

畳み込みニューラルネットワークを用いた気象時系列データにおける 変化点の検知と注目範囲の可視化についての基礎検討

前原宗太朗[†] 福井 健一^{††} 富田 智彦^{†††} 小野 智司[†]

[†] 鹿児島大学 大学院理工学研究科 情報生体システム工学専攻

^{††} 大阪大学 産業科学研究所

^{†††} 熊本大学 先端科学研究部

E-mail: [†]{sc113067,ono}@ibe.kagoshima-u.ac.jp, ^{††}fukui@ai.sanken.osaka-u.ac.jp,

^{†††}t-tomita@kumamoto-u.ac.jp

あらまし アメダス (Automated Meteorological Data Acquisition System: AMeDAS) は、降水量や気温などの気象データを観測するシステムであり、全国約 1,300 箇所に設置された観測点から構成される。観測地点の周囲の変化により観測データに影響が生じ、観測地点の変更が行われることがある。このとき、観測データに何らかの傾向の変化がみられる場合は変更があった旨が公表されるものの、観測値に明確な変化がみられない場合は観測地点の変更が特に公表されないことがある。このため、本研究では、畳み込みニューラルネットワークと訓練データの合成手法を用いることで、観測された気象データの微小な変化から観測環境の変化の有無を識別する手法を提案する。また、提案手法は、Guided Gradient-Weighted Class Activation Mapping を利用して、変化の有無の識別の際に注目された入力データの範囲を可視化する。観測地点の移転を仮想的に再現した気象データを用いて実験を行い、提案手法が変化点の検知を行えること、および、温度変化パターンにおいて着目する範囲の可視化を行えることを示す。

キーワード 変化点検知, 可視化, 時系列データ, 気象観測データ, 畳み込みニューラルネットワーク, 教師信号付訓練データ生成

A Preliminary Study on Change Point Detection Using Convolutional Neural Network and Visualization of Range of Interests for Weather Time Series Data

Sotaro MAEHARA[†], Ken-ichi FUKUI^{††}, Tomohiko TOMITA^{†††}, and Satoshi ONO[†]

[†] Department of Information Science and Biomedical Engineering, Graduate School of Science and Engineering, Kagoshima University

^{††} The Institute of Scientific and Industrial Research, Osaka University

^{†††} Faculty of Advanced Science and Technology, Kumamoto University

E-mail: [†]{sc113067,ono}@ibe.kagoshima-u.ac.jp, ^{††}fukui@ai.sanken.osaka-u.ac.jp,

^{†††}t-tomita@kumamoto-u.ac.jp

Abstract AMeDAS (Automated Meteorological Data Acquisition System) is a system that observes weather data such as precipitation, temperature, etc. and consists of about 1,300 observation points in Japan. However, a small environmental change such as relocation of an observation station and construction of buildings nearby it causes a slight change of observation data. In this paper, we attempt to detect such changes on the observation station environment from observed weather data using Convolutional Neural Network and training data synthesization. The proposed method also tries to visually explain for predicted results using Guided Gradient-weighted Class Activation Mapping. Experimental results using synthesized weather observation data showed that the proposed method successfully detected change points and demonstrated the range of interest to detect such changes in averaged temperature change patterns.

Key words change point detection, visualization, time series data, weather observation data, convolutional neural network, synthesization of training data with supervisory signal

1. 背景と目的

気象観測データの長期的な蓄積は、気候変動のメカニズム解明、将来予測や多様な気候モデルの解明のために不可欠である。降水量などの気象情報を観測する目的として、地域気象観測システム（アメダス）が全国約 1,300 か所に設けられている。一方で、地域気象観測においては、観測地点の周囲の環境の変化（建造物の建立など）が生じたり、観測地点の変更が行われることがあり、この前後において観測結果にわずかな変化が含まれる可能性がある。上記のような変化によって観測値に何らかの傾向の変化が明確にみられる場合は、変更があった旨が公表されるものの、観測値に明確な変化がみられない場合はそのような情報が特に公開されないことがある。しかし、全国規模の地球温暖化現象と観測地点周辺の都市化の問題の区別、さらには気候変動のメカニズムの正しい理解のために、上記のような変化の発生を把握することは重要である。

