

## 現代日本論演習

3年生対象: 2008年度前期 (5セメスター: 授業コード=L52505)  
<火4>コンピュータ実習室 (文学部本館 7F 711-2)

### 『講義概要』 p. 165 記載内容

◆授業内容: 意識調査・テスト・実験などのデータはどのように分析すればいいでしょうか。この授業では、小規模の標本調査を念頭において、統計分析の基礎的な手法を学びます。これまで統計的な分析をおこなったことのない人を対象に、初歩から講義します。同時に、コンピュータを実際に使って、毎回データ分析の実習をおこないます。  
◇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。  
◇テキスト: 吉田寿夫 (1998) 『本当にわかりやすいごく大切なことが書いてあるごく初歩の統計の本』北大路書房。

卒業論文等で質問紙調査を予定している者は、「現代日本論演習: 質問紙法の基礎を学ぶ」(水2: 鈴木教授) および 6セメスタ開講の「現代日本論演習: 応用統計分析」(火4: 田中) も受講することがのぞましい。

### 授業の概要

#### 目次

1. インTRODakション (4/15)
2. SPSS 入門 (4/22)
3. 統計分析の基礎 (5/13)
4. 記述統計(1): 度数分布とクロス表 (5/20~6/3)
5. 中間試験 (6/10)
6. 記述統計(2): 平均値の比較 (6/17~7/1)
7. 推測統計 (7/8~7/22)
8. 期末レポート (8月中旬提出)

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

#### 1. インTRODakション

- この授業の概要・スケジュール・評価方法
- 部屋とコンピュータの使いかた
- SPSS の起動
- データ行列 (データセット)
- 模擬データ入力実習

#### 2. データ配布・SPSS 入門

- データの配布
- SPSS の概要
- SPSS コマンド・シンタックス
- メニューによるシンタックス作成
- 変数値の再割り当て
- 他のソフトウェアについて
- 印刷

#### 3. 統計分析の基礎

- 実験と観察
- データの記述
- データの種類

#### 4. 記述統計 (1): 度数分布とクロス表

##### 4.1. 度数分布表

- frequencies コマンド
- 相対度数 (パーセンテージ)
- 棒グラフ・ヒストグラム・度数ポリゴン
- Excel で整形, グラフ作成

##### 4.2. クロス表

- 度数分布表のグループ化
- クロス表表記
- 行と列の%
- 周辺度数 (marginal distribution)
- crosstabs コマンドとそのオプション

##### 4.3. 無関連状態と期待度数

- $\Phi$  係数
- 期待度数・残差・連関係数
- クロス表とグラフの書きかた

#### 5. 中間試験

#### 6. 記述統計 (2): 平均値の比較

##### 6.1. 平均と分散

- データの種類: 復習
- 順序尺度と間隔尺度の変換
- 平均値
- 分散と標準偏差
- 分布と外れ値

##### 6.2. 平均値の層別比較

- 層別平均
- エフェクト・サイズ
- 相関比から分散分析へ
- 表とグラフの書きかた

#### 7. 推測統計

##### 7.1. 誤差の評価

- データの記述と誤差の評価
- 標本抽出の4段階モデル
- 無作為抽出
- 非標本誤差
- 標本誤差の統計的推測

##### 7.2. 平均値の推定

- 平均値の点推定
- 区間推定と t 分布
- 平均値の差の区間推定
- エフェクトサイズ・相関比と区間推定

##### 7.3. 統計的検定

- 区間推定の簡易表記としての有意水準
- 平均値の差の t 検定
- 連関係数の  $\chi^2$  検定
- 分散分析と F 検定
- 検定結果の表記

#### 8. 期末レポート

2008.4.15

## 現代日本論演習

統計分析の基礎

東北大学文学部 2008 年度  
田中 重人 (講師)

1

### 【目的】

統計分析の基礎的な手法の習得

- SPSS の操作
- クロス表分析
- 平均値の比較
- 推測統計の手法

2

### 【教科書】

吉田 寿夫 (1998)

