

差の検定

独立なデータ : Mann-Whitney U Test

信号の光がついたらすぐにスイッチを押すということを何回か行った場合に、各回における光が点いたときからスイッチが押されるまでの時間を、AとBの2人の人について測定した結果が、表1のようであったとする。

表1 AさんとBさんの反応時間

(ミリ秒単位)

A	B
168	202
159	257
249	203
179	204
239	241
174	221
172	202
157	209
165	225
208	192
167	187
212	210
213	218
223	182
170	229
	245
	235
	259

Aの測定値は15個(15回分)、Bの測定値は18個ある。Aの反応時間と、Bの反応時間に、差があるかどうかの検定を行うことを考える。反応時間の分布は正規分布に従っているとは考え難いので、t検定ではなく、データ値の順序情報を用いるMann-WhitneyのUテストと呼ばれている方法で行うこととする。

いま、Uテストを一般的に説明するため、m個のデータ、 X_1, \dots, X_m 、と、n個のデータ、 Y_1, \dots, Y_n があるとする。Uテストでは、 X_i の分布と Y_j の分布の差を見るために、 X_i と Y_j の大小関係によって値が決まる、次の D_{ij} という変数を導入する

(Gibbons, 1971)。

$$D_{ij} = \begin{cases} 1 & X_i > Y_j \\ 0 & X_i \leq Y_j \end{cases}$$

この D_{ij} の和として U を定義する。

$$U = \sum_{i=1}^m \sum_{j=1}^n D_{ij} \quad (1)$$

すなわち、 U は、 X_i と Y_j を比べたとき、 X_i の方が Y_j より大きい組み合わせの数である。従って、 X_i の方が Y_j より全体として値が小さいとき U の値は小さくなり、 X_i の方が Y_j より全体として値が大きいとき U の値は大きくなる。 U 検定では、この U の値にもとづいて検定が行われる。

帰無仮説「 X_i の分布と Y_j の分布に差はない」のもとで、 U の値が小さ過ぎないか、あるいは大き過ぎないかを調べる。帰無仮説のもとでの U の分布は、以下に説明するように漸化式で与えることができる (Gibbons, 1971)。

2 つの独立なサンプル、 X_1, \dots, X_m と Y_1, \dots, Y_n に対して、 (1) 式によつて与えられる U の値が u である確率を、 $p_{m,n}(u)$ で表わす。

U の値は、 m 個の文字 X と n 個の文字 Y を混ぜて一直線に並べたときに、これらの mn 個の文字の並びから 2 つの文字 (隣り合う文字である必要はない) をとったときに、左側の文字が X で右側の文字が Y である組み合わせの対の総数とみなすことができる。つまり、大きいものから順番に、左から並べられているとみなす。 m 個の X と n 個の Y の並べ方は $\binom{m+n}{m}$ 通りあるが、 X_i と Y_j の分布が同じであるという仮説のもとでは、これらの並べ方の生起確率はいずれも等しいと考えられる。従って、 m 個の X と n 個の Y を並べたときに、 U の値が u になる並べ方の総数を $r_{m,n}(u)$ とおけば、

$$p_{m,n}(u) = \frac{r_{m,n}(u)}{\binom{m+n}{m}}$$

となる。

XとYの文字の並べ方において、左端がYのものとXのものとに分けて考えれば、次の関係式の成り立つことがわかる。

$$r_{m,n}(u) = r_{m,n-1}(u) + r_{m-1,n}(u-n) \quad (2)$$

$r_{m,n-1}(u)$ は、左端がYであるときの並べ方の数を表わす。この場合は、左端のYを無視して、(n-1)個のYがあると考えて数える。

$r_{m-1,n}(u-n)$ は、左端がXであるときの並べ方の数を表わす。(m-1)個のXと、n個のYを並べてから、左端にXを付け加えると、uの値はn増えることに注意して、数える。

