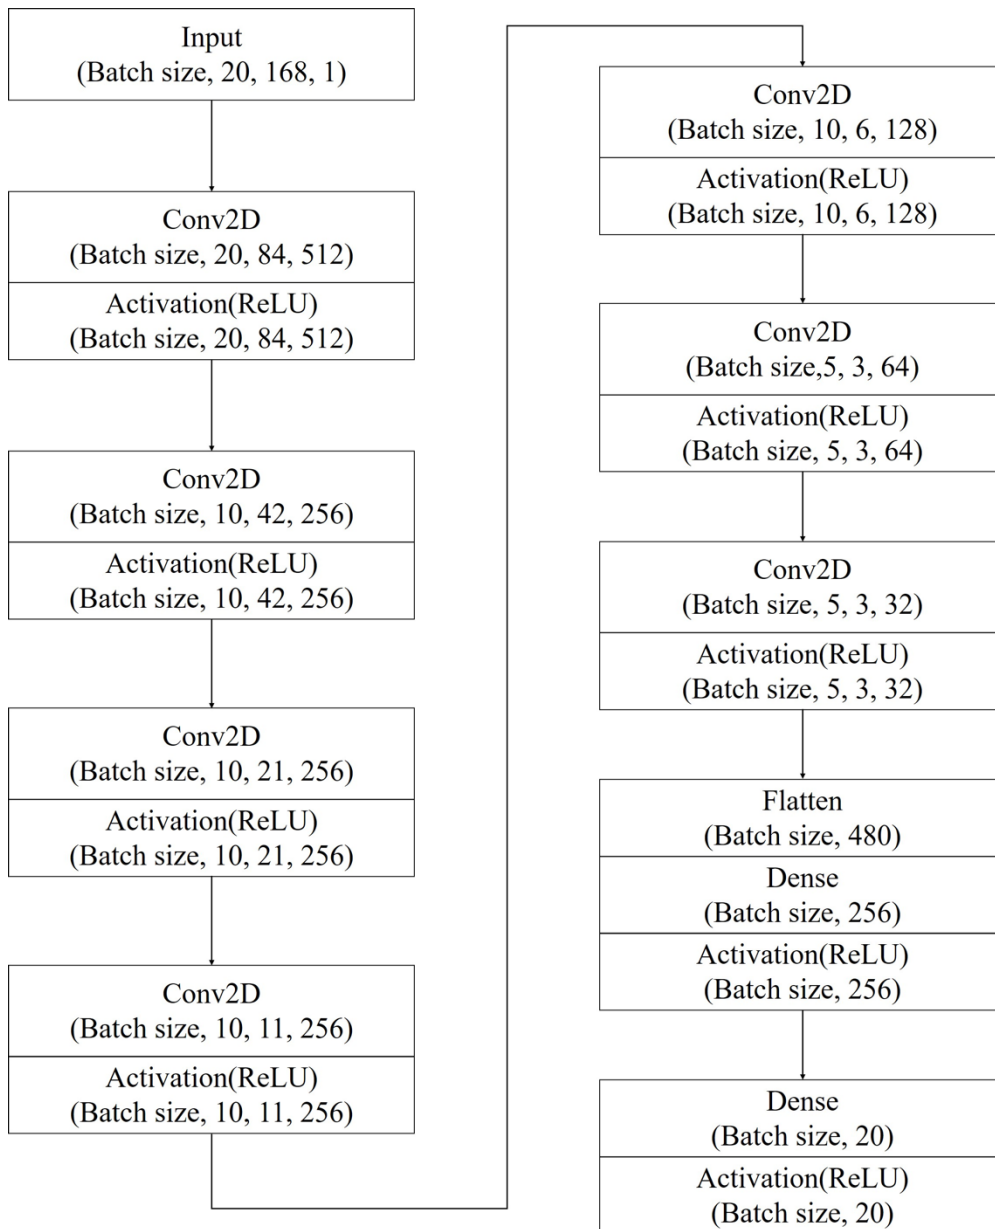


図4.1.8 新システム（畳み込み型深層ニューラルネットワーク）の内部構造

次に、データの前処理について説明する。図3.1.7にみられるとおり、通常、各エネルギー帯における光子のカウント数は多いところで数千にのぼる。このような広範囲の数値データを効率的に学習するため、入力データを

$$X = \frac{x - \mu_x}{s_x}$$

に基づいて標準化した。ここに、 $x$  は各チャンネルにおける光子のカウント数、 $\mu_x$  及び  $s_x$  は  $x$  の平均値及び標準偏差である。

