

統計的推定とは？


標本の特性→母集団の**特性**を推定



- ・平均値
- ・分散

標準偏差と標準誤差の相違


$$\text{標準誤差} = \frac{\text{母集団 or 標本の標準偏差}}{\sqrt{\text{標本のサンプルサイズ}}}$$



意味が違います



標準偏差 (SD: standard deviation)

データそのもののばらつき




標準誤差 (SE: standard error of mean)

サンプリングデータより
推測した平均値の信頼区間




母集団 $N(\mu, \sigma^2)$ から1個サンプリングした標本はこの分布に入る

正規分布
 $N(\mu, \sigma^2)$



$$N(\mu, \sigma^2)$$



$$\mu$$

$$\mu$$

$$N(\mu + \mu, \sigma^2 + \sigma^2) \\ = N(2\mu, (\sqrt{2}\sigma)^2)$$

2で割って
平均する

$$N\left(\mu, \left(\frac{\sigma}{\sqrt{2}}\right)^2\right)$$

2個の分布

$$x_1 + x_2$$

$$\sqrt{\sigma^2 + \sigma^2} = \sqrt{2\sigma^2} = \sqrt{2}\sigma$$

分散は加法性あり

平均 \bar{x} の分布

$$2\mu$$


$$\frac{\sqrt{2}\sigma}{\frac{2}{\sigma}} = \frac{\sigma}{\sqrt{2}}$$

拡張

n 個サンプリングした標本の
標準偏差は n 個の平均

$$\frac{\sqrt{n\sigma^2}}{n} = \frac{\sigma}{\sqrt{n}}$$

母集団
元のデータ



標本平均値の分布

標本平均値の標準偏差

$$\rightarrow \text{標準誤差 } u = \sigma / \sqrt{n}$$


μ

μ

μ

母集団の平均値 μ (未知) から、 n 個サンプリングして
標本とする。その標本平均の分布より母集団の μ を
推定する

サンプルサイズ n を大きくすると
標準誤差 u 小 → 推定値の信頼性向上



分布の推定

- ・性能評価
- ・信頼性推定

標本平均の標準偏差

n : サンプル
数

5%の確率で推定を間違う

$$\frac{\sigma}{\sqrt{n}} \text{ もしくは } \frac{s}{\sqrt{n-1}}$$

標本平均 \bar{x} を基準化する

$$T = \frac{\bar{x} - \text{期待値}}{\text{標準誤差}} = \frac{\bar{x} - \mu}{\sigma / \sqrt{n}} \text{ or } \frac{\bar{x} - \mu}{s / \sqrt{n-1}}$$

$\alpha = 0.05$ の時
 $Z(\alpha/2) = 1.96$

$$-1.96 < T = \frac{\bar{x} - \mu}{\sigma / \sqrt{n}} < 1.96$$

変形して平均値 μ の推定式は

$$\bar{x} - 1.96(\sigma / \sqrt{n}) < \mu < \bar{x} + 1.96(\sigma / \sqrt{n})$$

母集団の標準偏差 σ 不明のとき

$$-1.96 < T = \frac{\bar{x} - \mu}{s / \sqrt{n-1}} < 1.96$$

変形して平均値 μ の推定式は


$$\bar{x} - 1.96(s / \sqrt{n-1}) < \mu < \bar{x} + 1.96(s / \sqrt{n-1})$$

標本

平均値
の推定

母集団

境界値



サンプルサイズの算出式

母集団の平均値 μ は、

n 個の標本の平均値 \bar{x}

母集団の標準偏差 σ

信頼度の境界値 $Z_{(\alpha/2)}$

で推定できる

$n \geq 100$ の時

Z推定

$$\bar{x} - Z_{(\alpha/2)} \left(\frac{\sigma}{\sqrt{n}} \right) < \mu < \bar{x} + Z_{(\alpha/2)} \left(\frac{\sigma}{\sqrt{n}} \right)$$

許容誤差 E とすると

$$E = Z_{(\alpha/2)} \left(\frac{\sigma}{\sqrt{n}} \right)$$

サンプルサイズ n は、

$$n = \left(\frac{Z_{(\alpha/2)} \sigma}{E} \right)^2$$

間違えても
良い確率

両側 α	$Z_{(\alpha/2)}$
1%	2.57
5%	1.96
10%	1.64

サンプルサイズの算出式

母集団の平均値 μ は、

n 個の標本の平均値 \bar{x}

標本の標準偏差 s

信頼度の境界値 $t_{(\alpha/2,n-1)}$

←母集団の標準偏差 σ が不明な場合

で推定できる

$n < 100$ の時

t推定

$$\bar{x} - t_{(\alpha/2,n-1)} \left(\frac{s}{\sqrt{n-1}} \right) < \mu < \bar{x} + t_{(\alpha/2,n-1)} \left(\frac{s}{\sqrt{n-1}} \right)$$