『本当にわかりやすいすぐく大切なことが  
書いてあるごく初歩の統計の本』  
北大路書房。

3

### 【成績評価】

- ・ 授業中の課題 (50%)
- ・ 中間試験 (20%)
- ・ 期末レポート (30%)

4

### 【関連する授業】

#### 5 セメスタ

・ 現代日本論演習「質問紙法の基礎を学ぶ」  
(水 2) …鈴木教授

#### 6 セメスタ

・ 現代日本論演習「実践的統計分析法」  
(火 4) …田中

5

受講登録フォーム記入

6

### 【コンピュータ実習室について】

- ★ 入室に**学生証**が必要
- ★ 土足・飲食・喫煙 **厳禁**
- ★ 退出時は必要事項を紙に書く  
(書けるところを書いてみよう)
- ★ ドアの開けかた

7

### 【コンピュータの起動と終了】

- ・ 本体とディスプレイの電源を ON
- ・ 表示されるお知らせの内容をよく読む
- ・ 終了するときは、ディスプレイの電源を切ることをわすれないように

8

### 【ファイルの保存場所】

授業でつかうファイルは、  
授業開始時に マイドキュメント  
フォルダにコピーして使う。  
授業終了時に削除してかえること。

★ 内蔵 Disk にデータは置けない

9

必要なデータは各自で  
フロッピーかスティックメモリ  
にコピーして持ち帰る

→ 各自で購入しておくこと。

10

### 【SPSS】

データ解析用ソフトウェア

- ★ Windows での開発に  
特に力を入れている
- ★ 購入しやすい

11

### 【この授業で使用するデータ】

1995 年 SSM 調査 B 票の一部

cf. 『日本の階層システム』(全 6 巻)  
東京大学出版会、2000 年。

SSM 調査については <http://www.sai.tohoku.ac.jp/coe/ssm/> 参照

12

## 受講者の興味と数学的知識の調査

→別紙

## コンピュータ実習室について

### 入室・退室

学生証が必要 (ない人は、教務係で臨時カードを借りること)。

土足・飲食・喫煙厳禁。

退出時には必要事項を紙に記入。

### コンピュータの起動と終了

使いはじめるときは……

- コンピュータ本体の電源を入れる
- ディスプレイの電源を入れる (2-3秒押しつづけないと入らないので注意)
- 表示されるお知らせをひととおりよむこと
- キーボード右上の「NumLock」ランプがついているか確認

使い終わるときは……

- 「マイドキュメント」などに保存してある自分のファイルを削除
- 画面左下の「スタートメニュー」から「終了オプション」→「電源を切る」を選択
- コンピュータ本体の電源が切れたことを確認
- ディスプレイの電源を切る
- フロッピーディスク、USBスティック・メモリなどをわすれないこと

### ファイルの保存場所について

教室のコンピュータの内蔵ディスクには、個人のファイルを置いてはならない。授業中に必要なファイルは「マイドキュメント」フォルダに一時的に保存してよいが、授業が終わったら自分のフロッピーかスティック・メモリ等にコピーして、内蔵ディスクのほうのファイルは削除すること。

コンピュータ実習室で使えるリムーバブルメディアはつぎのふたつ。各自どちらかを購入しておくこと。

- フロッピーディスク (3.5インチ) ……「Windows フォーマット」のものが便利。安いがよく故障する。容量が小さい。
- フラッシュメモリ ……「USB2.0対応」のもの。値段は高いが容量が大きい。とりはずすときは画面右下の「ハードウェアの安全な取り外し」アイコンをクリックして、「USB大容量記憶装置」を停止させてから、メモリ本体を引き抜く。

## 模擬データ入力実習

### SPSS について

参考書: 宮脇典彦・和田悟・阪井和男 (2000)『SPSSによるデータ解析の基礎』培風館。

### SPSS の起動

スタートメニューから「プログラム」→「SPSS for Windows」→「SPSS for Windows 12.0J」で起動する。(※ここで何かエラーメッセージが出るかもしれないが、気にせず「続行」または「OK」する。)