この畳み込み型深層ニューラルネットワークに対して、条件付き敵対的生成ネットワークで作成した5,000×20層分を学習させ、残りのうち100個×20層分に対する正解率を評価した結果、表4.1.1に示すとおり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%となり、旧システムの正解率に比して大幅に向上した。

表4.1.1 深層ニューラルネットワークの正解率 [%]

		新定義 ( $X = 10\%$ )
深層ニューラルネットワーク (旧システム)	学習用データ	59.0%
	評価用データ	17.7%
畳み込み型深層ニューラルネットワーク (新システム)	学習用データ	99.9%
	評価用データ	100.0%

学習済みの深層ニューラルネットワークを開発した深度分布測定器に搭載させて実証実験を実施して得られた代表的な結果を図4.1.9に示す。図左は深度分布測定器で計測されたカウント数、図中は深度分布測定器で計測されたエネルギースペクトルデータを学習済みの深層ニューラルネットワークに入力して算出された放射能濃度 (Bq/kg)、図右は計測地点の土壌をスクレーパープレートで採取して高純度Ge半導体検出器で放射能濃度を計測した結果 (正解) である。深層ニューラルネットワークより出力された結果は、深度方向で最大放射能濃度を示す層と一致しており、かつ、その放射能濃度は真値±10%の範囲であった。これにより、実測データに対しても有効なニューラルネットワークを構築することが可能であった。

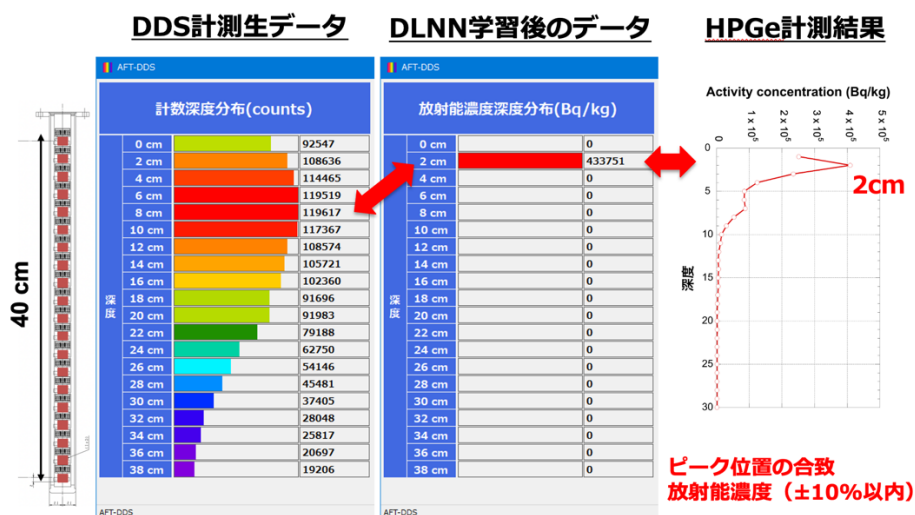


図4.1.9 実測データに対する学習済み深層ニューラルネットワークの出力結果

## 5. 研究目標の達成状況

中長期的な土壌中放射性セシウムの動態をモニタリング可能な「除去汚染土壌用のモニタリングシステム」および従来比で約半分の装置容積および重量まで軽量化した一般市民レベルで取り扱いが容易な「可搬型深度分布測定器」の開発に成功した。測定精度については、校正場の構築、PHITSシミュレーションの高精度化と高速化の両立およびニューラルネットワークの最適化により、当初の目標値である±10%以下を達成した。

## 6. 引用文献

特に記載すべき事項はない。

## III. 研究成果の発表状況の詳細

### (1) 誌上発表

#### <査読付き論文>

##### 【サブテーマ1】

- 1) M. SAKAMA, K. FUJIMOTO, K. INOUE, M. FUKUSHI, Y. IMAJO, T. FUKUHARA, M. MATSUURA, M. YAJIMA, M. ENDO, M. FUJISAWA, E. MATSUMOTO: Radiation Protection Dosimetry, 184(1-3), 328-333 (2019) (IF:0.831) Feasibility study on the fusion of PHITS simulations and the DLNN algorithm for a new quantitative method of in-situ multiple-channel depth distribution spectrometer.