本研究では、上記の様な観測環境の変化を、畳み込みニューラルネットワーク（Convolutional Neural Network: CNN）[1] を用いて検出を試みる。変化点検知を行う際は一般的に、正常なモデルを学習し、予測値と実測値の差異に基づいて行う方式が多い。これに対して提案方式では、観測値の非線形的な変化も検出できるよう、変化の有無を直接推定するネットワークを学習する。これにより、人間でも知覚が困難な観測値の微小な変化をもとに、観測環境の変化の有無を予測することが可能となる。本研究ではまた、提案するニューラルネットワークが、入力される気象観測データのどの範囲に着目することで変化点の検知を行っているかを確認するため、Guided Gradient-weighted Class Activation Mapping（Guided Grad-CAM）[2] を用いて可視化を試みる。

なお、アメダスの観測環境が変化する、あるいは、観測地点を移転する頻度は低く、十分な学習データを用意することは難しい。このため、本研究では、著者等が先行研究で提案した方式[3] を利用し、近傍にある 2 箇所の観測地点のデータを合成することで学習データを人工的に生成する。これにより、変化点検知を目的とする、教師信号を備えた十分な量の学習データを生成することが可能となる。九州内 7 都道府県の 35 地点で観測されたデータをもとに合成したデータを用いて実験を行い、本手法で観測環境変化の検知が可能であることを確認した。

2. 関連研究

近年、深層ニューラルネットワーク（Deep Neural Networks: DNNs）が幅広い分野に応用される一方で、ニューラルネットワークを用いた推論や予測の根拠の提示に対する需要が高まっている。このため、ニューラルネットワークの推論の過程や注目領域を可視化する技術についての研究が行われている[4]～[6]。DNNs の代表的なモデルの 1 つである CNN において、注目領域を可視化する技術の一つとして Grad-CAM が提案されている[2]。Grad-CAM は、画像のクラス分類を行った際に、CNN がどの画像領域に着目して推定を行ったかを可視化する技術である。Grad-CAM では、特徴マップの微分係数、すなわ

