

角度データのための扇形ヒストグラムの漸近的性質

和歌山県データ利活用推進センター研究員 鶴田靖人
金沢大学経済学経営学系 寒河江雅彦

角度データ（風向等）は周期性をもつために実数直線上のデータと位相構造が異なり、単位円周上の点として表される。そのために角度データを扱うための独自の統計学が発展し、最近では方向統計学と呼ばれる統計学の1つの分野となっている。方向統計学では角度データ（変数） $\Theta \sim f(\theta)$ を周期性を持つ密度関数 $f(\theta)$ ($f(\theta) = f(\theta + 2\pi)$) に従うと定義する。

本稿では角度データのためのヒストグラムを密度推定量と考え、その理論的性質を議論する。角度データのヒストグラム推定で最も用いられているのはローズダイアグラムである。ローズダイアグラムは、データが入る区間であるビン $B_k := [t_k, t_{k+1}) \in [-\pi, \pi]$ を中心角として持つ面積 v_k/n (B_k の相対頻度) の扇形 S_k を原点周りに並べることで定義される。一般的に各ビン B_k の中心角の大きさはすべて h （等角度）とする。このとき、扇形の面積の公式から S_k の半径は $r_k = \sqrt{2v_k/(nh)}$ である。

分布関数 $F(\theta)$ を原点 O から伸びる線分 $r_f(\theta)$ の通過領域からなる扇形として与える。 $f(\theta) = dF(\theta)/d\theta$ なので扇形の面積の公式より $r_f(\theta) = \sqrt{2f(\theta)}$ となる。ここで、ローズダイアグラムの半径 r_k を $r_f(\theta)$ の推定量と考え、ローズダイアグラム推定量を

$$\hat{r}(\theta; h) := \sqrt{2v_k/(nh)}, \quad \theta \in B_k$$

と定義する。通常のヒストグラム推定量 $\hat{f}(\theta; h) := v_k/(nh)$ を用いると $\hat{r}(\theta; h) = \{\hat{f}(\theta; h)\}^{1/2}$ となる。ローズダイアグラム推定量の誤差基準として、平均積分二乗誤差 (MISE) $MISE[\hat{r}(\theta; h)] := E \left[\int_{-\pi}^{\pi} \{\hat{r}(\theta; h) - r_f(\theta)\}^2 d\theta \right]$ を採用する。ちなみに、 $MISE[\hat{r}(\theta; h)]$ は、 $\hat{r}(\theta; h)$ の定義から Hellinger 距離 $HD[\hat{f}(\theta; h)] := \int_{-\pi}^{\pi} \{\hat{f}(\theta; h) - f(\theta)\}^2 d\theta$ の期待値に対応することが容易に分かる。本稿の主要な結果は次の3点である：

- $MISE[\hat{r}(\theta; h)]$ の導出 ($MISE[\hat{r}(\theta; h)] = O(n^{-2/3})$).
- MISE 基準に基づくビン幅 h の推定量の提案.
- frequency polygon を応用したローズダイアグラムの改良 ($MISE = O(n^{-4/5})$).

当日の発表ではこれらの結果と合わせて、 $MISE[\hat{r}(\theta; h)]$ と Hellinger 距離の対応関係について理論的に考察する。また、ローズダイアグラム推定量に関する数値実験の結果は当日発表する。




図1 風向を表す Wind データ ($n=310$)。Wind データは、統計ソフト R の `circular` パッケージから取得できる。




図2 Wind データのローズダイアグラム。