

URL: <http://www.nik.sal.tohoku.ac.jp/~tsigeto/statg/2.html>

作成: 田中重人 (講師) <tsigeto@nik.sal.tohoku.ac.jp>

比較現代日本論研究演習 II

大学院生対象: 2002 年度後期

<金 2 > コンピュータ実習室 (文学部本館 7F 711-2)

『講義概要』 p. 396 記載内容

◆ 講義題目: 実践的統計分析法

◆ 授業内容: 研究の現場で必要となる統計分析手法は、分析の目的とデータの特徴によってさまざまである。この授業では、さまざまな分析手法をとりあげて、それらの特徴と使い方を習得する。統計解析パッケージ SPSS を使ってデータ分析の実習をおこなう。

◇ 履修要件 前期開講の比較現代日本論研究演習 I を履修済みであるか、それと同等の知識を習得済みであること。

◇ テキスト: なし

◇ 成績評価の方法: 各回の授業中の課題 (50%)、中間試験 (20%)、期末レポート (30%) を合計して評価する。

授業の概要 (予定) 10/3 現在

目次

1. 推測統計入門 (10/4~10/25)
2. 順位相関 (11/8~11/15)
3. 中間試験 (11/29)
4. 変数をキーにした分析 (12/6~12/20)
5. クラスタ分析 (1/10~1/24)
6. 期末レポート

※ () 内の日付は、学期前のおおよその計画をあらわしていますが、実際の授業の進行状況によって前後にずれることがあります。

※ 11/1, 11/22 は休講です

1. 推測統計

- 誤差の評価 (含: 標本抽出についての復習) [10/4 提示資料 (PDF 形式)]
- 標本誤差の推定
- 平均値の点推定・区間推定
- 平均値の差の区間推定と t 検定
- 連関係数の区間推定と χ^2 検定

2. 順位相関

- 散布図
- 順序尺度の分析 (含: 尺度水準についての復習)
- Spearman の順位相関係数
- Kendall の順位相関係数
- その他の相関係数

3. 中間試験

4. 変数をキーにした分析

- 個体間変動と変数間変動
- 一致率の計算
- 対応のある分析

5. クラスタ分析

- 似た変数をまとめる
- 距離行列
- クラスタ分析の手法
- 樹状図
- 類似の分析手法

6. 期末レポート

第 13 回「無作為抽出と区間推定」

1. 標本誤差の推定

2. 平均値の推定

1

【標本誤差の推定】

「標本誤差」(sampling error)

=無作為抽出による誤差

- ★ 方向性をもたない
 - ★ 確率的に決まる
 - ★ 標本数が大きいほど誤差の範囲が小さい
- ➡ 「統計的推測」によって範囲を推定できる

2

【無限母集団の仮定】

母集団がある程度大きければ、統計的推測のうえでは、母集団は無限大とみなしてよい。

厳密にいうと、 $\frac{N-n}{(N-1)n} = \frac{1}{n}$ の場合

➡ 無限大の母集団から n 個の標本を無作為に選んだ場合について考える

3

【母集団平均値の推定】

- ★ 等確率標本の平均値は、母集団の平均値より高くなったり低くなったりする。
- ★ しかし**平均的にみれば**母集団の平均値に一致すると期待できる (点推定)

4

【平均値の信頼区間】

※「母集団では正規分布」の仮定が必要

- ★ 標本の平均値が母集団平均値からはずれる確率は正規分布にしたがう
- ➡ 標本平均値から逆算すれば、母集団の平均値の確率分布 (t 分布) がわかる

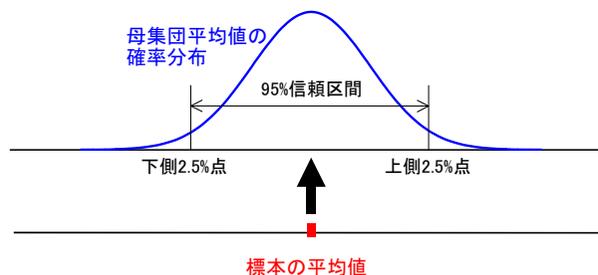
5

- ★ 母集団の平均値の確率分布から両端を α %分だけ切り落としてえられる区間を $(100 - \alpha)$ %の「**信頼区間**」という。

α を「危険率」、 $(100 - \alpha)$ を「信頼率」という。この値は自由に決めていいのだが、通常は $\alpha = 5\%$ として、95%信頼区間を求める。