「どのような作業を行いますか?」ときかかれたら「データを入力」をチェックして「OK」。

### データ入力

配布した架空の回答票をもとに、データを入力してみよう。

まず変数を定義

- 「データエディタ」ウインドウのいちばん下の「変数ビュー」タブに切り替える
- 変数名を必要だけつくる。今回は a, b, ..., e とでもしておこう。変数名は自分がわかればどんなものでもよい。日本語も使える。なお、変数名以外のフィールドは入力しなくてよい
- 書き終わったら「データビュー」タブに切り替えて、いちばん上の行に変数名がならんでいることを確認する。

つづいてデータを入力していく。今回は3人分のデータを用意してあって、変数は5個なので、3×5の行列型のデータができるはずである。

適当な名前で「マイドキュメント」内に保存してみる。(ほかのフォルダに保存してはならない。)

「マイドキュメント」を開いて、SPSS データファイル (なんとか.sav) ができていることをたしかめる。

このデータファイルは授業終了時に削除すること。(次回以降の授業ではつかわないので、コピーしておく必要はない。)

※ この方式はSPSSでデータを入力するときのいちばん簡単な方法であるが、大きなデータはあつかいにくいので、テキストファイルでデータを用意しておくのがふつうである。

2008.4.15

## 現代日本論演習 (田中重人)

### 受講登録フォーム

氏名：

学年：

学生番号：

所属 (文学部日本語教育学専修以外の場合)：

研究内容：

- ・ 自宅でパソコンを使えますか?                    **ある / ない**
- ・ SPSS を使った経験がありますか?                **ある / ない**
- ・ コンピュータ・プログラムを作成したり、プログラミングの授業を受けたりしたことがありますか?                    **ある / ない**  
    **ある場合**    **言語名 (                    )**

### 数学的予備知識の調査 (成績評価には関係ありません)

(1) 「乱数」とは何か。簡単に説明せよ。

(2) 「必要十分条件」とは何か。簡単に説明せよ。

(3) 「偏差値」はどのような目的のために使われるか。またどうやって求めるか。簡単に説明せよ

(4) つぎの数式の値を求めよ。計算のプロセスがわかるように解答すること

$$\sum_{k=1}^{10} k =$$

1. データの配布
2. 標本抽出
3. SPSS のウィンドウ構成
4. 変数値の再割り当て
5. 出力の読みかた・印刷

1

## 【データの配布】

### 1995 年 SSM 調査 B 票の一部

- ★ 全国から 70 歳以下の有権者を  
層化 2 段無作為抽出
  - ★ 訪問面接法
- cf. (2000)『日本の階層システム』(全 6 巻)  
東京大学出版会。

2

- ★ 意識項目と基本的属性に限定  
(調査票の×印はデータセットにない項目)
- ★ 250 ケースをランダムに抽出
- ★ 流出しないように
- ★ 変数ラベルは菅野剛  
(日本大学) 氏による

3

- ★ 毎回の授業で使うので、  
忘れないこと (調査票も)
- ★ 期末レポート提出時に返却

4

## 【標本抽出の 4 段階モデル】

ユニバース (universe)

母集団 (population)

計画標本 (designed sample)

有効標本 (valid sample / case)

5

- ★ 伝統的な統計学では 4 段階に  
わけずに、2 段階で考えるのが  
ふつう：

母集団 = universe + population

標本 = (designed/valid) sample

6

## 【無作為抽出】

母集団から計画標本を選ぶ際に、  
母集団にふくまれる すべての個体  
の抽出確率が等しくなるように  
抽出する (random sampling)