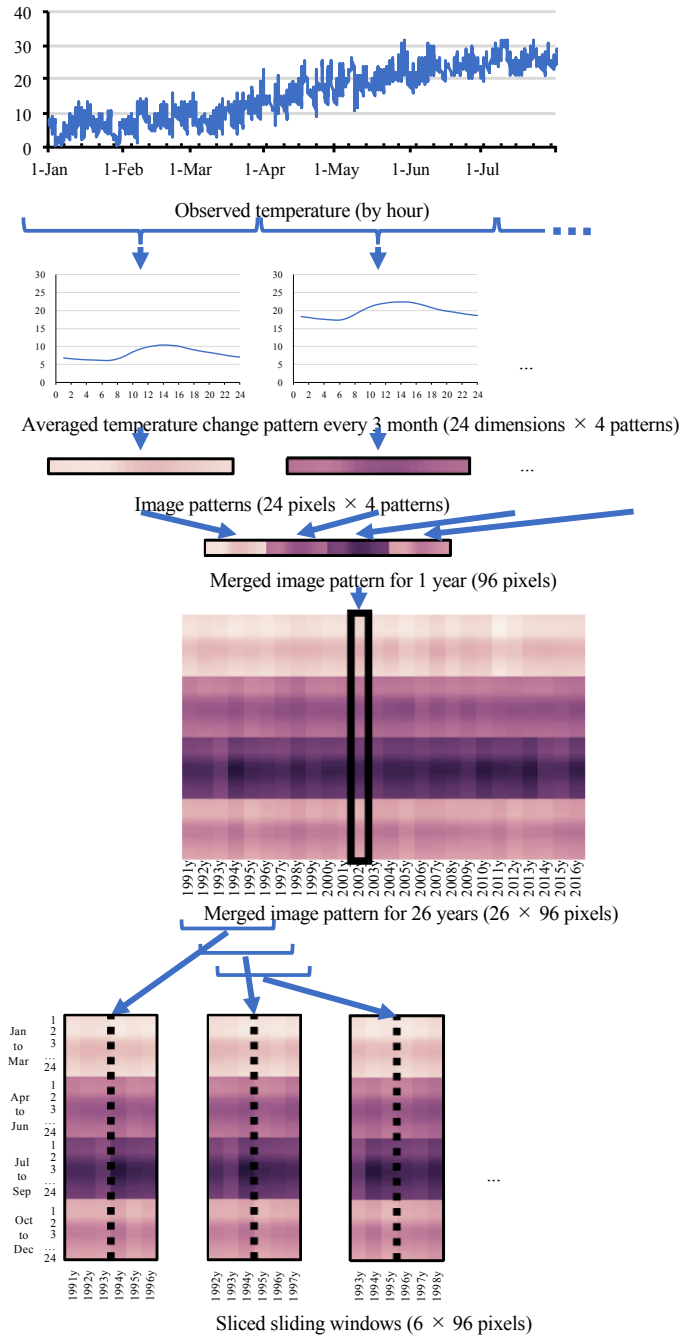


図 1 入力データの生成

ち、ある画像領域に微小な変化を加えた際の推論結果への影響が大きい場合にはクラス推定に与える影響が大きいと考え、特徴マップの微分係数の平均を重みとした加重平均で得られた画像を可視化画像とする。

3. 提案手法

3.1 基本アイデア

気象観測結果の変化の要因は、人工変動と自然変動に大別される。前者には、観測地点の移転や建物の建立など、局所的な変動が含まれる。後者は、自然気候変動や、全地球規模の地球温暖化の大域的かつ長期的な変動を指し、人工変動と比較する

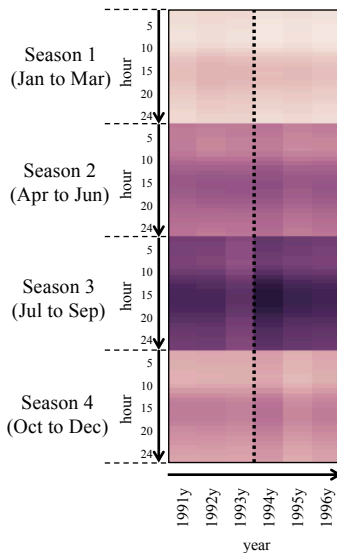


図 2 生成された入力データの例（移動窓のサイズ: 6 年）

と緩やかな変動となる。

本研究では、上記のような変化のうち人工変動を検出することを試みる。人工変動による観測データへの影響は非線形的であることが予測されるため、ニューラルネットワークの利用が好適であると考えられる。著者らによる先行研究 [3] では、再帰ニューラルネットワーク（Recurrent Neural Network: RNN）[7] を用いて検出を試み、微小な変化を検知できることを確認しているが、推論結果の根拠の提示が困難であるという問題があった。このため、本研究では、CNN による変化点検知を行う手法を提案するとともに、Guided Grad-CAM を適用することで注目する範囲の可視化を試みる。

なお、本研究では、先行研究で提案した訓練データを人工的に生成する方式 [3] を利用する。

3.2 入力データ

アメダスの観測データは、降水量や風向、風速等の情報を含む。本研究において観測環境の変化を予測するにあたり、降水量や風速は分散が大きいため、気温を用いることとする。

図 1 に、提案手法における入力データの生成方法を示す。アメダスは 1 時間単位で気温を観測するが、観測された時系列変化を直接利用するのではなく、1 年分の観測データを 3 ヶ月毎の 4 シーズン（1～3 月、4～6 月、7～9 月、10～12 月）に分け、各シーズンの代表的な気温観測値（時間単位：24 次元）に着目する。各シーズンの各時間ごとの平均値を取り、これをそのシーズンの代表的な気温の変化パターンとし、これを平均変化パターンと呼ぶことにする。各年において、平均変化パターンを 4 シーズン分を用いた計 96 次元の特徴量を入力値として扱う。

