

テクニカルノート

いくつかの f ダイバージェンス間の不等式について

一森 哲男^{1,a)}

受付日 2013年5月9日, 採録日 2013年7月3日

概要: 情報理論の分野では, 分布間の差異を測るダイバージェンスという情報量が多数存在する. 本ノートでは, いくつかの f ダイバージェンス間の不等式について議論する. 具体的には, 全変動距離と θ ダイバージェンス間の不等式, θ ダイバージェンスと α ダイバージェンス間の不等式, および, α ダイバージェンス間どうしの不等式を導く. θ ダイバージェンスとは新たに本ノートの中で定義した情報量で, Pearson と Neyman のカイ二乗ダイバージェンス, および, 三角ダイバージェンスを一般化したものである.

キーワード: 情報ダイバージェンス, f ダイバージェンス, α ダイバージェンス, 全変動距離

On Inequalities between f -Divergences

TETSUO ICHIMORI^{1,a)}

Received: May 9, 2013, Accepted: July 3, 2013

Abstract: There exist many measures of the divergence (or distance or discrimination) between probability distributions in the literature on information theory. This note deals with inequalities for some of the f -divergences, specifically, for the total variation distance, the θ -divergences and the α -divergences. The θ -divergences introduced here are generalizations of Pearson's and Neyman's χ^2 divergences and the triangular discrimination.

Keywords: K-L divergence, f -divergence, α -divergence, total variation distance

1. はじめに

情報理論では, 2つの分布間の差異を定量化するために f ダイバージェンスという情報量のクラスが定義されている. 本論文では, この f ダイバージェンスのクラスに属するダイバージェンス間で成立する不等式について議論する. つまり, Kullback-Leibler ダイバージェンスと全変動距離との関係を表す Pinsker の不等式のような不等式について議論する. 具体的には, 全変動距離と θ ダイバージェンス間で成立する不等式, θ ダイバージェンスと α ダイバージェンス間で成立する不等式, 最後に, α ダイバージェンス間どうしで成立する不等式を新たに導く. θ ダイ

バージェンスは新しく定義した情報量で, Pearson のカイ二乗ダイバージェンス, Neyman のカイ二乗ダイバージェンス, および, 三角ダイバージェンスを一般化したものである.

導かれた不等式はすべてパラメータを含むが, これらは著者の知る限り新規の不等式である. パラメータに具体的な数値を代入すればいくらかでも (パラメータを含まない) 不等式を導くことが可能である. 実際, θ ダイバージェンスおよび α ダイバージェンスに含まれるパラメータ θ および α にいくつかの値を代入することにより, 多くの既知の不等式を導いている. これらは, たとえば, 文献 [1] や [2] などに散見される. また, θ ダイバージェンスは新しく提案したものであることもあり, パラメータ θ および α にその他のさまざまな値を代入することにより, 未知の関係式を作り出すことも可能である.

¹ 大阪工業大学
Osaka Institute of Technology, Hirakata, Osaka 573-0196,
Japan

^{a)} ichimori@is.oit.ac.jp

2. f ダイバージェンス

分布間の差異を計測するダイバージェンスとして, Csiszár の f ダイバージェンス [3] は最も一般的なものとして知られている. これは Ali-Silvey 距離 [4] ともいわれているが, f ダイバージェンスは数学で定義される距離関数とは異なり, 対称性や三角不等式が成り立たないので, 厳密には, 距離とはいえない.

1 から n までの整数の集合 $\mathbb{N} = \{1, 2, \dots, n\}$ を定義する. 2つの離散確率分布 $P = (p_1, p_2, \dots, p_n)$ と $Q = (q_1, q_2, \dots, q_n)$ が与えられたとする. ここで, $p_i > 0$ ($i \in \mathbb{N}$) かつ $\sum_{i=1}^n p_i = 1$ であり, $q_i > 0$ ($i \in \mathbb{N}$) かつ $\sum_{i=1}^n q_i = 1$ である. このとき, 両分布間の f ダイバージェンスとは

$$D_f(P||Q) = \sum_{i=1}^n q_i f\left(\frac{p_i}{q_i}\right)$$

と定義されている. 正の実数の集合を \mathbb{R}_+ とし, 実数の集合を \mathbb{R} と書く. 関数 $f: \mathbb{R}_+ \rightarrow \mathbb{R}$ は狭義凸で, さらに, $f(1) = 0$ と正規化されている. しばしば, $D_f(P||Q)$ は P から Q までの (有向) 距離という. ただし, これを Q から P までの距離と定義する人もいる.

