

ディリクレ分布
と
ディリクレ過程

法数学勉強会





2017/10/14

京都大学(医)統計遺伝学分野

山田 亮

今日と次回(と次々回)の構成

- ディリクレ分布
- ディリクレ過程
 - https://en.wikipedia.org/wiki/Dirichlet_persistent_process
- (ノンパラメトリック・ベイズ)



どうしてディリクレ分布

どうしてディリクレ分布

- アレル頻度のためにある

どうしてディリクレ過程

どうしてディリクレ過程

- アレルの種類数が未知なままに、アレル頻度の推定をしたいことがある
 - Y染色体ハプロタイプ頻度推定

ヨハン・ペーター・グスタフ・ルジュー ヌ・ディリクレ

- <https://ja.wikipedia.org/wiki/%E3%83%9A%E3%83%BC%E3%82%BF%E3%83%BC%E3%83%BB%E3%82%B0%E3%82%B9%E3%82%BF%E3%83%95%E3%83%BB%E3%83%87%E3%82%A3%E3%83%AA%E3%82%AF%E3%83%AC>



どうしてディリクレ分布

- アレル頻度のためにある
- 10人のSNP(一塩基多型) のジェノタイプを調べたら
 - AA 5人
 - AG 3人
 - GG 2人
- だった

どうしてディリクレ分布

- アレル頻度のためにある
- 10人のSNP(一塩基多型) のジェノタイプを調べたら
 - AA 5人
 - AG 3人
 - GG 2人
- だった
- アレルAの頻度はいくつ？

標本頻度と母集団頻度

- AA 5人
 - AG 3人
 - GG 2人
-
- $A : 2 * 5 + 1 * 3 + 0 * 2 = 13$
 - $G : 0 * 5 + 1 * 3 + 2 * 2 = 7$
-
- $13 + 7 = 20 = 10 * 2$

標本頻度と母集団頻度

- AA 5人
- AG 3人
- GG 2人

- Aの割合は
 - $13/20 = 0.65$

- $A : 2 * 5 + 1 * 3 + 0 * 2 = 13$
- $G : 0 * 5 + 1 * 3 + 2 * 2 = 7$

- $13 + 7 = 20 = 10 * 2$

標本頻度

- Aの割合は
 - $13/20 = 0.65$
- 0.65 の意味することは
 - 20本の染色体を観測したら、その65%がAだった、という事実

母集団の頻度

- ある人 X のあるマーカーのジェノタイプを調べたら
 - AAだった
- 現場の試料 Y のジェノタイプを調べたら
 - AAだった
- X が現場に試料を残したと仮定したとき
 - 尤度 $L(Y=AA \mid X=AA) = 1; Y = X$

母集団の頻度

- ある人 X のあるマーカーのジェノタイプを調べたら
 - AAだった
- 現場の試料 Y のジェノタイプを調べたら
 - AAだった
- X ではない、誰か Z が現場に試料を残したと仮定したとき
 - 尤度 $L(Y=AA \mid Z=??) = ? ; Y = Z$

母集団の頻度

- ある人 X のあるマーカーのジェノタイプを調べたら
 - AAだった
- 現場の試料 Y のジェノタイプを調べたら
 - AAだった
- X ではない、誰か Z が現場に試料を残したと仮定したとき
 - 尤度 $L(Y=AA | Z=??) = ? ; Y = Z$
 - $\Pr(Z=AA), \Pr(Z=AG), \Pr(Z=GG)$ が知りたい
 - なぜなら
 - $L(Y=AA | Z=??) = \Pr(Z=AA) * L(Y=AA|Z=AA) + \Pr(Z=AG) * L(Y=AA|Z=AG) + \Pr(Z=GG) * L(Y=AA| Z=GG)$
 - $L(Y=AA | Z=??) = \Pr(Z=AA) * 1 + 0 + 0 = \Pr(Z=AA)$

母集団の頻度

- $L(Y=AA \mid Z=??) = \Pr(Z=AA)$
- $\Pr(Z=AA)$, $\Pr(Z=AG)$, $\Pr(Z=GG)$ が知りたい
- $\Pr(Z=**)$ は、想定している集団のジェノタイプ頻度
- $\Pr(Z=AA) = \text{????} 0.65 * 0.65 \text{????}$

- AA 5人
- AG 3人
- GG 2人

- A: $2 * 5 + 1 * 3 + 0 * 2 = 13$
- G: $0 * 5 + 1 * 3 + 2 * 2 = 7$

- $13 + 7 = 20 = 10 * 2$

- Aの割合は
 - $13/20 = 0.65$

母集団の頻度

- AA 5人
- AG 3人
- GG 2人

- $A : 2 * 5 + 1 * 3 + 0 * 2 = 13$
- $G : 0 * 5 + 1 * 3 + 2 * 2 = 7$

- $13 + 7 = 20 = 10 * 2$

- Aの割合は
 - $13/20 = 0.65$

- AA 5000人
- AG 3000人
- GG 2000人


- $A : 2 * 5000 + 1 * 3000 + 0 * 2000 = 13000$
- $G : 0 * 5000 + 1 * 3000 + 2 * 2000 = 7000$

- $13000 + 7000 = 20000 = 10000 * 2$


- Aの割合は
 - $13000/20000 = 0.65$

母集団の頻度のベイズ推定


全10人



全10000人



母集団の頻度のベイズ推定



尤度を計算する

- 母集団でのAの割合が p だとしたとき
- 20本中13本がAとして観察される確率は
- 20本中13本がAという観測をしたとき
- 母集団でのAの割合が p である尤度