➡ 「等確率標本」

7

つぎの条件が必要：

- ★ 母集団の人口が既知
- ★ 個体を網羅した「台帳」

※ 個体によって抽出確率が違う場合も、事後的に調整して  
等確率標本と同様の統計処理をおこなうことは可能

※ 「台帳」が完備していない状況でも、工夫次第で  
無作為抽出に近づけることができる

8

統計的な推測は、**等確率標本を前提とする**

実際の調査で理想的な標本抽出ができることはまずない。  
また計画標本のなかから無効回答があるので、  
無作為ではない誤差がかならず発生する。  
この誤差は 統計的には処理できないので、個別に推測する

- ・ どの層を過剰に代表しているかを把握する
- ・ おなじ母集団を対象にした調査と比較する

9

## 【宿題】

論文や新聞・雑誌記事で使われている調査データについて、  
標本抽出の4段階にそって紹介する。  
人数分コピーを用意してきて、次回授業時に報告。

10

## 【層化2段無作為抽出】

- ・まず「**地点**」を抽出 (第1次抽出)
- ・その際、**地域・都市規模**等で地点抽出数を割り当てておく (**層化**)
- ・その地点の台帳から**個人**を抽出 (第2次抽出)

11

## 【データ・セット】

- ★ ケース × 変数
- ★ 変数は変数名で管理
- ★ 変数名以外に「ラベル」
- ★ 無回答などの欠損値 (.)

12

## 【SPSSのウィンドウ構成】

- データ・エディタ
- シンタックス・エディタ
- 出力ビューア

13

## 【メニューとシンタックス】

- ★ 分析手法をえらぶ
- ★ 必要なオプションを指定
- ★ 「**貼り付け**」をクリック
- ★ シンタックスの必要部分を選択して実行 (▶)

14

## 【出力ビューア】

- ★ 左側に目次、右側に出力内容
- ★ エラー表示もここに出る

## 【印刷】

- ★ 左側の目次で選択
- ★ 電源の入れかた
- ★ 出力先の切り替え
- ★ ジョブの確認・取り消し
- ★ 印刷前にプレビュー
- ★ タイル印刷 (2面, 4面, ...)

15

## 【変数値の再割り当て】

- データエディタのメニューバーで
- 「変換」→「値の再割り当て」→「他の変数へ」
  - 変換先変数の名前をつける

16

- 「今までの値と新しい値」
- 値の組を指定したら「続行」
- シンタックスを貼付けて実行
- 新変数の度数分布を確認
- 問題がなければデータセットを保存

17

## 【実習】

満年齢 (Q1\_2a)を10才刻みに区切って  
度数分布表を出力し、印刷して提出

## 【その他のアプリケーション】

- 文書作成 (Word)
- 表計算 (Excel)
- 電卓 (アクセサリ)

18

1. データ収集から分析まで
2. 度数分布表

1

### 【データ収集から分析まで】

データの収集 (実験 / 観察)  
分析可能な形に加工  
・ 分析の単位  
・ 変数の同定  
・ 尺度水準  
データ・セット作成

2

データの特徴を少数の数値に要約  
= 記述統計

誤差の評価

(この手続きの一部が推測統計)

(教科書 p. 1-6)

3

### 【尺度水準】

比率尺度 (ratio scale)  
間隔尺度 (interval —)  
順序尺度 (ordinal —)  
名義尺度 (nominal —)  
(質的変数とも)

(教科書 p. 8)

4

### 【尺度の変換】

上位の尺度のほうが  
あつかえる演算が豊富  
上位の尺度は下位の尺度の特  
徴を兼ね備えている

分析手法の選択幅がひろい

5

私たちが測定するものはい  
順序尺度以下である

上位の尺度への変換には  
一定の理論的根拠が必要

6

### 【実習】

SSM 調査の調査票中で、比率尺度  
とみなせるものはどれか

7

### 【度数分布表】

Frequencies コマンドを使う  
度数  
相対度数 (%)  
累積度数・累積相対度数  
欠損値のあつかい

(教科書 p. 27-31)

8

### 【累積%とパーセンタイル】

順序尺度以上の場合のみ意味を持つ

Percentile(= %点)

