

情報処理のレポートについて

2008年1月8日

横山 暁

レポートの採点での総評や、間違いが多かった部分について記述したものを Web にアップしておきます。 (http://www.ae.keio.ac.jp/~satoru_y/shouei/Report07_result.pdf)
各自でチェックして復習をしてください。

<採点・評価について>

レポートは 25 点満点で行いました。各問題で解答をすべき内容が書いてありかつ正解であれば 21 点, その他に途中の計算方法や考察が書いてあるごとに最大 4 点加点しています。成績は, 前期の出席・レポートと後期の出席・レポートを総合して, 最終的な成績評価を行っています。

<レポートの総評>

今回のレポートは, 同じデータを用いているため, Excel の計算は全員同じになります。そのため, たとえ Excel の計算は友達と協力したとしても, Word で提出してもらうことによって各自でレポートを作成し, 内容の理解 (復習) をして欲しいと思っていました。

しかし, 残念ながら昼間部, 夜間部を合わせて, 同じレポートが 4 パターンほどありました。しかもその 4 パターンのすべてが, Excel の計算を間違っているだけでなく, レポートの指示に従っておらず, 特に帰無仮説や対立仮説を書いてありませんでした。さらに誤字もそのまま (「対立仮説を**指示**する」になっている) で, 酷いレポートでは, 名前を変えただけのレポートもありました。

内容が難しかったのかもしれませんが, 時間も十分にあったはずですし, 基本的にすべて後期の授業で学習したことであり, 講義資料もすべてウェブページに掲載してあるため, きちんとしたレポートを作成することができたはずでした。現にきちんとしたレポートを提出した人も多くいました。きちんとしたレポートを提出した人は, 内容もきちんと理解できているようで, レポートの出来は非常に良いように感じました。

先生によっては, 同じレポートは一切採点を行わないこともあるだけでなく, その授業を不合格することすらあり得ます。今回は採点行いましたが, 今後十分に注意してください。

1. 記述統計

(1) 平均・分散等の計算 (1点)

基本的によくできていました。ただし、答えを入れてもらおうとしていた C 列の隣の D 列にある「ヒストグラムの階級」の列を使って計算した人がいたため、平均から最小値までと範囲の値が間違っている人がいました。

平均	24.9
分散	7.116092
標準偏差	2.6676
最大値	30.0
最小値	20.5
中央値	24.5
第 1 四分位	23
第 3 四分位	27.375
最頻値	24.5
範囲	9.5

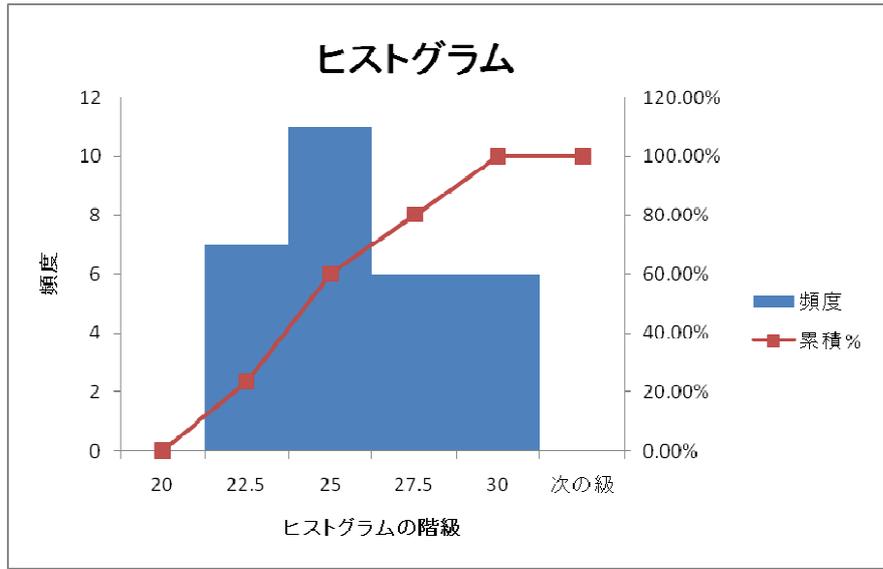
(2) 度数分布表・ヒストグラムの作成 (各 1点)

データと D 列にある「ヒストグラムの階級」の値を使って「分析ツール」の「ヒストグラム」で作成できます。その際に「累積度数分布の表示」と「グラフ作成」のチェックボックスにチェックをします。