有名な Jensen の不等式より

$$\sum_{i=1}^n q_i f\left(\frac{p_i}{q_i}\right) \geq f\left(\sum_{i=1}^n q_i \frac{p_i}{q_i}\right) = f(1) = 0$$

が導かれ, その値が非負 $D_f(P||Q) \geq 0$ であることが分かる. また, 関数の狭義凸性より, $D_f(P||Q) = 0$ となるのは, すべての $i \in \mathbb{N}$ に対し $p_i = q_i$ となるとき, および, そのときのみである.

たとえば, $f(t) = t \log t$ ($t > 0$) とおけば, f ダイバージェンスは

$$\sum_{i=1}^n p_i \log \frac{p_i}{q_i}$$

となり, Kullback-Leibler (以下, K-L と略する) ダイバージェンス [5] が得られる. これは相対エントロピーや情報ダイバージェンスなどさまざまな名前で呼ばれている [6].

表 1 に関数 $f(t)$ とそれにより定まるダイバージェンスをいくつか与える. 表 1 の $D = D(P||Q)$ は K-L ダイバージェンスを, また, $\bar{D} = D(Q||P)$ は逆 K-L ダイバージェンスを示す. $\chi^2 = \chi^2(P||Q)$ は Pearson のカイ二乗ダイバージェンス [7] を, また, $\bar{\chi}^2 = \chi^2(Q||P)$ は Neyman のカイ二乗ダイバージェンスを表している. $H = H(P||Q)$ は Hellinger 距離の二乗 (Hellinger ダイバージェンス) [8] と呼ばれ, P と Q に関して対称である. すなわち, $H = H(P||Q)$ は $H(Q||P)$ に等しい. $\Delta = \Delta(P||Q)$ と $V = V(P||Q)$ はそれぞれ三角ダイバージェンス (triangular discrimination) と全変動距離 (ℓ_1 距離) といわれ, これらも P と Q に関し

表 1 代表的な f ダイバージェンス

Table 1 Typical examples of f -divergences.

$f(t)$ ($t > 0$)	ダイバージェンス
$t \log t$	$D = D(P Q) = \sum_{i=1}^n p_i \log \frac{p_i}{q_i}$
$-\log t$	$\bar{D} = D(Q P) = \sum_{i=1}^n q_i \log \frac{q_i}{p_i}$
$(t-1)^2$	$\chi^2 = \chi^2(P Q) = \sum_{i=1}^n \frac{(p_i - q_i)^2}{q_i}$
$\frac{(t-1)^2}{t}$	$\bar{\chi}^2 = \chi^2(Q P) = \sum_{i=1}^n \frac{(q_i - p_i)^2}{p_i}$
$\frac{(\sqrt{t}-1)^2}{2}$	$H = H(P Q) = \sum_{i=1}^n \frac{1}{2} (\sqrt{p_i} - \sqrt{q_i})^2$
$\frac{(t-1)^2}{t+1}$	$\Delta = \Delta(P Q) = \sum_{i=1}^n \frac{(p_i - q_i)^2}{p_i + q_i}$
$ t-1 $	$V = V(P Q) = \sum_{i=1}^n p_i - q_i $
$\frac{t^\alpha - 1}{\alpha(\alpha - 1)}$	$A_\alpha = A_\alpha(P Q) = \frac{1}{\alpha(\alpha - 1)} \left(\sum_{i=1}^n \frac{p_i^\alpha}{q_i^{\alpha-1}} - 1 \right)$

表 2 代表的な α ダイバージェンス

Table 2 Typical examples of α -divergences.

