

# 物理実験学 (6)

竹下徹 (029july2004)

**推定**：実験結果から本当の値を推定するにはどうするか？

種々の測定があるとき、結果はその関数であるときどうやって推定するか。

真の値が  $a$  のときある測定値  $x$  を得る確率密度を  $\hat{P}(x : a)$  とする、一連の複数の測定結果  $\{x_1, x_2, x_3, \dots, x_N\}$  の結果を得る全体の確率密度  $\hat{L}(x_1, x_2, \dots, x_N; a) = \hat{P}(x_1 : a) \hat{P}(x_2 : a) \dots \hat{P}(x_N : a)$  と各測定の確率の積でかけられる。ということは測定値  $x_i$  の関数  $f(x_1, x_2, \dots, x_N)$  があるとき、その平均値  $\langle f(x_1, x_2, \dots, x_N) \rangle$  は確率解釈をすると、一変数にまねて

$$\langle f(x_1, x_2, \dots, x_N) \rangle = \int f(x_1', x_2', \dots, x_N') \hat{P}(x_1' : a) \hat{P}(x_2' : a) \dots \hat{P}(x_N' : a) dx_1' dx_2' \dots dx_N'$$

$$\langle f(x_1, x_2, \dots, x_N) \rangle = \int f(x_1', x_2', \dots, x_N') \hat{L}(x_1', x_2', \dots, x_N') dx_1' dx_2' \dots dx_N' \text{ を}$$

$x_1, x_2, \dots, x_N = X$  として、 $\langle f(X) \rangle = \int f(X) \hat{L}(X) dX$  と書いてしまおう。このとき

$$\sigma_a^2 \geq \frac{1}{\left\langle \left| \frac{d \log L}{da} \right|_{a=\hat{a}} \right\rangle} = \frac{-1}{\left\langle \left| \frac{d^2 \log L}{da^2} \right|_{a=\hat{a}} \right\rangle}$$

が成立する。この式は Minimum Variance Bound (MVB) と

呼ばれる式が証明されている。ここで  $\hat{a}$  は真の値  $a$  の推定値を意味する。我々が計算できるのはこの  $\hat{a}$  の値のみである。

例えば分布がガウス分布に従うとき、

$$\hat{P}(x_i; a, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x_i - a)^2}{2\sigma^2}}$$

$$\ln L = - \sum_1 \frac{(x_i - a)^2}{2\sigma^2} - N \ln(\sigma\sqrt{2\pi})$$

$$\frac{d \ln L}{da} = \sum_1 \frac{(x_i - a)}{\sigma^2} = \frac{1}{\sigma^2} \sum x_i - \frac{a}{\sigma^2} \sum 1$$

$$\frac{d^2 \ln L}{da^2} = \frac{d}{da} \left( \frac{d \ln L}{da} \right) = \frac{d}{da} \left( \frac{1}{\sigma^2} \sum x_i - \frac{a}{\sigma^2} N \right) = -\frac{N}{\sigma^2}$$

$$\sigma_a^2 \cong \frac{1}{\langle \left( \frac{d \ln L}{da} \right)^2 \rangle} = \frac{-1}{\langle \left( \frac{d^2 \ln L}{da^2} \right) \rangle} = \frac{\sigma^2}{N}$$

なので  $\sigma_{\hat{a}}^2 \geq \frac{\sigma^2}{N}$  が成立する。こ

では  $x_i \pm \sigma_i = x_i \pm \sigma$  つまりすべての精度が等しいときには、大数の法則が成り立つなら、推定

$$\hat{a} = \frac{\sum \frac{x_i}{\sigma_i^2}}{\sum \frac{1}{\sigma_i^2}} = \frac{\sum x_i}{N} = a$$