中央値 (median) = 50%点

「割り切れてしまう」場合は中点をとる

(教科書 p. 43)

同じ値が並ぶ場合は多少の操作が必要

(森敏昭・吉田寿夫(編)(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. p. 15)

9



1. グラフの利用
2. 棒グラフとヒストグラム

1

### 【グラフの利用】

表 (table).....正確な数値がわかるが、全体の傾向を読み取るには熟練が必要

グラフ (graph/chart).....全体の傾向が簡単に読み取れるが、正確さは犠牲になる

初心のうち、表とグラフの両方を作成して読んでいくのがよい

2

### 【棒グラフとヒストグラム】

棒グラフ.....棒同士の間空白をあける。高さ(長さ)をよむ。  
histogram (柱グラフ).....柱の間隔をあけない。面積をよむ。

縦軸は度数または%

3


連続量を階級分けした場合  
ヒストグラム

それ以外の場合 (離散量 /  
名義尺度) 棒グラフ

度数多角形 (polygon) は複数の変数の分布を比較するとき便利。

(教科書 p. 32-36)

4



SPSS では histogram が書きにくい。

recode で整形した上で度数分布表のメニューで「図表...」指定。棒グラフを書く  
グラフ インタラクティブ ヒストグラム  
では等間隔の区間に分割してくれる

5

Excel を使う場合：

recode で整形した上で度数分布表を出力  
表を Excel にコピーする

棒グラフを作成

グラフの棒の上で左クリック

「データ系列の書式設定」

「オプション」

「棒の間隔」を0にする

6

### 【実習】

- (1) 本人年収 (Q44\_1)を 5~7 程度の適切な間隔に区切って度数分布表を出力
- (2) 年齢の度数分布表を出力し、中央値と 80% 点に印をつけよ

7

- (3) 適当な変数について棒グラフ  
またはヒストグラムを作成

8



### 【キーワード】

行 (row) 列 (column) セル (cell)

周辺度数 (marginal frequency)

行% (row percent) 列% (column percent)

1

### 【度数分布表の比較】

データエディタのメニューで  
「データ」「ファイルの分割」  
「グループの比較」

度数分布表を出力

2

「データ」「ファイルの分割」  
「すべてのケースを分析」  
でもとにもどしておく

3

### 【クロス表の基本型】

質的変数 (名義尺度) 同士の関連  
についての基本的な分析法

	1	2	3	合計
行 1	a	b	c	a+b+c
2	d	e	f	d+e+f
3	g	h	i	g+h+i
合計	a+d+g	b+e+h	c+f+i	N

列

周辺度数

4

5

### 【Crosstabs コマンド】

性別 × 「性別による不公平」  
のクロス表を書いてみよう

「分析」「記述統計」「クロス集計表」

6

### 【行%と列%】

「クロス集計表」メニューで「セル」にパー  
センテージ (行・列) を追加

行%, 列%のつかいわけは

説明 被説明の関係に対応

行 列の説明をすることが多い

周辺度数の%とも比較する

7

### 【グラフを書いてみる】

クロス表は帯 (積み上げ棒)

グラフで表現することが多い

SPSS ではうまくかけない。コピーして  
Excel に貼付けてグラフを書くのがよい

度数にも注意

8

### 【課題】

性別 × 適当な変数で

クロス表作成、%からわかること  
をコメントする。

グラフも書いて印刷して提出

9

【キーワード】

連関 (association), 独立 (independence),  
期待度数 (expected frequency),  $\phi$  係数,  
クラメールの連関係数 (Cramer's V)