6

信頼区間のもとめかた



7

- ★ 平均値の信頼区間のおおよその値：

$$\text{標本平均} \pm 1.96 \times \frac{\text{標準誤差}}{\sqrt{n}}$$

↓
t 臨界値

8

【SPSS コマンド】

「分析」→「記述統計」→「探索的」

- ◎ 「従属変数」を指定
- ◎ パネル左下の「統計」だけをチェック

※ 信頼率を変更するには「統計」を選択
 ※ 「因子」を指定すると層別に分析できる

9

第3回「統計的検定」

1. 平均値の差の推定
2. 区間推定と統計的検定
3. 分散分析と F 検定
4. クロス表の独立性の検定
5. 検定結果の表示

1

【平均値の差の推定】

2層間の **平均値の差** についても
平均値そのものと同様の区間推定ができる：
このとき 95%信頼区間はおよそ

$$d \pm 1.96 \times \text{併合SD} \times \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

(平均値の差) (標準誤差)

ただし n_1, n_2 はそれぞれの層の人数

2

各層の人数が多いほど
平均値の差の信頼区間が狭くなる

▶ 標本を均等にわけると
信頼性が高い

3

【SPSS のコマンド】

「平均値の比較」→「独立したサンプルの T 検定」

- ◎ 「グループ化変数」は、数値を指定しないとイケない。
連続量を一定の値で切ることもできる

出力は「独立サンプルの検定」の 1 行目
「等分散を仮定する」を見る

4

【区間推定と統計的検定】

統計的検定 = 特定の値を設定して、その値が
信頼区間に含まれているかどうかを判定する
0 に設定するのがふつう

95%信頼区間が 0 をふくまない
⇔ 「5%水準で有意」

※ 統計的検定の論理は本当はもっと複雑である。

5

【統計的検定のいろいろ】

★ 平均値の差の T 検定
コマンドの指定は区間推定とおなじ。
出力の「有意確率 (両側)」を見る

- ※ 2層の間の差の検定にしか使えない
- ※ 「母集団では正規分布」を前提とする
- ※ 2層の間で分散が等しいことが前提

6

★ 分散分析と F 検定

「平均値の比較」→「グループの平均」
オプション「分散分析表とイータ」を指定
出力「分散分析表」の右端「有意確率」

- ※ 3層以上の場合に使う。
 η の信頼区間を使って判断するのと同じである。
- ※ 2層の場合にも使えるが、T 検定と同じ結果になる
- ※ 必要とする前提も T 検定と同様

7

★ クロス表の独立性の検定

「クロス集計表」の「統計」で
「カイ 2 乗」を指定。
出力の「Pearson」の列の右端が有意確率

- ※ V の信頼区間を使って判断するのとおなじ
- ※ 各セルの期待度数が 5 以上であることを前提とする

8

【検定結果の表示】

	例 1			例 2		
	平均	標準偏差	(人)	平均	標準偏差	(人)
男性	1.77	0.67	(111)	2.62	1.02	(114)
女性	1.89	0.65	(132)	2.24	0.91	(136)
合計	1.84	0.66	(243)	2.41	0.98	(250)

$\eta = 0.086, p > 0.05$. 無回答 = 7. $\eta = 0.198^*$. *: 5%水準で有意

9

第4回「サンプルサイズの決定」

1. 検定力
2. ϕ 係数と%の差
3. ϕ 係数と χ^2 臨界値
4. サンプルサイズと検定力

1

【検定力】

母集団における一定の大きさの関連を
どれくらいの危険率で検出できるか

→ サンプルサイズに依存

2

【 ϕ 係数と%の差】

2×2 クロス表の%の差

=周辺度数がバランスしていれば、
 ϕ 係数に等しい

3

【 ϕ 係数と χ^2 臨界値】

2×2 クロス表で独立性の検定が5%有意

$$\chi^2 = N\phi^2 > 3.84$$

4

【サンプルサイズと検定力】

ある%差を5%水準で検出するのに
必要なサンプルサイズ： $N > 3.84/\phi^2$

- 20%差 → $3.84 / 0.2^2 \doteq 96$
- 16%差 →
- 14%差 →
- 12%差 →
- 10%差 →
- 5%差 →
- 1%差 →

