


平均値の差の検定と効果量: 実験結果の適切な報告の仕方 (90分tutorial)

酒井 哲也 (早稲田大学)


sakailab.com/tetsuya/

このtutorialのpdfは上記ページより入手可




March 8, 2023@DEIM 2023, 岐阜


2015



2018



2020



このtutorialより詳しい内容はこの本で!
<http://sakailab.com/leirbook/>

Tutorial outline

(I) 復習: t検定 [15分]

- ギネスビールの社員の話
- 対応のあるデータのt検定
- 対応のないデータのt検定

(II) 「統計的に有意である」と言うだけでいいか? [15分]

- 統計的検定の弊害
- 効果量
- 統計的検定に代わるアプローチ

(III) 三つ以上のシステムの比較においてt検定を繰り返していいか? [15分]

- ワインを飲みすぎた客の話
- 全体としての第一種の誤り
- Bonferroni補正はちょっと古い

(IV) Tukey HSD検定 [15分]

- 対応のあるデータのTukey HSD検定
- 対応のないデータのTukey HSD検定
- ランダム化検定とランダム化Tukey HSD検定

(V) 実験結果の適切な報告の仕方 [5分]

- 2つのシステムの比較
- 3つ以上のシステムの比較

(VI) さらにレベルアップ [10分]

- 有意水準、検出力、効果量、サンプルサイズの関係
- 今やったばかりのt検定の検出力は? 今後のサンプルサイズは?

(VII) Q&A・バッファ [15分]

William Sealy Gosset (1876-1937)

Ziliak and McCloskey: The Cult of Statistical Significance, p.3, 2008

“He worked at the Guinness Brewery in Dublin, where for most of his working life he was the head experimental brewer. He saw in 1905 the need for a small-sample test because he was testing varieties of hops and barley in field samples with **N as small as four**.”

おいしいギネスビールの開発に取り組んでいた社員。
(**サンプルサイズ** $n=4$ くらいが彼の関心事だった!)

VOLUME VI

MARCH, 1908

No. 1

BIOMETRIKA.

THE PROBABLE ERROR OF A MEAN.

By STUDENT.

Introduction.

ANY experiment may be regarded as forming an individual of a "population" of experiments which might be performed under the same conditions. A series of experiments is a sample drawn from this population.

Now any series of experiments is only of value in so far as it enables us to form

Gossetは
Studentというペンネームで
t検定の基本的アイデアについて
発表

ギネスビールを飲むときと
統計的検定をやるときは
Gossetのことを思い出してください

t検定の頑健性

- t検定の導出は母集団分布が正規分布であるという仮定からスタート。しかし!
- データが厳密に正規分布に従っていなくても基本的には適用可。

実際、正規性の仮定に依存しないランダム化検定 (Part [IV]) と意外にも似た結論が得られる。(それでも心配ならランダム化検定か古典的ノンパラメトリック検定を行えばよい)

- とくにサンプルサイズがある程度大きくなると、中心極限定理によりサンプル平均はほぼ正規分布に従う。
- 「正規性の検定」⇒「t検定」という手順は適切か? Part III (ワインを飲みすぎた客の話) を聴いてから考えてみよう。

どちらの検索エンジンがよいか (対応のあるデータ)

基本的な検索評価指標について:

<https://waseda.box.com/sakai14PROMISE>

<http://sakailab.com/iaembook/>

例: 平均精度, nDCG

$n = 3$

検索エンジン	検索クエリ	スコア
Bing	information retrieval	0.4
Google	information retrieval	0.4
Bing	winter olympics 2018	0.8
Google	winter olympics 2018	0.6
Bing	japan cronyism cover-up	0.7
Google	japan cronyism cover-up	0.5

検索結果の比較 (n = 3):

- information retrieval**: Bing (0.4) vs Google (0.4)
- winter olympics 2018**: Bing (0.8) vs Google (0.6)
- japan cronyism cover-up**: Bing (0.7) vs Google (0.5)

対応のあるデータのt検定 (1)

x_{1j} : システム1, 第jトピックのスコア

x_{2j} : システム2, 第jトピックのスコア

各トピックのスコアが独立かつ

$$x_{1j} \sim N(\mu_1, \sigma_1^2), \quad x_{2j} \sim N(\mu_2, \sigma_2^2)$$

のとき、各スコアの差 $d_j = x_{1j} - x_{2j}$ について

正規分布の性質より $d_j \sim N(\mu_1 - \mu_2, \sigma_1^2 + \sigma_2^2)$

対応のあるデータのt検定 (2)

$$d_j \sim N(\mu_1 - \mu_2, \sigma_1^2 + \sigma_2^2)$$

(スコア差の)母分散

⇒

$$t = \frac{\bar{d} - (\mu_1 - \mu_2)}{\sqrt{V_d/n}} \sim t(n-1)$$

自由度 $\phi = n-1$

詳しくは <http://sakailab.com/leirbook/> (Chapter 1)

これが母分散だったらtは標準正規分布に従う。
代わりにその不偏推定量を用いるためt分布に従う

ここで

サンプル平均

$$\bar{d} = \frac{1}{n} \sum_{j=1}^n d_j$$

不偏分散

$$V_d = \frac{\sum_{j=1}^n (d_j - \bar{d})^2}{n-1}$$

対応のあるデータのt検定 (3)

$$t = \frac{\bar{d} - (\mu_1 - \mu_2)}{\sqrt{V_d/n}} \sim t(n-1)$$

詳しくは <http://sakailab.com/leirbook/> (Chapter 1)