式(21)より、 $p_{m,n}(u)$ についての次の関係式が得られる。

$$\begin{aligned} p_{m,n}(u) &= \frac{r_{m,n}(u)}{\binom{m+n}{m}} \\ &= \frac{r_{m,n-1}(u)}{\binom{m+n}{m}} + \frac{r_{m-1,n}(u-n)}{\binom{m+n}{m}} \\ &= \frac{n}{m+n} \cdot \frac{r_{m,n-1}(u)}{\binom{m+n-1}{m}} + \frac{m}{m+n} \cdot \frac{r_{m-1,n}(u-n)}{\binom{m-1+n}{m-1}} \\ &= \frac{np_{m,n-1}(u) + mp_{m-1,n}(u-n)}{m+n} \end{aligned}$$

確率 $p_{m,n}(u)$ は、上式により再帰的に求めることができる。

分布関数は、次式により与えられる。

$$P(u \leq U) = \sum_{u=0}^U p_{m,n}(u)$$

Uの値の計算においては、次の関係が利用される(Siegel, 1956)。

X_1, \dots, X_m と Y_1, \dots, Y_n を一緒にして、小さいものから順番に1、2、…、 $m+$

n と順位付けを行ったときの Y_j の順位を、 R_j^{XY} で表わす。 Y_j を、 Y_1, \dots, Y_n のなかで、

1 から n までの順位付けを行ったときの順位は、 R_j^Y で表わす。 Y_j より小さい X_i の総数は、

$$m - \sum_{i=1}^m D_{ij}$$

で与えられるので、次式が成り立つ。

$$R_j^{XY} = m - \sum_{i=1}^m D_{ij} + R_j^Y$$

上式の両辺の、 j についての和をとれば、次式となる。

$$\sum_{j=1}^n R_j^{XY} = mn - \sum_{j=1}^n \sum_{i=1}^m D_{ij} + \sum_{j=1}^n R_j^Y$$

すなわち

$$\begin{aligned} \sum_{j=1}^n R_j^{XY} &= mn - U + \frac{n(n+1)}{2} \\ U &= mn + \frac{n(n+1)}{2} - \sum_{j=1}^n R_j^{XY} \end{aligned} \quad (3)$$

となる。

いま、

$$D'_{ij} = \begin{cases} 1 & \text{if } Y_j > X_i \\ 0 & \text{if } Y_j < X_i \end{cases}$$

$$U' = \sum_{i=1}^m \sum_{j=1}^n D'_{ij}$$

とおき、 X_1, \dots, X_m と Y_1, \dots, Y_n を一緒に順位付けしたときの X_i の順位を R_i^{XY}

とおいて、 X_i と Y_j を入れ替えて考えれば

$$U' = mn + \frac{m(m+1)}{2} - \sum_{i=1}^m R_i^{XY}$$

の成り立つことが分かる。

したがって、

$$U + U' = 2mn + \frac{n(n+1)}{2} + \frac{m(m+1)}{2} - \sum_{j=1}^n R_j^{XY} - \sum_{i=1}^m R_i^{XY}$$

$$\begin{aligned}
&= 2mn + \frac{n(n+1)}{2} + \frac{m(m+1)}{2} - \frac{(m+n)(m+n+1)}{2} \\
&= mn
\end{aligned} \tag{4}$$

となる。

プログラム PMWU.dpr では、式(3)および式(4)が用いられている。さらに、Uの値を変換して、正規分布による検定も行えるようになっている。

Uの平均 μ と標準偏差 s は、 X_i の分布と Y_j の分布に差が無いという仮説のもとでは次式で与えられる。

$$\begin{aligned}
\mu &= \frac{mn}{2} \\
s &= \sqrt{\frac{mn(m+n+1)}{12}}
\end{aligned}$$

