

春季の高温事例と南高北低の気圧配置との関係

The Relationship between Hot Events in Spring and South-High North-Low Pressure Pattern

小松大晟・榎本剛

Taisei KOMATSU and Takeshi ENOMOTO

Synopsis

This study investigates the relationship between hot events in spring and the “South-High North-Low” (SHNL) pressure pattern in Japan. Mean sea-level pressure patterns during April and May from 1975 to 2024 were clustered using the Self-Organizing Map (SOM, Kohonen 1982, 1990), employing learning strategies of Eckert et al. (1996). The frequency of hot events and the degree of SHNL were then analyzed for each cluster. To measure the latter, we propose the SN index defined by the difference of SOM weights at 10 degrees north and south away from the selected locations. Then, to validate the SN index, the SN index of each SOM node is compared with the clustered hot events. We found that the SN index is consistent actual hot events with a few exceptions. The promising results motivate us to conduct case studies to clarify how the SHNL pattern affect the occurrence of hot extremes.

キーワード: クラスタリング, 教師なし学習, 極端気象, 北半球春季, 気圧配置

Keywords: clustering, unsupervised learning, extreme weather, boreal spring, pressure pattern

1. はじめに

予てより, 国内外で夏の高温事例にはしばしば関心が向けられ, 研究対象になることも多い。

夏の高温事例はよく取り沙汰される一方で, 少なくとも日本においては春の高温事例についての先行研究の数は夏に比べて少ないのではないかと考えている。とりわけ昨今では 4 月や 5 月であっても, 25°C どころか 30°C 以上を観測するような事例も珍しくない。例えば 2004 年 4 月 22 日には静岡, 名古屋, 高松, 福岡などで 30°C 以上の高温が観測され, 2019 年 5 月 25 日には, 全国的に 30°C 以上の高温が観測された。

こうした背景を踏まえると, 春の高温事例についての研究の必要性も増しているのではないかと考えられる。春の高温事例の予兆を検知し, 備えることで熱中症の予防などに活かすことが期待される。

日本では, そうした春の高温事例の中には, 南側で高気圧・北側で低気圧といった「南高北低」型 (いわ




Fig. 1 The weather chart in 2004/04/22 00UTC, Japan Meteorological Agency.

ゆる夏型) の気圧配置が見られることがある。上述の 2004 年 4 月 22 日の事例でも「南高北低」の気圧配置が見られる。Fig.1 に見られるように, 太平洋上に高気圧が見られ, 低気圧が日本海上, 沿海州, カム

チャツカ半島沖に低気圧が分布しているとわかる。

では、南高北低の気圧配置は春季の高温事例の主な原因になりうるのだろうか？

本研究は、南高北低の気圧配置と春季の高温事例との関係が統計的に明らかなのかを調べることを目標にしている。それにあたり、まずは南高北低の気圧配置が観測された高温事例を抽出する。そのために、Kohonen (1982, 1990) が提唱した「自己組織化マップ (SOM)」を用いて日本近辺の気圧分布のクラスタリングを行う。クラスタリングの中から南高北低の気圧配置を抽出し、そこにクラスタリングされる高温事例の頻度を求める。クラスタリングの手法は Eckert et al. (1996) を参考にする。また、南高北低の度合いを示す指数として SN index を定義する。SOM の各ノードについて SN index の値を求め、所定の閾値を超えているノードを、南高北低のノードとする。

本稿は次のような章立てで進めていく。

まず第2節では、クラスタリングに用いるSOMの機能的な説明を行う。続く第3節では、実験設定として、使用したデータや、高温事例や南高北低の定義を紹介する。またSOMの具体的な学習プロセスも第3章で説明する。第4節では実際にクラスタリングした結果を説明する。ここではSOMのアウトプットに加え、各パターンに高温事例がどれほどクラスタリングされたか、各パターンにどれほど南高北低の傾向が見られるのかを調べた結果も説明する。さらに第5節では、実際に各パターンにクラスタリングされた事例について、SN indexがそのパターンと近い値になっているのかを検証する。最後に第6節で本研究の結果をまとめ、課題について述べる。

2. 自己組織化マップ (SOM)

まずは、本研究でクラスタリングに用いる自己組織化マップ (SOM) について Eckert et al. (1996) に倣い説明する。ここでは構造についての説明を中心に、計算過程については後ほど説明する。SOM は教師なしの機械学習の一種で、シート状の人工ニューラルネットワークである。Fig.2 を使って説明すると、データ A_k (Input event) をネットワークにインプットし、必要に応じて扱いやすいようにデータを加工する。(Relaying network) 続いてネットワーク (Interactive network) 中のノード (Processing units) にデータを学習させる。それに応じて各ノードがアウトプット (Output responses) を行う。そしてこれらのアウトプットは、学習を繰り返す度に修正され、やがて似たようなアウトプットのノードが寄り集まっていき、そうでないノード同士は離れていく。

では、SOM の構造について説明していく。

まず、インプットするデータを、物理空間上の $k \times l$ の行列とする。ノードは、 $i \times j$ 個だけ Kohonen 空間に配置されており、Fig. 3 のような関係になっている。




Fig. 2 Illustration of a system which implements an ordered mapping, cited from Kohonen (1982).