- $\frac{20!}{13!7!} \times p^{13} \times (1-p)^7$


- AA 5人
- AG 3人
- GG 2人

- A: $2 * 5 + 1 * 3 + 0 * 2 = 13$
- G: $0 * 5 + 1 * 3 + 2 * 2 = 7$


- $13 + 7 = 20 = 10 * 2$

- Aの割合は
 - $13/20 = 0.65$

- $\frac{20!}{13!7!} \times p^{13} \times (1-p)^7$





- $\frac{20000!}{13000!7000!} \times p^{13000} \times (1-p)^{7000}$



- $\frac{20!}{13!7!} \times p^{13} \times (1-p)^7$

- $\frac{20000!}{13000!7000!} \times p^{13000} \times (1-p)^{7000}$

尤度関数は積分して1になるとは限らない



p

p

尤度関数を定数倍して、積分 = 1 にする

- $? \times p^{13} \times (1-p)^7$
- p について0から1まで積分して、1になるように？を掛ける

- $\frac{20!}{13!7!} \times p^{13} \times (1-p)^7$ 確率・尤度

- $\frac{21!}{13!7!} \times p^{13} \times (1-p)^7$ 積分して1になるように直した



どこが違う？

ベータ分布

- 起きるか起きないか、の観測データに基づいて、成功率の尤度を考える
- この尤度関数を定数倍して、積分が1になるような確率密度分布をベータ分布と呼ぶ
- 「起きた回数：S」 「起きなかった回数：F」
- $\frac{(S+F+1)!}{S!F!} \times p^S \times (1-p)^F$

ベータ分布


- $\frac{(S+F+1)!}{S!F!} \times p^S \times (1-p)^F$
- 別の書き方もよくする
- $S \rightarrow A-1, F \rightarrow B-1$
- $\frac{((A-1)+(B-1)+1)!}{(A-1)!(B-1)!} \times p^{(A-1)} \times (1-p)^{(B-1)}$
- $\Gamma(z+1) = z!, \Gamma(w) = (w-1)!$
- $\frac{\Gamma(A+B)!}{\Gamma(A)!\Gamma(B)!} \times p^{(A-1)} \times (1-p)^{(B-1)}$

練習問題

- 成功率が a であるような確率事象を 5 回の試みたところ、4 回成功して 1 回失敗する確率を計算する式を書け
- 5 回の試行で 4 回成功し、1 回失敗した。この確率事象の成功率が a であるような尤度を計算する式を書け
- このような尤度に比例したベータ分布の確率密度関数の式を書け


ベータ分布の期待値と最頻値

- 赤：最頻値
- 緑：期待値




ベータ分布の期待値と最頻値

- 赤：最頻値
- 尤度が最大
- 最尤推定値
- $13/20$
- 標本頻度



ベータ分布の期待値と最頻値

- 緑：期待値
- 最頻値よりも
- 中央寄り
- 20回の試行後
- 21回目に成功する確率



$$\bullet \beta'(p|S, F) = \frac{(S+F+1)!}{S!F!} \times p^S \times (1-p)^F$$

練習問題

$$\bullet \beta(p|A, B) = \frac{\Gamma(A+B)!}{\Gamma(A)! \Gamma(B)!} \times p^{(A-1)} \times (1-p)^{(B-1)}$$

- 10回の試行、4回の成功
 - 式でのS,Fはいくつか、A,Bはいくつか？
 - 「標本成功率」はいくつか？
 - この確率事象の成功率はベータ分布を取る。そのベータ分布の確率密度を最大とする成功率はいくつか？
 - この確率事象の成功率の最尤推定値はいくつか？
 - この確率事象の成功率を表すベータ分布の期待値はいくつか？

$$\bullet \beta'(p|S, F) = \frac{(S+F+1)!}{S!F!} \times p^S \times (1-p)^F$$

練習問題

$$\bullet \beta(p|A, B) = \frac{\Gamma(A+B)!}{\Gamma(A)! \Gamma(B)!} \times p^{(A-1)} \times (1-p)^{(B-1)}$$

- 0回の試行、0回の成功
 - 式でのS,Fはいくつか、A,Bはいくつか？
 - 「標本成功率」はいくつか？
 - この確率事象の成功率はベータ分布を取る。そのベータ分布の確率密度を最大とする成功率はいくつか？
 - この確率事象の成功率の最尤推定値はいくつか？
 - この確率事象の成功率を表すベータ分布の期待値はいくつか？
- 一様分布
 - 一様分布となるS,Fはいくつか、A,Bはいくつか？