サンプル数が多いとき、次式

$$z = \frac{U - \mu}{s}$$

で与えられる z は、平均 0、分散 1 の標準正規分布に従う、として検定が行われる。

X_i と Y_j を一緒にしたときの順位付けにおいて、同じ順位のもの（タイ・スコア）があるときには、 z の値は次のように修正される。すなわち、順位 r のものが t_r 個あったときの修正値 s_c は、次式で与えられる (Siegel & Castellan, 1988)。

$$s_c = \sqrt{\frac{mn}{N(N-1)} \left(\frac{N^3 - N}{12} - \sum_{r=1}^N \frac{t_r^3 - t_r}{12} \right)}$$

ここで、

$$N = m + n$$

である。

Uの値の計算のためのプログラム PMWU.dpr を実行すると、図1のフォームが表示される。

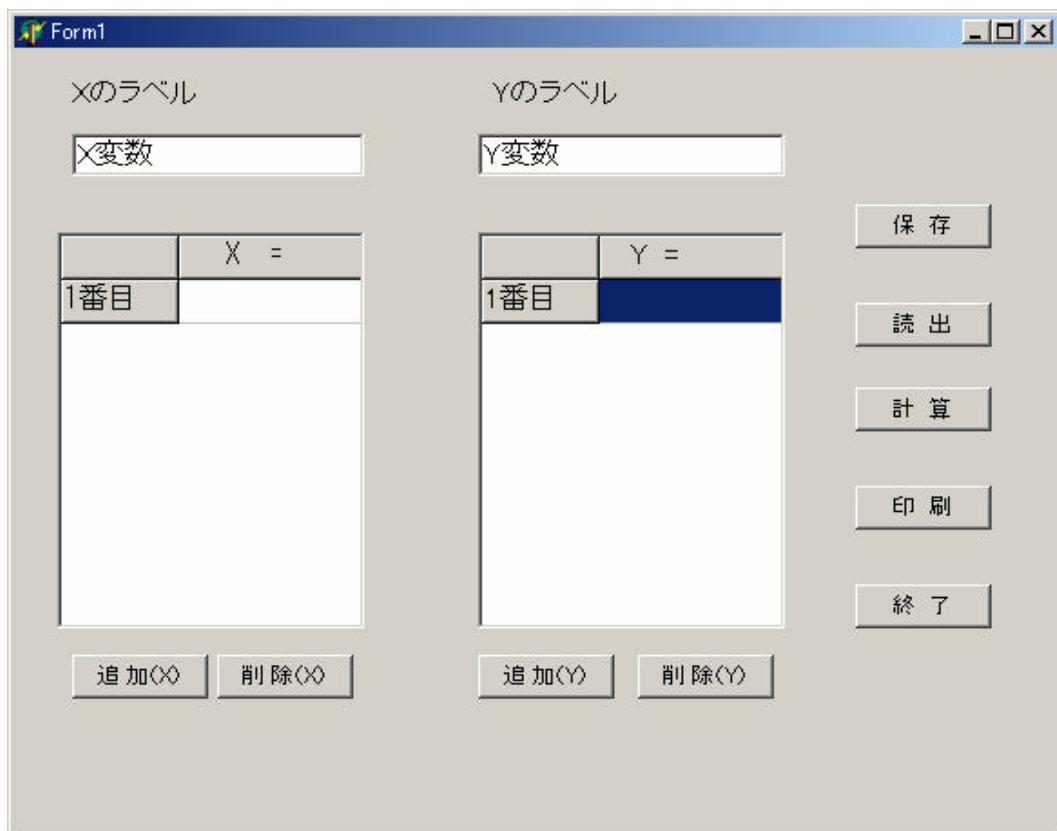


図1 起動時のフォーム

対応のないデータの分析なので、左側と右側の2つのデータ設定用StringGrid、及びそれぞれ独立に行数を設定するための「追加」ボタンと「削除」ボタンが用意されている。「追加」ボタンをクリックすると、その上のStringGrid内のアクティブなセルの下に行が新しく追加・挿入される。セルをアクティブにするには、そのセルをクリックする。「削除」ボタンをクリックすると、その上のStringGrid内のアクティブなセルを含む行が削除される。