α	ダイバージェンス
-1	$\bar{\chi}^2 = 2A_{-1}$
0	$\bar{D} = A_0$
1/2	$H = 1/4 A_{1/2}$
1	$D = A_1$
2	$\chi^2 = 2A_2$

て対称である. 最後は Chernoff の α ダイバージェンス [9] であり, これは 1つのパラメータ $-\infty < \alpha < +\infty$ を含んでいる. $\alpha = 1$ の場合は極限操作により

$$f(t) = \lim_{\alpha \rightarrow 1} \frac{1}{\alpha(\alpha - 1)} (t^\alpha - 1) = t \log t$$

となり, K-L ダイバージェンス D が導かれる. $\alpha = 0$ の場合は極限操作により $f(t) = -\log t$ となり, 逆 K-L ダイバージェンス \bar{D} が導かれる. そのため, α ダイバージェンス A_α はすべての $-\infty < \alpha < +\infty$ の値に対して定義される. いくつかのパラメータ α の値に対応するダイバージェンスを表 2 に与える.

3. 全変動距離と θ ダイバージェンス間の不等式

この節では, カイ二乗ダイバージェンス χ^2 , $\bar{\chi}^2$ および三角ダイバージェンス Δ を一般化した θ ダイバージェンスを定義し, 全変動距離 V の二乗との大小関係を導く.

補題 1 $0 \leq \theta \leq 1$ ならば, 関数 $(x-1)^2 / (\theta x + 1 - \theta)$ ($x > 0$) は狭義凸である.

証明 $f(x) = (x-1)^2 / (\theta x + 1 - \theta)$ とするとき $f'(x) = 2\{\theta x^2 + 2(1-\theta)x + \theta - 2\} / (\theta x + 1 - \theta)^2$ となり, さらに, $f''(x) = 4 / (\theta x + 1 - \theta)^3$ となる. この分母に含まれる項 $\theta x + 1 - \theta$ を $\theta x + 1 - \theta = \theta x + (1 - \theta)1$ と見

表 3 代表的な θ ダイバージェンス
Table 3 Typical examples of θ -divergences.

θ	ダイバージェンス
0	$\chi^2 = \Theta_0$
1/2	$\Delta = 1/2 \Theta_{\frac{1}{2}}$
1	$\bar{\chi}^2 = \Theta_1$

なせば、 $0 < \min\{x, 1\} \leq \theta x + 1 - \theta \leq \max\{x, 1\}$ となることから、 $\theta x + 1 - \theta > 0$ が得られる。ゆえに、 $f''(x) > 0$ となり、 $f(x)$ は狭義凸となる。□

この狭義凸関数 $(x-1)^2/(\theta x + 1 - \theta)$ ($x > 0$) により定まる f ダイバージェンスを θ ダイバージェンスと呼ぶことにする。すなわち、

$$\Theta_\theta = \Theta_\theta(P||Q) = \sum_{i=1}^n \frac{(p_i - q_i)^2}{\theta p_i + (1 - \theta)q_i} \quad (1)$$

を定義する。順に、 $\theta = 0, 1/2, 1$ を代入すると、 $\Theta_0 = \chi^2$ (Pearson のカイ二乗ダイバージェンス)、 $\Theta_{\frac{1}{2}} = 2\Delta$ (三角ダイバージェンス)、 $\Theta_1 = \bar{\chi}^2$ (Neyman のカイ二乗ダイバージェンス) が導かれる。この結果を表 3 に与える。

定理 1 $0 \leq \theta \leq 1$ ならば、不等式 $V^2 \leq \Theta_\theta$ が成り立つ。

証明 定義より、 $V^2 = \{\sum_{i=1}^n |p_i - q_i|\}^2 = \{\sum_{i=1}^n \sqrt{(p_i - q_i)^2}\}^2$ となる。ここで、 $\theta p_i + (1 - \theta)q_i > 0$ なので、この式は

$$V^2 = \left\{ \sum_{i=1}^n \sqrt{\frac{(p_i - q_i)^2}{\theta p_i + (1 - \theta)q_i}} \sqrt{\theta p_i + (1 - \theta)q_i} \right\}^2$$

と書き直せる。ここで、Cauchy-Schwarz の不等式 $(\sum_i x_i y_i)^2 \leq (\sum_i x_i^2)(\sum_i y_i^2)$ を用いると、すなわち、 $x_i = \sqrt{(p_i - q_i)^2/(\theta p_i + (1 - \theta)q_i)}$ および $y_i = \sqrt{\theta p_i + (1 - \theta)q_i}$ とおくと、

$$V^2 \leq \left(\sum_{i=1}^n \frac{(p_i - q_i)^2}{\theta p_i + (1 - \theta)q_i} \right) \left(\sum_{i=1}^n (\theta p_i + (1 - \theta)q_i) \right)$$

