3ZC-03

福島周辺の放射空間線量率を用いた、危険地域への進入の検出

田村　脩†
慶應義塾大学大学院理工学研究科
開放環境科学専攻†

櫻井　彰人‡
慶応義塾大学理工学部管理工学科‡

1. 背景

2011 年の東日本大震災により、福島県の一部地域は放射線による被害を受けた。現在でも、放射線量の多い地域は「帰還困難区域」に指定されており、立ち入り禁止となっている。帰還困難区域に指定されていない状態であっても、放射線量の高い地域に進入することは、極力避けるべきである。仮に他の地域が放射線の被害を受けた場合、帰還困難区域等が指定されていない状態では、人間が知らぬ間に危険な地域に進入してしまう可能性が大きい。

本研究では、福島第一原子力発電所周辺を走行するモニタリングカーのデータを用いて、危険地域への進入を検知する機械学習モデルの構築を目指す。

2. 提案手法

2.1 データ詳細

日本原子力研究開発機構が収集した、福島第一原発の周辺を走行するモニタリングカーのデータ[1]を用いる。

上記のデータには、モニタリングカーで回った各地点の空間線量率に加え、各地点の地理情報（緯度経度や、原子力発電所からの距離等）や天候などの情報が存在し、1025 日、34838 の時点にわたって時系列順に記録されている。
表 1 に、具体的なデータ例を示す。

表 1: モニタリングカーデータの概観

測定日	時刻	市町村	空間線量率（μSv/h）
2011/3/16	13:31	二本松市	10
2011/3/16	13:36	二本松市	11
2011/3/16	13:47	田村市	6.7
2011/3/16	13:52	田村市	1

Detection of entry into contaminated area using radiation dose data around Fukushima
† Tamura Shu, Graduate School of Science and Technology, Keio University
‡ Sakurai Akito, Faculty of Science and Technology, Keio University

2.2 提案モデルの概要

人々が携帯し、危険地域に進入した際にアラートを出せるデバイスまたは機能が求められるため、以下の入出力モデルを考える。

入力: 時点ごとの空間線量率
出力:「危険地域か否か」の二値

以上のモデルを作成するため、あらかじめ 2.1 で述べたデータを用いて学習を行い、より高い精度のモデルの構築を行う。

なお、空間線量率以外の特徴量についてであるが、現状空間線量率のみで検知できることに越したことはないため、本研究では用いないこととする。

2.3 学習の方法

本研究では「帰還困難区域」=「現状の危険地域」とし、以下のフローで学習を行う。
①モニタリングカーの地理データを用いて、各時点における計測地点が、帰還困難区域か否かを 2 値でラベル付けする。
②1 日分の空間線量率を 1 つの時系列データとし、1025 の時系列データをランダムに 922 の学習データと 103 のテストデータに分割する。
③学習器に学習データを入力し、教師付き学習を行う。
④テストデータで精度の確認を行う。

2.4 学習器

前述したモデルでは、一地点につき 1 つの出力が必要とされる。しかし、その一地点における線量の値のみでは学習に限界があると考えられるため、過去の線量の値を反映できるような学習器を用いる。本研究では、時系列データに対応した学習器として再帰型ニューラルネットワークを、さらに比較手法としてサポートベクターマシンを用いる。

Copyright ©2018 Information Processing Society of Japan.
All Rights Reserved.

2.4.1 再帰型ニューラルネット(RNN)

再帰型ニューラルネット（以下 RNN）とは、時系列データに対して効果的なネットワークであり、過去の時点での情報を保持することができるという特徴を持つ。本研究では、RNN モデルの中でも特に学習能力が高いとされる LSTM モデル[2]を用いた。図 1 に RNN モデルの概観を示す。

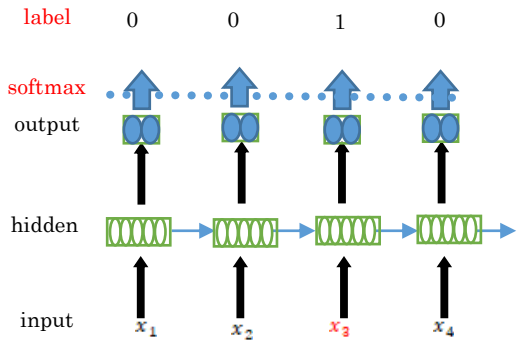


図 1: RNN モデルの概観図

なお、batchsize を 10, epoch を 1000, 最適化手法を Adam[3]とし、隠れ層の素子数は 5, 10, 20, 50 として、それぞれ実験を行った。

2.4.2 サポートベクターマシン(SVM)

RNN の比較手法として、サポートベクターマシン（以下 SVM）を用いた 2 値分類を行った。SVM では時系列データに対応した方法がないため、過去 7 地点における空間線量率の値を入力とした。なお、パラメータについては、グリッドサーチによるチューニングを行った。カーネルには、Linear 及び rbf を用いた。

3. 実験結果及び考察

3.1 実験結果

表 2 に、2 値分類の結果を示した。

表 2: 実験結果

隠れ層の素子数	precision	recall	F1	accuracy
5	0.87	0.78	0.82	0.97
10	0.88	0.83	0.86	0.97
20	0.85	0.80	0.82	0.97
50	0.90	0.82	0.86	0.97
SVM	0.65	0.83	0.73	0.94

3.2 考察

表 2 より、最も良いと考えられるモデルについて考察を行う。

基本的には、「実際は危険地帯に入ったにも関わらず、アラートが鳴らない」という状況を最も避けるべきであるため、recall の値を重要視すべきである。また、1025 時系列のすべての時系列要素のうち、上の表より、 recall の値が 0.83 と最も高い手法は、素子数 10 の RNN 及び、SVM である。そして、その 2 手法間では、precision のより高い RNN が、より望ましいモデルであると考えられる。

4. 結論・今後の展望

RNN モデルによって、帰還困難区域への進入したことを約 83%の recall 率で検知するモデルを構築することができた。

今後の展望としては

・パラメータチューニングを綿密に行い、精度の向上を目指す。

・隠れ層の素子数と、モデル精度との関連性について追究する。

・特に recall の値を大きく調整できるような手法を考案する。

・他の有用な手法との比較を行う。例として、AR モデルなどの自己回帰モデルを適用することが挙げられる。

などが考えられる。

参考文献

[1] 国立研究開発法人日本原子力研究開発機構. (2017 年 11 月 9 日閲覧). モニタリングカーを用いた固定測定点における空間線量率の測定結果 http://emdb.jaea.go.jp/emdb/portals/10410201/

[2] Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory." Neural computation 9.8 (1997): 1735-1780.

[3] Kingma, Diederik, and Jimmy Ba. "Adam: A method for stochastic optimization." https://arxiv.org/pdf/1412.6980

Copyright ©2018 Information Processing Society of Japan.
All Rights Reserved.