るものとする。ここで、各ノードがシナプスによって、物理空間の全ての点に接続している。インプットされたデータは、ネットワークを通して個々のノードが持つ $k \times l$ の行列として学習されていく。物理空間上の点 Ψ_{kl} のデータを学習し、ノード n^j の点 (k, l) に反映させる値を、シナプス重み w_{kl}^{ij} として、その初期値を小さなランダム値とする。 D_{RMS} を、シナプス重み w_{kl}^{ij} の値と入力データの点 Ψ_{kl} での値の差の 2 乗の総和の平方根とする。

逐次的にデータをインプットしていき、 D_{RMS} が最小になるノード (Elected unit) を選択する。そのノードの周囲に活動球 (Ball of activity) を定義し、活動球の内側のノードのシナプス重みを更新してインプットしたデータに近づけ、そうでないノードとかけ離れたパターンになるようにする。

また、学習を進めるにつれてシナプス重みを更新する大きさや活動球の半径を縮小させることで、結果を収束させ、過学習を防いでいる。

クラスタリングの一例を Fig. 4 に示す。Fig. 4 は日本域 (120°E-150°E/20°N-50°N) の 500hPa 面ジオポテンシャル高度のパターンを示している。




Fig. 3 The input space of the network given by the geographical area, a schematic representation of the Kohonen network, and Functional diagram of one node, cited from Eckert et al. (1996).




Fig. 4 Self-organizing maps for boreal winter, cited from Enomoto (2021).

連続的に分布が推移していることや、類似したパターン同士で集まり、逆にそうでないパターンが離れてクラスタリングされていることがわかる。

3. 実験設定

本章では、使用したデータや、高温事例や南高北低の定義、さらにSOMの学習過程について述べる。

3.1 データ

まず、今回の実験で使ったデータについて説明する。高温事例を定義するためのデータには、気象庁から提供されているアメダス（AMeDAS）の日最高気温データを利用している。これらアメダスのデータのうち、Fig. 5上の青いドットで示した14ヶ所（千葉、つくば、網代、静岡、伊良湖、名古屋、尾鷲、京都、姫路、呉、高松、高知、福岡、熊本）の値を用いて高温事例を定義する。これら14点はいずれも特別気象地域気象観測所または地域气象台に属し、1975年4月～2024年5月の間移転しておらず、互いに50 km以上離れている。またどの点も関東以南かつ太平洋側に位置しているが、地域ごとの気候条件をある程度揃え、事例解析をしやすくするためである。

一方、SOMで学習させるデータには、JRA-3Q長期再解析データ（Kosaka et al., 2024）のガウス格子上の海面更正気圧（MSLP）データを採用している。ただし、JRA-3Qは6UTCでの日本域（120°E-160°E/15°N-50°N）のデータを採用し、また緯度・経度グリッド上のデータになるよう補間している。そのため、データの大きさは81×71となる。

どちらのデータも、1975～2024年の4月1日～5月31日のデータ（計3050日）を対象とする。また、MSLPデータには緯度方向にガウス重みを乗じ、グリッド




Fig. 5 Selected observation points (blue dots).

が代表している面積を考慮した値を学習させる。

3.2 高温事例の定義

1975～2024年の4月1日～5月31日の日最高気温の偏差について、14ヶ所のアメダスのうち3ヶ所以上で、その地点別/日付別の時間方向の標準偏差の1.5倍以上になった事例を「高温事例」（HE）とする。ここでは、3ヶ所以上で1.5以上の倍の事例をHE1.5、3ヶ所以上で2倍以上の事例をHE2とする。HE全体は3050日中340日で、そのうちHE2は83日確認された。

なお、欠損値については偏差の値をNullから「同日のそれ以外の地点の気温の平均値と、その地点の日付での偏差の平均値の差」に置換しており、また偏差の平均値は偏差の値に比べて十分小さく、0に近似できるとする。

3.3 南高北低の定義

SOMのノード上における「南高北低」を同定するためのインデックス“SN index”を式 (1) のように定義する。

Fig. 6について、紅色/藍色の点はそれぞれ、各アメダスから南に10°離れた点 S_a と、北に10°離れた点 N_a を表している。

SOMでのノード上での紅色/藍色の点での「重み」の値を求め、アメダスごとにとった差分の総和をSN indexとする。SN indexの値が30以上のノードを、南高北低のノードとする。

$$\text{SN index}_{i,j} = \sum_a (100 \times (w_{S_a}^{i,j} - w_{N_a}^{i,j})) \quad (1)$$




Fig. 6 SN index is determined by points 10° south and 10° north of observation points.