の関係が得られる。 $\sum_i p_i = \sum_i q_i = 1$ なので、上式の右辺第 2 項は 1 に等しくなり、 θ ダイバージェンスの定義式 (1) より $V^2 \leq \Theta_\theta$ が得られる。□

系 1 $V^2 \leq \chi^2$, $V^2 \leq 2\Delta$, $V^2 \leq \bar{\chi}^2$ が成り立つ。

証明 順に、 $\theta = 0, 1/2, 1$ を定理 1 の不等式に代入すると結果が得られる。□

4. α ダイバージェンスと θ ダイバージェンス間の不等式

パラメータ $-1 \leq \alpha \leq 2$ を持つ関数 $f_\alpha(x)$ ($x > 0$) を以下のように定義する。すなわち、 $\alpha \neq 0, 1$ の場合、

$$f_\alpha(x) = \left(\frac{x^\alpha - 1}{\alpha(\alpha - 1)} - \frac{x - 1}{\alpha - 1} \right) \times \left(-\frac{\alpha - 2}{3}x + \frac{\alpha + 1}{3} \right) - \frac{(x - 1)^2}{2}$$

と定義し、 $\alpha = 0, 1$ の場合は、それぞれ、

$$f_0(x) = (-\log x + x - 1) \left(\frac{2}{3}x + \frac{1}{3} \right) - \frac{(x - 1)^2}{2}$$

および

$$f_1(x) = (x \log x - x + 1) \left(\frac{1}{3}x + \frac{2}{3} \right) - \frac{(x - 1)^2}{2}$$

と定義する。

補題 2 パラメータが $-1 \leq \alpha \leq 2$ のとき、 $x > 0$ に対し $f_\alpha(x) \geq 0$ となる。

証明 $\alpha \neq 0, 1$ の場合を考える。 $f'_\alpha(x)$ および $f''_\alpha(x)$ を求めると、それぞれ、

$$f'_\alpha(x) = \frac{x^{\alpha-1} - 1}{\alpha - 1} \left(-\frac{\alpha - 2}{3}x + \frac{\alpha + 1}{3} \right) - \frac{\alpha - 2}{3} \left(\frac{x^\alpha - 1}{\alpha(\alpha - 1)} - \frac{x - 1}{\alpha - 1} \right) - (x - 1)$$

および

$$f''_\alpha(x) = x^{\alpha-2} \left(-\frac{\alpha - 2}{3}x + \frac{\alpha + 1}{3} \right) - \frac{2(\alpha - 2)}{3} \left(\frac{x^{\alpha-1} - 1}{\alpha - 1} \right) - 1$$

が得られる。さらに、 $g(x) = f''_\alpha(x)$ とおくと、

$$g'(x) = -\frac{1}{3}(\alpha + 1)(\alpha - 2)x^{\alpha-3}(x - 1)$$

が得られる。 $-1 \leq \alpha \leq 2$ なので、 $(\alpha + 1)(\alpha - 2) \leq 0$ となることから、 $g(x)$ は $0 < x < 1$ の範囲で減少、 $x > 1$ で増加となる。さらに、 $g(1) = 0$ となることから、 $g(x) = f''_\alpha(x) \geq 0$ となり、 $f_\alpha(x)$ が凸となる。 $f_\alpha(1) = f'_\alpha(1) = 0$ であることから、 $f_\alpha(x) \geq 0$ ($x > 0$) が得られる。 $\alpha = 0, 1$ の場合も、同様に証明ができる。よって、 $-1 \leq \alpha \leq 2$ のとき、 $f_\alpha(x) \geq 0$ ($x > 0$) となる。□