#### <その他誌上発表（査読なし）>

##### 【サブテーマ1】

- 1) 井上一雅：首都大学東京総合研究推進機構NEWS Miyacology, vol.4, 9 (2019)  
「福島の復興を目指して簡易で携帯可能な放射能濃度測定装置をつくる」
- 2) 井上一雅：きらぼしBusiness & Management, vol.10, 22 (2020)  
「福島の復興をスピードアップする新たな放射線測定装置をつくる」

### (2) 口頭発表（学会等）

##### 【サブテーマ1】

- 1) 阪間稔、藤本憲市、井上一雅、福士政広、今城裕介、福原隆宏、遠藤倫崇、川口絵里佳、濱邊大、神谷慶和、森本真壽：日本放射線安全管理学会第18回学術大会（2019）  
「AI技術活用によるIn-situ多チャンネル放射能濃度深度分布スペクトロメトリーの放射能濃度弁別処理技術開発の進展」
- 2) 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：日本放射線安全管理学会第19回学術大会（2020）  
「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) 梅本拓登、藤本憲市、阪間稔、井上一雅、福士政広、今城祐介、福原隆宏、遠藤倫崇：電気・電子・情報関係学会四国支部連合大会（2021）  
「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) 「国民との科学・技術対話」の実施

##### 【サブテーマ1】

- 1) 東京都立大学オープンキャンパス（令和元年8月6日、参加者約250名）にて成果紹介

### (4) マスコミ等への公表・報道等>

##### 【サブテーマ1】

特に記載すべき事項はない。

#### (5) 本研究費の研究成果による受賞

##### 【サブテーマ1】

特に記載すべき事項はない。

#### IV. 英文 Abstract

Development of a Monitoring System Utilizing Artificial Intelligence Technology for Removed Contaminated Soil

Principal Investigator: Kazumasa INOUE

Institution: Tokyo Metropolitan University, Tokyo, JAPAN

Tel: +81-3-3819-1211 / Fax: +81-3-3819-1406

E-mail: kzminoue@tmu.ac.jp

[Abstract]

Key Words: Depth distribution of activity concentration, Radioactive cesium, In-situ measurement, Fukushima Daiichi Nuclear Power Plant accident, Deep learning

The rationalization of decontamination work for contaminated soil and proper management for removed soil that occurred due to radionuclide releases in the Fukushima Daiichi Nuclear Power Plant accident is required. However, the current depth distribution measurement utilizes a scraper plate to collect soil samples which are then measured in a laboratory. This means one week is spent in obtaining results. In this study, a portable radioactivity depth distribution measuring systems that can obtain results in-situ without soil collection was developed. Additionally, a stationary radioactivity depth distribution monitoring systems for the interim storage facility was developed.

A detector equipped with 20 CsI(Tl) scintillators with multi-channel analyzer was constructed which was able to measure radioactivity depth distribution to 40 cm depth in a one-time measurement. A convolutional Neural Network (NN) was used to convert from count rate to activity concentration. The machine learning was carried out using data obtained from field study and Monte Carlo simulation as input data and data obtained from the scraper plate technique and simulation data as output data. When unknown measurement data were inputted into the system, the accurate activity concentration could be provided. The validity of this system was estimated to be 100% when the error range was set to  $\pm 10\%$ . The time spent in measuring the radioactivity depth distribution could be reduced to 10 - 30 min by using the radioactivity depth distribution measuring system. In the future, it is expected that rationalization of decontamination work and work for the interim storage facilities for contaminated removed soils will be possible based on the findings of this research.