両側検定:

コンピュータサイエンス系の実験では多くの場合両側検定がお奨め

$H_0 : \mu_1 = \mu_2$

$H_1 : \mu_1 \neq \mu_2$


帰無仮説 H_0 のもとでは以下が成り立つはず

検定統計量 (t値)

$$t_0 = \frac{\bar{d}}{\sqrt{V_d/n}} \sim t(n-1)$$

対応のあるデータのt検定 (4)

帰無仮説 H_0 のもとでは $t_0 = \frac{\bar{d}}{\sqrt{V_d/n}} \sim t(n-1)$



従って $|t_0| \geq t_{inv}(n-1; \alpha)$
 のとき(H_0 のもとで
 ほぼありえないことが
 観測されたので) H_0 を棄却

「t分布に従っとらんのとちゃうか」

平均値の差は有意水準 α において
 有意差あり (母平均はおそらく異なる)

<http://www.f.waseda.jp/tetsuya/20topics3runs.mat.csv>

m=3 systems

n=20 topics

	A	B	C
1	System1	System2	System3
2	0.4695	0.3732	0.3575
3	0.2813	0.3783	0.2435
4	0.3914	0.3868	0.3167
5	0.6884	0.5896	0.6024
6	0.6121	0.4725	0.4766
7	0.3266	0.233	0.2429
8	0.5605	0.4328	0.4066
9	0.5916	0.5073	0.4707
10	0.4385	0.3889	0.3384
11	0.5821	0.5551	0.4597
12	0.2871	0.3274	0.2769
13	0.5186	0.5066	0.4066
14	0.5188	0.5198	0.3859
15	0.5019	0.4981	0.4568
16	0.4702	0.3878	0.3437
17	0.329	0.4387	0.2649
18	0.4758	0.4946	0.4045
19	0.3028	0.34	0.3253
20	0.3752	0.4895	0.3205
21	0.2796	0.2335	0.224

20topics3runs.mat.csv をRで読み込む

```
> matURL <- "http://www.f.waseda.jp/tetsuya/20topics3runs.mat.csv"
> mat <- read.csv( file=matURL, header=TRUE )
> mean( mat$System1 )
[1] 0.45005
> mean( mat$System2 )
[1] 0.427675
```

サンプル平均は
システム1のほうが高い

Rで対応のあるデータのt検定を実行

```
> t.test(mat$System1, mat$System2, paired=TRUE)
```

t値

Paired t-test

自由度 ϕ

data: mat\$System1 and mat\$System2

t = 1.3101, df = 19, p-value = 0.2058

alternative hypothesis: true difference in means is not equal to 0

95 percent confidence interval:

-0.01337109 0.05812109

sample estimates:

mean of the differences

0.022375

両側検定

どちらの検索エンジンがよいか (対応のないデータ)

n1 = 3

information retrieval 0.4

All Images Videos Maps News Shop | My saves

50,700,000 Results Any time ▾

Information retrieval  Share

Information retrieval (IR) is the activity of obtaining information

winter olympics 2018 0.8

All Images Videos Maps News Shop | My saves

87,600,000 Results Any time ▾

WINTER OLYMPICS 2018 HOME SPORTS ATHLETES SCHEDULE

japan cronyism cover-up 0.7

All Images Videos Maps News Shop | My saves

46,800,000 Results Any time ▾

News about Japan Cronyism Cover-up
bing.com/news

 Japan PM, finance minister under fire

n2 = 4

waseda university 1.0

すべて 地図 画像 ニュース 動画 もっと見る 設定 ツール

約 438,000 件 (0.80 秒)

Waseda University

springer 0.8

すべて ニュース ショッピング 画像 書籍 もっと見る 設定 ツール

約 177,000,000 件 (0.58 秒)

Springer
www.springer.com/in/ ▾

cherry blossoms 0.1

すべて 画像 ニュース 地図 動画 もっと見る 設定 ツール

約 18,400,000 件 (0.76 秒)

cherry blossomsの意味・使い方 - 英和辞典 Weblio辞書
https://ejje.weblio.jp/content/cherry+blossoms ▾

cherry blossomsの意味や使い方 桜花 - 約1036万語ある英和辞典・和英辞典。発音・イディオムも分かる英語辞書。

guinness brewery 0.5

すべて 地図 画像 ニュース 動画 もっと見る 設定 ツール

対応のないデータのt検定 (1)


形は同じ、位置は違うかも

x_{1j} : システム1, 第jトピックのスコア

x_{2j} : システム2, 第jトピックのスコア

各トピックのスコアが独立かつ

$$x_{1j} \sim N(\mu_1, \sigma^2), \quad x_{2j} \sim N(\mu_2, \sigma^2)$$



以下、等分散性を仮定したStudentのt検定を議論。

等分散性を仮定しないWelchのt検定もあるが、必ずしも後者のほうがよいというわけではない。

前者は母分散やサンプルサイズが極端に違わない限り頑健

詳しくは 永田靖: 入門 統計解析法, 日科技連, 1992

もしくは <http://sakailab.com/leirbook/> (Chapter 2)