定理 2 $-1 \leq \alpha \leq 2$ ならば、不等式

$$A_\alpha \geq \frac{1}{2}\Theta_{-\frac{\alpha-2}{3}}$$

が成り立つ。

証明 $\theta = -(\alpha - 2)/3$ とおくと、 $-1 \leq \alpha \leq 2$ ならば $0 \leq \theta \leq 1$ となる。よって、 $x > 0$ のとき $\theta x + 1 - \theta > 0$ となる。 $1 - \theta = (\alpha + 1)/3$ より、 $(-\alpha - 2)/3 x + (\alpha + 1)/3 = \theta x + (1 - \theta) > 0$ に注意すると、補題 2 の不等式 $f_\alpha(x) \geq 0$ は、 $\alpha \neq 0, 1$ のとき、

$$\frac{x^\alpha - 1}{\alpha(\alpha - 1)} - \frac{x - 1}{\alpha - 1} \geq \frac{1}{2} \frac{(x - 1)^2}{\theta x + 1 - \theta}$$

と書き直せる。左辺は狭義凸関数であり、これにより定まる f ダイバージェンスは、

$$\sum_{i=1}^n \frac{1}{\alpha - 1} \left(\frac{p_i}{q_i} - 1 \right) q_i = \sum_{i=1}^n \frac{p_i - q_i}{\alpha - 1} = 0$$

に注意すると, A_α に等しくなる. また, 右辺も補題 1 より狭義凸関数であり, これにより定まる f ダイバージェンスは, 定義式 (1) より, $\frac{1}{2}\theta_\theta$ である. $\alpha = 0, 1$ の場合も, 同様に証明ができる. よって, この定理が成り立つ. \square

系 2 不等式 $H \geq \frac{1}{4}\Delta$ が成り立つ.

証明 $\alpha = 1/2$ を定理 2 の不等式に代入すると結果が得られる. \square

系 3 $-1 \leq \alpha \leq 2$ ならば, 不等式 $A_\alpha \geq \frac{1}{2}V^2$ が成り立つ.

証明 定理 1 と定理 2 の不等式から導かれる. \square

系 4 不等式 $\bar{\chi}^2 \geq V^2, \bar{D} \geq \frac{1}{2}V^2, H \geq \frac{1}{8}V^2, D \geq \frac{1}{2}V^2, \chi^2 \geq V^2$ が成り立つ.

証明 順に, $\alpha = -1, 0, 1/2, 1, 2$ を系 3 の不等式に代入すると結果が得られる. \square

$\alpha = 1$ のときの不等式 $D \geq \frac{1}{2}V^2$ は Pinsker の不等式として知られている [10].

5. α ダイバージェンス間どうしの不等式

定理 3 $\alpha \leq \beta$ のとき, 不等式

$$\alpha A_\alpha \leq \beta A_\beta$$

が成り立つ.

証明 これを証明するためには, 関数

$$F(\alpha) = \alpha A_\alpha \quad (-\infty < \alpha < +\infty)$$

が増加関数であることを示せばよい. 最初に, $F(\alpha)$ が $\alpha = 1$ で連続であることを示す. $\alpha = 1$ では $F(1) = A_1 = D$ となる. 一方, $\alpha \neq 1$ のとき,

$$F(\alpha) = \frac{1}{\alpha - 1} \left(\sum_{i=1}^n \frac{p_i^\alpha}{q_i^{\alpha-1}} - 1 \right)$$

となり, $\alpha \rightarrow 1$ のときの極限を調べてみると,

$$\lim_{\alpha \rightarrow 1} F(\alpha) = \sum_{i=1}^n p_i \log \frac{p_i}{q_i} = D$$

となる. このことから, $F(\alpha)$ が $\alpha = 1$ で連続であることが分かる.

次に, $\alpha \neq 1$ と仮定して, $F'(\alpha)$ を求めると,

$$F'(\alpha) = \frac{\sum_{i=1}^n \frac{p_i^\alpha}{q_i^{\alpha-1}} \left\{ (\alpha - 1) \log \frac{p_i}{q_i} - 1 \right\} + 1}{(\alpha - 1)^2}$$

となる. この式の分子の最後の項の 1 を $\sum_{i=1}^n p_i$ で置き換えると, この式の分子は

$$\sum_{i=1}^n \left[\frac{p_i^\alpha}{q_i^{\alpha-1}} \left\{ (\alpha - 1) \log \frac{p_i}{q_i} - 1 \right\} + p_i \right]$$

と書ける.

この式全体を $p_i > 0$ で除し, さらに, 添え字 i を省略し,

見やすいように $x = p_i/q_i$ と書き換えた第 i 項の式を

$$f(x) = x^{\alpha-1} \{ (\alpha - 1) \log x - 1 \} + 1, \quad x > 0$$

と定義する. 以下では, $f(x)$ ($x > 0$) が非負であることを示す.

