

## 自己組織化マップを用いた大気循環パターンの分類 Classification of Atmospheric Circulation Patterns Using Self-Organizing Maps

○榎本剛  
○Takeshi Enomoto

The atmospheric circulation exhibits distinct patterns, such as west-high and east-low or south-high and north-low, typical during winter and summer, respectively, and bring associated weather and climate anomalies. These classification of the atmospheric circulation have been conducted subjectively or objectively. The empirical orthogonal functions (principal component) analysis can extract dominant patterns with small number of modes, but the relationship between different modes can be difficult to interpret due to the orthogonality. As an attempt to facilitate interpretation, a self-organizing Kohonen network is used to classify the atmospheric circulation patterns. After unsupervised learning of input data, similar patterns are mapped topologically close on the Kohonen network. The locations of positive and negative anomalies, gradients, and flow direction vary smoothly on the map. Atmospheric patterns similar to those in the literature were replicated using reanalysis for ten years.

### 1. はじめに

大気循環は、西高東低の冬型や南高北低の夏型のような循環パターンを示し、それに伴い天候の偏差が生じる。大気循環の分類は主観的または客観的に行われる。経験的直交函数 (Empirical Orthogonal Function, EOF) 解析と呼ばれる主成分分析は主要なパターンを少ないモードで抽出することができるが、モード間の関係は直交性のために解釈が容易ではない。

解釈を容易にするため、Kohonen (1982)が提案した自己組織化ネットワークを用いて大気大循環の分類を試みる。

### 2. 分類手法と入力データ

多数の入力データを用意し、教師なし学習を行う。出力は2次元に配置されたユニットからなるKohonen図で、類似パターンは近距離に写像される。

類似の尺度は入力とユニットのシナプス重みとの距離で定義する。 $p$ 番目の入力 $\Psi^p$ とユニット $i, j$ との距離は以下のように定義される。

$$D_{\text{RMS}}[w^{ij}, \Psi^p] = \sqrt{\sum_r [w_r - \Psi_r^p]^2}$$

ここで $r$ は物理空間での(1次元化された)格子番号である。この距離が最小となるユニットを選択ユニットとする。選択ユニットとその近隣ユニットを意味する活動球においてシナプス重みを入力に近づける。活動球外のシナプス重みは相対的に小さくなる。重みの変化量と活動球の大きさは学習回数とともに縮小させる。

先行研究 (Eckert et al. 1996) の追試として、欧州域の500 hPa面高度のパターンを分類した。米国環境予測センター (National Centers for Environmental Prediction) /国立大気研究センター (National Center for Atmospheric Research) 再解析 (Kalnay et al. 1996) から2010~19年までの10年間の500 hPa面高度について00及び12 UTC (7304時刻) を抽出した。欧州域に準ずる $10^\circ\text{W}-17.5^\circ\text{E}$ ,  $35^\circ\text{N}-55^\circ\text{N}$  ( $12 \times 9 = 108$ ) に対して、ランダムにサンプルを抽出し $8 \times 8$ の乱数で重みを初期化した矩形ネットワークを用いて学習を行なった。先行研究とは異なり、特定の地点の月平均ではなく、各地点での月平均からの偏差を求め、偏差の二乗平均平方根で規格化したものを入力として用いた。学習回数はサンプル数の5倍の36520回である。

### 3. 数値実験の結果

分類の例をFigure 1に示す。高気圧偏差と低気圧偏差が中心に位置する対照的なユニットが左上と右下に存在し、その位置や強度が少しずつ異なるユニットが近隣に配置されている。右上の高気圧偏差は下に向かって、南そして東南にずれていき、西風、北西風、北風と変化している。右方向には偏差が東にずれるとともに南東風そして東風の場に変化している。場が連続的に変化していることから、適切に分類されていると考えられる。

Kohonen図においては、角や辺で高頻度となることが指摘されている。この分類では、(0, 2)が469、(7, 0)が440、(0, 7)が366回選択されている (Figure 2)。最も少ない(5, 6)でも14回あり、極端に少ないユニットは見られなかった。

### 4. まとめと今後の課題

自己組織化Kohonenマップを用いて500 hPa高度を分類し、隣接するユニットが連続的に変化するネットワークを得ることができた。乱数で初期化するアルゴリズムであるため、学習のたびに異なる結果が得られる。学習結果をEOF解析するなどして、結果の再現性について検討する必要がある。角や辺に偏りやすい問題は球面上に準一様に配置されたユニットを用いることで解決できる。

今後は先行研究が行なったアンサンブル予報の信頼性の検証を行ったり、日本域や北半球など異なる領域や、月平均など異なる時間スケール、変数に対して適用したりすることが考えられる。深層学習のベースとして発展させていきたい。

### 参考文献

- Eckert, P., D. Cattani, and J. Ambühl, 1996: Classification of ensemble forecasts by means of an artificial neural network. *Meteorological Applications*, 3, 169–178, <https://doi.org/10.1002/met.5060030207>.
- Kalnay, E., and Coauthors, 1996: The NCEP/NCAR 40-year reanalysis project. *BAMS*, 77, 437–471.
- Kohonen, T., 1982: Self-organized formation of topologically correct feature maps. *Biol. Cybern.*, 43, 59–69, <https://doi.org/10.1007/BF00337288>.




Figure 1: The Kohonen map obtained by learning 36520 random samples of 7304 geopotential height at the 500 hPa surface over Europe (0°W–17.5°E, 35°N–55°N) prepared from twice daily National Centers for Environmental Prediction/National Center for Atmospheric Research reanalysis (Kalnay et al. 1996) from 1 January 2010 to 31 December 2019.




Figure 2: Frequencies being the elected units for each unit in the experiment same as in Fig. 1.