値と真値は等しい。

N個の同種の測定から得られる分散と

$$\sigma_{\hat{a}}^2 = \frac{\sigma^2}{N}$$

の関係が成立する。つまり中心極限定理でしめした複数のガウス分布をする測定の分散は1/Nになる結果と一致する。

**推定法：Maximum Likelihood (ML) 推定法（最ゆう（尤）法）**：Lの最大値を与えるaの推定値

$\hat{a}$  を与えるという方法で各 $x_i$ がガウス分布するとき（確率密度関数として ガウス関数を取

つて）、 $P(x_i; \mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x_i - \mu)^2}{2\sigma^2}}$ （ただし全ての分散  $\sigma_i^2$  は等しいとする）

$$L(x_1, x_2, \dots, x_N; a) = P(x_1; a)P(x_2; a)P(x_3; a) \dots P(x_N; a)$$

$$\ln L = \ln P(x_1; a) + \ln P(x_2; a) + \dots + \ln P(x_N; a) = \sum_{i=1}^N \ln(P(x_i; a))$$

がLの定義で、すべてPの

積の形なのでlnLはlnPの和となる。これをガウス分布の場合

$\ln P(x_i; \mu, \sigma) = -\ln(\sigma\sqrt{2\pi}) - \frac{(x_i - \mu)^2}{2\sigma^2}$  に当てはめると、すべてのiについて和を取ると、

$$\ln L = \sum \ln P(x_i; \mu, \sigma) = -\sum \ln(\sigma\sqrt{2\pi}) - \sum \frac{(x_i - \mu)^2}{2\sigma^2}$$

$$\left. \frac{d \ln L}{d\mu} \right|_{\mu = \hat{\mu}} = 2 \sum (x_i - \hat{\mu}) \frac{1}{2\sigma^2} = 0 \Rightarrow \sum (x_i - \hat{\mu}) = 0$$

という当たり前の答えを得る。これ

は、正しい推定では推定された平均値とデータの平均は一致するというものだ。一方分散の推

定では、 $\left. \frac{d \ln L}{d \sigma} \right|_{\sigma=\hat{\sigma}} = -\sum \frac{1}{\sigma} + \sum \frac{(x_i - \hat{\mu})^2}{\sigma^3} = 0 \Rightarrow -\frac{N}{\hat{\sigma}} + \frac{1}{\hat{\sigma}^3} \sum (x_i - \hat{\mu})^2 = 0 \Rightarrow \hat{\sigma}^2 = \frac{\sum (x_i - \hat{\mu})^2}{N}$  となる。

問題：ポアソン分布に対するML推定を行え。

$P_{Poisson}(r_i; \lambda) = \frac{\lambda^{r_i}}{r_i!} e^{-\lambda}$  各 $r_i$ がポアソン分布する（つまり、離散型の時は正確に確率Pの積としてLを定義できる）とき、

$L(r_1, r_2, \dots, r_N; \lambda) = P_{Poisson}(r_1; \lambda) P_{Poisson}(r_2; \lambda) \dots P_{Poisson}(r_N; \lambda)$  がLの定義で、すべてPの積の形なので $\ln L$ は $\ln P$ の和となる。これをポアソン分布分布の場合に当てはめると、

$\ln L = \sum \ln P_{Poisson}(r_i; \lambda) = \sum (r_i \ln \lambda - \lambda - \ln(r_i!))$  これは、正しい推定で

は推定された平均値  $\lambda$  に対して次の式がなりたつ。 $\left. \frac{d \ln L}{d \lambda} \right|_{\lambda=\hat{\lambda}} = 0$ 。実際のポアソン分布の

関数形を代入すると、 $\frac{d \ln L}{d \lambda} = \sum \left( \frac{r_i}{\lambda} - 1 \right)$  となり、 $\lambda = \hat{\lambda}$  でこれがゼロとなるから

$\left. \frac{d \ln L}{d \lambda} \right|_{\lambda=\hat{\lambda}} = \sum \left( \frac{r_i}{\hat{\lambda}} - 1 \right) = \frac{1}{\hat{\lambda}} \sum r_i - N = 0$  より、 $\hat{\lambda} = \frac{1}{N} \sum r_i = \langle r \rangle$  をえ

