

Konzentrationsungleichungen

Übungsblatt 11

TU Dortmund, Sommersemester 2021

Prof. Dr. Ivan Veselić

Übung 1. Seien X_1, \dots, X_n diskrete Zufallsvariablen auf Räumen $\mathcal{X}_1, \dots, \mathcal{X}_n$ mit gemeinsamer Verteilung P und Dichte p und seien Y_1, \dots, Y_n eine weitere Familie von Zufallsvariablen auf den selben Räumen $\mathcal{X}_1, \dots, \mathcal{X}_n$ mit gemeinsamer Verteilung Q und Dichte q . Für $i \in \{1, \dots, n\}$ bezeichnen $P_{1:i}$ und $Q_{1:i}$ die jeweiligen Randdichten der Vektoren (X_1, \dots, X_i) bzw. (Y_1, \dots, Y_i) und bezeichnen $P_{X_i|1\dots i-1}$ und $Q_{Y_i|1\dots i-1}$ die jeweiligen bedingten Dichten von X_i bezüglich X_1, \dots, X_{i-1} unter P bzw. Y_i bezüglich Y_1, \dots, Y_{i-1} unter Q .

Zeigen Sie, dass für die Kulback-Leibler-Divergenz von P unter Q , definiert durch

$$D(P\|Q) := \sum_{x \in \mathcal{X}_1 \leq i \leq n, p(x) > 0} p(x) \ln \left(\frac{p(x)}{q(x)} \right)$$

gilt:

$$D(P\|Q) = \sum_{i=1}^n \mathbb{E}_{P_{1:i-1}} [D(P_{X_i|1\dots i-1} \| Q_{Y_i|1\dots i-1})].$$

Beweis. Sei ohne Einschränkung $p(x) > 0$ für alle x . Wir verwenden die (etwas unsaubere) Notation:

$$p(x_1, \dots, x_i) := P(X_1 = x_1, \dots, X_i = x_i)$$

und analog für Q . Dann gilt

$$P_{X_i|1\dots i-1}(X_i = x_i) = \frac{p(x_1, \dots, x_i)}{p(x_1, \dots, x_{i-1})}.$$

Damit folgt:

$$D(P_{X_i|1\dots i-1} \| Q_{Y_i|1\dots i-1}) = \sum_{x_i \in \mathcal{X}_i} \frac{p(x_1, \dots, x_i)}{p(x_1, \dots, x_{i-1})} \ln \left(\frac{p(x_1, \dots, x_i) \cdot q(x_1, \dots, x_{i-1})}{q(x_1, \dots, x_i) \cdot p(x_1, \dots, x_{i-1})} \right).$$

Somit haben wir

$$\begin{aligned} & \mathbb{E}_{P_{1:i-1}} [D(P_{X_i|1\dots i-1} \| Q_{Y_i|1\dots i-1})] \\ &= \sum_{x_1, \dots, x_{i-1}} p(x_1, \dots, x_{i-1}) D(P_{X_i|1\dots i-1} \| Q_{Y_i|1\dots i-1}) \\ &= \sum_{x_1, \dots, x_i} p(x_1, \dots, x_i) \ln \left(\frac{p(x_1, \dots, x_i) \cdot q(x_1, \dots, x_{i-1})}{q(x_1, \dots, x_i) \cdot p(x_1, \dots, x_{i-1})} \right). \end{aligned}$$

Wir zeigen nun die Aussage per Induktion. Der Fall $n = 1$ ist aus letzterer Formel klar.