許容誤差 E とすると

$$E = t_{(\alpha/2,n-1)} \left(\frac{s}{\sqrt{n-1}} \right)$$

サンプルサイズ n は、

$$n = \left(\frac{t_{(\alpha/2,n-1)} s}{E} \right)^2 + 1$$

間違えても
良い確率

α	$n - 1$	$t_{(\alpha/2,n-1)}$
5%	1	12.70
	2	4.30
	4	2.78
	9	2.26
	19	2.09

統計的推定:

母集団

ある市の中学1年男子12,000人
平均体重 μ は不明 ←統計的推定

標本

サンプル数 $n=100$ 人
平均値 $\bar{x}=44.1\text{kg}$
標準偏差 $u=3.9\text{kg}$

標本平均 \bar{x} を基準化する

$$T = \frac{\bar{x} - \text{期待値}}{\text{標準偏差}} = \frac{\bar{x} - \mu}{\sigma / \sqrt{n}}$$

標準正規分布表において95%の確率になるのは $-1.96 < T < 1.96$

よって $-1.96 < (\bar{x} - \mu) / \sigma / \sqrt{n} < 1.96$

$$\bar{x} - 1.96 \sigma / \sqrt{n} < \mu < \bar{x} + 1.96 \sigma / \sqrt{n}$$

母集団の標準偏差 σ が未知のとき

サンプルサイズ n が大きければ($n \geq 100$)、 $u \approx \sigma$


標本の数値を代入して、母集団の平均体重は

$$43.3 < \mu < 44.9 \text{ kg} \text{ と推定される}$$

標本平均の分布


期待値: μ

標準偏差: σ / \sqrt{n}




標準正規分布

95%



母集団の平均体重 μ は
信頼度95%の確率で
この範囲内にある



$$43.3 < \mu < 44.9 \text{ kg}$$




精度 = 信頼区間／2



信頼区間

この場合の有意水準は
$$\frac{100 - 95}{100} = 0.05$$


実験データから平均値や分散(バラつき)を推定する方法 → 統計的推定



例

サンプルサイズは以下の2つの要素で決まる

- ①信頼度
- ②コスト



$$n = \left(\frac{Z_{(\alpha/2)} \sigma}{E} \right)^2$$

社員26人の会社で、1日当たり平均吸うタバコの本数を推定することにしました。25人のデータは調査でき、平均喫煙本数 $\bar{x}=7$ 本、標準偏差 $u=4$ 本でした。26名の平均値を推定すると？

$n < 100$ なので、t推定。信頼度95%とすると

$$\bar{x} - t(n-1, \alpha/2) (\sigma / \sqrt{n}) < \mu < \bar{x} + t(n-1, \alpha/2) (\sigma / \sqrt{n}) \text{ の公式に}$$

$$t(25-1, 0.05/2) = 2.064 \quad u = \sigma / \sqrt{n} = 4 / \sqrt{25} = 4 / 5 = 0.8 \text{ を代入して}$$

$$7 - 2.064 \times 0.8 < \mu < 7 + 2.064 \times 0.8 \quad 5.3 < \mu < 8.7$$

26人の内の25人と100,000人の内の25人の調査では信頼区間が異なる

$$\bar{x} - t(n-1, \alpha/2) (\sigma / \sqrt{n}) \sqrt{\frac{N-n}{N-1}} < \mu < \bar{x} + t(n-1, \alpha/2) (\sigma / \sqrt{n}) \sqrt{\frac{N-n}{N-1}}$$

$$\sqrt{\frac{N-n}{N-1}} = \sqrt{\frac{26-25}{26-1}} = 0.2 \quad 7 - 2.064 \times 0.8 \times 0.2 < \mu < 7 + 2.064 \times 0.8 \times 0.2$$

$$6.7 < \mu < 7.3$$

サイズが小さい有限母集団の際は補正項を乗ずる


母集団

元のデータ

母分散の推定

標本として10人の体重を計測


67.0	64.7	52.3	59.0	54.6
59.0	58.2	52.2	52.6	48.1



$$\bar{x} = \frac{67.0 + 64.7 + \dots + 52.6 + 48.1}{10} = 56.8$$

$$s^2 = \frac{(67.0 - \bar{x})^2 + (64.7 - \bar{x})^2 + \dots + (48.1 - \bar{x})^2}{10 - 1} = 35.4$$

$Z = (n-1)s^2 / \sigma^2$ は
自由度 $f = n-1$ の χ^2 分布にしたがう



Z値

$$2.7 \leq \frac{(10-1)s^2}{\sigma^2} \leq 19.0$$

$$\frac{9s^2}{19.0} \leq \sigma^2 \leq \frac{9s^2}{2.7}$$

$s^2 = 35.4$ を代入して

$$16.7 \leq \sigma^2 \leq 118.0$$