

AI を活用した放射線測定データの解析



佐々木美雪
Sasaki Miyuki

1 はじめに

2011年の福島第一原子力発電所（1F）における事故後、日本では有人ヘリコプターや無人機（UAV）を用いた上空からの放射線モニタリングが行われてきた^{1, 2)}。上空からの放射線測定は、人が立ち入れない森林等も含め、迅速に広範囲を測定できるというメリットがある。しかしその一方で、上空での測定値から地上の線量率に換算するには、地形や地上の構造物の状況を考慮する必要があるため複雑な換算が必要になるというデメリットがある。従来、上空での放射線測定値を地上における線量率に換算するには、測定対象となる地表面は平らで線量率分布が一定と仮定した簡易的なパラメータで換算を行っていた（Flat Surface Model：FSM）。そのような仮定条件から逸脱する地形や線量率の変化が複雑なエリアでは不確かさが大きくなりやすい。UAVによる上空からの測定データを簡便かつ正確に換算できることは、現状の1F周辺のモニタリングの効率化が期待できるだけでなく、将来の原子力防災技術としての応用も可能である。また、地形や構造物等のジオメトリの効率的な評価は、上空からの放射線モニタリングに限らず、地上でのサーベイやひいては、原子力発電所施設内や医療用の放射線計測技術にも応用可能と考えられる。

日本原子力研究開発機構（JAEA）では、1F周辺の放射線モニタリングを事故後、継続して実施して

おり、事故から10年以上経過した今、そのデータは膨大なものとなっている。本稿では、1F周辺において取得してきた、UAVによる上空からの放射線モニタリングデータと対になる地上における歩行サーベイのピックデータを学習データとして、機械学習を利用した新たな上空放射線測定値の解析手法についてまとめる。なお、本研究内容の詳細は、既報論文に詳しい³⁾。

2 ANN を利用した解析

近年、計算機の高速化及び人工知能（AI）の基礎となっている人工ニューラルネットワーク（ANN）の研究開発が進み、AIの産業応用等が急速に進んでいる。それに合わせて機械学習を手軽にできるGUIツール等のソフトウェアも普及し、専門知識がなくても簡単にANNの構築等を行うことができる。ANNは様々な手法があるが、誤差逆伝搬学習法を使用した多層パーセプトロンが最も多用されている⁴⁾。このモデルは、ネットワーク構造を使用者が入力する必要があるため、ニーズ毎に構造構築のためのノウハウが必要であり、入力の際の恣意性が排除できない課題がある。そこで、本研究では、ANNの構築にカスケードコリレーション（CC）を用いるExcelベースの汎用ソフトウェアであるNeuralWorks Predict（NeuralWare社製）を使用した⁵⁾。CCはフィードフォワード型のネットワークであり、