る。つまりポアソン分布するデータ $r_i$ の平均値がポアソン分布の期待値 $\lambda$ の推定値を与えている。

問題：指数分布に対するML推定を行え。¥グラフは上に凸になる。頂点が最大値で=

**推定法：Maximum Likelihood 推定法の応用**

データの組 $(x_i, y_i)$ が得られるとき、例えば、ストップウォッチで移動する物体の速さを測ろうとするとき、 $x_i$ は道につけられた位置を表し、 $y_i$ は時計の読みである、このとき $a$ は速さと言う関係になる。

測定データからある量 $a$ を推定する方法のうち $y_i$ が $f(x_i, a)$ との差がガウス分布をとるとき最小二

$y_i = f(x_i, a), P(y_i; a) = \frac{1}{\sigma_i \sqrt{2\pi}} e^{-\frac{(y_i - f(x_i, a))^2}{2\sigma_i^2}} \Rightarrow \ln L = \sum \ln P(y_i; a)$


乗法と呼ばれる。

$$\ln L = -\sum \ln(\sigma_i \sqrt{2\pi}) - \sum \frac{[y_i - f(x_i; a)]^2}{2\sigma_i^2} < 0$$

この  $\ln L < 0$  は負であり、複数のデータ  $(x_i, y_i)$  の組から  $a$  を推定することは、 $\ln L$  の最大値 (Maximum Likelihood) ( $L$  は確率あるいは (離散型の場合)、確率密度関数の積 であるのでほぼ最大確率を意味する) を与える  $a$  を求めることである。

$$\ln L = \text{constant} - \frac{\chi^2}{2}, \chi^2 \equiv \sum \frac{[y_i - f(x_i; a)]^2}{\sigma_i^2}$$

ということはこの定義によるカイ二乗の最小値を求める



事に相当する。そのため、これを最小二乗法と呼ぶ。

$\ln L$  の最大

値を探す Maximum Likelihood法はMVBにより最小の分散  $\sigma_a^2$  を探すことに相当する。なぜ

$$\sigma_a^2 \geq \frac{1}{\left\langle \left( \frac{d \ln L}{da} \right)^2 \right\rangle} = \frac{-1}{\left\langle \left( \frac{d^2 \ln L}{da^2} \right) \right\rangle} : MVB$$

なら であるから。推定法：最小二乗法

データの組  $(x_i, y_i)$  が得られるとき、 $y_i$  が  $f(x_i, a)$  との差がガウス分布をするとき最小二乗法と呼ば

$$\chi^2 \equiv \sum \frac{[y_i - f(x_i)]^2}{\sigma_i^2}$$

れる。この定義によるカイ二乗の最小値を求めるには、

$$\left. \frac{d\chi^2}{da} \right|_{a=\hat{a}} = 0$$

を満たす  $\hat{a}$  を探し当てればよい。つまり次の式を計算する。

$$\left. \frac{d\chi^2}{da} \right|_{x=x_i} = \sum \frac{-2}{\sigma_i^2} [y_i - f(x_i; a)] \frac{df(x_i; a)}{da} = 0$$

次は  $f(x_i; a)$  の形を決めないと計算不可能なので、ま

$$\chi^2 \equiv \sum \frac{[y_i - ax_i]^2}{\sigma_i^2} \Rightarrow \frac{d\chi^2}{da} = \sum \left[ -2x_i \frac{y_i - ax_i}{\sigma_i^2} \right] \text{計}$$