Gelte die Aussage für $n - 1$. Dann ist

$$\begin{aligned}
& D(P\|Q) \\
&= \sum_{x_1, \dots, x_n} p(x_1, \dots, x_n) \ln \left(\frac{p(x_1, \dots, x_n)}{q(x_1, \dots, x_n)} \right) \\
&= \sum_{x_1, \dots, x_n} p(x_1, \dots, x_n) \left[\ln \left(\frac{p(x_1, \dots, x_n)q(x_1, \dots, x_{n-1})}{q(x_1, \dots, x_n)p(x_1, \dots, x_{n-1})} \right) + \ln \left(\frac{p(x_1, \dots, x_{n-1})}{q(x_1, \dots, x_{n-1})} \right) \right] \\
&= \mathbb{E}_{P_{1:n-1}} [D(P_{X_n|1\dots n-1}\|Q_{Y_n|1\dots n-1})] + \sum_{x_1, \dots, x_{n-1}} p(x_1, \dots, x_{n-1}) \ln \left(\frac{p(x_1, \dots, x_{n-1})}{q(x_1, \dots, x_{n-1})} \right) \\
&= \sum_{i=1}^n \mathbb{E}_{P_{1:i-1}} [D(P_{X_i|1\dots i-1}\|Q_{Y_i|1\dots i-1})],
\end{aligned}$$

wobei wir im vorletzten Schritt $\sum_{x_n} p(x_1, \dots, x_n) = p(x_1, \dots, x_{n-1})$ und im letzten die Induktionshypothese verwendet haben. \square

Übung 2. Sei eine Familie von Graphen $\mathcal{G}(n)$, $n \in \mathbb{N}$ mit endlichen Kantenmengen gegeben. Wir definieren zufällige Teilgraphen $\mathcal{G}(n, p)$ durch Perkolation auf $\mathcal{G}(n)$ mit Parameter $p \in (0, 1)$ (Kanten sind unabhängig voneinander aktiviert mit Wahrscheinlichkeit p und mit Wahrscheinlichkeit $1 - p$ deaktiviert). Bezeichne $A(n, p)$ das Ereignis, dass $\mathcal{G}(n, p)$ zusammenhängend ist und setze $p_n := \frac{2 \log n}{n}$

a) Nehmen Sie an, dass gilt:

$$1 - \frac{1}{2n} \geq \mathbb{P}[A(n, p_n)] \geq 1 - \frac{1}{n}.$$

Zeigen Sie dass dann für den totalen Einfluss auf $A(n, p_n)$ folgt:

$$I(A(n, p_n)) \geq \frac{1}{8 \log^2 n}, \quad n \gg 1.$$

b) Nehmen Sie an, dass gilt:

$$3/4 \geq \mathbb{P}(A(n, p_n)) \geq 1/4.$$

Zeigen Sie dass dann für den totalen Einfluss auf $A(n, p_n)$ folgt:

$$I(A(n, p_n)) \geq \frac{n}{32 \log^2 n}, \quad n \geq 2.$$

Beweis. Das Ereignis $A := A(n, p_n)$ ist monoton in den einzelnen Bernoulli-Zufallsvariablen, die die Kanten an- und ausschalten. Damit sind wir im Setting von Korollar 4.28 (auch wenn dort n etwas anderes ist, nämlich die Anzahl der Zufallsvariablen, also die Kantenmenge von $\mathcal{G}(n)$). Also gilt:

$$I(A) \geq \frac{\mathbb{P}(A) \log\left(\frac{1}{\mathbb{P}(A)}\right)}{p_n \log\left(\frac{1}{p_n}\right)}.$$

Es gilt $p_n \log\left(\frac{1}{p_n}\right) > 0$. Zudem gilt $x \log\left(\frac{1}{x}\right) \geq x(1 - x)$ (Das folgt aus $-\log x \geq 1 - x$ bzw. $\log x \leq x - 1$).

a) Damit haben wir

$$I(A) \geq \frac{\mathbb{P}(A)(1 - \mathbb{P}(A))}{\frac{2 \log n}{n} (\log n - \log(2 \log n))} \geq n \frac{\mathbb{P}(A)(1 - \mathbb{P}(A))}{2 \log^2 n} \geq n \frac{(1 - \frac{1}{n}) \frac{1}{2n}}{2 \log^2 n} \geq \frac{1}{8 \log^2 n}.$$

Hierbei haben wir verwendet, dass $\log(2 \log n) \geq 0$ und $1 - \frac{1}{n} \geq \frac{1}{2}$ für hinreichend große n .

Bemerkung: Die Ungleichung $\mathbb{P}(A) \geq 1 - 1/n$ ist bekannt für Erdős-Rényi; bei der anderen bin ich mir nicht mal sicher, ob sie in diesem Fall stimmt ...

