

知的情報処理 4. ナイーブなベイズ法 補足 (Laplace correction)

慶應義塾大学理工学部
櫻井 彰人

前置き

- Laplace correction については、講義資料「4. ナイーブなベイズ法」の p.5 右上のスライドに記し、また、講義中でも説明した。
- しかし、聞き落とした人がいるようなので、以下、説明を追加しようと思う。
- しかし、ただ、追加するんじゃ、解答を示すようなもので、ちょっと癪だし、聞いていた人には不公平だろう。
- というわけで、ちょっと意地悪なんだが、説明を少し詳しくし、余分な話題を入れて、目くらまししてみました。
- どうだろうか？

Laplace's Law of Succession

- ラプラスの「連の法則」とでも訳しましょうか。
- 同じ事象が n 回連続して起こった場合に、その事象が $n+1$ 回目も起こる確率は、 $(n+1)/(n+2)$ である。
- この定理の不思議さ：
 - 普通に、丁半勝負を考えよう。
 - 丁ばかり10回続いた。丁が出る確率は最尤推定すると $10/10 = 1$ である。従って、次に丁となる確率は1である。
 - まあ、10回も続けば、いかさまサイコロだと思うよね。
 - しかし、ラプラスによれば、 $11/12$

最尤推定 vs Laplace

- 10回などといわずに、2回にしてみよう。すなわち、丁が2回続いたとしよう。
- 最尤推定なら、丁が出る確率は $2/2=1$ ゆえ、次に丁の出る確率は1。
- Laplaceによれば、 $3/4$ 。
- どちらが正しい？
- では、丁が1回続いた(続いてない?)
- 最尤推定なら、丁の出る確率は $1/1=1$ ゆえ、次に丁の出る確率は1。
- Laplaceによれば、 $2/3$ 。
- さて、どちらが正しいですか？

証明

- ここでは、丁半勝負、ではなかった、ベルヌーイ試行 (coin-tossing) を考える。
- ただしコインは $N+1$ 種類あり (表が出る確率は異なる)、どのコインであるかは、出題者は知っているが回答者は知らないとする。
- i 番目のコインの表が出る確率は i/N ($i=0, \dots, N$) とする。
- 出題者は、 $N+1$ 個のコインを等確率で選び、一回選べば、あとはそれを使い続けるとする。
- n 回連続して表が出たときに、 $n+1$ 回目も表が出る確率を求めたい。
- コイン i を選んだという条件下で、 n 回連続して表が出る確率は $(i/N)^n$ である。従って、 n 回連続して表が出る確率は $(1/(N+1)) \sum_{i=0}^N (i/N)^n$ これを $F_{N,n}$ と表す。
- $n+1$ 回連続して表が出る確率は $F_{N,n+1} = (1/(N+1)) \sum_{i=0}^N (i/N)^{n+1}$ である
- 従って、求める確率は $F_{N,n+1} / F_{N,n}$ である (式は複雑)。そこで次頁。

証明 (続)

- $N \rightarrow \infty$ の極限を考えよう。
 - これは、コインの表が出る確率が、 $[0, 1]$ 上の一様分布に従うことを意味する。
- $F_{N,n} = (1/(N+1)) \sum_{i=0}^N (i/N)^n \rightarrow \int_0^1 x^n dx = 1/(n+1)$
- 従って、求める確率は、 $N \rightarrow \infty$ のとき、 $F_{N,n+1}/F_{N,n} \rightarrow F_{\infty,n+1}/F_{\infty,n} = (n+1)/(n+2)$
- つまり、より正確に述べれば、Laplace's law of succession は、(coin tossing を例にすれば) 出題者は、表が出る確率を一様分布に従ってランダムに決め、それを用いて coin toss をする、一方回答者は、表が出る確率を知らないで (しかし、一様分布に従っていることは知っている)、 n 回連続して表が出たときに、 $n+1$ 回目も表が出る確率を求めるといった状況において、その確率は、 $(n+1)/(n+2)$ であると主張している。

補足: 誤った証明(?)