3.4 クラスタリング方法

Eckert et al. (1996) の手法を参考にしつつ, SOM を利用して日本域の6UTCでのHEのMSLP分布をクラスタリングしていく. なお, ここではノードの数は4×4個として, Fig. 7のように矩形に配置されているものとする.




Fig. 7 A schematic chart of nodes' positions (black circles).

クラスタリングの手法は次の通りである.

1. 1975～2024年の4月1日～5月31日のある日 l のMSLP ψ^l と, 4月1日～5月31日の対応する日 $\bar{\psi}^k$ を使い $(\psi^l - \bar{\psi}^k)$ を標準化する. ($k = 1, 2, \dots, 61; l = 1, 2, \dots, 3050; k \equiv l \pmod{50}$)
2. Seed値を固定し, シナプス重み $w_{m,n}^{i,j}$ に小さい正のランダム値を与え, ノルムで初期化する. ($m = 1, 2, \dots, 71; n = 1, 2, \dots, 81; i, j = 0, 1, 2, 3$)
3. 全学習回数 $N_{\text{all}} = 68000$ とする. $N \leq N_{\text{all}}/10$ で

$Z = 10$, $N_{\text{all}}/10 \leq N \leq 2N_{\text{all}}/10$ で $Z = 9$, $\dots$, $9N_{\text{all}}/10 \leq N$ というように学習回数 N に対して Z を定め, 標準化した $(\psi^l - \bar{\psi}^k)$ を Z 個ランダムに抽出し平均する. その平均値を Ψ とする. (確率的勾配降下法, Amari, 1967)

4. 4×4個ある各ノード $W(i,j)$ と Ψ の距離 $d_{i,j}$ を式(2)で求める.

$$d_{i,j} = \sqrt{\sum_{m,n} (w_{m,n}^{i,j} - \Psi_{m,n})^2} \quad (2)$$

5. $d_{i,j}$ が最小になるノード $W(I,J)$ を特定し, 更新範囲を式(3)で求める. ここでは $\sigma_0 = 27.00$, $\Pi = 0.20N_{\text{all}}$ である.

$$\sigma(N) = \sigma_0 / \exp(N/\Pi) \quad (3)$$

6. $W(i,j)$ と $W(I,J)$ との距離 $D_{i,j}^{I,J}$ を式(4)で求め, $D_{i,j}^{I,J} < \sigma(N)$ を満たすノードのシナプス重みを式(5)のように更新し, 全てのシナプス重みを各ノードでのノルムで標準化する. ここでは, $x = 8.75$, $y = 10$, $\tau_0 = 7.00 \times 10^{-2}$ とする.

$$D_{i,j}^{I,J} = \sqrt{x^2(i-I)^2 + y^2(j-J)^2} \quad (4)$$

$$\begin{cases} w_{m,n}^{i,j} \rightarrow w_{m,n}^{i,j} + \tau(N) \times (w_{m,n}^{i,j} - \Psi_{m,n}) \\ \tau(N) = \tau_0 / \exp(N/\Pi) \end{cases} \quad (5)$$

7. 3.～6. を N_{all} 回繰り返して学習を終了する.
8. MSLPパターン ψ^l に最も類似したシナプス重みパターンを持つノードを4.の要領で求め, そのノードに各事例を分類し, 各ノードにクラスタリングされたHEの数を求める.

4. 海面更正気圧のクラスタリング

本章では, 上記で紹介した手法によってHEでのMSLPデータをクラスタリングした結果について述べる. HEでのMSLPパターンをFig. 8, 各ノードでのHEの数及びSN indexをFig. 9に示す.

Fig. 8について, 紅色の点及び藍色の点がアメダスより南/北に10°離れた点を示している. さらに正の偏差の等値線を実線で, 負の偏差の等値線を破線でそれぞれ示している.

第3.3節で定義したように, SN indexが30以上のノードを南高北低のノードとするので, Fig. 8とFig. 9を比較すると, 南高北低のノードは (0,0), (1,0), (2,0), (2,1), (3,0), (3,1), (3,2)の7つとなる. HEの数につ

いてはそれらのノードの中でもばらつきがあるものの、(3,2)のノードはHEの数が16個のノードの中で最多で40件を超えている。

一方で、(0,1)や(3,3)のような明らかに南高北低ではないノードでもHEの数が多いたことが読み取れる。このことから、南高北低の気圧配置は、春季の高温事例において見られる気圧配置の1つという予想を立てることができる。




Fig. 8 Each node shows its own MSLP pattern at HEs.