「印刷」ボタンをクリックすると、設定されているデータがプリンタに出力される。

	X =		Y =
9番目	165	12番目	210
10番目	208	13番目	218
11番目	167	14番目	182
12番目	212	15番目	229
13番目	213	16番目	245
14番目	223	17番目	235
15番目	170	18番目	259

追加(O) 削除(O) 追加(Y) 削除(Y)

保存 読出 計算 印刷 終了

図2 データの設定（表1のデータ）

図2のようにデータを設定後、「計算」ボタンをクリックするとUの値の計算が始まる。
 「計算」ボタンをクリックする前に、StringGridには空白のセルがないようにし、余分なセルがあれば「削除」ボタンをクリックして削除しておく。
 「計算」ボタンをクリックすると、まず図3のダイアログボックスが表示される。

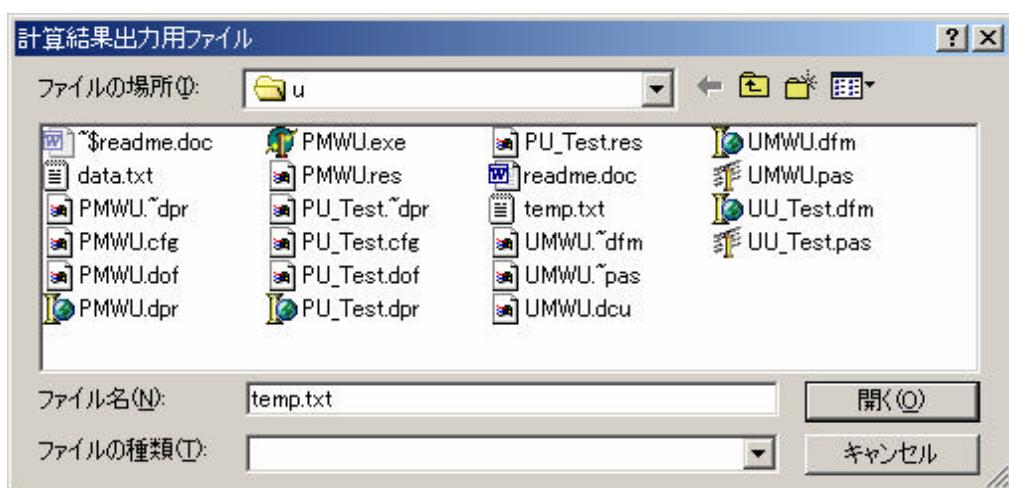


図3 計算結果出力用ファイル名の設定

ファイル名の設定後、「開く」ボタンをクリックすると計算が始る。計算結果は、図3で設定した名前のファイルにテキストファイルとして書き出されるので、プログラムの実行終了後、エディタなどで開いて見ることができる。

