

正規分布の標準偏差に対する 簡便不偏推定法

統計数理研究所 鈴木 義一郎

(1979年4月 受付)

Note on Unbiased Estimation of the Standard Deviation of Normal Distribution

Giitiro Suzuki

(The Institute of Statistical Mathematics)

Unbiased estimation of the standard deviation of the normal distribution based on the sample standard deviation

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2}, \quad \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

has been thoroughly explored in a series of articles [1]~[8].

In this note, we propose the estimate

$$S_0^* = \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 / g_n},$$
$$g_n = n - \frac{3}{2} + \frac{n+1}{4(n-1)(2n+1)},$$

which is a simple and very accurate approximation to the exactly unbiased estimate

$$S_0 = \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 / k_n},$$
$$k_n = 2 \left[\frac{\Gamma\left(\frac{n}{2}\right)}{\Gamma\left(\frac{n-1}{2}\right)} \right]^2.$$

Gurland and Tripathi [4] derived another approximation

$$S_0^{**} = \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 / t_n},$$
$$t_n = n - \frac{3}{2} + \frac{1}{8(n-1)},$$

using the asymptotic expansion for $\log k_n$. Our result is based on rather heuristic method. From Figure 1 and Table 1, it will be seen that our result is more accurate than [4].

1. はじめに

最近、いろんな関数キーについている電卓が安価に手に入るようになった。そのような関数キーの一つに、偏差平方和をデータ数 n で割ってから平方根をとったもの、 $n-1$ で割って平方根をとったものがある。しかも前者に標本標準偏差、後者には母標準偏差という呼称がつけられたりしている。正しい統計の知識が身につかないまま計算法だけが先行している昨今の風潮を、垣間みた感じがする。

ともあれデータ数 n が大きければ両者の値がそう違わないが、 n の小さいときが問題である。

そもそも偏差平方和を $n-1$ で割るのは、母分散の不偏推定を得るためにいた。その平方根をとってみても、分散の平方根である標準偏差に対して不偏にはならない。母集団に正規性を仮定できる場合には、偏差平方和を $n-1.5$ で割ってから平方根をとると、不偏推定量により近いものが得られる。いずれにせよ標準偏差の推定を行う目的の場合は、 $n-1$ で割る根拠は無いといってよい。それなら単純にデータ数 n で割るほうがすっきりしている。

正規性の仮定の下では、標準偏差の不偏推定を得るための修正係数がガンマ関数を用いて表現できる。この小稿では、そのような係数に対する単純な有理式を用いた近似式(3)を提示する。

2. 標準偏差の不偏推定に対する修正係数

X_1, X_2, \dots, X_n を平均 μ 、標準偏差 σ の正規分布からの標本とする。

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

と置いて

$$V_0 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

を考えれば、これは分散 σ^2 に対する不偏推定量となるが、 $\sqrt{V_0}$ は標準偏差 σ の不偏推定ではない。 μ が未知の場合

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2}$$

が σ の最尤推定量であるが、無論不偏ではない。そこで

$$a_n = \frac{\Gamma\left(\frac{n-1}{2}\right)}{\Gamma\left(\frac{n}{2}\right)} \sqrt{\frac{n}{2}}$$

$$a_n' = \frac{\Gamma\left(\frac{n-1}{2}\right)}{\Gamma\left(\frac{n}{2}\right)} \sqrt{\frac{n-1}{2}} = a_n \sqrt{\frac{n-1}{n}}$$

と置いて

$$S_0 = a_n S = a_n \sqrt{V_0}$$

を考えると、これが σ の不偏推定量で分散は

$$\begin{aligned} V\{S_0\} &= \left[a_n^2 \frac{n-1}{n} - 1 \right] \sigma^2 \\ &= \frac{\sigma^2}{2n} + O\left(\frac{1}{n^2}\right) \end{aligned}$$

で与えられる。

σ に対する不偏推定量を得るために修正係数に関する簡単な歴史を、Jarrett [6] が報じている。Pearson [7] は $1/a_n$ に対する4桁の表を、Treloar [8] は a_n に対する5桁の表を与えた。これらの表の存在に気づかずに、Holtzman [5] は a_n' に対する表を、Cureton [3] は $k_n = n/a_n^2 = (n-1)/a_n'^2$ に対する表を、さらに Bolch [1] も a_n 及び a_n' に対する表を与えた。