$f(x)$ の右辺で, $t = x^{\alpha-1} > 0$ とおいた式を $g(t)$ とすると

$$g(t) = t \log t - t + 1$$

が得られる. $g'(t) = \log t, g''(t) = 1/t$ より $g(1) = g'(1) = 0$ かつ $g''(t) > 0$ より, $g(t) \geq 0$ すなわち $f(x) \geq 0$ が示される. よって, $F'(\alpha) \geq 0$ となり, 結果, $F(\alpha)$ は増加関数となる. \square

系 5 $2H \leq D, 2H \leq \chi^2, D \leq \chi^2$ が成り立つ.

証明 順に, $(\alpha, \beta) = (1/2, 1), (1/2, 2), (1, 2)$ を定理 3 の不等式に代入すると結果が得られる. \square

系 6 $2H \leq \bar{D}, 2H \leq \bar{\chi}^2, \bar{D} \leq \bar{\chi}^2$ が成り立つ.

証明 系 5 の P と Q を入れ替えて, $H = H(P||Q) = H(Q||P)$ に注意すればよい. \square

6. あとがき

新たに θ ダイバージェンスを導入し, 全変動距離と θ ダイバージェンスの間の大小関係 (定理 1), θ ダイバージェンスと α ダイバージェンスの間の大小関係 (定理 2), 最後に, α ダイバージェンス間どうしの大小関係 (定理 3) を明らかにした. 著者の知る限り, これらの関係は新規である. さらに, パラメータにいくつかの値を代入することにより, 多くの既知の不等式を導いた.

参考文献

- [1] Topsøe, F.: Some Inequalities for Information Divergence and Related Measures of Discrimination, *IEEE Trans. Inform. Theory*, Vol.46, No.4, pp.1602–1609 (2000).
- [2] Taneja, I.J. and Kumar, P.: Relative Information of Type s , Csiszár's f -divergence, and Information Inequalities, *Information Sciences*, Vol.166, pp.105–125 (2004).
- [3] Csiszár, I.: Information-type Measures of Difference of Probability Distributions and Indirect Observation, *Studia Sci. Math. Hungarica*, Vol.2, pp.299–318 (1967).
- [4] Ali, S.M. and Silvey, S.D.: A General Class of Coefficients of Divergence of One Distribution from Another, *Journal of the Royal Statistical Society Series B*, Vol.28, pp.131–142 (1966).
- [5] Kullback, S. and Leibler, R.A.: On Information and Sufficiency, *Annals of Mathematical Statistics*, Vol.22, pp.79–86 (1951).
- [6] Cover, T.M. and Thomas, J.A.: *Elements of Information Theory, 2nd Edition*, Wiley, Hoboken, New Jersey (2006).
- [7] Pearson, K.: On the Criterion That a Given System of Deviations from the Probable in the Case of a Correlated System of Variables is Such That it can be Reasonably Supposed to Have Arisen from Random Sampling, *Philosophical Magazine*, Vol.50, No.302, pp.157–172 (1900).

- [8] Hellinger, E.: Neue Begründung der Theorie der Quadratischen Formen von Unendlichvielen Veränderlichen, *Journal für die Reine und Angewandte Mathematik*, Vol.136, pp.210–271 (1909).
- [9] Chernoff, H.: A Measure of Asymptotic Efficiency for Tests of a Hypothesis Based on a Sum of Observations, *Annals of Mathematical Statistics*, Vol.23, No.4, pp.493–507 (1952).
- [10] Pinsker, M.S.: *Information and Information Stability of Random Variables and Processes*, Holden-Day, San Francisco (1964).



一森 哲男 (正会員)

昭和 28 年生。昭和 57 年大阪大学大学院工学研究科応用物理学専攻博士後期課程修了。同年広島大学工学部助手。昭和 60 年より大阪工業大学工学部専任講師。昭和 63 年より大阪工業大学工学部助教授。平成 8 年より大阪工業大学情報科学部教授。システムの最適化に関する研究に従事。工学博士。昭和 62 年日本オペレーションズ・リサーチ学会事例研究奨励賞受賞。日本オペレーションズ・リサーチ学会、日本応用数学会各会員