計算が終了すると、図4のように「計算を終了しました」のメッセージがフォームに表示される。

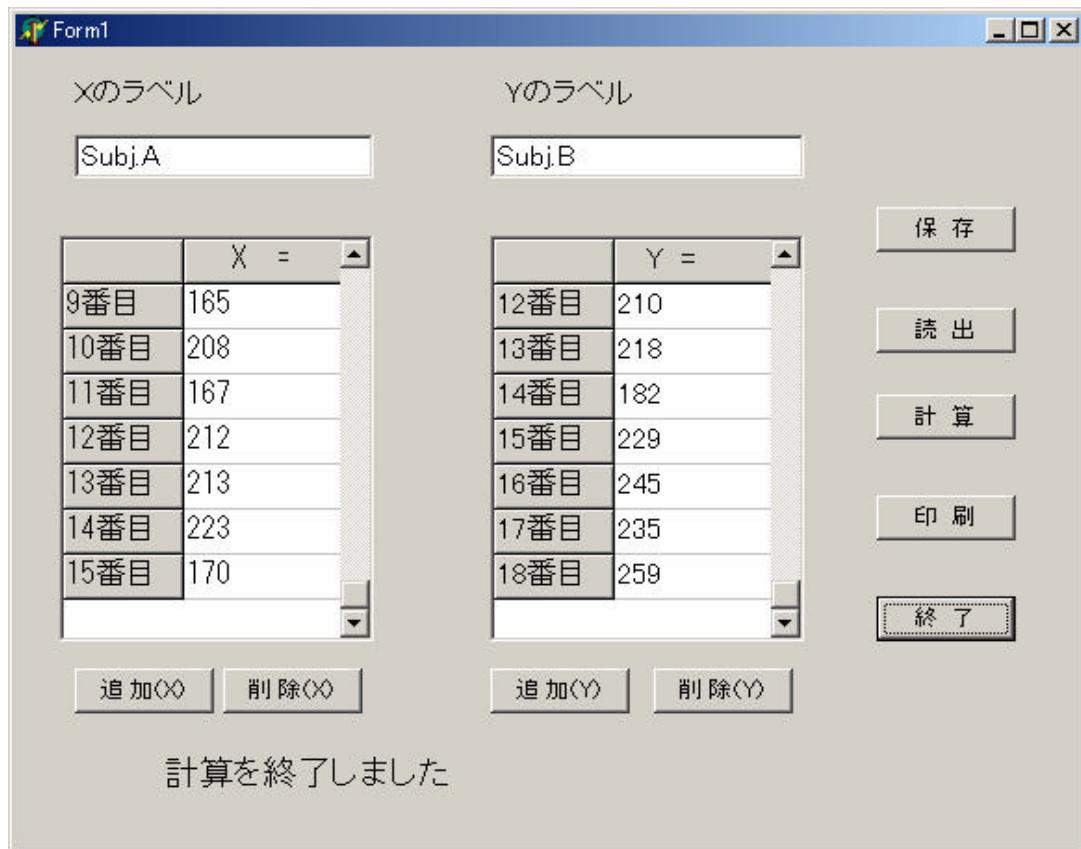


図4 計算終了時のフォーム

「終了」ボタンのクリックでプログラムの実行終了となる。

プログラムの実行終了後、図3で設定した名前の出力ファイルをエディタなどで開いて見ることができる。図2のデータの場合の計算結果の出力は、リスト1のようになっている。

リスト 1 計算結果の出力内容

データ 1 =	168.00 159.00 249.00 179.00 239.00 174.00 172.00 157.00 165.00 208.00 167.00 212.00 213.00 223.00 170.00		
中央値 =	174.00		
データ 2 =	202.00 257.00 203.00 204.00 241.00 221.00 202.00 209.00 225.00 192.00 187.00 210.00 218.00 182.00 229.00 245.00 235.00 259.00		
中央値 =	214.00		
U =	66.0	m = 15	n = 18
Z	= -2.495		
Z(corrected)	= -2.495		

リスト 1 における U の値に対する累積確率は

$$P(u \leq 66) \approx 0.0059 < 0.05 = 5\%$$

となる。U の変換値 z に対する累積確率は

$$P(z \leq -2.495) \approx 0.0063 < 0.05 = 5\%$$

となっている。図2のデータの場合、有意水準5%で差が認められる。

図2のように設定されているデータは、「保存」ボタンのクリックでファイルに保存することができる。「保存」ボタンをクリックすると図5のダイアログボックスが表示される。