提案手法で変化点の検知を行う際は、移動窓法により、対象となる年を注視として数年程度の期間の平均変化パターンを切り出す。このため、図 2 に示すように、提案手法で用いる CNN の入力値は、移動窓のサイズを S 年とすると、 $S \times 96$ 画素




図 3 提案手法の構成（移動窓のサイズが 6 の場合）

表 1 提案手法におけるパラメータ

| layer name | output size | kernel size | padding |
|------------|-------------------------|--------------|---------|
| conv1 | $16 \times 3 \times 48$ | 5×5 | 2 |
| conv2 | $32 \times 2 \times 24$ | 5×5 | 2 |
| conv3 | $64 \times 1 \times 12$ | 5×5 | 2 |
| FC1 | 64 | - | - |
| FC2 | 2 | - | - |




図 4 観測地点の分布

の画像として表現される。

以上のようにしてデータを生成することで、天候による日単位の変動をキャンセルしたデータを学習に利用することが可能となる。すなわち、提案手法の入力データは、オリジナルな温度観測データである 1 次元の時間単位の時系列データではなく、96 次元の年単位の時系列データであることに留意されたい。

3.3 CNN を用いた変化点検知モデル

本研究で提案する変化点検知手法は、図 3 および表 1 に示す構成をとるニューラルネットワークである。3.2 節で述べた移動窓内の平均温度変化パターンを入力とし、移動窓の中心に位置する年間における変化の有無（2 種類のクラス）を出力とする。なお、移動窓の中心以外の位置で変化が生じている場合は、変化無しとみなすこととする。

提案手法で利用する CNN は、3 層の畳み込み層の後ろに 2 層の全結合層を含む比較的な単純な構造を用いる。例えば、移動窓のサイズが 6 の場合に畳み込み層では、各層を通過するごとに、画像サイズを 3×48 , 2×24 , 1×12 と縮小させる一方で、16, 32, 64 とチャンネル数を増加させる。このため、畳み込み層を適用した後に 64 枚の特徴マップが生成されることとな