1

【2×2クロス表の性質】

以下、つぎの記号法を使う

	$\beta$		
$\alpha$	1	2	合計
1	$a$	$c$	$g$
2	$b$	$d$	$h$
合計	$i$	$j$	$N$

2

(1) 行%は1列について比較すればよい:

$$\frac{a}{g} - \frac{b}{h} = \frac{d}{h} - \frac{c}{g}$$

(2) 行%の差がゼロなら列%の差もゼロ

(3) 行%の差が100なら列%の差も100

(4)  $g=i$  or  $g=h$  なら行%差と列%差は同じ:

$$\frac{a}{g} - \frac{b}{h} = \frac{a}{i} - \frac{c}{j}$$

3

(5) これら以外の場合、行%の差と列%の差はちがう値になる

4

(例1) 行%の差 = 8%

60%	40%	100%
52%	48%	100%

(例2) 行・列とも%に差なし (例3) 行・列とも10%の差

52	48	100	70	30	100
52.0%	48.0%	100.0%	70.0%	30.0%	100.0%
66.7%	66.7%		70.0%	60.0%	
26	24	50	30	20	50
52.0%	48.0%	100.0%	60.0%	40.0%	100.0%
33.3%	33.3%		30.0%	40.0%	
78	72	150	100	50	150
52.0%	48.0%	100.0%	52.0%	48.0%	100.0%

5

【 $\phi$ 係数】

2×2クロス表の「連関」の尺度

$$\phi = \frac{ad - bc}{\sqrt{ghij}}$$

この係数の意味は?

(分子だけ取り出して考えてみよう)

6

【 $\phi$ 係数の性質】

- $\phi$  = 交差積の差 /  $\sqrt{(\text{周辺度数の積})}$
- $\phi$  = 相関係数の特殊ケース
- $|\phi|$  = 行%差と列%差の中間の値
- $\phi^2$  = 標準残差の2乗の総計 /  $N$   
( $\rightarrow$  2×2以上のクロス表に拡張できる)

7

【期待度数と $\phi$ 係数】

※記号法は前回と同じ

独立 (無関連):  $a/b = c/d$

期待度数 (expected frequency)

周辺度数を固定しておいて独立なクロス表を作ったとき、各セルに入る度数:

$$\frac{gi/N}{hi/N} \quad \frac{gj/N}{hj/N}$$

8

各セルの期待度数は?

		100	100.0%
		50	100.0%
78	72	150	
52.0%	48.0%	100.0%	

9

- ★ 期待度数はたいてい小数になる
- ★ 期待度数について行%と列%を計算すると、周辺度数の%とおなじになる

観測度数 各セルに入る実際の度数  
残差 (residual) 観測度数と期待度数の差  
標準残差 (standardized ---) 残差/ $\sqrt{\text{期待度数}}$

ex.  $A = \frac{a - gi/N}{\sqrt{gi/N}}$

10

観測度数が下記の場合、  
各セルの残差と標準残差は?

40	60	100	100.0%
38	12	50	100.0%
78	72	150	
52.0%	48.0%	100.0%	

11

$\chi^2$  (chi-square) 標準残差の平方和  
各セルに入る標準残差を  $A, B, C, D$  とする

$$\chi^2 = A^2 + B^2 + C^2 + D^2 = N \left( \frac{a^2}{gi} + \frac{b^2}{hi} + \frac{c^2}{gj} + \frac{d^2}{hj} - 1 \right)$$

$\chi^2$  を人数で割った値が  $\phi$  の2乗に等しい

$$\phi^2 = \frac{\chi^2}{N} \quad \text{すなわち} \quad |\phi| = \sqrt{\frac{\chi^2}{N}}$$

12

【クラメールの連関係数  $V$ 】

- $k \times l$  表への  $\phi$  係数の拡張 (教科書 p.114-117)
- ★  $k$  と  $l$  のうち小さいほうを  $m$  とする
  - ★  $2 \times 2$  表と同様に期待度数・残差を求める
  - ★  $\chi^2$  を求める
  - ★  $\chi^2$  を  $N$  と  $(m-1)$  で割って平方根をとる

$$V = \sqrt{\frac{\chi^2}{N(m-1)}}$$

13

【 $V$ の性質】

- ★ 行・列変数が独立のとき  $V = 0$
- ★ 関連が強くなると大きくなる
- ★ 最大値は 1

14

【SPSSで実習】

- クロス表のオプションを指定:
- 「セル」… 度数(観測/期待)  
残差(標準化なし/標準化)
  - 「統計」… カイ2乗  
ファイと Cramer の  $V$