修正係数に対して、ガンマ関数を用いない近似式を最初に与えたのが Brugger [2] である。Cureton の与えた表からもすぐ見当つくことであるが

$$a_n = \sqrt{n/(n-1.5)}$$

$$a'_n = \sqrt{(n-1)/(n-1.5)}$$

で算出したものが、 n が 6 以上なら結構よい近似を与える。Gurland-Tripathi [4] は

$$(1) \quad t_n = n - \frac{3}{2} + \frac{1}{8(n-1)}$$

が $k_n (=n/a_n^2)$ に対するかなり良い近似を与えることを示した。この t_n は

$$\log k_n = \log(n-1) - \frac{1}{2(n-1)} + \frac{1}{12(n-1)^3} + \dots$$

の展開式の指数部の第 2 項までをとって得られたものである。

ところが図 1 からみてもわかるように、(1) で与えられる t_n の値は正確な k_n の値より一様に小さい。そこで

$$(2) \quad k_n = n - \frac{3}{2} + \frac{1}{n-1} \cdot \frac{1}{8 - \frac{1}{\delta_n}}$$

の形の近似を考えてみる。そのためには

$$\delta_n = \left\{ 8 - \frac{1}{(n-1)(k_n - n + \frac{3}{2})} \right\}^{-1}$$

をプロットしたのが図 2 である。ほぼ直線的傾向を示すから、最小二乗直線を求めると

$$(0.5378) + (0.2556)n$$

が得られる（図 2 の実線）。ところがこの直線、 $n=3 \sim 16$ の辺で一様に上すぎる。 n の値の小さなところでのずれのほうがむしろ深刻であるから（係数も多少丸めて）

$$(0.25) + (0.25)n$$

という直線（図 2 の点線）を用いたほうが良さそうである。これを (2) 式の δ_n に代入して




図 1




図 2

表 1

n	k_n	t_n	g_n
2	0.6366	0.6250	0.6500
3	1.5708	1.5625	1.5714
4	2.5464	2.5417	2.5463
5	3.5343	3.5312	3.5341
6	4.5271	4.5250	4.5269
7	5.5223	5.5208	5.5222
8	6.5190	6.5179	6.5189
9	7.5165	7.5159	7.5164
10	8.5146	8.5139	8.5146
11	9.5131	9.5125	9.5130
12	10.5118	10.5114	10.5118
13	11.5108	11.5104	11.5108
14	12.5100	12.5096	12.5099
15	13.5092	13.5089	13.5092
16	14.5086	14.5083	14.5086
17	15.5080	15.5078	15.5080
18	16.5075	16.5074	16.5076
19	17.5071	17.5069	17.5071
20	18.5065	18.5066	18.5067

$$(3) \quad g_n = n - \frac{3}{2} + \frac{n+1}{4(n-1)(2n+1)}$$

という近似式が得られる。これは図1からみても判るように、 $n=2$ 以外では驚くほど精度が高い。表1に、正確な k_n の値と2つの近似式の値とを掲げておいた。

参考文献

- [1] Bolch, B.W. (1968) More on unbiased estimation of the standard deviation, *Amer. Statistician*, **22** (3), 27.
- [2] Brugger, R.M. (1969) A note on unbiased estimation of the standard deviation, *Amer. Statistician*, **23** (4), 32.
- [3] Cureton, E.E. (1968) Unbiased estimation of the standard deviation, *Amer. Statistician*, **22** (1), 22.
- [4] Gurland, J. and Tripathi, R.C. (1971) A simple approximation for unbiased estimation of the standard deviation., *Amer. Statistician*, **25** (4), 30-32.
- [5] Holtzman, W.H. (1950) The unbiased estimate of the population variance and standard deviation, *Amer. J. Psychology*, **63**, 615-617.
- [6] Jarrett, A.E. (1968) A minor exercise in history, *Amer. Statistician*, **22** (3), 25-26.
- [7] Pearson, K. (1915) *The Distribution of the Standard Deviation of Small Samples*, Appendix I to papers by "Student" and R.A. Fisher.
- [8] Treloar, A.E. (1935) *Outline of Biometric Analysis*, Burgess Publishing Co., Minneapolis.