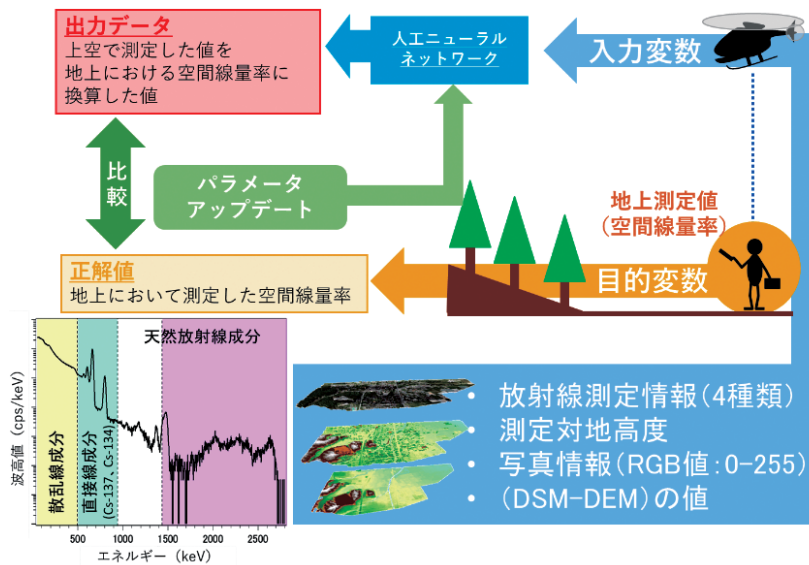


図1 ANN構築の概要

入力層と出力層の単純なネットワークからはじめて徐々に中間層を追加していく手法である。順次ノード数(層の繋がり)を変化させて、最適なノード数が決定されるため、ノード数設定に関する恣意性の問題が避けられる利点がある。

本研究では、入力データ(入力変数)にUAVにより上空で得られた放射線測定データ等を使用し、出力データとして測定ポイント直下の地上における空間線量率を得るために、CCを使用したANNの教師あり学習により、回帰問題を解く解析を行った結果を紹介する。図1にANN構築の概要を示す。

3 ANNによる放射線マッピング

図2に、1F周辺において実施した無人ヘリコプターによるモニタリングデータを、ANNを用いて解析した結果例を示す。この例では、ANNの構築(学習)のために使用する訓練データに、1F周辺において実施したUAVによるモニタリング及び同地点の地上における歩行サーベイのデータセットを用いてANNを構築している。入力変数及び目的変数は以下のものを用いた。

入力変数

・上空でのガンマ線計数率(cps): UAV専用の放射線測定システム(1.5"Φ×1.5"HのLaBr₃(Ce)シンチレータ3本を使用)によるγ線エネルギースペクトルを下記の5つのROI(Regions of interest)毎に

振り分けた計数率。50-2,800 keV(TC), 50-450 keV(E50), 450-900 keV(E450), 900-1,400 keV(E900), 1,400-2,800 keV(E1400)における計数率(ここではE50, E450, E900, E1400の4つ合わせて4Cと呼ぶ)

- ・測定高度(m): 無人ヘリコプターの測定対地高度(AGL)
- ・地形データ(m): 建物や樹木を含んだ表面高さのモデル(DSM)と地盤の高さのモデル(DEM)の差分(DSM-DEM)
- ・写真カラーデータ(RGB数値:0-255): 無人ヘリコプターで上空から撮影した写真から構築したオルソ画像のカラーデータ(RGB)

目的変数

・地上1m空間線量率(μSv h⁻¹): 歩行サーベイで得られた地上測定値

図2における計算では、ネットワークを構築する際に使用した入力変数の組み合わせを変え、それぞれで得られた訓練済みのANNを使用して、上空で得られた放射線測定情報を地上1mの空間線量率へと換算している。また、実際の再現度は、それぞれのマップ上部に記載した実際の地上測定値と上空データの換算値から計算したRMSE(Root Mean Square Error)が指標となる。RMSEは2つの値の差の二乗平均の平方根であり、値が小さいほど2つの値の誤差が小さい。図2(b)に示した従来のモデル(FSM)と図2(c)で示したAGL及びTCで換算した結果のRMSEを見ると、ANNを使用した場合