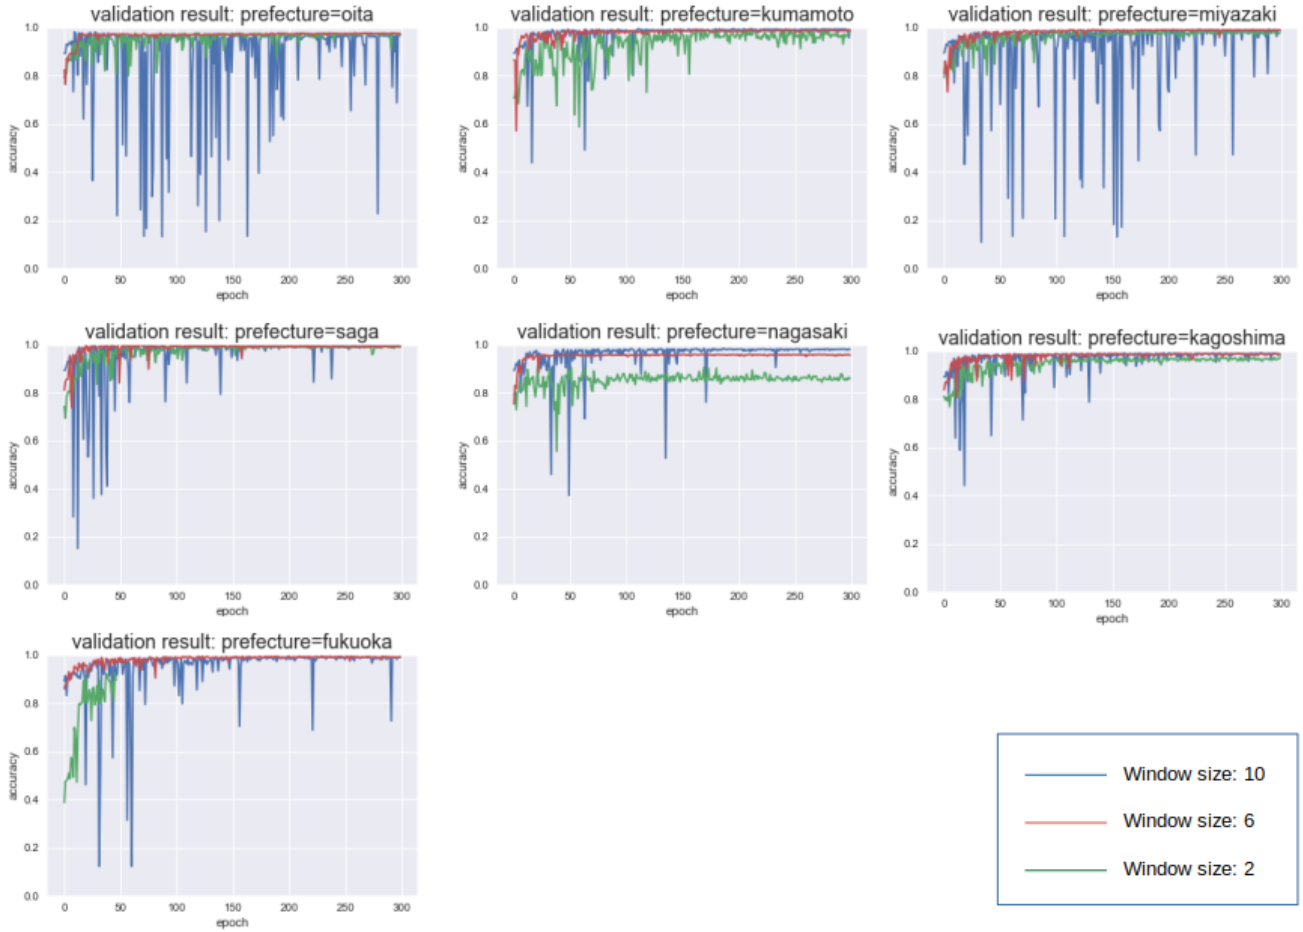


図5 変化点検知の正解率（左上から順に、大分、熊本、宮崎、佐賀、長崎、鹿児島、福岡における結果を表す）

る。すべての中間層において活性化関数には ReLU を用い、出力層では softmax 関数を用いる。

3.4 Guided Grad-CAM による視覚的説明

提案手法が変化の有無の予測を行う際に参照する平均温度変化パターンの範囲を明らかにするために、可視化技術を用いて視覚的な説明を試みる。本研究では、視覚的説明の代表的な手法の一つである Guided Grad-CAM を利用する [2]。この手法では、特徴マップの加重平均によって算出される Grad-CAM と、Guided backpropagation [8] とを併用する。Grad-CAM がマップ単位の算出であるのに対して、Guided backpropagation ではピクセル単位の貢献度を算出することが可能となる。

Grad-CAM は、クラス c の k 番目の特徴マップ A^k における貢献度 α_k^c を以下の式により算出する。

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (1)$$

ここで、 y^c はクラス c の確率スコア、 A_{ij}^k は k 番目の特徴マップにおける画素 (i, j) の強度を示す。クラスの確率スコアを特徴マップの強度で微分し、その勾配の全画素における平均を算出することで α_k^c を算出する。 α_k^c が高いほど、クラス c にとって特徴マップ A^k が重要であることを意味する。

次に、式 (1) で算出した貢献度を用い、これを重みとして特


徴マップの加重平均を算出することで、Grad-CAM のヒートマップ画像 $L_{Grad-CAM}^c$ を算出する。

$$L_{Grad-CAM}^c = ReLU\left(\sum_k \alpha_k^c A^k\right) \quad (2)$$


Guided backpropagation は、各ニューロンが固有の特徴を検出する検出器であると考え、各ニューロンがどのような特徴を検出したかに着目する。すなわち、勾配の平均をとるかわりに正值のみを入力まで伝搬させることで可視化を行う。Guided Grad-CAM は、上記の Guided backpropagation の結果に Grad-CAM の出力を重ねることで、高解像度とクラス依存性を考慮したヒートマップ画像を得る。