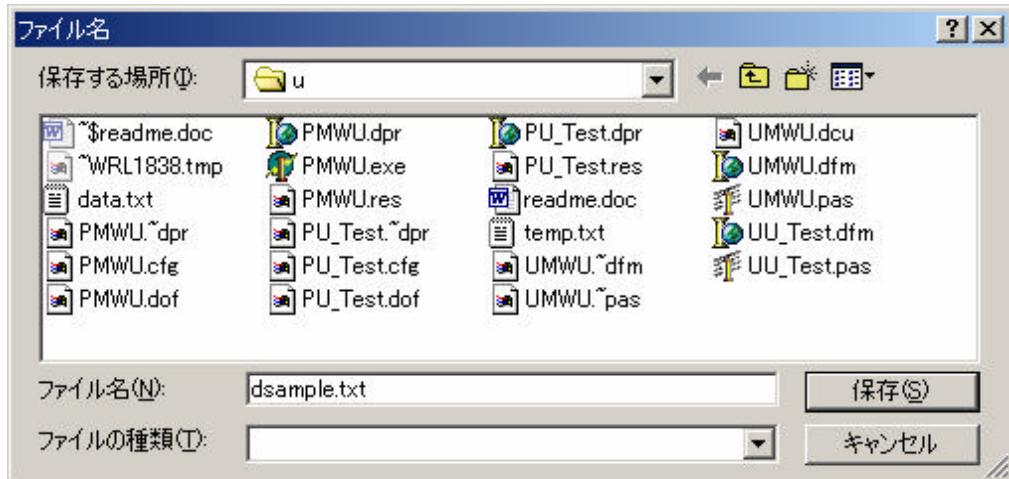


図5 データ保存用ファイル名の設定

データを保存するファイルの名前を設定して、図5のダイアログボックスの「保存」ボタンをクリックすると、設定した名前のファイルにデータが保存される。

保存したデータは「読み込む」ボタンのクリックで読み込むことができる。「読み込む」ボタンをクリックすると、図6のダイアログボックスが表示される。

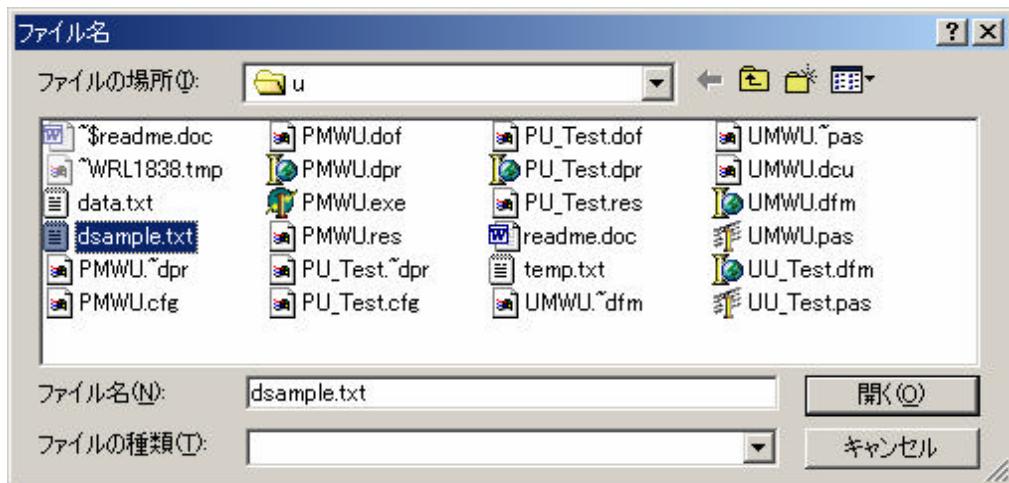


図6 データ読み出し用ファイル名の設定

データを読み出すファイルの名前を設定後、「開く」ボタンをクリックすると、設定した名前のファイルからデータが読み込まれる。

参考文献

- Gibbons,J.D.(1971). *Nonparametric statistical inference*. McGraw-Hill,Inc.
- 岡本安晴 (1998). *Delphi で学ぶデータ分析法* . CQ 出版社 .
- Siegel,S (1956). *Nonparametric Statistics: For the Behavioral Sciences*. McGraw-Hill Book Company,Inc.
- Siegel,S. & Castellan,N.J.,Jr.(1988). *Nonparametric statistics for the behavioral sciences. 2nd. Ed.* McGraw-Hill,Inc.