5

【サンプルサイズの決定】

- 変数の測定法・分析法をきめる
 - どの程度の強さの関連を検出できればよいかを決める
 - 必要なサンプルサイズを決める
 - 分析のキーとなるカテゴリに均等分配した場合を最低限度とする
- ※不均等な配分を前提として厳密に求めることも可能

6

【その他の係数の場合】

Pearson の相関係数 → ϕ 係数とほぼおなじ

連関係数 V → χ^2 臨界値が自由度で変わる。
またカテゴリ数(少ない方)を考慮する。
一般に $N > \chi^2 \text{ 臨界値} / (m-1)V^2$

たとえば 3×3 クロス表なら

$$N > 9.49 / 2V^2$$

7

相関比 η → 次の式を使う (k はカテゴリ数) :

$$\frac{\eta^2}{1-\eta^2} \times \frac{N-k}{k} > F \text{ 臨界値}$$

- ※ $k \times 2$ クロス表の V 係数とほぼおなじ
- ※ 2グループ間の平均比較なら ϕ 係数とほぼ同じ

順位相関係数類 → 後日

8

0. 尺度水準：復習
1. 尺度水準と分析法
2. 相関係数とは
3. 散布図
4. Goodman-Kruskal の γ と Kendall の τ_b
5. Pearson の r
6. Spearman の r_s

1

【尺度水準と分析法】

名義×名義 → クロス表

名義×間隔 → 分散分析・平均値の比較

2

順序×順序 → 順位相関係数

(rank correlation coefficient)

Goodman-Kruskal の γ

Kendall の τ_b

Spearman の r_s

間隔×間隔 → 積率相関係数

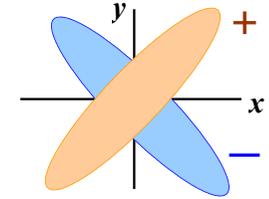
(product-moment correlation coefficient)

Pearson の r

3

【相関係数とは】

正(+)の関係か、負(-)の関係か



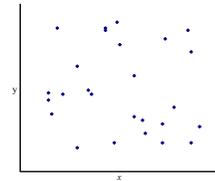
4

-1~+1 の範囲の値をとる：

- ・ 無関連のときゼロ
- ・ 完全な関連のとき±1

5

【散布図】



6

【ペア】

散布図上の任意の2点を直線で結んだとき

- 右上がり → Concordant
- 左上がり → Discordant

それぞれのペアの個数を C, D とする。

Goodman-Kruskal の $\gamma = \frac{C-D}{C+D}$

同順位ペアをうまく扱えないので、あまり使われない

7

【Kendall の順位相関係数】

Kendall の順位相関係数 $\tau_b = \frac{C-D}{\sqrt{KL}}$

K: xについて同順位でないペア数
L: yについて同順位でないペア数

同順位ペアがなければ、Goodman-Kruskal の γ と同じ

8

【変数の標準化】

(間隔尺度の場合)

平均=0, 標準偏差=1になるよう変換する。

$$X = \frac{x - \text{平均}}{\text{SD}}$$

これで単位を気にせずに比較できるようになる

9

【相関係数】

Pearson の積率相関係数

標準化済みの変数 X, Y について

$$r = \frac{XY \text{の総和}}{N}$$

単に「相関係数」といえばこの r をさす

欠点：はずれ値や歪みに弱い

10

【Spearman の順位相関係数】

r_s であらわす。

各変数を順位に変換した上で、Pearson の積率相関係数を求める。

11

【相関係数類の使いわけ】

順序尺度の場合 → Kendall の τ_b
または Spearman の r_s

間隔尺度の場合

正規分布なら → Pearson の r

歪みや外れ値 → Spearman の r_s

12

【SPSS コマンド】

「相関」→「2変量」

変数を指定する

相関係数の種類をチェック

Goodman-Kruskal の γ は出ない
(クロス表のオプションで出せる)

13

【相関係数行列】

3変数以上について総当たりで出すこともできる(correlation matrix)

14

【欠損値の処理】

- 対単位 (pairwise) の除去
個々の組み合わせごとに欠損ケースを除く

- 表単位 (listwise) の除去
分析に使う変数にひとつでも欠損のあるケースを除く

(「オプション」で「リストごとに除去」をえらぶ)

