

2変量角度データのための確率分布

加藤 昇吾 数理・推論研究系 助教

研究の目的

2変量角度データ

2変量角度データとは、2つの角度のペア (θ_1, θ_2) ($-\pi \leq \theta_1, \theta_2 < \pi$) として表される観測の集合のことである。

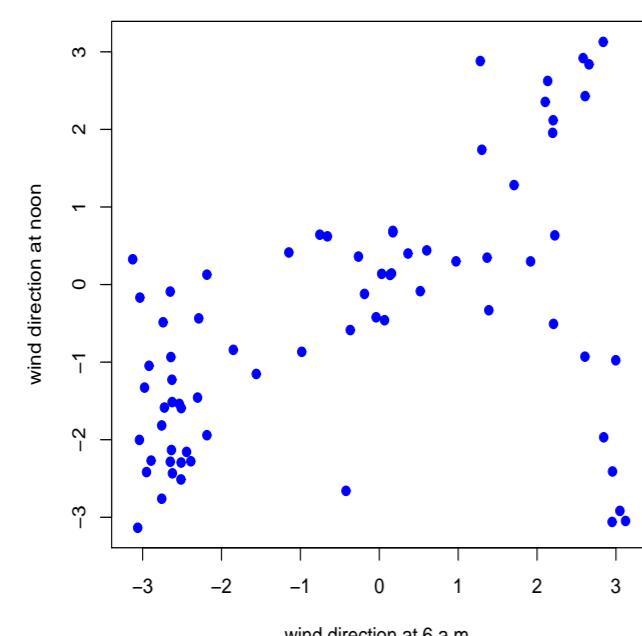


図1. ヒューストン（アメリカ）の気象観測所にて観測された午前6時と正午の風向データ。個々の観測が、左図では $[-\pi, \pi]^2$ 上の点として、右図ではトーラス上の点として表わされている。

2変量角度データのための確率分布

角度には周期性があるため、2変量角度データに（周期性を持たない）2変量確率分布をそのまま当てはめても、満足な当てはめは期待できない。

このような背景の下で、Mardia et al. (2007), Shieh et al. (2011)らが2変量角度データのための確率分布を提案。

⇒ しかし、モデルの解釈・解析的な扱いやすさなどに問題。

研究の目的

本研究では、以下の性質を持つ確率分布の提案を目指す：

- i. 確率密度関数が陽な形で表わされる,
- ii. 5つのパラメータを持ち、それぞれの解釈が明確である,
- iii. 周辺分布・条件付分布がよく知られた分布になる,
- iv. 変量間のdependenceを幅広く調節することができる。

なお、本研究はArthur Pewsey (University of Extremadura)との共同研究である。

2変量角度データのための確率分布

以後便利のため、角度 θ を複素平面における単位円周上の点 $\cos \theta + i \sin \theta$ として表すことにする。ここで、 i は虚数をあらわす ($i^2 = -1$)。

分布の定義

Ω ：複素平面上の単位円,

$U_1, U_2 \sim i.i.d. \Omega$ 上の一様分布,

とする。このとき、新たな確率分布を

$$(Z_1, Z_2) = \left(\eta_1 \frac{V_1 + \xi_1}{\xi_1 V_1 + 1}, \eta_2 \frac{V_2 + \xi_2}{\xi_2 V_2 + 1} \right), \quad (1)$$

で定義する。ここに、 $V_1 = U_1$, $V_2 = (U_2 + r)/(\bar{r}U_2 + 1)$, $r = |\rho|U_1^{\text{sgn}(\rho)}$, $\eta_1, \eta_2 \in \Omega$, $0 \leq \xi_1, \xi_2 < 1$, $-1 < \rho < 1$, $\text{sgn}(x) = 1$ ($x \geq 0$), $\text{sgn}(x) = -1$ ($x < 0$)。

確率密度関数

確率ベクトル (Z_1, Z_2) の確率密度関数は、

$$f(z_1, z_2) = \frac{1}{4\pi^2} \frac{(1 - \rho^2)(1 - \xi_1^2)(1 - \xi_2^2)}{|a_{11}(\bar{z}_1 \eta_1)^q z_2 \bar{\eta}_2 + a_{12}(\bar{z}_1 \eta_1)^q + a_{21} z_2 \bar{\eta}_2 + a_{22}|^2}, \quad z_1, z_2 \in \Omega,$$