Interpretation: Wir können mit unserer Methode nicht zeigen, dass der totale Einfluss auf A für $n \rightarrow \infty$ nicht gegen 0 geht. Aber immerhin geht er langsam gegen 0.

b) Wir rechnen (analog zu oben)

$$I(A) \geq n \frac{1/16}{2 \log^2 n} \geq \frac{n}{32 \log^2 n}.$$

□

Übung 3. Ziel dieser Aufgabe ist, zu zeigen, dass für Wahrscheinlichkeitsverteilungen auf endlichen Mengen die Han-Ungleichung äquivalent zur Subadditivität der Entropie ist. Zur Erinnerung an die Subadditivität der Entropie: Für $Y = f(X_1, \dots, X_n)$, wobei X_1, \dots, X_n unabhängige Zufallsvariablen sind, gilt

$$\text{Ent}(Y) \leq \mathbb{E} \sum_{i=1}^n \text{Ent}^{(i)}(Y). \quad (1)$$

Dies war im Fall, dass die Zufallsvariablen endliche Wertebereiche haben, mit Hilfe der Han-Ungleichung bewiesen worden.

Sei nun \mathcal{X} endlich und seien X_1, \dots, X_n unabhängige Zufallsvariablen auf \mathcal{X} . Verwenden Sie (1), um daraus die Han-Ungleichung

$$H(X) \leq \frac{1}{n-1} \sum_{i=1}^n H(X^{(i)})$$

herzuleiten. Dabei gilt für die Verteilung von $X^{(i)} = (X_1, \dots, X_{i-1}, X_{i+1}, \dots, X_n)$, dass

$$\mathbb{P}(X^{(i)} = (x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n)) = \sum_{t \in \mathcal{X}} q(x_1, \dots, x_{i-1}, t, x_{i+1}, \dots, x_n),$$

wobei $q(x) := \mathbb{P}(X = x)$ und $H(X) := -\sum_x q(x) \log q(x)$ ist die Shannon-Entropie von X .

Beweis. Sei Q die Verteilung der Zufallsvariable X und sei P die uniforme Verteilung auf \mathcal{X}^n . Sei q die Verteilungsfunktion von X , d.h. $q(x) := \mathbb{P}(X = x)$ und $k := |\mathcal{X}|$. Sei $Y = dQ/dP$. Dann gilt $Y(x) = q(x)k^n$ und $\mathbb{E}_P(Y) = 1$. Nun gilt

$$\text{Ent}_P(Y) = D(Q||P) = \sum q(x) \log(q(x)k^n) = -H(X) + n \log k.$$

sowie

$$\begin{aligned} \mathbb{E}_P \left[\text{Ent}_P^{(1)}(Y) \right] &= \text{Ent}_P(Y) - \sum_{x \in \mathcal{X}^{n-1}} \left(\sum_{t \in \mathcal{X}} q(t, x) \right) \log \left(k^{n-1} \sum_{t \in \mathcal{X}} q(t, x) \right) \\ &= \text{Ent}_P(Y) + H(X^{(1)}) - (n-1) \log(k) \end{aligned}$$

und analog mit 1 ersetzt durch $i \in \{1, \dots, n\}$. Also haben wir insgesamt:

$$\begin{aligned}
 -H(X) &= -n \log(k) + \text{Ent}_P(Y) \leq -n \log(k) + \sum_{i=1}^n \mathbb{E} \left[\text{Ent}_P^{(i)}(Y) \right] \\
 &= -n \log(k) + \sum_{i=1}^n \left(\text{Ent}_P(Y) + H(X^{(i)}(Y)) - (n-1) \log(k) \right) \\
 &= (-n - n(n-1)) \log k + \sum_{i=1}^n (-H(X) + n \log k + H(X^{(i)}(Y))) \\
 &= -nH(x) + \sum_{i=1}^n H(X^{(i)}(Y)).
 \end{aligned}$$

Umstellen liefert das gewünschte Resultat. \square

Übung 4. Sei μ das Lebesgue-Maß auf \mathbb{R}

- Seien P und Q Gaußmaße mit Erwartungswerten $\mu, \tilde{\mu} \in \mathbb{R}$ und Varianzen $\sigma, \tilde{\sigma} > 0$. Berechnen Sie die Kullback-Leibler-Divergenz $D(P\|Q)$.
- Sei P die Gleichverteilung auf dem Intervall $[-1/2, 1/2]$ und Q das Standardgaußmaß auf \mathbb{R} (Erwartungswert 0, Varianz 1). Berechnen Sie die Kullback-Leibler-Divergenz $D(P\|Q)$.
- Sei nun P die Gleichverteilung auf dem Intervall $[-a, a]$, $a > 0$ und Q das Standardgaußmaß auf \mathbb{R} . Finden Sie das a , welches $D(P\|Q)$ minimiert.