対応のないデータのt検定 (2)

$$x_{1j} \sim N(\mu_1, \sigma^2), \quad x_{2j} \sim N(\mu_2, \sigma^2)$$

$$\Rightarrow t = \frac{\bar{x}_{1\bullet} - \bar{x}_{2\bullet} - (\mu_1 - \mu_2)}{\sqrt{V_p(1/n_1 + 1/n_2)}} \sim t(n_1 + n_2 - 2)$$

詳しくは永田靖: 入門 統計解析法, 日科技連, 1992
もしくは <http://sakailab.com/leirbook/> (Chapter 1)

サンプル平均

$$\bar{x}_{1\bullet} = \frac{\sum_{j=1}^{n_1} x_{1j}}{n_1}, \quad \bar{x}_{2\bullet} = \frac{\sum_{j=1}^{n_2} x_{2j}}{n_2}$$

併合分散

$$S_1 = \sum_{j=1}^{n_1} (x_{1j} - \bar{x}_{1\bullet})^2, \quad S_2 = \sum_{j=1}^{n_2} (x_{2j} - \bar{x}_{2\bullet})^2, \quad V_p = \frac{S_1 + S_2}{n_1 + n_2 - 2}$$

対応のないデータのt検定 (3)

$$t = \frac{\bar{x}_{1\bullet} - \bar{x}_{2\bullet} - (\mu_1 - \mu_2)}{\sqrt{V_p(1/n_1 + 1/n_2)}} \sim t(n_1 + n_2 - 2)$$

$$H_0 : \mu_1 = \mu_2 \quad H_1 : \mu_1 \neq \mu_2$$

帰無仮説 H_0 のもとでは以下が成り立つはず

$$\text{検定統計量 (t値)} \quad t_0 = \frac{\bar{x}_{1\bullet} - \bar{x}_{2\bullet}}{\sqrt{V_p(1/n_1 + 1/n_2)}} \sim t(n_1 + n_2 - 2)$$

従って $|t_0| \geq t_{inv}(n_1 + n_2 - 2; \alpha)$ のとき H_0 を棄却

平均値の差は有意水準 α において
有意差あり (母平均はおそらく異なる)

Rで対応のないデータのt検定を実行

```
> t.test(mat$System1, mat$System2, var.equal = TRUE)
```

Two Sample t-test

data: mat\$System1 and mat\$System2

t = 0.6338, df = 38, p-value = 0.53

alternative hypothesis: true difference in means is not equal to 0

95 percent confidence interval:

-0.04909139 0.09384139

sample estimates:

mean of x mean of y

0.450050 0.427675

データが対応しているという情報を活用した場合のp値と比べてみよう

Tutorial outline

(I) 復習: t検定 [15分]

- ギネスビールの社員の話
- 対応のあるデータのt検定
- 対応のないデータのt検定

(II) 「統計的に有意である」と言うだけでいいか? [15分]

- 統計的検定の弊害
- 効果量
- 統計的検定に代わるアプローチ

(III) 三つ以上のシステムの比較においてt検定を繰り返していいか? [15分]

- ワインを飲みすぎた客の話
- 全体としての第一種の誤り
- Bonferroni補正はちょっと古い

(IV) Tukey HSD検定 [15分]

- 対応のあるデータのTukey HSD検定
- 対応のないデータのTukey HSD検定
- ランダム化検定とランダム化Tukey HSD検定

(V) 実験結果の適切な報告の仕方 [5分]

- 2つのシステムの比較
- 3つ以上のシステムの比較

(VI) さらにレベルアップ [10分]

- 有意水準、検出力、効果量、サンプルサイズの関係
- 今やったばかりのt検定の検出力は? 今後のサンプルサイズは?

(VII) Q&A・バッファ [15分]

半世紀以上炎上している統計的検定(1)

“Little advancement in the teaching of statistics is possible [...] until the literature and classroom be rid of terms so deadening to scientific enquiry as null hypothesis, population [...]”

Deming, W.E.: On Probability as a Basic for Action, American Statistician, 29(4), 1975.

超訳: 学校で帰無仮説とか母集団とかアホらしいことを教えるのはやめちまえ

半世紀以上炎上している統計的検定(2)

“Despite the stranglehold that hypothesis testing has on experimental psychology, I find it difficult to imagine a less insightful means of transiting from data to conclusions.”

Loftus, G.R.: On the Tyranny of Hypothesis Testing in the Social Sciences, *Contemporary Psychology*, 36(2), 1991.

超訳: データから結論を得るためのこれよりアホな方法はちょっと考えらんない

半世紀以上炎上している統計的検定(3)

“And we, as teachers, consultants, authors, and otherwise perpetrators of quantitative methods, are responsible for the ritualization of **null hypothesis significance testing** (NHST; I resisted the temptation to call it **s**tatistical **h**ypothesis **i**nference **t**esting) to the point of meaninglessness and beyond.”

Cohen, J.: The Earth is Round ($p < .05$), *American Psychologist*, 49(12), 1994.