Fig. 9 Numbers show each node's the numbers of clustered HEs, and colors represent SN index.

5. SN index の妥当性

南高北低の度合いを決定するために3.3節でSN indexを定義し、SOMの各ノードでのSN indexを第4章で提示したが、ここではそれが実際の事例に沿うものなのかを確認する。

ここでは、各ノードにクラスタリングされた事例についてSN indexを求め、それがFig. 9で示された値に合致するののかを確認する。




Fig. 10 Histograms describing clustered HE's SN index and frequency. Black dashed lines show SN index of nodes. Red dashed lines show the median of clustered HE's SN index.

Fig. 10は各ノードにクラスタリングされた個々のHEでのSN index (横軸) 及びその頻度 (縦軸) をヒストグラムで、SOMの各ノードでのSN indexを破線でそれぞれ示している。ただし、(0,2)のノードにはHEが1件もクラスタリングされなかったため、割愛している。

Fig. 10を見ると、SN indexが大きいノードで、そのノードのSN indexが、各ノードの個々のHEでのSN indexの中央値よりもやや大きいノードが多く見られることと、逆にSN indexが10未満のノードで、そのノードのSN indexが、個々のHEでの中央値とほぼ等しいかそれを下回っていることがわかる。(2,1)を除いて中央値とノードのSN indexが極端に乖離しているノードは見られず、ある程度適当な値であると解釈できる。

一方で、事例ごとのSN indexの分布は、ガウス関数のようにノードのSN indexに近い値にある程度集中するかと予想していたものの、予想に反して値の幅が広がっていたノードがほとんどであった。特に、南高北低としたノードにも関わらずSN indexが負の事例もクラスタリングされていたことが判明した。アメダスの南北に10°離れた点でSN indexを算出している以上、これらの点より離れた領域でのみ南高北低の状態になっている可能性がある。温度が上昇した背景を検証するには、これらの事例についても確認が必要になると考えられる。

6. まとめ

春季の高温事例と南高北低の気圧配置の関係性について調べるべく、4月、5月の高温事例のMSLP偏差をSOMで学習させてクラスタリングしたところ、高

温事例の中でも、南高北低の気圧配置の事例が比較的多い傾向にあると予想を立てることができた。南高北低ではないノードでも高温事例の数が多い場合があることを踏まえると、現状の結果として、南高北低という気圧配置は、春季の高温事例において見られる気圧配置の1つであると言えるだろう。

しかし、南高北低の気圧配置の事例が多い傾向を確認できた一方で、その原因についてはまだノートッチである。さらに、南高北低のノードにクラスタリングされた事例の中にはSN indexが低いものも散見された。これらの事例について、実際に南高北低だったのかを検証しクラスタリング結果が誤りではないことを確認したい。

また今後は事例解析という形で、南高北低の高温事例だけではなく、南高北低ではない高温事例についても検証し、南高北低の気圧配置が高温事例にどのような影響を与えているのかを検証したい。特に、温度上昇に寄与していると考えられる暖気移流や放射による非断熱加熱について、それらを構成する成分や移流について細分化しつつ、またその成分の寄与と南高北低との因果関係に着目したいと考えている。

謝 辞

本研究の遂行にあたり、理学研究科の先生や学生の皆様によるご指摘やご意見を頂いており、また本研究はJSPS科研費24H02226の支援を受けている。この場をお借りして御礼申し上げます。

参考文献

- 榎本 剛(2021): 自己組織化マップを用いた大気循環パターンのクラスタ解析, 京都大学防災研究所年報, 64号B, pp. 313-316.
- 気象庁: 日々の天気図, 2004年4月 (2025.8.25参照)
<https://www.data.jma.go.jp/yoho/data/hibiten/2004/0404.pdf>
- Amari, S. (1967): A theory of adaptive pattern classifiers, *IEEE Trans. Electron. Comput.* No. 3, pp. 299-307.
- Eckert, P., Cattani, D., and Ambühl, J. (1996): Classification of ensemble forecasts by means of an artificial neural network, *Meteor. Appl.*, Vol.3, No. 2, pp. 169-178.
- Kohonen, T. (1982): Self-organized formation of topologically correct feature maps, *Biol. Cybern.*, Vol.43, No. 1, pp. 59-69.
- Kohonen, T. (1990): The self-organizing map, *Proc. IEEE*, Vol.78, No. 9, pp. 1464-1480.
- Kosaka, Yuki, et al. (2024): The JRA-3Q reanalysis, *J. Meteor. Soc. Japan. Ser. II* Vol.102, No. 1, pp. 49-109.

(論文受理日: 2025年8月29日)