ヒストグラムは、レポートの指示にもあったように、頻度の系列において「データ系列の書式設定」より棒の間隔を 0 にします。

一部のレポートで、データをそのまま棒グラフにしているものがありましたが、間違いです。

階級	頻度	累積 %
20	0	0.00%
22.5	7	23.33%
25	11	60.00%
27.5	6	80.00%
30	6	100.00%
次の級	0	100.00%



2. 回帰

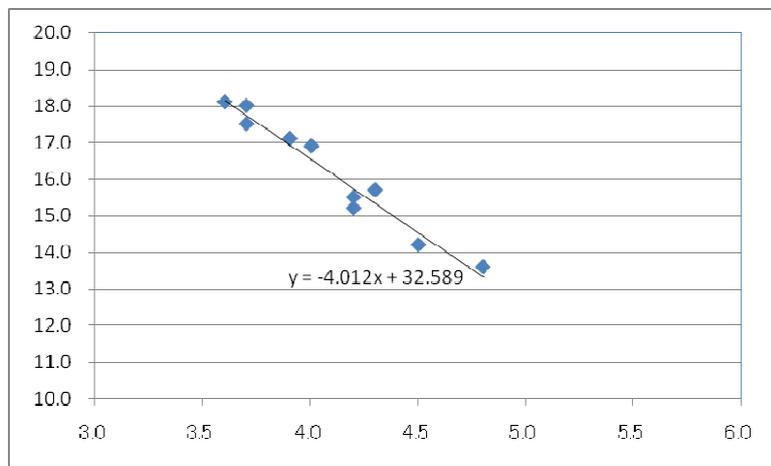
(1) 相関係数 (1点)

相関係数は **CORREL** という関数で計算します。 **-0.9786** になります。

A列B列で計算すると、これらの列は「セルの書式設定」の「表示形式」で小数点以下の桁数が1になっているため、 **-1.0** と表示されてしまいますが、散布図を描いてもわかるように、データは一直線に並んでいませんので、 **-1** にはなりません。

(2) 散布図・回帰式 (2点)

散布図は以下の図のようになります。



回帰式は、散布図の点を右クリックして「近似曲線の追加」で「線形近似」をクリックし「グラフに数式を表示する」にチェックをすれば回帰式が求まります。

その他の求め方として、「分析ツール」の「回帰分析」からも求められます。ただし、値は求まりますが、式の形式ではないので、きちんと式で表してください。

3. 検定・信頼区間 1

(Z 検定, t 検定共に仮説が書いてあって 1 点, 計算ができていて 1 点, 仮説が棄却されるかどうか書いてあって 1 点, 信頼区間が合っていて 1 点, 合計 8 点)

(1) Z 検定・信頼区間

問題が両側検定という指示があるので, 仮説は以下のようになります.

帰無仮説: データの (母集団での) 平均が 20 である

対立仮説: データの (母集団での) 平均が 20 でない

両側確率を求めます. 授業中にはあまり触れませんでした, 資料には書いてあります. 片側 (上下) 確率を求め, 小さい方を 2 倍します. 0.0177 になりますので, これを 0.05 と比較します.

$0.0177 < 0.05$ ですので, 帰無仮説を棄却し対立仮説を支持します. つまりデータの母集団の平均は 20 でないことになります.

信頼区間は, 標本平均 \pm 正規分布両側 5% 点 \times 既知の標準誤差なので, (20.05, 20.55) になります.

(2) t 検定・信頼区間

Z 検定と同じく仮説は以下のようになります.

帰無仮説: データの (母集団での) 平均が 20 である

対立仮説: データの (母集団での) 平均が 20 でない

t 値を求め, 両側確率を TDIST で求めます. 0.040 になります. これを 0.05 と比較します.

$0.040 < 0.05$ ですので, 帰無仮説を棄却し対立仮説を支持します. つまりデータの母集団の平均は 20 でないことになります.

信頼区間は, 標本平均 \pm t 分布 5% 点 \times 標準誤差なので, (20.02, 20.58) になります.

ちなみに, Z 検定の信頼区間より t 検定の信頼区間の方が広がります.

Excel での計算は以下のようになります.