超訳: 検定を無意味な儀式にしちゃったのはワシらのせい
NHSTというより〇〇〇〇

統計的検定の問題点1

- 多くの人が検定を正しく理解していない
and/or 正しく利用していない

Gossetの論文から100年以上たっても
まだこんな注意が必要 orz

- American Statistical Associationの2016年の声明の一部:

“P-values do not measure the probability that the studied hypothesis is true, or the probability that the data were produced by random chance alone.”

p-value = $\Pr(D+|H)$
not $\Pr(H|D)$!

p値を正しく説明できますか?
「帰無仮説のもとで、観測されたデータもしくは
さらに極端なことが起こる確率」

研究者は「観測されたデータのもとで自分の仮説が正しい
確率」を知りたかったりする

統計的検定の問題点2

- 二元論「有意差あり？ 有意差なし？ どっちなの？」

$p=0.049 \Rightarrow$ 有意差あり、論文が書ける？

$p=0.051 \Rightarrow$ 有意差なし、論文が書けない？

- より重要なのは

どれくらいの差があるのか

その差はわれわれにとってどのような意味があるのか

実用的有意差

論文に「 $p=0.049$ 」と書いたほうが「 $p<0.05$ 」と書くよりは情報量が多いが、それでもまだ不十分！

統計的検定の問題点3

差の大きさ、本当の関心事

P-value = f(サンプルサイズ, 効果量)

効果量大 $\Rightarrow$ p-value小

サンプルサイズ大 $\Rightarrow$ p-value小

効果量 (差が標準偏差いくつぶんか)
が大 $\Rightarrow t_0$ が大 $\Rightarrow$ p値が小
はいいとして...

例: 対応のあるデータのt値

$$t_0 = \frac{\bar{d}}{\sqrt{V_d/n}} = \sqrt{n} \frac{\bar{d}}{\sqrt{V_d}}$$

マジか

サンプルサイズが大 $\Rightarrow t_0$ が大 $\Rightarrow$ p値が小
つまり十分大きなサンプルをとれば小さな差も有意になる

効果量(ここでは差が標準偏差いくつぶんか)の例

- 対応のあるデータのt検定より

$$d_{paired} = \frac{\bar{d}}{\sqrt{V_d}} \quad (t_0 = \sqrt{n} d_{paired})$$

- 対応のないデータのt検定より

Hedge's g

$$g = \frac{\bar{x}_{1\bullet} - \bar{x}_{2\bullet}}{\sqrt{V_p}} \quad (t_0 = \sqrt{\frac{n_1 n_2}{n_1 + n_2}} g)$$


統計的検定に代わるアプローチ (の例)

Fisherがおそらく

大嫌いだった

Bayes統計 (事後確率)

Fisher, R.A.:
Statistical Methods for
Research Workers, 1970



Bayes統計を一枚で説明 (できない)

詳しくは 豊田秀樹: はじめての統計データ分析, 朝倉書店, 2016 など

θ : 母数 (例えば母平均。古典的検定では定数だが、Bayes統計では変数。)
 x : データ

θ の事前確率
 (誰にもわからないので「適当に」仮定)

尤度

θ の事後確率

$$f(\theta|x) = \frac{f(x|\theta)f(\theta)}{f(x)} = \frac{f(x|\theta)f(\theta)}{\int_{-\infty}^{+\infty} f(x|\theta)f(\theta)d\theta}$$

みたことあるはずの定理!

- 歴史的には事後確率の計算が困難だったが、
 MCMC (Markov Chain Monte Carlo) 法の発展により今やPCでも計算可能
- 母数や任意の仮説Hに対する $\Pr(H|D)$ (p.25)が推定できる (p値より直感的?)
 (が少なくとも私の周辺の研究コミュニティではBayes統計が盛り上がる気配はない…)

Tutorial outline

(I) 復習: t検定 [15分]

- ギネスビールの社員の話
- 対応のあるデータのt検定
- 対応のないデータのt検定

(II) 「統計的に有意である」と言うだけでいいか? [15分]

- 統計的検定の弊害
- 効果量
- 統計的検定に代わるアプローチ

(III) 三つ以上のシステムの比較においてt検定を繰り返していいか? [15分]

- ワインを飲みすぎた客の話
- 全体としての第一種の誤り
- Bonferroni補正はちょっと古い

(IV) Tukey HSD検定 [15分]

- 対応のあるデータのTukey HSD検定
- 対応のないデータのTukey HSD検定
- ランダム化検定とランダム化Tukey HSD検定

(V) 実験結果の適切な報告の仕方 [5分]

- 2つのシステムの比較
- 3つ以上のシステムの比較

(VI) さらにレベルアップ [10分]


- 有意水準、検出力、効果量、サンプルサイズの関係
- 今やったばかりのt検定の検出力は? 今後のサンプルサイズは?