ず、 $f(x_i; a) = ax_i$  の時を考える。

算を簡単にするためにすべての\*が等しい場合を考えよう。  $\sigma_i^2 = \sigma^2$

$$\left. \frac{d\chi^2}{da} \right|_{a=\hat{a}} = \frac{-2}{\sigma^2} \sum [x_i(y_i - \hat{a}x_i)] = 0 \Rightarrow \sum [x_i(y_i - \hat{a}x_i)] = 0$$

$$\sum x_i y_i = \hat{a} \sum x_i^2 \Rightarrow \hat{a} = \frac{\sum x_i y_i}{\sum x_i^2} = \frac{\frac{1}{N} \sum x_i y_i}{\frac{1}{N} \sum x_i^2} = \frac{\langle xy \rangle}{\langle x^2 \rangle}$$

$$\sigma_a^2 = \sigma_a^2(x, y) = \sum \left( \frac{\partial \hat{a}}{\partial y_i} \right)^2 \sigma_y^2 + \sum \left( \frac{\partial \hat{a}}{\partial x_i} \right)^2 \sigma_x^2 = \sum \left( \frac{\partial \hat{a}}{\partial y_i} \right)^2 \sigma_y^2 = \left( \frac{1}{N^2 \langle x^2 \rangle^2} \sum x_i^2 \right) \sigma_y^2 = \frac{\sigma_y^2}{N \langle x^2 \rangle}$$

ここでは x方向の精度

は無限に良い、すなわち  $\sigma_x^2 = 0$  としてy方向の精度のみ問題にした。

問題：等速直線運動を観測し、次の時刻tと位置xのデータを得た。

t 0 1.0 2.0 3.0 4.0 5.0 (秒)

x 0 14.5 30.3 43.8 58.9 77.1 (m) 速さ、と速さの精度とカイ二乗を計算せよ。

B 時間の精度は大変良く、一方位置の測定精度がそれぞれ+0.5mとする。

最もよく使われるのはこの式のもうちょっと一般化された一次式である、なぜなら  $y=f(x)=ax$  というのは  $x=0$  で  $y=0$  を要求しており、強い制限を課しているからである。それに対してここで言う  $y=f(x)=ax+b$  の場合それがない線形で一般的な場合である。

$$\chi^2 \equiv \sum \frac{[y_i - ax_i - b]^2}{\sigma_i^2} \Rightarrow \frac{d\chi^2}{da} = \sum \left[ -2x_i \frac{y_i - ax_i - b}{\sigma_i^2} \right]$$

$$\left. \frac{\partial \chi^2}{\partial a} \right|_{a=\hat{a}} = \frac{-2}{\sigma^2} \sum [x_i(y_i - \hat{a}x_i - \hat{b})] = 0 \Rightarrow \sum [x_i(y_i - \hat{a}x_i - \hat{b})] = 0$$

つまり

$$\sum (x_i y_i - \hat{a} x_i^2 - \hat{b} x_i) = \langle xy \rangle - \hat{a} \langle x^2 \rangle - \hat{b} \langle x \rangle = 0$$

を得る。同様にbについて

微分して0であることを要求すると、


$$\left. \frac{\partial \chi^2}{\partial b} \right|_{a=\hat{a}} = \frac{-2}{\sigma^2} \sum [1(y_i - \hat{a}x_i - \hat{b})] = 0 \Rightarrow \sum [(y_i - \hat{a}x_i - \hat{b})] = 0$$

$$\langle y \rangle - \hat{a} \langle x \rangle - \hat{b} = 0$$

a,bについての連立方程式と

$$\hat{a} = \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\langle x^2 \rangle - \langle x \rangle^2}, \hat{b} = \frac{\langle x^2 \rangle \langle y \rangle - \langle x \rangle \langle xy \rangle}{\langle x^2 \rangle - \langle x \rangle^2} = \langle y \rangle - \hat{a} \langle x \rangle$$