15

【文献】

池田 央 (編)(1989)『統計ガイドブック』新曜社

森 敏明 + 吉田 寿夫 (1990)『心理学のためのデータ解析テクニカルブック』北大路書房。

16

1. 相関係数の推定と検定
2. 相関係数行列の書きかた

1

【相関係数の推定と検定】

母集団において **2変量正規分布** のとき

r の 95%信頼区間は次式に近似：

$$Z = \ln \frac{1+r}{1-r}, \quad c = 2 \times 1.96 \sqrt{\frac{1}{N-3}} \quad \text{と お いて}$$

$$\text{上限} : \frac{\exp[Z+c]-1}{\exp[Z+c]+1}$$

$$\text{下限} : \frac{\exp[Z-c]-1}{\exp[Z-c]+1}$$

2

この信頼区間に $r=0$ が含まれるかを
検定すればよい

この方法は近似値である。
正確には t 分布を利用した検定をおこなう。

相関係数の検定の検出力：

N=100 で $r=\pm 0.2$

N=400 で $r=\pm 0.1$

3

Spearman の順位相関係数 r_s も、
 r と同じ方法で推定・検定できる。

Kendall の順位相関係数 τ_b の推定は
別の方法を用いる (省略)。

r よりも検出力が低い

4

【相関係数行列の書きかた】

- ★ 線対称なので、
右上／左下の三角部分だけを書けばよい。
- ★ 小数第3位までが原則
- ★ 小数点の前につくゼロは省略してもよい
- ★ 検定の結果にしたがって*をつける
- ★ 小数点をそろえること

5

【文献】

George W. Bohrnstedt + David Knoke; 海野 道郎 + 中村 隆(監
訳)(1992)『社会統計学』(学生版) ハーベスト社。

森 敏明 + 吉田 寿夫 (1990)『心理学のためのデータ解析テク
ニカルブック』北大路書房。

6

【課題】

5つ以上の変数を使って pairwise, listwise の
相関係数行列をそれぞれ出力し、整形して
印刷して提出

提出先：日本語教育学研究室の田中のレター
ケース

7

表1 順位相関係数行列 (listwise)

	変数名 1	変数名 2	変数名 3	変数名 4	変数名 5	変数名 6	変数名 7
変数名 2	.133						
変数名 3	.203*	.200*					
変数名 4	.054	.102	.076				
変数名 5	.134	.186	.015	.032			
変数名 6	.110	.261*	-.002	.099	.319*		
変数名 7	.195*	.132	-.124	.016	.185	-.165	
変数名 8	.132	.205*	-.012	-.233*	-.022	.057	.084

Spearman の順位相関係数. *: $p < 0.05$. N=105.

表2 順位相関係数行列 (pairwise)

	変数名 1	変数名 2	変数名 3	変数名 4	変数名 5	変数名 6	変数名 7
変数名 2	.133 (110)						
変数名 3	.203* (119)	.200* (111)					
変数名 4	.054 (120)	.102 (110)	.076 (116)				
変数名 5	.134 (110)	.186 (112)	.015 (113)	.032 (112)			
変数名 6	.110 (112)	.261* (118)	-.002 (118)	.099 (111)	.319* (115)		
変数名 7	.195* (110)	.132 (118)	-.124 (118)	.016 (116)	.185 (110)	-.165 (115)	
変数名 8	.132 (110)	.205* (114)	-.012 (118)	-.233* (110)	-.022 (112)	.057 (113)	.084 (115)

Spearman の順位相関係数. *: $p < 0.05$. ()内は人数

小数点をそろえるのが大変。
「書式」→「セル」で表示形式を「文字列」にしておいて、「配置」とスペースで微調整する。

1. 先週の内容への補足
2. 結果の書きかた

1

【先週の内容への補足】

方向性の一致度

→一定の率（たとえば80%）よりも
偏っているかどうかの問題。

→測定値がこの率を下回っている場合には、
検定する意味はない。

2

2項検定では、「分割点」以下の値を持つケースの比率と
「検定比率」とが比較される

→「分割点」以上の比率を検定するときは、
(1-基準値)を検定比率にする

3

$x=y$ ケースを分析からのぞくには、
「値の再割り当て」の際に

recode 変数名 (lowest thru -1=-1)
(0 = sysmis) (1 thru highest=1).

