

Bayessche Statistik

Christian Meisel

19.07.2007

Gliederung

- 1 Einleitung
- 2 Wahl der a priori Verteilung
- 3 Bezug zur Maximum Likelihood Methode

Wahrscheinlichkeitsbegriff

- In Bayesscher Statistik wird Wahrscheinlichkeit p im Sinne von unvollständigem Wissen über ein Ereignis verwendet.
- Bei gleichem Vorwissen über unterschiedliche Ereignisse werden diesen dementsprechend auch gleiche Wahrscheinlichkeiten zugeordnet.

Wahrscheinlichkeitsbegriff

Im Gegensatz dazu wird Frequenz f abgegrenzt, welche die Häufigkeit des Auftretens eines Ereignisses bei repetitiven Zufallsexperimenten beschreibt.

Wahrscheinlichkeitsbegriff

Beispiel Münzwurf: beide Ergebnisse haben $p = 1/2$ und $f = 1/2$
(Anzahl der Versuche gegen unendlich)

p und f dürfen jedoch nicht verwechselt oder gleich gesetzt werden. Statt dessen soll die Wahrscheinlichkeit $p(f)df$, dass die Frequenz im Intervall df liegt, berechnet werden.

Bedingte Wahrscheinlichkeiten

- Bayessche Statistik arbeitet mit bedingten Wahrscheinlichkeiten
- A ist wahr unter der Bedingung B: $A|B$
- deren Wahrscheinlichkeit $p(A|B)$

Bayessches Theorem

- aus klassischer Statistik gilt:

$$p(A|BC)p(B|C) = \frac{p(A \cap B \cap C)}{p(B \cap C)} * \frac{p(B \cap C)}{p(C)} = \frac{p(A \cap B \cap C)}{p(C)}$$

- somit ist $p(AB|C) = p(A|BC)p(B|C)$
- da AB und BA den gleichen Zustand beschreiben, lässt sich A und B auf rechter Seite austauschen, also
- $p(A|BC)p(B|C) = p(B|AC)p(A|C)$


Durch umstellen folgt das Bayessche Theorem:

$$p(A|BC) = p(A|C) \frac{p(B|AC)}{p(B|C)}$$

Bayessches Theorem

$$p(A|BC) = p(A|C) \frac{p(B|AC)}{p(B|C)}$$

- $p(A|C)$ ist a priori-Wahrscheinlichkeit, abhängig nur von A
- $p(A|BC)$ ist a posteriori-Wahrscheinlichkeit, beeinflusst durch die zusätzliche Information B
- $p(B|AC)$ wird als Likelihood bezeichnet



A-priori- und A-posteriori-Dichte

Bayessches Theorem

- Bayessches Theorem als Lernprozess
- erstem Wissen, welches nur C beinhaltet, werden die veränderten Bedingungen unter B hinzugefügt
- neue Informationen B_1, B_2, \dots können eingeschlossen werden.

Umgekehrt wichtig zu fragen, was wussten wir über A bevor B gesehen zu haben.

Anwendungsbeispiel zum Bayesschen Theorem

Berühmtes Beispiel von Laplace

- A: Masse von Saturn M_S liegt in bestimmtem Intervall
- B: Daten von Observatorien ueber gegenseitige Störungen von Jupiter und Saturn
- C: 'common sense', dass M_S weder so klein sein kann, dass er seine Ringe verliert, noch so gross, dass er das Sonnensystem zerstört

Daten aus dem 18. JH liessen mit BT eine Schätzung von M_S und Vorhersage auf 1 Prozent Genauigkeit zu, bis heute Wert nur um 0,63 Prozent korrigiert.

Anwendungsbeispiel zum Bayesschen Theorem

- zwei Freunde in Pub, einer muss zahlen
- wie gross ist Wahrscheinlichkeit des Betrugs?
- $p(C|W_n) = p(C) * \frac{p(W_n|C)}{p(W_n)}$
- $p(W_n) = p(W_n|C) * p(C) + p(W_n|H) * p(H)$
- ferner seien $p(W_n|C) = 1$; $p(W_n|H) = 2^{-n}$
- unter freundschaftlicher Annahme $p(C) = 0,05$:

n	$P(C W_n)$ (%)	$P(H W_n)$ (%)
0	5.0	95.0
1	9.5	90.5
2	17.4	82.6
3	29.4	70.6
4	45.7	54.3
5	62.7	37.3
6	77.1	22.9
...