見立てて、解くと。 を得ることになる。 こうして原点が不確かな実験にあってもこれも fitting の自由度として取り入れ



て決定できる。さて次はこれの精度を表す量 を計算しよう。精

$$\begin{aligned} \sigma_a^2 &= \sum \left( \frac{\partial \hat{a}}{\partial x_i} \right)^2 \sigma_{x_i}^2 + \sum \left( \frac{\partial \hat{a}}{\partial y_i} \right)^2 \sigma_{y_i}^2 = \sum \left( \frac{\partial \hat{a}}{\partial x_i} \right)^2 \sigma^2 + \sum \left( \frac{\partial \hat{a}}{\partial y_i} \right)^2 \sigma^2 \\ &= \sum_i \left( \frac{\partial}{\partial y_i} \left( \frac{\langle xy \rangle - \langle x \rangle \langle y \rangle}{\langle x^2 \rangle - \langle x \rangle^2} \right) \right)^2 \sigma^2 = \sum_i \left( \frac{x_i - \langle x \rangle}{(\langle x^2 \rangle - \langle x \rangle^2) N} \right)^2 \sigma^2 \\ &= \left[ \sum_i \frac{(x_i - \langle x \rangle)^2}{N} \right] \frac{\sigma^2}{(\langle x^2 \rangle - \langle x \rangle^2)^2 N} = \left[ \langle x^2 \rangle - \langle x \rangle^2 \right] \frac{\sigma^2}{(\langle x^2 \rangle - \langle x \rangle^2)^2 N} \\ &= \frac{\sigma^2}{(\langle x^2 \rangle - \langle x \rangle^2) N} \end{aligned}$$

度の伝搬式より、 また

$$\begin{aligned} \sigma_b^2 &= \sum \left( \frac{\partial \hat{b}}{\partial y_i} \right)^2 \sigma_{y_i}^2 = \sum_i \left[ \frac{\partial}{\partial y_i} \left( \frac{\langle x^2 \rangle \langle y \rangle - \langle x \rangle \langle xy \rangle}{\langle x^2 \rangle - \langle x \rangle^2} \right) \right]^2 \sigma^2 \\ &= \sum_i \left[ \frac{\langle x^2 \rangle - \langle x \rangle x_i}{N(\langle x^2 \rangle - \langle x \rangle^2)} \right]^2 \sigma^2 = \frac{\langle x^2 \rangle^2 - 2 \langle x^2 \rangle \langle x \rangle \langle x \rangle + \langle x \rangle^2 \langle x^2 \rangle}{N(\langle x^2 \rangle - \langle x \rangle^2)^2} \sigma^2 \\ &= \frac{\langle x^2 \rangle (\langle x^2 \rangle - \langle x \rangle^2)}{N(\langle x^2 \rangle - \langle x \rangle^2)^2} \sigma^2 = \frac{\langle x^2 \rangle}{N(\langle x^2 \rangle - \langle x \rangle^2)} \sigma^2 \end{aligned}$$

と計算できる。今まで

はずうと計算の楽さのために等しい  $\sigma_i^2$  の場合を計算して来たが、異なる場合は、

$$\langle x^2 \rangle = \frac{\sum \frac{x_i^2}{\sigma_i^2}}{\sum \frac{1}{\sigma_i^2}}, \sigma^2 = \frac{\sum \frac{\sigma_i^2}{\sigma_i^2}}{\sum \frac{1}{\sigma_i^2}} = \frac{N}{\sum \frac{1}{\sigma_i^2}}$$

という置き換を行い、

$$\sigma_s^2 = \frac{N}{\sum \frac{1}{\sigma_f^2}} = \frac{1}{(\langle x^2 \rangle - \langle x \rangle^2) \sum \frac{1}{\sigma_f^2}}$$

とすればよい。

このさてこのカイ二乗は分布関数の一つである。すなわちガウス分布や指数分布のようにであ

$$\chi^2 \equiv \sum \frac{[y_i - f(x_i)]^2}{\sigma_i^2}$$

る。カイ二乗は [(y の測定値)-(yの理想値)]の二乗/(yの精度の二乗)と読める。カイ二乗が小さいということは測定値が理想値に近い事を表している。逆にカイ二乗が大きいうことはy=f(x)という関数への当てはめがよろしくない、あるいは間違っている事を示唆している。カイ二乗をyと関数への当てはめの良さを表す量として定義した。これを確率で表して、分布関数とする。そのためには f(x)に含まれる変数(f(x)=ax+bの時はaとbの二つが変数の数nvとして、測定点数をNmとし、Nm-nv=nを自由度という。この自由度nの時のカイ二乗がいくらになる確率がカイ二乗分布と呼ばれる。次の式でかけられる：

$$\hat{P}(\chi^2, n) = \frac{2^{-\frac{n}{2}}}{\Gamma(\frac{n}{2})} \chi^{n-2} e^{-\frac{\chi^2}{2}}$$