Beweis. a) Wir müssen die Abbildungen $X, Y : \mathbb{R} \rightarrow [0, \infty)$ aus der Definition identifizieren. Es gilt:

$$P(A) = \int_A f_P(t) dt,$$

also ist $X(t) = f_P(t)$, wobei $f_P(t)$ die Dichte des Gaußmaßes P ist. Analog $Y(t) = f_Q(t)$. Damit ist

$$\begin{aligned}
 D(P\|Q) &= \mathbb{E}_P [\ln(X/Y)] = \int_{\mathbb{R}} f_P(t) \ln(f_P(t)/f_Q(t)) dt \\
 &= \int_{\mathbb{R}} f_P(t) \left(\ln \left(\frac{\tilde{\sigma}}{\sigma} \right) + \frac{-(x-\mu)^2}{2\sigma^2} + \frac{(x-\tilde{\mu})^2}{2\tilde{\sigma}^2} \right) dt \\
 &= \ln \left(\frac{\tilde{\sigma}}{\sigma} \right) - \frac{1}{2} + \int_{\mathbb{R}} f_P(t) \frac{(x-\tilde{\mu})^2}{\tilde{\sigma}^2} dt \\
 &= \ln \left(\frac{\tilde{\sigma}}{\sigma} \right) - \frac{1}{2} + \int_{\mathbb{R}} f_P(t) \frac{(x-\mu)^2 + 2x\tilde{\mu} - \mu^2 + \tilde{\mu}^2}{2\tilde{\sigma}^2} dt \\
 &= \ln \left(\frac{\tilde{\sigma}}{\sigma} \right) - \frac{1}{2} + \frac{\sigma^2}{2\tilde{\sigma}^2} + \frac{(\mu - \tilde{\mu})^2}{2\tilde{\sigma}^2} \\
 &= \ln \left(\frac{\tilde{\sigma}}{\sigma} \right) + \frac{1}{2} \left(\frac{\sigma^2}{2\tilde{\sigma}^2} - 1 \right) + \frac{(\mu - \tilde{\mu})^2}{2\tilde{\sigma}^2}.
 \end{aligned}$$

- Wir müssen wieder X und Y identifizieren. Es gilt (analog zu oben): $X(t) = \mathbb{1}_{[-1/2, 1/2]}(t)$ und $Y(t) = f(t)$, wobei $f(t)$ die Dichte der Standard-Normalverteilung ist. Es ist

$P(Y = 0) = 0$, also können wir die Kullback-Leibler-Divergenz wie folgt berechnen:

$$\begin{aligned} D(P\|Q) &= \mathbb{E}_P \left[\ln \left(\frac{X}{Y} \right) \right] = \int_{-1/2}^{1/2} \ln(f(x)^{-1}) \, dx = \int_{-1/2}^{1/2} \ln(\sqrt{2\pi}) + \frac{x^2}{2} \, dx \\ &= \frac{1}{2} \ln(2\pi) + \frac{2(1/2)^3}{6} = \frac{1}{2} \ln(2\pi) + \frac{1}{24}. \end{aligned}$$

c) Jetzt ist $X(t) = \frac{1}{2a} \mathbf{1}_{[-a,a]}(t)$. Wir berechnen analog zu Teil b):

$$D(P\|Q) = \ln(\sqrt{2\pi}) - \ln(2a) + \frac{a^2}{6}.$$

Kurvendiskussion (oder Wolframalpha) zeigt, dass das minimal wird bei

$$a = \sqrt{3}.$$

□

Abgabe bis zum 05.07.2021