(VII) Q&A・バッファ [15分]

今、 m 個のシステムの平均値を比較しており、
全 $k=m(m-1)/2$ システム対の差に興味がある。
そこでさきほど復習した t 検定を k 回繰り返した。


このやり方は正しいか？

レストランにワインセラーがある(ワインは無限にある)。ただし20本に1本は酸っぱいワインである。




ワインセラーからランダム
にワインを取り出す。
それが酸っぱい確率は
 $1/20 = 0.05$

お客さんがワインを1本注文した場合




この人に酸っぱいワイン
を飲ませてしまう確率は
0.05

お客さんがワインを2本注文した場合



この人に酸っぱいワイン
を飲ませてしまう確率は
 $1 - P(2本ともセーフ)$
 $= 1 - 0.95^2$
 $= 0.0975$

お客さんがワインを3本注文した場合



この人に酸っぱいワイン
を飲ませてしまう確率は
 $1 - P(3\text{本ともセーフ})$
 $= 1 - 0.95^3$
 $= 0.1426$

全体（ファミリー）としての第一種の誤り

レストランは個々のワインが酸っぱい確率ではなく、
k本のワインを出した場合にお客さんが酸っぱいワインを
体験してしまう確率を例えば5%以下に抑えたい。

酸っぱいワイン出しよったな
ツイートしたるでホンマ



われわれ研究者の場合

母平均に差がないのにあわてて差があると結論づけてしまう確率

第一種の誤り確率を α に抑えた上でt検定を $k=m(m-1)/2$ 回繰り返すと、ファミリーとしての第一種の誤り確率は $1-(1-\alpha)^k$ まで膨れ上がる可能性がある。

抑えたいのはむしろ後者!

k対のうちひとつでもあわてて差があると結論づけてしまう確率

例: $\alpha=0.05$, $k=10$

⇒ ファミリーとしての第一種の誤り確率 $\approx 40\%$!

第二種の誤り確率 (母平均に差があるのにぼんやりして見逃してしまう確率) は β で表す。Part VI参照

t検定×k回 + Bonferroni補正 はちょっと古い

Bonferroni補正: α をkで割っておく。もしくはp値にkをかけてから α と比較する。

“The **old fashioned approach** was to use Bonferroni’s correction: [...] you divide your α value by the number of comparisons you have done. [...] Bonferroni’s correction is very harsh and will often **throw out the baby with the bathwater**. [...] The modern approach is [...] to use the wonderfully named **Tukey’s honestly significant differences**”

HSD

Crawly, M.J.: Statistics: An Introduction Using R (Second Edition), Wiley, 2015.

Bathwater = 母平均に差がないシステム対 (捨てたいもの)
Baby = 母平均に差があるシステム対 (捨てたくないもの)

Tutorial outline

(I) 復習: t検定 [15分]

- ギネスビールの社員の話
- 対応のあるデータのt検定
- 対応のないデータのt検定

(II) 「統計的に有意である」と言うだけでいいか? [15分]

- 統計的検定の弊害
- 効果量
- 統計的検定に代わるアプローチ

(III) 三つ以上のシステムの比較においてt検定を繰り返していいか? [15分]

- ワインを飲みすぎた客の話
- 全体としての第一種の誤り
- Bonferroni補正はちょっと古い

(IV) Tukey HSD検定 [15分]

- 対応のあるデータのTukey HSD検定
- 対応のないデータのTukey HSD検定
- ランダム化検定とランダム化Tukey HSD検定

(V) 実験結果の適切な報告の仕方 [5分]


- 2つのシステムの比較
- 3つ以上のシステムの比較

(VI) さらにレベルアップ [10分]

- 有意水準、検出力、効果量、サンプルサイズの関係
- 今やったばかりのt検定の検出力は? 今後のサンプルサイズは?

(VII) Q&A・バッファ [15分]

Tukey HSD検定の原理



- t検定を $k=m(m-1)/2$ 回繰り返す代わりに、 k 個の検定統計量の**最大値**(最高・最低のシステムの差から計算)に着目。
- この最大値はt分布そのものではなく **Studentised range分布**に従う。
- 全 k 個の差について上記分布をもちいた検定を行う。
- 最大値が統計的に有意でないとき、残りの $(k-1)$ 個も統計的に有意でない。⇒ 最大値について α を設定すれば、自動的にファミリーとしての第一種の誤り確率が α で抑えられる。

どこかのシステム間に差があるか?

Tukey HSD 検定の前に**分散分析**による検定を行う必要があるか?→ **NO**

詳しくは 永田靖: 多重比較法の実際, 応用統計学27(2), 1998 or <http://sakailab.com/leirbook/> (Chapter 4) など参照

対応のあるデータのTukey HSD検定 (1)

二元配置分散分析(繰り返しなし)のデータ構造

システム*i*の
サンプル平均

$$\bar{x}_{i\bullet} = \sum_{j=1}^n x_{ij} / n$$

System	Per-topic scores			
1	x_{11}	x_{12}	$\dots$	x_{1n}
2	x_{21}	x_{22}	$\dots$	x_{2n}
$\vdots$	$\vdots$			
m	x_{m1}	x_{m2}	$\dots$	x_{mn}

トピック*j*の
サンプル平均

$$\bar{x}_{\bullet j} = \frac{\sum_{i=1}^m x_{ij}}{m}$$

対応のあるデータのTukey HSD検定 (2)

$$S_{E2} = \sum_{i=1}^m \sum_{j=1}^n (x_{ij} - \bar{x}_{i\bullet} - \bar{x}_{\bullet j} + \bar{x})^2, \quad V_{E2} = \frac{S_{E2}}{\phi_{E2}}$$

帰無仮説 $H_{i,i'}$:

システム i, i' の母平均は等しい

$$\phi_{E2} = (m - 1)(n - 1)$$

検定統計量 $t'_{i,i'} = \frac{\bar{x}_i - \bar{x}_{i'}}{\sqrt{V_{E2}/n}}$

Studentised range分布より

$|t'_{i,i'}| \geq q_{inv}(m, \phi_{E2}; \alpha)$ のとき $H_{i,i'}$ を棄却

対応のあるデータのTukey HSD検定 (3)

```
> mat2 <- data.frame(Topic=1:20, mat)
> head(mat2, 3)
  Topic System1 System2 System3
1      1  0.4695  0.3732  0.3575
2      2  0.2813  0.3783  0.2435
3      3  0.3914  0.3868  0.3167
> tail(mat2, 3)
  Topic System1 System2 System3
18     18  0.3028  0.3400  0.3253
19     19  0.3752  0.4895  0.3205
20     20  0.2796  0.2335  0.2240
```

対応のあるデータのTukey HSD検定 (4)

```
> library(tidyr)
> mat2tidy <- gather( mat2, key=System, value=Score, -Topic )
> head(mat2tidy, 3)
  Topic System  Score
1      1 System1 0.4695
2      2 System1 0.2813
3      3 System1 0.3914
> tail(mat2tidy, 3)
  Topic System  Score
58     18 System3 0.3253
59     19 System3 0.3205
60     20 System3 0.2240
```

「Topicの列以外について
値を列挙せよ」

対応のあるデータのTukey HSD検定 (5)

```
> TukeyHSD( aov(Score ~ factor(System) + factor(Topic), data=mat2tidy),
+ "factor(System)", ordered=TRUE )
```

```
Tukey multiple comparisons of means
95% family-wise confidence level
factor levels have been ordered
```

「出力のdiff (平均値の差) の値が負にならないよう、どちらからどちらを引くか決めて」

```
Fit: aov(formula = Score ~ factor(System) + factor(Topic), data = mat2tidy)
```

```
$`factor(System)`
```

	diff	lwr	upr	p adj
System2-System3	0.061470	0.02813169	0.09480831	0.0001829
System1-System3	0.083845	0.05050669	0.11718331	0.0000011
System1-System2	0.022375	-0.01096331	0.05571331	0.2428822

システム2,3間、1,3間のみ有意

対応のないデータのTukey HSD検定 (1)

グループサイズが等しい場合

グループサイズが等しくない場合は <http://sakailab.com/leirbook/> (Chapter 4)

グループサイズが等しい一元配置分散分析のデータ構造

システム*i*の
サンプル平均

$$\bar{x}_{i\bullet} = \sum_{j=1}^n x_{ij} / n$$

System	Per-topic scores
1	$x_{11}, x_{12}, \dots, x_{1n}$
2	$x_{21}, x_{22}, \dots, x_{2n}$
$\vdots$	$\vdots$
m	$x_{m1}, x_{m2}, \dots, x_{mn}$

グループサイズが全て*n*だが対応なし

対応のないデータのTukey HSD検定 (2)

$$S_{E1} = \sum_{i=1}^m \sum_{j=1}^n (x_{ij} - \bar{x}_{i\bullet})^2, \quad V_{E1} = \frac{S_{E1}}{\phi_{E1}}$$

帰無仮説 $H_{i,i'}$: $\phi_{E1} = m(n - 1)$

システムi, i' の母平均は等しい

検定統計量 $t'_{i,i'} = \frac{\bar{x}_i - \bar{x}_{i'}}{\sqrt{V_{E1}/n}}$

$|t'_{i,i'}| \geq q_{inv}(m, \phi_{E1}; \alpha)$ のとき $H_{i,i'}$ を棄却

対応のないデータのTukey HSD検定 (3)

```
> library(tidyr)
> mattidy <- gather(mat, key=System, value=Score)
> head(mattidy, 3)
  System Score
1 System1 0.4695
2 System1 0.2813
3 System1 0.3914
> tail(mattidy, 3)
  System Score
58 System3 0.3253
59 System3 0.3205
60 Svstem3 0.2240
```

対応のないデータのTukey HSD検定 (3)

```
> TukeyHSD( aov(Score ~ factor(System), data=mattidy), ordered=TRUE )
Tukey multiple comparisons of means
 95% family-wise confidence level
factor levels have been ordered
```

```
Fit: aov(formula = Score ~ factor(System), data = mattidy)
```

```
$`factor(System)`
```

	diff	lwr	upr	p adj
System2-System3	0.061470	-0.019844676	0.1427847	0.1725122
System1-System3	0.083845	0.002530324	0.1651597	0.0418683
System1-System2	0.022375	-0.058939676	0.1036897	0.7862427

システム1,3間のみ有意

ランダム化(Tukey HSD)検定

データの正規性などの仮定からスタートして分布を数学的に導出する古典的検定とは違い、観測されたデータをもとに**計算機をぶんまわして**分布を描く

簡単な実装例: <https://research.nii.ac.jp/ntcir/tools/discpower-ja.html>

NTCIR Project
Tools

Discpower

[\[ENGLISH\]](#) [\[NTCIR Home\]](#) [\[NTCIR Tools Home\]](#)