3.5 変化点検知を目的とした教師信号付き訓練データの合成

提案手法は CNN に基づくため、教師信号を用いて学習を行う必要がある。しかし、アメダスの観測地点の移転などの変化は希に行われるため、十分な量の訓練データを用意することが困難である。このため、変化点検知を目的とした教師信号付き訓練データを合成する [3]。これは、近傍（数十 km 程度）にある 2 点の観測地点における観測データを結合することで、観測地点を仮想的に移動させたことに相当する、教師信号付きの訓練データを生成する方式である。2 点の観測値の選択、およ




(a) 入力データ（平均気温変化パターン）




(b) 可視化された重要範囲

図 6 福岡のデータにおける可視化の例（左側 3 サンプルは移動窓の中央で変化無しと推定されたデータであり，右側 3 サンプルは変化有りと推定されたデータ




(a) 入力データ（平均気温変化パターン）



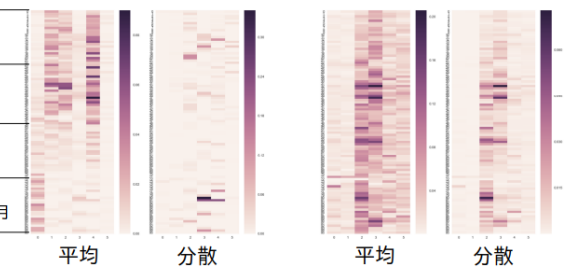
(b) 可視化された重要範囲

図 7 長崎のデータにおける可視化の例（左側 3 サンプルは移動窓の中央で変化無しと推定されたデータであり，右側 3 サンプルは変化有りと推定されたデータ）



(a) 変化無しと推定されたサンプル (b) 変化有りと推定されたサンプル

図 8 福岡における重要範囲の可視化画像の平均と分散



(a) 変化無しと推定されたサンプル (b) 変化有りと推定されたサンプル

図 9 長崎における重要範囲の可視化画像の平均と分散

び，2 点の観測データを結合する年の選択により，生成に用いる観測地点の数を増やすことで，指数関数的に訓練データの量を増やすことが可能となる．これにより，実際の観測データにおける観測環境の変化に関する情報の不十分さを補い，提案手法で利用するニューラルネットワークの学習を行うことが可能となる．

4. 実 験

4.1 観測地点の仮想的な移転の検出性能の評価

3.5 節で述べた方法を，九州 7 県の観測所 35 カ所（図 4）で観測されたデータに適用し，データセットの生成を行った．各県 5 カ所の観測所で観測されたデータから 2 カ所の観測データを選択し，ある時点で入れ替えることで変化を含む観測データを生成した．1991 年から 2016 年までのデータを用意し，12

月と1月の間でのみデータの入れ替えを行った。このため、各県あたり、20箇所×25時点=500個のデータサンプルを作成したこととなる。また、訓練用データと検証用データを分けるために、県単位での交叉検定を行った。移動窓のサイズ S は2年、6年、10年の3通りを検証した。

実験結果を図5に示す。横軸は学習における反復回数(epoch数)、縦軸は検証用データにおける正解率、すなわち、予測結果と正解が一致した割合を表す。

総じて、移動窓のサイズが6年(予測時点を挟んで前後3年の観測データを含む)の場合に最も正解率が高いことがわかる。移動窓のサイズが10年の場合は過学習が生じて汎化性能が低下することがあった。2年の場合は、大分、宮崎、佐賀、福岡の観測データにおいては、6年の場合に近い高い正解率を示したが、長崎において大幅に正解率が低下し、熊本および鹿児島でも若干正解率が低下した。移動窓の設定指針の明確化は今後の重要な課題である。

4.2 入力データにおける重要な範囲の可視化

Guided Grad-CAMを用いて、変化の有無の識別に影響を与えている気温変化の範囲の可視化を試みた。移動窓のサイズを6年とした。変化点推定の正解率が比較的高かった福岡県、および低かった長崎県において、それぞれ6つのサンプルを抽出し、重要範囲の可視化を行った結果を図6および図7に示す。それぞれの図において、左側3サンプルは移動窓の中央で変化無しと推定されたデータ、右側3サンプルは変化有りと推定されたデータである。入力データおよび可視化結果は 6×96 画素の画像となるが、視認性を高めるために横方向にのみ拡大を行った。重要領域の可視化結果では、濃色になるほどクラス識別の際に重要であると判定された範囲であることを示す。また、各クラスに識別された全データサンプルの可視化結果に対して、平均とその分散を算出した結果を図8および図9に示す。