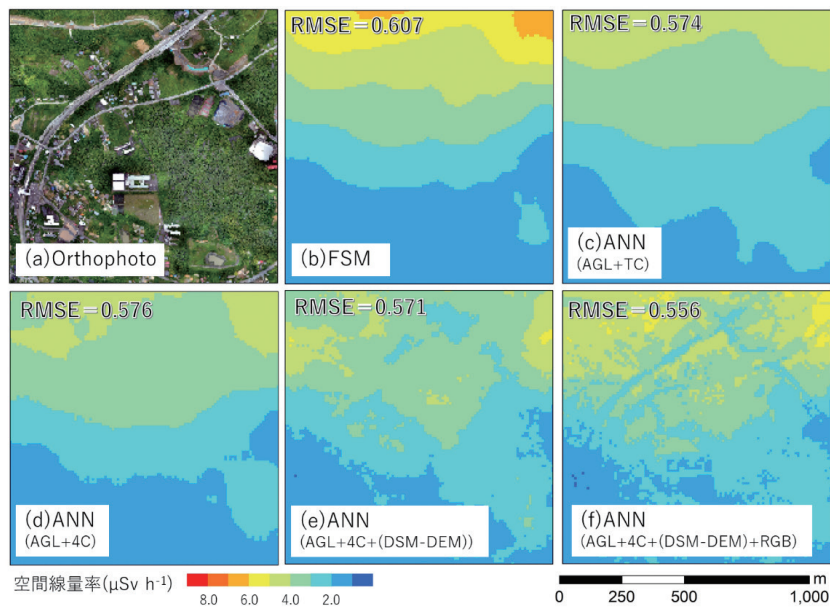


図2 上空放射線測定値から作成した空間線量率マップ

RMSEは本マップのエリアだけでなく1F周辺5km圏内で測定したデータの上空測定換算値と地上測定値を比較した値である。なおマップ比較のためFSMは地上測定値との相対偏差中央値がANNと同じになるように調整している。調整前のオリジナルのFSMのRSMEは0.985である

の方が、数値としての再現度が向上していることが分かる。図2(c)で使用したAGL及びTCはFSMでも入力変数として使用するが、ANNによる再現度が改善された理由としては、換算のパラメータが最適化されたことが原因と考えられる。図3はFSMとANNのパラメータの設定値を比較することを目的とし、AGLとTC及び換算で得られた線量率をTCで割った値（換算係数：Conversion factor）の関係性を3次的に示している。FSMの場合は、放射線の空気減衰のみ考慮しているため、TCが変化してもその換算傾向は一定である。一方、ANNの換算傾向を見ると、AGLだけでなくTCの変化に伴って換算係数が変化していることが分かる。実際の環境中では、事故で放出された放射性セシウム以外に事故前から存在する自然放射性核種が存在する。理論的には、事故の影響が大きくなるほどTCは大きくなり、自然放射性核種の影響が無視できるようになる。逆にTCが小さいほど、相対的にエネルギーの大きい、自然放射性核種の影響が大きくなる。ANNでは、学習により、TCとAGLの情報だけでこの傾向を捉えることができていると考えられる。一方、従来の人間が理論からパラメータを設定するFSMの手法では、TCやAGL毎に換算係数を準備することはできないので、ANNの換算結果の

方がより再現性が向上したものと考えられる。ANNのメリットは、このように人間では解析の難しい複数のパラメータのすべての関係を自動的に評価し、測定条件ごとにパラメータを設定できることが大きな利点となる。

図2(d)-(f)で示すように、入力変数を追加することで、放射線分布の位置分解能が詳細化していく様子が確認できる。特に写真カラーデータ(RGB)を入力変数に入れたANNの換算結果は、アスファルトの洗い流し効果や人為的な除染効果により周辺よりも道路及び線路上の線量率が低くなる現象が再現されている。マップの見た目では分布の詳細度が明確に改善しているように見えるものの、RMSEで数値化すると、図2(c)から図2(f)で示したようにANNの入力変数を増やしても数値上の改善は確認されない。この原因の1つとしては、目的変数に使用する地上測定データが歩行できるエリアに限られていたため、RMSEの数値としては大きく変わらなかったことが考えられる。このように、計算の目的ごとに効果を定量化する指標を設定することは、本方法の課題である。また、現在得られている訓練データは1F周辺で取得されたデータであり、1F周辺の換算に特化したANNのモデルとなっているため、他のエリアへの汎用性が低いという課題がある。