Discpower by Tetsuya Sakai

Discpowerはrandomised Tukey HSD testを用いて評価指標の判別能力を計算するツールキットです。判別能力は与えられた有意水準 α に対して計算することもできますが、p-valueをシステム対に対してプロットするAchieved Significance Level (ASL) 曲線のほうが情報量が多いです。Discpowerが出力するcsvファイルから、簡単にMicrosoft ExcelなどによりASL曲線を描くことができます。

詳細についてはtarファイルに含まれるREADMEおよび下記の論文を参照してください。

Download

2つのシステムの場合の原理 (対応のあるデータのt検定に相当)

3つ以上の場合は
対応のあるデータの
Tukey HSD検定に相当

帰無仮説: 「各トピックについて2つの値を生成し、コインを投げていずれのシステムに割り当てるかを決定している(システム間の差に意味なし)」

Observed matrix U

X11	X21
X12	X22
:	:
X1n	X2n

$\bar{x}_{1\cdot}$ $\bar{x}_{2\cdot}$

$H_0: x_{11}, x_{21}, \dots$
all come from
the same
system

U^{*1}

X11	X21
X22	X12
:	:
X1n	X2n

$\bar{x}_{1\cdot}^{*1}$ $\bar{x}_{2\cdot}^{*1}$

Difference $\bar{d}^{*1}$

U^{*2}

X21	X11
X12	X22
:	:
X2n	X1n

$\bar{x}_{1\cdot}^{*2}$ $\bar{x}_{2\cdot}^{*2}$

$\bar{d}^{*2}$

U^{*B}

X11	X21
X22	X12
:	:
X2n	X1n

$\bar{x}_{1\cdot}^{*B}$ $\bar{x}_{2\cdot}^{*B}$

$\bar{d}^{*B}$

Distribution of $\bar{d}^{*b}$

$\bar{x}_{1\cdot} - \bar{x}_{2\cdot}$

帰無仮説が正しいなら
平均の差は
こんな分布に従うはず

Tutorial outline

(I) 復習: t検定 [15分]

- ギネスビールの社員の話
- 対応のあるデータのt検定
- 対応のないデータのt検定

(II) 「統計的に有意である」と言うだけでいいか? [15分]

- 統計的検定の弊害
- 効果量
- 統計的検定に代わるアプローチ

(III) 三つ以上のシステムの比較においてt検定を繰り返していいか? [15分]

- ワインを飲みすぎた客の話
- 全体としての第一種の誤り
- Bonferroni補正はちょっと古い

(IV) Tukey HSD検定 [15分]

- 対応のあるデータのTukey HSD検定
- 対応のないデータのTukey HSD検定
- ランダム化検定とランダム化Tukey HSD検定

(V) 実験結果の適切な報告の仕方 [5分]

- 2つのシステムの比較
- 3つ以上のシステムの比較

(VI) さらにレベルアップ [10分]

- 有意水準、検出力、効果量、サンプルサイズの関係
- 今やったばかりのt検定の検出力は? 今後のサンプルサイズは?

(VII) Q&A・バッファ [15分]

統計的検定結果の適切な報告の仕方

論文を読んだ人がその結果を検証するに足る情報を提供:

サンプルの収集方法、検定の種類、サンプルサイズ、自由度、検定統計量、p-value、効果量

×「提案手法はベースラインを統計的に有意に上回った」

→ **どんな検定をやったのかさえわからない**

×「提案手法1, 2, ベースラインを比較したところその差は統計的に有意であった」

→ **多重比較法を用いたのか? 何と何の間に有意差があったのか?**

×「提案手法1はベースラインを有意水準 $\alpha=0.05$ にて統計的に有意に上回り、提案手法2は $\alpha=0.01$ にて上回った」

→ **α は事前に決めるもの。またp-valueその他の情報がない(二元論)**

(対応のないデータの)t検定結果の報告例

Table 5.2 Comparison of retrieval effectiveness

表の目的を明記

各サンプルサイズを明記。本文中に書いてあっても
のちの研究者のために表にも明記推奨

System	#topics	Mean nDCG
Proposed (System 1)	$n_1 = 20$	0.4500
Baseline (System 2)	$n_2 = 20$	0.4277

数字がなんなのか明記。
平均なら平均と明記。
「nDCG」は不正確

“We conducted a Student’s t-test for the difference between our proposed system and the baseline in terms of mean nDCG. The difference is not statistically significant, $t(38) = 0.639$, $p=0.530$, $95\%CI[-0.049, 0.094]$, with Hedge’s $g = 0.200$.”

t値と自由度

(ランダム化) Tukey HSD検定結果の報告例

Table 5.3 Comparison of systems 1–3 in terms of mean nDCG over $n = 20$ topics. In each cell, the difference in mean nDCG, ES_{E2} (effect size) and the p -value (randomised Tukey HSD test with $B = 5,000$ trials), are shown

このスライドでは
平均nDCGの表を省略

	System 2		System 3	
System 1	0.0224	$(ES_{E2} = 0.5182)$	0.0838	$(ES_{E2} = 1.9386)$
		$(p = 0.4996)$		$(p \approx 0.0000)$
System 2	–		0.0615	$(ES_{E2} = 1.4227)$
				$(p = 0.0024)$

各平均値の差を
標準偏差の推定値
で割った効果量
(ただし等分散性を仮定)

$$ES_{E2}(i, i') = \frac{\bar{x}_{i\bullet} - \bar{x}_{i'\bullet}}{\sqrt{V_{E2}}}$$

“We conducted a paired randomised Tukey HSD test with $B=5,000$ trials to compare every system pair [...] System 3 statistically significantly underperforms Systems 1 ($p=0.0000$) and 2 ($p=0.0024$). Moreover, Systems 1 and 3 are almost two standard deviations apart from each other (Sakai 2018).”