	A	B	C
1	No	データ	B 列の計算式
2		1	20.3
3		2	20.5

4		3	19.8	
5		4	20.2	
6		5	20.4	
7		6	20.8	
8		7	20.7	
9		8	20.7	
10		9	19.7	
11		10	19.9	
12	平均		20.3	'=AVERAGE(B2:B11)
13	標準偏差		0.394405	'=STDEV(B2:B11)
14	分散		0.155556	'=VAR(B2:B11)
15	標本の大きさ		10	'=COUNT(B2:B11)
16	従来之母平均		20	
17	既知之母標準偏差		0.4	
18	信頼度		0.95	
19	Z 検定			
20	既知の標準誤差		0.126491	'=B17/SQRT(B15)
21	z		2.371708	'=(B12-B16)/B20
22	下側確率		0.991147	'=NORMSDIST(B21)
23	上側確率		0.008853	'=1-B22
24	両側確率		0.017706	'=2*MIN(B22:B23)
25	区間推定			
26	両側 5%点		1.959964	'=NORMSINV(1-(1-B18)/2)
27	下側信頼限界		20.05208	'=B12-B26*B20
28	上側信頼限界		20.54792	'=B12+B26*B20
29	t 検定			
30	標準誤差		0.124722	'=B13/SQRT(B15)
31	自由度		9	'=B15-1
32	t		2.405351	'=(B12-B16)/B30
33	両側確率		0.039549	'=TDIST(B32,B31,2)
34	区間推定			
35	両側 5%点		2.262157	'=TINV(1-B18,B31)
36	下側信頼限界		20.01786	'=B12-B35*B30
37	上側信頼限界		20.58214	'=B12+B35*B30

4. 検定・信頼区間 2

(分散の検定, 平均の差の t 検定共に仮説が書いてあって 1 点, 計算ができていて 1 点, 仮説が棄却されるかどうかを書いてあって 1 点, 平均の佐野 t 検定の信頼区間が合っていて 1 点, 合計 7 点)

(1) 分散の検定

分散の検定は分散が等しいかを検定しますので, 仮説は以下のようになります.

帰無仮説: 2 つのデータの分散が等しい

対立仮説: 2 つのデータの分散が等しくない

分散比を計算し, **FDIST** から片側確率を求め, 片側確率の小さい方を 2 倍することで両側が求まります. **0.928** になります. 明らかに **0.05** より大きいので, 帰無仮説は棄却できません. つまりほぼ間違いなく 2 つのデータの分散は等しくないことになります.

(2) 平均の差の t 検定

分散に差がないことが分かったので, **Welch** の検定ではなく, 平均の差の t 検定を行います. 仮説は以下のようになります. 帰無仮説: まず **DEVSQ** で偏差平方和を求め共通の分散の推定値を求めます. さらに平均の差から平均の差の標準偏差を求めます. この 2 つの値から t 値を求め, **TDIST** で両側確率を求めます. **0.024** になります. $0.024 < 0.05$ より帰無仮説を棄却します. つまり平均に差があることになります.

信頼区間は平均の差 $\pm t$ 分布 5% 点 \times 標準誤差なので, **(-7.39, -0.58)** になります.

Excel での計算は以下のようになります.

	A	B	C	D
1	No.	データ 1	データ 2	B 列の計算式
2	1	78	81	
3	2	80	84	
4	3	79	82	
5	4	83	88	
6	5	82	86	
7	6	85	83	
8	7	78	78	

9	8	74	84	
10	9	76	89	
11	10	84		
12	平均	79.9	83.88889	'=AVERAGE(B2:B11)
13	標準偏差	3.573047	3.443996	'=STDEV(C2:C11)
14	分散	12.76667	11.86111	'=VAR(C2:C11)
15	標本の大きさ	10	9	'=COUNT(C2:C11)
16	自由度	9	8	'=C15-1
17	等分散性の検定			
18	分散比	1.076347		'=B14/C14
19	下側確率	0.464063		'=FDIST(B18,B16,C16)
20	上側確率	0.535937		'=1-B19
21	両側確率	0.928126		'=2*MIN(B19:B20)
22	平均の差の t 検定 or Welch の方法			
23	偏差平方和	114.9	94.88889	'=DEVSQ(C2:C11)
24	共通の分散の推定値	12.34052		'=(B23+C23)/(B16+C16)
25	平均の差	-3.98889		'=B12-C12
26	平均の差の標準誤差	1.61407		'=SQRT((1/B15+1/C15)*B24)
27	t 値	-2.47132		'=B25/B26
28	両側確率	0.024333		'=TDIST(ABS(B27),B16+C16,2)
29	t 分布 5%点	2.109816		'=TINV(0.05,B16+C16)
30	95%下側信頼限界	-7.39428		'=B25-B29*B26
31	95%上側信頼限界	-0.5835		'=B25+B29*B26