- コイン*i*が選ばれたとき、*n*回連続して表が出る確率は $(i/N)^n$ であり、*n*+1回連続して表が出る確率は $(i/N)^{n+1}$ である。
- 従って、コイン*i*が選ばれたとき、*n*回連続して表が出た後、*n*+1回目も表が出る確率は、 $(i/N)^{n+1} / (i/N)^n = i/N$ である。
- コイン*i*が選ばれる確率は $1/(N+1)$ であるから、*n*回連続して表が出た後、*n*+1回目も表が出る確率は $(1/(N+1)) \sum_{i=0}^N (i/N) = 1/2$ である。

補足: 式で書いて比較しよう

- $P(n+1 \text{ 回表} | n \text{ 回表})$
 $= P(n+1 \text{ 回表}, n \text{ 回表}) / P(n \text{ 回表})$
 $= P(n+1 \text{ 回表}) / P(n \text{ 回表})$
 - $P(n \text{ 回表})$
 $= \sum_{i=0}^N P(n \text{ 回表} | \text{コイン } i) P(\text{コイン } i)$
 $= \sum_{i=0}^N (i/N)^n (1/(N+1)) \rightarrow 1/(n+1)$
 - $P(n+1 \text{ 回表} | n \text{ 回表}) \rightarrow (n+1)/(n+2)$
- どこに間違いがあるか？
- $P(n+1 \text{ 回表} | n \text{ 回表})$
 $= \sum_{i=0}^N P(n+1 \text{ 回表} | n \text{ 回表}, \text{コイン } i) P(\text{コイン } i)$
 $= \sum_{i=0}^N P(\text{コイン } i) P(n+1 \text{ 回表}, n \text{ 回表}, \text{コイン } i) / P(n \text{ 回表}, \text{コイン } i)$
 $= \sum_{i=0}^N P(\text{コイン } i) P(n+1 \text{ 回表}, \text{コイン } i) / P(n \text{ 回表}, \text{コイン } i)$
 $= (1/(N+1)) \sum_{i=0}^N (i/N)$
 $= 1/2$

Laplace correction

Laplace smoothing とも言います

- 先ほどの問題で、最尤法を用いてより直感に合う結果を得る方法でもある。
- 再び最尤推定で考えよう。
- 最初から*n*回続けて表が出れば、表が出る確率の最尤推定量は $n/n = 1$ 。
- しかし、これはおかしい。裏が出る確率が0というのはありえない。仮に、回答者が見る前に、表・裏一回ずつ出たものとしてみよう(これが Laplace correction)。
- そうすると、全部で *n*+2回試行し、*n*+1回表が出たことになるので、表が出る確率の最尤推定量は、 $(n+1)/(n+2)$
- Laplace's law of succession の結果とぴったり合う！

パラメータの事前分布

- 最尤推定ではなく、事後確率分布によるパラメータの期待値を推定値としてみよう。すなわち、表が出る確率 *p* を $\bar{p} = \int_0^1 p P(p | n \text{ 回表}) dp$ で推定したい。
-ではなく(∧)にしたいのですが、できませんでした。
- この推定を行うには、パラメータ *p* の事前分布を知る必要がある。仮に、 $[0, 1]$ 上の一様分布だと考えよう。そうすると、
 $\bar{p} = \int_0^1 p P(n \text{ 回表} | p) P(p) / P(n \text{ 回表}) dp$
 $= \int_0^1 p^{n+1} / (\int_0^1 p^n dp) dp$
 $= (n+1)/(n+2)$

 $P(n \text{ 回表})$
 $= \int_0^1 P(n \text{ 回表} | p) P(p) dp$
 $= \int_0^1 p^n dp$
- これはLaplace's law of successionの結果に一致する！
- すなわち、Laplace's law of successionの結果は(Laplace correctionの結果は)、パラメータの事前分布を一様分布と仮定し、事後分布によるパラメータの期待値を推定値とすることに相当する！

パラメータの事前分布 (続)

- 一様分布では気に食わない？
 - 誰でもそう思う。
- では、ベータ分布 $f(x; \alpha, \beta) = x^{\alpha-1} (1-x)^{\beta-1} / B(\alpha, \beta)$ を考えよう。なお $f(x; 1, 1)$ が一様分布である。
 - なぜベータ分布か？って？ 二項分布の双対分布だから。
 - なぜ双対分布か？って？ そうでない計算ができないから、...
- このとき、事後分布によるパラメータの期待値を推定値とすると、その値は、 $(n+\alpha)/(n+\alpha+\beta)$ となる
- これをLaplace correctionの拡張として用いることができる。 $(n+1)/(n+2)$ の代わりに $(n+1/2)/(n+1)$ や $(n+1/3)/(n+2/3)$ などを用いる方法となる。
- もっとも、そうなると、どれを使ったらよいのだろうか？という迷いが生まれる
 - 選択肢が多いと困ることもある
- 実は、(理論的な)答えは、ない