ここで  $\Gamma(\frac{n}{2})$  はガンマ関数である。

グラフの形は、図のようであり、 $n \rightarrow \infty$ の極限でガウス関数に近づく。但しその平均値は

$$\langle \chi^2 \rangle = n$$

を満たす。ここでnは自由度である。この式はつまりカイ二乗の平均値は自由度程度になるべしと主張しているわけだ。従って測定点が5個あってfittingに2個の変数を使ったときは、自由度nはn=5-2=3であり、カイ二乗を計算して3より大変小さい（たとえば0.1）とかあるいは10とかいう値を取った場合は、fitting関数f(x)が不適切と見なすべきである。あるいは定義から明らかなようにガウス分布する測定量の二乗の和は自由度nのカイ二乗分布をする。ちなみにガウス分布する測定量の和の分布はガウス分布である。

下の図で横軸はカイ二乗で、縦軸は確率密度関数値である。線は各n=1(d),2(e),3(f),5(g),10(h)に対応している。



$$P(\chi^2; n) = \int_{\chi^2}^{\infty} \hat{P}(\chi'^2; n) d\chi'^2$$

確率

はこの式で与えられる。

$\chi^2$

が横軸なので、こ

れで積分する必要がある。

$\chi^2$

の値が実験結果として得られたとき、その値の平均値はn(自由

度)に一致するため、これから遠く離れる確率は小さい。これを表すのが以下の

$\chi^2$

の表である。

n (自由度)	確率=10%	5%	2%	1%
1	2.71	3.84	5.41	6.63
2	4.61	5.99	7.82	9.21
3	6.25	7.82	9.84	11.34
4	7.78	9.49	11.67	13.28
5	9.24	11.07	15.03	16.81
6	10.64	12.59	15.03	16.81
7	12.02	14.07	16.62	18.47
8	13.36	15.51	18.17	20.09
9	14.68	16.92	19.68	21.67
10	15.99	18.31	21.16	23.21




11	17.27	19.68	22.62	24.72
12	18.55	21.03	24.05	26.22
13	19.81	22.36	25.47	27.69
14	21.06	23.68	26.87	29.14
15	22.31	25.00	28.26	30.58
20	28.41	31.41	35.02	37.57
25	34.38	37.65	41.57	44.31
30	40.26	43.77	47.96	50.89

表の横軸10%,5%,2%,1% はそれぞれ積分された確率であり表はその確率を与える区切りとなる

$\chi_c^2$

をあたえている。グラフでしめすと、



$$P(\chi^2; n) = \int_{\chi_c^2}^{\infty} \hat{P}(\chi'^2; n) d\chi'^2$$

を満たす。例

えば測定点が17点あり、fittingを直線で行うと(f(x)=ax+b) 2個の自由度がここで失われ、n=17-

2=15となる。このとき  $\chi^2$  が22であったとするなら、この結果は10%以上の確率で起こり、

十分に良い結果として指示される。もし  $\chi^2$  が30となると、これが起こる確率は1%程度であり、とてもまともな結果とは考えられないという尺度をあたえる。このとき、1次関数をやめ

て2次関数で fitして、  $\chi^2$  が24程度になった場合、自由度は14で、その確率は5%出有り、改

善が認められ、1次関数より2次関数が好まれる。一方余り  $\chi^2$  が小さい場合も危険である。

本来確率密度関数のピークは  $\chi^2 > n$  にありここから離れる事は起こりにくい。この場合、

精度因子  $\sigma_i^2$  が大きすぎる場合がある。もちろんあまりデータと理論線が近い場合はその他の理由が有るかもしれない、これを疑うべきである。

**Minimum Variance Bound (MVB) と呼ばれる式の証明。**

$$\sigma_{\hat{a}}^2 \geq \frac{1}{\left\langle \left( \frac{d \ln L}{da} \right)^2 \right\rangle} = \frac{-1}{\left\langle \frac{d^2 \ln L}{da^2} \right\rangle} < \hat{a} \rangle = \int \hat{a} L dX = a: \lim_{N \rightarrow \infty} (\hat{a} - a) = 0$$