Problematik der objektiven a priori-Verteilung

Subjektivität

- verschiedene Physiker
- verschiedene Ansichten
- verschiedene Resultate

Objektivierbarkeit durch

- minimale Information
- maximale Ignoranz
- Skalenargumente

Minimale Information

- wichtig ist, nicht zuviel 'Wissen' in a priori Verteilung zu integrieren
- von allen Verteilungen ist die zu nehmen, in welcher das a priori Wissen minimal ist
- anders formuliert, muss das Mass an Unsicherheit maximal sein

Shannon Entropie

$$S_I = - \sum p_i \lg p_i$$

- ist in Mass für Unsicherheit
- $S_I = \textit{maximal}$ wenn alle $p(x_i)$ identisch
- $S_I = \textit{minimal}$ wenn $p(x_0) = 1$ oder 0

Maximale Entropie

- Ergebnisraum X bestehend aus Elementarereignissen $(x_1 \dots x_N)$
- aufgrund von physikalischen Restriktionen nicht alle in gleicher Weise realisierbar
- daher bestehen zusätzliche Einschränkungen auf $p_i = p(x_i)$
- Problem: Suche p_i auf erlaubten Konfigurationen, so dass möglichst viele Freiheitsgrade erhalten bleiben

Maximale Entropie

- **Problem:** $S(p) \doteq \max$ unter NB $\sum f_k(x_i)p(x_i) = F_k$
- **Lösung** mit Lagrangesche Multiplikatoren:
$$L(p; \lambda) = - \sum p_i \lg p_i + \sum \lambda_k (\sum f_k(x_i) - F_k) = \max$$
- $\delta_{p_j} = - \lg p(x_j) - 1 + \sum \lambda_k f_k(x_j) = 0$
- $p_j = \frac{1}{Z(\lambda)} \exp(\lambda_1 f_1(x_j) + \dots + \lambda_m f_m(x_j))$
mit $Z(\lambda_1 \dots \lambda_m) = \sum \exp(\lambda_1 f_1(x_i) + \dots + \lambda_m f_m(x_i))$
- $F_k = \delta_{\lambda_k} \lg Z(\lambda_1 \dots \lambda_m)$

Transinformation

- seien x, y Parameter mit gemeinsamer Dichte $p(x, y)$
- $S(p) = - \sum p(x, y) \lg p(x, y)$
- Relative Entropie/Transinformation

$$- \sum p(x, y) \lg \frac{p(x, y)}{p(x)p(y)} =$$

$$= - \sum p(x, y) \lg p(x, y) + \sum p(x, y) \lg p(x) + \sum p(x, y) \lg p(y)$$

$$= S(x, y) - S(x) - S(y)$$

$$= I(x, y) = \text{Transinformation}$$

- $I(x, y) = 0$ wenn x, y unabhängig

Reference Prior

- $I(x,y)$ entspricht Verminderung (im Mittel) der Unsicherheit eines Parameters durch Beobachten des anderen
- 'Lerneffekt'
- Reference Prior: wähle jene a priori Verteilung, welche Lerneffekt I maximiert

Skaleninvarianz

- Zuordnung der a priori Verteilung muss skaleninvariant sein
- gegeben sei $p(x|C)dx = p(y|C)dy$
- unter Ortstransformation
 - $y = x + b \Rightarrow p(x|C)dx = p(x + b|C)dx$
 - $p(x|C) = \text{const.}$, ergibt also gleichen Prior
- unter Skalentransformation
 - $y = \alpha x, dy = \alpha dx \Rightarrow p(x|C)dx = \alpha p(\alpha x|C)dx$
 - $p(x|C) = 1/x$ ist Jeffreys Prior

Skaleninvarianz

- beispielhaft zwei Beobachter die mit verschiedenen Uhren Experiment beobachten
- haben gleiches Vorwissen und sollten deshalb auch gleichen Prior verwenden
- Wahl eines anderen Priors würde ein unterschiedliches Vorwissen implizieren

Bezug zur Maximum Likelihood Methode

- sei $\underline{x} = x_1, \dots, x_n$ N-Tupel von Observablen
- Likelihood unter Parameter μ \underline{x} zu finden ist in diesem Fall $f(\underline{x}|\mu)$
- BT $f(\mu|\underline{x}) = f_0(\mu) \frac{f(\underline{x}|\mu)}{f(\underline{x})}$
- es kann gezeigt werden, dass der Einfluss des Priors auf die a posteriori Verteilung für zunehmende Information (z.B. durch Iteration) asymptotisch abnimmt
- $f(\mu|\underline{x}) \approx \frac{f(\underline{x}|\mu)}{f(\underline{x})}$
- $f(\mu|\underline{x}) \propto f(\underline{x}|\mu) \equiv L(\mu; \underline{x})$
- asymptotisch nähert sich die a posteriori Wskt der normalisierten Likelihood

Beispiel Binomialverteilung

- $p(x|\theta) = \binom{n}{k} \theta^k (1 - \theta)^{n-k}$
- BT $f(\theta|x) = \frac{p(x|\theta)f(\theta)}{\int p(x|t)f(t)dt}$
- Mittelwert mit MaxLike Schätzer $\hat{p} = \arg \max p(x|\theta) = k/n$
- betrachten Standardisierte Gauss-Verteilung
 $f(\theta) = 1/\sqrt{2\pi} \exp -\theta^2/2$