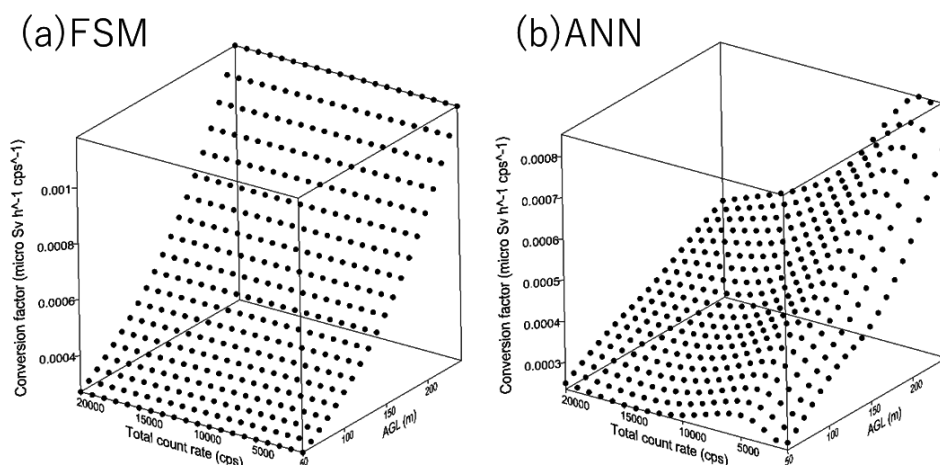


図3 FSMとANNの換算傾向を比較

AGLは測定対地高度、TCは全計数率、Conversion factorは換算で得られた値を全計数率で割った値である。
 (a)はFSMでの換算傾向、(b)は入力変数をAGL及びTCとして構築したANNの換算傾向である

4 今後の展望

本研究において、過去の測定データを教師データとすることにより、従来よりも簡便で精度の良い解析が可能となることが分かった。ただし、実際は訓練データとは完全に一致しない条件における解析が当たり前である。例えば、図2(f)では道路が周辺よりも低い線量であることが再現されていたが、これは道路が除染されている状態でのモニタリングデータが訓練データとなっていることに起因する。すなわち、この訓練データを利用して事故直後の除染がされていないデータを換算すると過小評価することになる。また、図3で議論したように、ANNはTCに伴いパラメータを最適化しているが、これは沈着した放射性核種の条件により変わる。今後、未知の状況に対応するには、放射性核種や沈着後の経過時間等を変化させた訓練データをあらかじめ用意することが必要となると考えられる。

また、機械学習による解析は、訓練によって換算のためのパラメータが自動的に作成できることがメリットであるが、与えられたデータに対する推論の過程がブラックボックス化され、その入力値からなぜその出力値が得られたのかという理論的な説明が難しいという課題がある。放射線解析以外の画像処理による物体認識や文字認識において、それはさほど問題とはならないが、放射線解析のような数値解析においては、数値の信憑性、他の研究への汎用性

等を考えると、得られた数値の理論的な算出過程を評価することは更なる精度向上のため必要である。

数値解析においては、ANNを用いて得られた傾向と、理論とのすり合わせを行うことで、新たなパラメータを抽出し、ANNに人為的にフィードバックすることで、汎用性を高めることができると考えられる。今後、上空からの放射線測定値換算をモデルケースとして、更なるデータの蓄積と、訓練により得られる換算傾向の抽出を行い、より複雑なモデルにおける数値解析へ、パラメータのフィードバックを進める。

【謝辞】

本研究は名古屋大学との共同研究の成果の一部である。本研究を推進した名古屋大学の山本章夫教授、遠藤知弘准教授に心より感謝申し上げる。

参考文献

- 1) 原子力規制委員会, 放射線モニタリング情報, <https://radioactivity.nsr.go.jp/ja/index.html>
- 2) Y. Sanada, et al., *Radioact.*, **139**, 294-299 (2015)
- 3) M. Sasaki, et al., *Scientific Reports*, 11-1857 (2021)
- 4) David E., et al., *Nature*, **323**(9), 533-536 (1986)
- 5) S. E. Fahlman and C. Lebiere, *Advances in Neural Information Processing Systems*, **2**, 524-532 (1990)

((国研)日本原子力研究開発機構)