まず、変化が無いと推定されたサンプルに着目する。図6および図7から、福岡および長崎の双方において、抽出されたサンプルにおいては重要範囲の分布に明確な傾向がないようにみられる。しかし、図8および図9から、福岡のデータでは移動窓内の1, 2, 4, 6年目の平均温度変化パターンが、長崎のデータでは移動窓内の2, 3, 5年目のパターンが、それぞれ参照される傾向が強いことがわかる。

次に、変化があると推定されたサンプルに着目する。図6および図8から、福岡県では変化直前の年の7~12月の午前8時~10時の時間帯に注視が集中していることがわかる。また、図7および図9から、長崎県では、4~6月の8~10時や13~14時、7~9月の8~10時など、変化の前後の年において同じ時期の近い時間帯に着目していることがわかる。

一般に、温度変化の多くは日射と連動しており、特定の季節の特定の時間帯に、例えば観測点が建物の影に入るなどの変化が生じている可能性がある。また、建物や地形等の障害物により特定の方向からの風が入りにくくなることで温度移流の効果が変化する可能性もある。さらには、局地的な雨の降り方の相違が反映された可能性も考えられる。

5. 結 論

アメダスの観測データをもとに、観測環境の変化を検知する方式を提案した。本方式は、CNNを利用することで、3ヶ月ごとの平均気温変化パターンをもとに観測環境の変化の有無を識別する。特に、Guided Grad-CAMの利用により、識別の際に重要とされた範囲を可視化できる点に特徴がある。九州7県で観測されたデータをもとに実験を行い、提案方式が観測地点の仮想的な移動を検知できること、および、注視範囲の可視化により、特定の季節の特定の時間帯の温度変化に着目して識別が行われていることを確認した。

本論文では仮想の変化を含む気象観測データを用いて実験を行ったため、今後、実際の観測データにおける有効性を検証する。

謝辞

本研究の一部は科学研究費補助金(課題番号: 16K12490)、および、物質・デバイス領域共同研究拠点の支援により実施された。

文 献

- [1] A. Krizhevsky, I. Sutskever, and G.E. Hinton, "Imagenet classification with deep convolutional neural networks," Advances in neural information processing systems, pp.1097-1105, 2012.
- [2] R.R. Selvaraju, A. Das, R. Vedantam, M. Cogswell, D. Parikh, and D. Batra, "Grad-cam: Why did you say that? visual explanations from deep networks via gradient-based localization," CoRR, abs/1610.02391, vol.7, pp.●-●●, 2016.
- [3] 前原宗太郎, 福井健一, 富田智彦, 小野智司, "気象時系列データにおける変化点検知の基礎検討," 人工知能学会全国大会(第31回), pp.●-●●, 2017.
- [4] Q.V. Le, "Building high-level features using large scale unsupervised learning," Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on IEEE, pp.8595-8598 2013.
- [5] P.-J. Kindermans, K.T. Schütt, M. Alber, K.-R. Müller, D. Erhan, B. Kim, and S. Dähne, "Learning how to explain neural networks: Patternnet and patternattribution," arXiv preprint arXiv:1705.05598, pp.●-●●, 2017.
- [6] M.T. Ribeiro, S. Singh, and C. Guestrin, "Why should i trust you?: Explaining the predictions of any classifier," Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining ACM, pp.1135-1144 2016.
- [7] S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural computation, vol.9, no.8, pp.1735-1780, 1997.
- [8] J.T. Springenberg, A. Dosovitskiy, T. Brox, and M. Riedmiller, "Striving for simplicity: The all convolutional net," arXiv preprint arXiv:1412.6806, pp.●-●●, 2014.