推定のよりどころが、

この式である。

よって  $\frac{d \langle \hat{a} \rangle}{da} = 1 = \frac{d}{da} \int \hat{a} L(X_1, X_2, \dots, X_N; a) dX = \int \hat{a} \frac{dL}{da} dX$  一般に  $\frac{dL}{da} = L \frac{d(\ln L)}{da}$  なので

$$\int \hat{a} \frac{dL}{da} dX = \int \hat{a} L \frac{d(\ln L)}{da} dX$$

また確率の定義より、

$$\int L dX = 1 \Rightarrow \frac{d}{da} \int L dX = \int \frac{dL}{da} dX = \int L \frac{d(\ln L)}{da} dX = \left\langle \frac{d(\ln L)}{da} \right\rangle = 0$$

よって

$$\int (\hat{a} - a) L \frac{d(\ln L)}{da} dX = 1 - 0 = 1$$

という関係式が得られる。

Schwarzの式： $\left( \int u^2 dX \right) \left( \int v^2 dX \right) \geq \left( \int uv dX \right)^2$  があるので、(例えば  $u = \frac{1}{3}, v = \frac{1}{3}, \int \int \frac{1}{3} \frac{1}{3} dxdy = \left( \int \int \frac{1}{9} dxdy \right)^2 = \frac{1}{16} > \frac{1}{9}$  よって  $\left( \int \int \frac{1}{3} \frac{1}{3} dxdy \right)^2 = \frac{1}{16} > \frac{1}{9}$  式は成立つ。この式

$$u = (\hat{a} - a)\sqrt{L}, v = \frac{d \ln L}{da} \sqrt{L},$$

$$\left( \int (\hat{a} - a)^2 L dX \right) \left( \int \left( \frac{d \ln L}{da} \right)^2 L dX \right) \geq 1$$

$$\int (\hat{a} - a)^2 L dX = \sigma_{\hat{a}}^2, \int \left( \frac{d \ln L}{da} \right)^2 L dX = \left\langle \left( \frac{d \ln L}{da} \right)^2 \right\rangle$$

$$\sigma_{\hat{a}}^2 \left\langle \left( \frac{d \ln L}{da} \right)^2 \right\rangle \geq 1; \sigma_{\hat{a}}^2 \geq \frac{1}{\left\langle \left( \frac{d \ln L}{da} \right)^2 \right\rangle}$$

は

をしめす。

$$\left\langle \frac{d \ln L}{da} \right\rangle = 0 = \int L \frac{d \ln L}{da} dX = \int \left( \frac{dL}{da} \frac{d \ln L}{da} + L \frac{d^2 \ln L}{da^2} \right) dX$$

$$\int \left( \frac{dL}{da} \frac{d \ln L}{da} \right) dX = \int \left( L \frac{d \ln L}{da} \frac{d \ln L}{da} \right) dX = \int \left( L \left( \frac{d \ln L}{da} \right)^2 \right) dX = \left\langle \left( \frac{d \ln L}{da} \right)^2 \right\rangle$$

$$\int \left( L \frac{d^2 \ln L}{da^2} \right) dX = \left\langle \frac{d^2 \ln L}{da^2} \right\rangle$$

$$0 = \left\langle \left( \frac{d \ln L}{da} \right)^2 \right\rangle + \left\langle \frac{d^2 \ln L}{da^2} \right\rangle$$

$$\left\langle \left( \frac{d \ln L}{da} \right)^2 \right\rangle = - \left\langle \frac{d^2 \ln L}{da^2} \right\rangle$$

2番目の等号の証明