とする。

4

天井効果・床効果に注意
測定上の上限/下限に偏っている場合

5

【結果の書きかた】

クロス表（または散布図）が基本：
各セルには度数と **全体での%** を書く。

6

統計量などは表の下に：

対応のある t 検定 → 相関係数、平均値の差、
有意水準（対応のある検定であることを明記）

2項検定 → $x>y$ ケースと $x<y$ ケースの比率、
有意水準（基準比率と検定法を明記）。

$x=y$ ケースを除いた場合はその旨明記。
50%基準なら単に「符号検定」と書いてもよい。

7

圧縮した書きかた：

対応のある t 検定 → 各変数の平均・SD の表
表の下に、人数、相関係数、平均値の差、
有意水準（対応のある検定であることを明記）

2項検定 → $x>y$, $x=y$, $x<y$ 各ケースの比率の表
表の下に、有意水準（基準比率と検定法を明記）

8

多数の変数を総当りで比較する場合：

Hasse diagram (ハッセ図)

★ $x>y$ か $x<y$ か「どちらともいえない」か

★ 上下関係に従って並べ、順位付け可能な組を線で結ぶ

★ 上から下に向かって線をたどれば、

2変数間に順序付け可能である

何を基準としたのかを明記すること

9

表1 自分にとって大切なこと

	家族の信頼・尊敬を得ること (y)				合計
	1	2	3	4	
高い地位を得ること(x)					
1. そう思う	13 (5.4)	1 (0.4)	0 (0.0)	1 (0.4)	15 (6.3)
2. どちらかといえばそう思う	35 (14.6)	12 (5.0)	2 (0.8)	0 (0.0)	49 (20.5)
3. どちらかといえばそう思わない	79 (33.1)	37 (15.5)	9 (3.8)	0 (0.0)	125 (52.3)
4. そう思わない	32 (13.4)	15 (6.3)	3 (1.3)	0 (0.0)	50 (20.9)
合計	159 (66.5)	65 (27.2)	14 (5.9)	1 (0.4)	239 (100.0)

度数 (全体%) を示す。

平均値の差=1.48 (x=2.88, y=1.40), p<0.01 (対応のある t 検定による)。r=0.073。 対応のあるt検定の場合

x>yケース84.1%, x<yケース1.7%, 2項検定の場合

x>yケース84.1%, x<yケース1.7%, p<0.01 (80%を基準とする2項検定、x=yケースを除く)。 2項検定 (x=yケース除く) の場合

x>yケース84.1%, x<yケース1.7%, p<0.01 (符号検定)。 2項検定 (x=yケース除く、基準=50%) の場合

表2 自分にとって大切なこと

	平均	SD
高い地位を得ること	2.88	0.81
家族の信頼・尊敬を得ること	1.40	0.62

平均値の差=1.48, p<0.01 (対応のある t 検定による)。r=0.073。 N=239。

表3 自分にとって大切なこと

	N	(%)
x>y	201	(84.1)
x=y	34	(13.6)
x<y	4	(1.7)
合計	239	(100.0)

x: 高い地位を得ること, y: 家族の信頼・尊敬を得ること。
p>0.05 (x>yケース80%を基準とする2項検定)。

1. 多変量解析
2. 類似度行列の並べ替え
3. クラスタ分析の一般的手続き
4. グループ間平均連結法
5. デンドログラム

1

【多変量解析】

3つ以上の変数を同時にあつかう分析

- **因果分析型** (回帰分析/分散分析)
因果関係を設定する…独立変数と従属変数
(グループ別分析を洗練させたもの)
→事前に統制できない変数の影響を事後的に排除
→交互作用効果

2

● 類似関係型

- 「似ている」変数を見つける (全変数が同レベル)
- ・ 因子分析 (EFA/CFA)
 - ・ 多次元尺度構成法 (MDS)
 - ・ 林の数量化 (I~IV)
 - ・ クラスタ分析

3

【類似度行列と距離行列】

相関係数 = 変数間の類似度を表す

- ・ その他、いろいろな類似度の係数がある

距離 = 変数間の**非**類似度

4

【クラスター分析の手続き】

- ・ データの準備 ・ 標準化
- 類似度 (距離) 行列を作成
- 類似した変数同士を順次クラスター化する
- 樹状図 (デンドログラム) を描く
- ・ クラスター化による「ゆがみ」の評価