Tutorial outline

(I) 復習: t検定 [15分]

- ギネスビールの社員の話
- 対応のあるデータのt検定
- 対応のないデータのt検定

(II) 「統計的に有意である」と言うだけでいいか? [15分]

- 統計的検定の弊害
- 効果量
- 統計的検定に代わるアプローチ

(III) 三つ以上のシステムの比較においてt検定を繰り返していいか? [15分]

- ワインを飲みすぎた客の話
- 全体としての第一種の誤り
- Bonferroni補正はちょっと古い

(IV) Tukey HSD検定 [15分]

- 対応のあるデータのTukey HSD検定
- 対応のないデータのTukey HSD検定
- ランダム化検定とランダム化Tukey HSD検定

(V) 実験結果の適切な報告の仕方 [5分]

- 2つのシステムの比較
- 3つ以上のシステムの比較

(VI) さらにレベルアップ [10分]

- 有意水準、検出力、効果量、サンプルサイズの関係
- 今やったばかりのt検定の検出力は? 今後のサンプルサイズは?

(VII) Q&A・バッファ [15分]

α 、 β 、効果量、サンプルサイズ

	H ₀ 採択	H ₀ 棄却
H ₀ は真 (母平均は等しい)	正しい結論 (確率 $1-\alpha$)	第一種の誤り α (あわてもの)
H ₀ は偽 (母平均は異なる)	第二種の誤り β (ぼんやりもの)	正しい結論 (確率 $1-\beta$)

検出力: 本物の差
を見出せる確率

有意水準 α (例: 5%)、確実に検出したい効果 (例: 標準偏差1/5分の差は実用上意味があると思なす)を定めたもとで、
サンプルサイズを大きくする → 検出力が上がる (見逃しが減る)

検出力過小な実験: サンプルサイズが小さすぎて本当の差を見逃しまくる

検出力過大な実験: サンプルサイズが大きすぎて実用的有意差なしでも統計的に有意に

今やったt検定の検出力は？ 今後のサンプルサイズは？

<https://waseda.box.com/SIGIR2016PACK>

豊田秀樹: 検定力分析入門, 東京図書, 2009

上記パッケージは豊田先生の本のRコードをハックしたもの。
例: 対応のあるデータのt検定の結果について:

```
> future.sample.pairedt( 0.953, 28 )
```

t値とサンプルサイズを入力

```
INPUT: t= 0.953 n= 28 Alt= two.sided ALPHA= 0.05 POWER= 0.8
```

```
EShat= 0.1801001
```

効果量: 標準偏差いくつぶん? (p.27)

```
Achieved_power= 0.1510342
```

「今回の検出力は15%
ぜんぜんだめ」

デフォルトは有意水準5%
検出力80%
(Cohenの慣例)

```
Sample size n per group = 244
```

「これくらいの効果量について検出力80%を保証したいならサンプルサイズはこれくらいないとね」

多重比較における「検出力」はややこしいので (永田靖: 多重比較法の実践, 応用統計学 27(2), 1998)
最も関心のあるシステム対に注目してt検定の検出力を議論するのが個人的なおすすめ

Tutorial outline

(I) 復習: t検定 [15分]

- ギネスビールの社員の話
- 対応のあるデータのt検定
- 対応のないデータのt検定

(II) 「統計的に有意である」と言うだけでいいか? [15分]

- 統計的検定の弊害
- 効果量
- 統計的検定に代わるアプローチ

(III) 三つ以上のシステムの比較においてt検定を繰り返していいか? [15分]

- ワインを飲みすぎた客の話
- 全体としての第一種の誤り
- Bonferroni補正はちょっと古い

(IV) Tukey HSD検定 [15分]

- 対応のあるデータのTukey HSD検定
- 対応のないデータのTukey HSD検定
- ランダム化検定とランダム化Tukey HSD検定

(V) 実験結果の適切な報告の仕方 [5分]

- 2つのシステムの比較
- 3つ以上のシステムの比較

(VI) さらにレベルアップ [10分]

- 有意水準、検出力、効果量、サンプルサイズの関係
- 今やったばかりのt検定の検出力は? 今後のサンプルサイズは?

(VII) Q&A・バッファ [15分]

まとめ

- 統計的検定（今回は平均値の差の検定）の前提と意味を正しく理解し、正しく報告しよう。P-valueだけでなく効果量を議論!
- 適切な多重比較法を使おう。
- 検出力とサンプルサイズを気にしよう。
- 統計的検定にはたくさん批判もあることを知ろう。

ただしこれは論文で検定も何もやらない言い訳にはならない。

- 永田靖先生、豊田秀樹先生の本などで勉強しよう！

英語でよければ <http://sakailab.com/leirbook/> も！

（是非引用してください）