で与えられる。ここで、 $a_{11} = \xi_1 \xi_2 - \psi$, $a_{12} = \psi \xi_2 - \xi_1$, $a_{21} = \psi \xi_1 - \xi_2$, $a_{22} = 1 - \psi \xi_1 \xi_2$, $\psi = |\rho|$, $q = \text{sgn}(\rho)$ 。

パラメータの解釈

5つのパラメータのうち、 η_j は Z_j の位置を調節し、 ξ_j は Z_j の集中度を調節し、 ρ は Z_1 と Z_2 の dependence を調節する役割を持つ ($j = 1, 2$)。

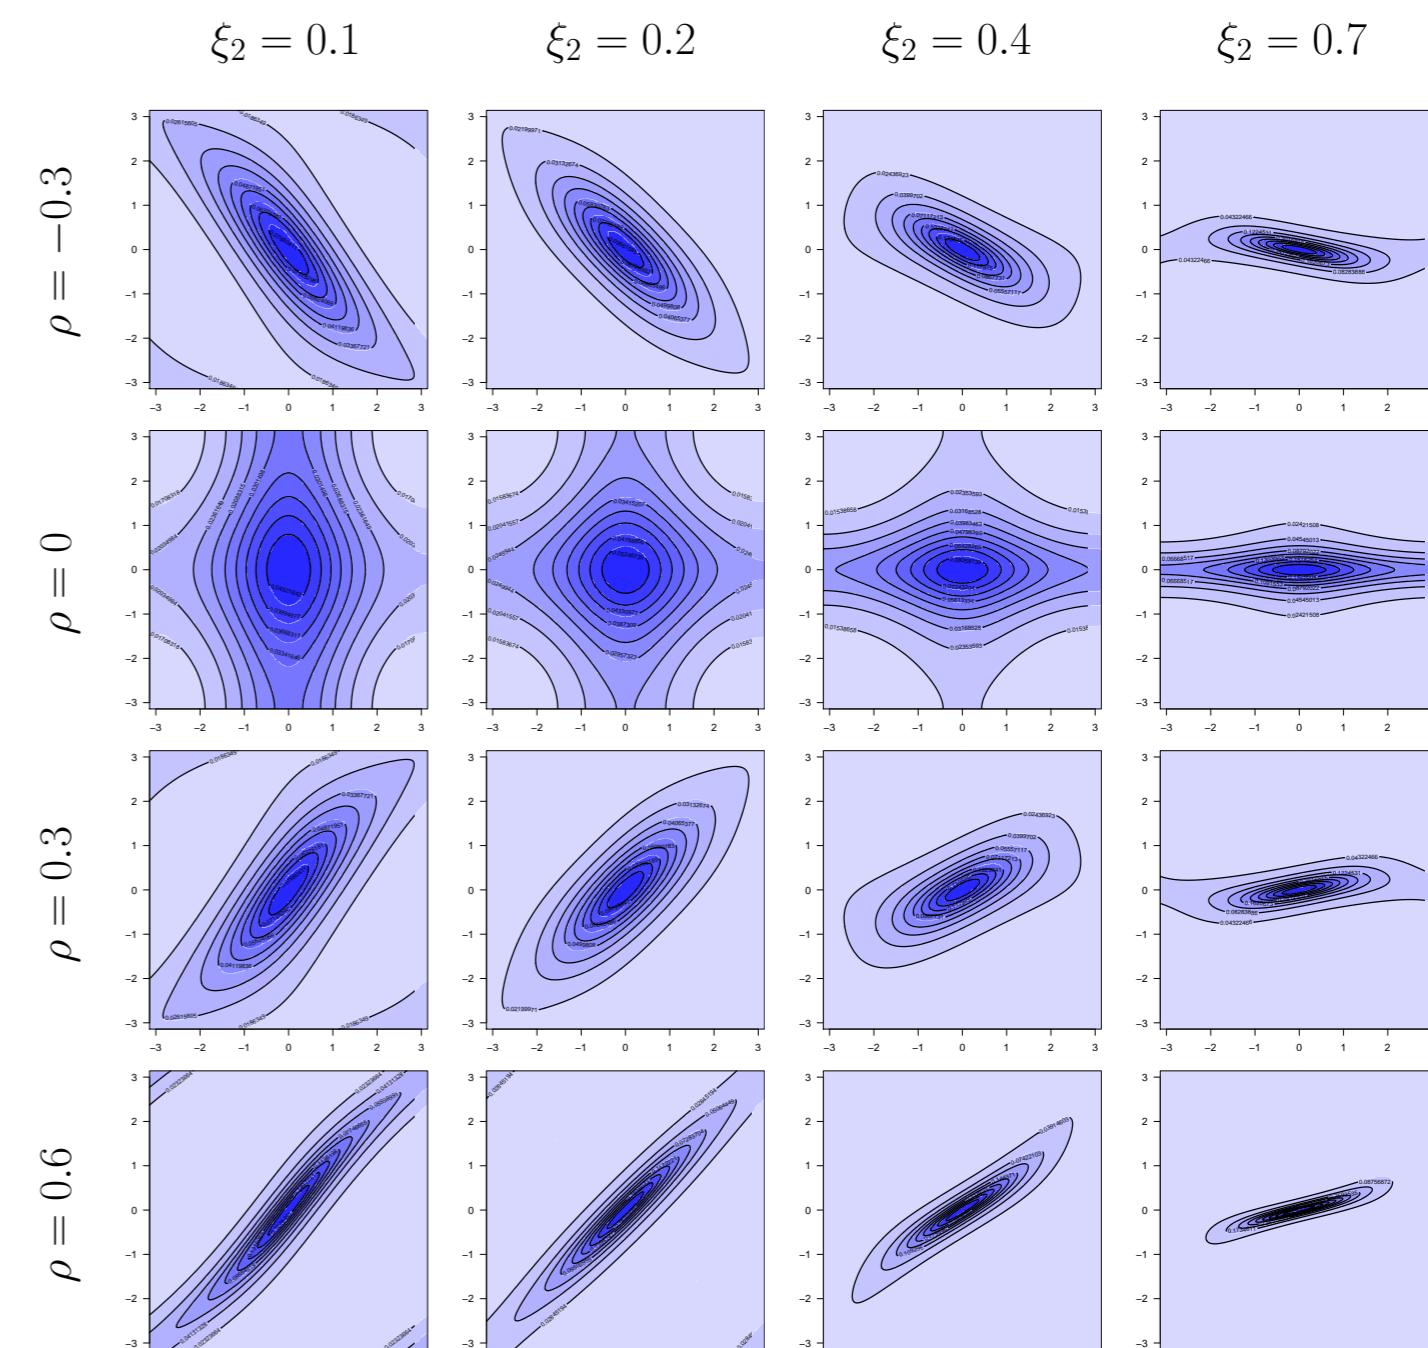


図2. 確率密度関数(2) ($\arg(\eta_1) = \arg(\eta_2) = 0$, $\xi_1 = 0.2$) のプロット。

周辺分布と条件付分布

確率ベクトル (Z_1, Z_2) が、分布(2)に従っているとする。このとき、

$$Z_1 \sim C^*(\xi_1 \eta_1), \quad Z_2 \sim C^*(\xi_2 \eta_2),$$

$$Z_1 | z_2 \sim C^* \left(-\eta_1 \frac{a_{11} \bar{z}_2 + a_{12}}{a_{21} \bar{z}_2 + a_{22}} \right), \quad Z_2 | z_1 \sim C^* \left(-\eta_2 \frac{a_{11} \bar{z}_1 + a_{21}}{a_{12} \bar{z}_1 + a_{22}} \right),$$

が成り立つ。ここに、 $\tilde{z}_j = (z_j \bar{\eta}_j)^q$, $j = 1, 2$. また、 $C^*(\phi)$ は以下の確率密度関数を持つ wrapped Cauchy 分布を表す。

$$f(z) = \frac{1}{2\pi} \frac{1 - |\phi|^2}{|z - \phi|^2}, \quad z \in \Omega; |\phi| < 1.$$

References

- [1] MARDIA, K.V., TAYLOR, C.C. & SUBRAMANIAM, G.K. (2007). Protein bioinformatics and mixtures of bivariate von Mises distributions for angular data. *Biometrics* **63**, 505–512.
- [2] SHIEH, G.S., ZHENG, S., JOHNSON, R.A., CHANG, Y.-F., SHIMIZU, K., WANG, C.-C. & TANG, S.-L. (2011). Modeling and comparing the organization of circular genomes. *Bioinformatics* **27**, 912–918.