5

【グループ間平均連結法】

UPGMA

- ・ いちばん「近い」変数同士を連結する
- ・ 連結してできた「クラスター」について
2変数の平均を代入して類似度を再計算

このステップを繰り返して行って、最終的に全変数が1クラスターになるまでつづける

6

【デンドログラム】

クラスター化の各ステップで、
どれだけの類似度のものを連結したか

- 変数を適当に並べ替えて
「デンドログラム」を書く

7

【SPSS コマンド】

「分類」 → 「階層クラスタ」

- ・ 「クラスタ対象」を「変数」に
- ・ 「統計」オプションで
「クラスタ凝集経過工程」「距離行列」をチェック
- ・ 「作図」オプションで「デンドログラム」チェック、
「つららプロット」を「なし」に
- ・ 「方法」オプションで「測定方法」を
「間隔」の「Pearson の相関」に

8

複数のコマンドが出力されるので注意

(類似度行列作成/クラスター分析/作業ファイル削除)

【参考文献】

- 古谷野 亘 (1988)『数学の苦手な人のための多変量解析ガイド』川島書店。
大野 高裕 (1998)『多変量解析入門』同友館。
三土 修平 (2001)『数学の要らない因子分析入門』日本評論社。
Romesburg, H. C. (1992)『実例クラスター分析』内田老鶴圃。

9

相関係数行列

	評価高い職業	高い収入	高い学歴	家族の信頼尊敬	volunteer、町内会活動	趣味サークル	多くの財産
評価高い職業							
高い収入	0.429						
高い学歴	0.524	0.426					
家族の信頼尊敬	0.209	0.174	0.144				
volunteer、町内会活動	0.202	0.172	0.238	0.424			
趣味サークル	0.190	0.130	0.213	0.146	0.413		
多くの財産	0.367	0.470	0.394	0.089	0.183	0.357	
高い地位	0.554	0.383	0.518	0.074	0.124	0.311	0.525

	評価高い職業	高い地位	高い学歴	高い収入	多くの財産	家族の信頼尊敬	volunteer、町内会活動
評価高い職業							
高い地位	0.554						
高い学歴	0.524	0.518					
高い収入	0.429	0.383	0.426				
多くの財産	0.367	0.525	0.394	0.470			
家族の信頼尊敬	0.209	0.074	0.144	0.174	0.089		
volunteer、町内会活動	0.202	0.124	0.238	0.172	0.183	0.424	
趣味サークル	0.190	0.311	0.213	0.130	0.357	0.146	0.413

1. クラスター分析の選択肢
2. 類似度と距離のいろいろ
3. クラスター化の方法

1

【クラスター分析の選択肢】

- 類似度 (距離) の選択
- 標準化・係数の変換
- クラスター化の方法

2

【SPSS コマンド】

「方法」オプション

- クラスター化の方法
- 測定方法 ……変数の種類と類似度 (距離)
- 値の変換
- 測定方法の変換

3

【類似度 (距離) のいろいろ】

間隔尺度の場合

- Pearson の相関 (説明省略)
 - ・ もともと標準化された係数 (単位に無関係)
 - ・ 絶対値変換をするか?
- ユークリッド距離 ……多次元空間上の「距離」
 - ・ 変数の単位に依存する
 - ・ あらかじめ標準化しておくか?
 - ・ 「係数の絶対値をとる」ことはできない

4

2 値変数の場合

- ϕ 係数
- 単純マッチング
- Jaccard の類似性係数

その他

5

順序尺度の場合

- 順位相関係数を使う (SPSS 対象外)

名義尺度の場合

- ダミー変数に変換して 2 値変数として扱う

6

【クラスター化の方法】

- グループ間平均連結法
- 最近隣法
- 最遠隣法
- Ward 法

7

【選択肢の選択基準】

- 理論的根拠
- 先行研究との比較
- 複数の方法を試してみること (結果の頑健性)

8

【期末レポート】

期限：2月4日(火) 17:00

提出先：田中研究室または 205 レターケース

課題：(1) 相関係数、(2) 対応のある分析、(3) クラスター分析をそれぞれおこない、結果の表(読みやすく整形したもの)と結果に対する解釈を書く。(1)と(2)は推測統計的分析を含んでいなければならない。分析は、同じ変数を使用した一続きのものでもよいし、それぞれ独立したものでもよい。

追記：レポート提出時にSSMデータのディスクを返却すること。手元のコピーもすべて消去すること。

9