事前分布

$$\bullet \beta'(p|S, F) = \frac{(S+F+1)!}{S!F!} \times p^S \times (1-p)^F$$

事後分布

共役事前分布

$$\bullet \beta(p|A, B) = \frac{\Gamma(A+B)!}{\Gamma(A)! \Gamma(B)!} \times p^{(A-1)} \times (1-p)^{(B-1)}$$

- 実験前に、成功率 p が一様分布であると思っていた
 - $p = 0.3$ の事前確率はいくつか？ $p = 0.4$ の事前確率いくつか？
 - 事前分布を $\beta(p|A, B)$ と考えると、 A, B をいくつとみなしていたことになるか？
- 実験を行った。試行3回、成功2回だった
 - $p = 0.3$ と $p = 0.4$ との尤度比を β 分布関数を用いて考えよ
 - 事後確率 = 事前確率 \times 尤度である。どのような式になるか？
- 実験前に、なんとなく、成功率が0.5より高いような予感がしていた、
と言う
 - その事前分布を p の関数として図示してみよ
 - その事前分布に近いベータ分布のパラメタが a, b だったとする
 - このとき、事後分布はどのような式になるか？






共役事前分布

- 成功確率をベイズ推定する場合
- 事前分布としてベータ分布を用いると
- 実験後の事後分布は
 - 事前分布のベータ分布を表すパラメタ値と
 - 尤度を表すベータ分布を表すパラメタ値と
 - だけを使って
 - 事後分布のベータ分布を表すパラメタ値が算出できる
- このような便利な事前分布を共役事前分布と呼ぶ
 - したがって
 - ベータ分布は、二項現象にとっての共役事前分布
 - ベータ分布と二項分布は共役

ディリクレ分布は、ベータ分布の多項版

- ベータ分布は、二項事象の成功確率の尤度関数に比例し、積分して1になるような確率密度分布
- ディリクレ分布は、項数が増えたときに、同じく
 - 尤度関数に比例し
 - 積分して1になるような確率密度関数

ベータ分布とディリクレ分布(項数 3)の形





正単体

ベータ分布・ディリクレ分布の「領域」

- 三角形の一般化

- $p_1 + p_2 + \dots + p_k = 1$ の一般化



式を比べる

K=2がベータ分布になることを確認

- ベータ分布 $\beta(p|A, B) = \frac{\Gamma(A+B)!}{\Gamma(A)! \Gamma(B)!} \times p^{(A-1)} \times (1-p)^{(B-1)}$

台

$$x \in [0; 1]$$

- ディリクレ分布

台

$$x_1, \dots, x_K \text{、ここで、} x_i \in [0, 1] \text{ かつ}$$
$$\sum x_i = 1$$

式を比べる

$$\beta(p|A, B) = \frac{\Gamma(A+B)!}{\Gamma(A)! \Gamma(B)!} \times p^{(A-1)} \times (1-p)^{(B-1)}$$

- ベータ分布

確率密度関数

$$\frac{x^{\alpha-1} (1-x)^{\beta-1}}{B(\alpha, \beta)}$$

- ディリクレ分布

確率密度関数

$$\frac{1}{B(\boldsymbol{\alpha})} \prod_{i=1}^K x_i^{\alpha_i-1}$$

$$\text{ここで、 } B(\boldsymbol{\alpha}) = \frac{\prod_{i=1}^K \Gamma(\alpha_i)}{\Gamma(\sum_{i=1}^K \alpha_i)}$$

$$\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_K)$$

式を比べる

$$\beta(p|A, B) = \frac{\Gamma(A+B)!}{\Gamma(A)! \Gamma(B)!} \times p^{(A-1)} \times (1-p)^{(B-1)}$$

- ベータ分布

期待値

$$\mathbf{E}[X] = \frac{\alpha}{\alpha + \beta}$$

- ディリクレ分布

期待値

$$\mathbf{E}[X_i] = \frac{\alpha_i}{\sum_k \alpha_k}$$

式を比べる

$$\beta(p|A, B) = \frac{\Gamma(A+B)!}{\Gamma(A)! \Gamma(B)!} \times p^{(A-1)} \times (1-p)^{(B-1)}$$

- ベータ分布

最頻値

$$\frac{\alpha - 1}{\alpha + \beta - 2}$$

- ディリクレ分布

最頻値

$$x_i = \frac{\alpha_i - 1}{\sum_{i=1}^K \alpha_i - K}$$

式を比べる

$$\beta(p|A, B) = \frac{\Gamma(A+B)!}{\Gamma(A)! \Gamma(B)!} \times p^{(A-1)} \times (1-p)^{(B-1)}$$

- ベータ分布
 - 一様分布の α 。B は？
- ディリクレ分布
 - 一様分布の $\alpha = (\alpha_1, \alpha_2, \dots)$ は？

式を比べる

最頻値

$$x_i = \frac{\alpha_i - 1}{\sum_{i=1}^K \alpha_i - K}$$

最頻値

$$\frac{\alpha - 1}{\alpha + \beta - 2}$$

ディリクレ過程

- 次回のお楽しみ

中華料理店過程(チャイニーズレストラン 過程)