15

【予告】

- 来週 (7/1) は中間試験
- ・ 何でも持ち込み可
  - ・ 出題範囲は、今回授業まで

16

第10回「平均値と標準偏差」

1. 尺度水準と分析法
2. 代表値と散布度
3. 平均値と標準偏差
4. SPSSのコマンド
5. 平均値の層別比較
6. エフェクト・サイズ

1

【尺度水準と分析法】

名義×名義 → クロス表

名義×間隔 → 平均値の比較

2

【代表値と散布度】

★ 中央値 (median) — 四分位偏差 (Q)  
(順序尺度以上)

★ 平均値 (mean) — 標準偏差 (SD)  
(間隔尺度以上)

(教科書 p.42-51)

3

【平均値】

総和をデータ数で割ったもの

【標準偏差】

平均値からの偏差の2乗値の平均が「分散」  
分散の平方根が「標準偏差」

★ 平均値と標準偏差はセットで使う

4

★ 次のデータの平均と SD は?

{0, 1, 4, 5, 7}

5

値	偏差	偏差 <sup>2</sup>
0		
1		
4		
5		
7		

平方和=

分散=

SD =

6

【SPSSのコマンド】

「記述統計」 → 「度数分布表」

→ 「統計」 オプションで

「平均値」と「標準偏差」をチェック  
「記述統計」 → 「記述統計」でもよい

7

【平均値の層別比較】

ふたつの層の間の平均値の比較

★ 平均値の差をもとめる  
(層別平均)

★ 標準偏差を基準にして差を評価  
(effect size)

8

【SPSSのコマンド】

「平均の比較」 → 「グループの平均」

従属変数=平均値を求める変数  
(間隔尺度)

独立変数=層を指定する変数  
(名義尺度)

9

【エフェクト・サイズ】

ES = 平均値の差 / 標準偏差

★ 正式には層別 SD の重みつき平均のような  
数値 (併合 SD) をつかう (教科書 p.137)

10

【例】

性別による生活全般満足度の違い


	平均	SD	(人数)
男性	2.62	1.02	(114)
女性	2.24	0.91	(136)
合計	2.41	0.98	(250)

平均の差=0.39 併合 SD=0.97  
ES=0.401

※ ES は SPSS では計算してくれない

11

性別による生活満足度の違い



12

【ESの特徴と問題点】

- ★ 各層の人数を考慮せず平均値だけ比較  
→ 大きさがちがう場合は?
- ★ 2層間の比較だけ  
→ 3つ以上の層を比較したい場合は?

13

【注意事項】

層別の平均値を分析する場合、  
各層の人数は一定以上必要

(最低 20 人?)

→ カテゴリ統合が必要になることがある

14

【期末レポート】

期限: 8/12 (火) 17:00

提出先: 日本語教育学研究室 (文法合同棟 2F)  
205 室の田中のレターケース

内容: クロス表・平均値の比較の両方を使い、適当な分析をして結果を解釈する。図表は読みやすく整形し、論文としての体裁を整えること。

備考: 後期の授業を受講しない者は、SSM データのディスクをレポートと一緒に提出。データのコピーをすべて消去すること。

15

第 11 回「分散分析」

1. 相関比
2. SPSS のコマンド
3. 分散分析 (ANOVA)
4. エフェクト・サイズとの関係

1

【相関比】

- ★ 各層の個体が全員その層の平均値を持つ状況を仮定して SD を求める
- ★ この仮想 SD を実際の SD で割った数値が「相関比」。 $\eta$  (イータ) であらわす
- ★ 相関比の 2 乗  $\eta^2$  を「決定係数」「分散説明率」などという  
※  $\eta^2$  を「相関比」ということもある

2

- ★ SPSS では「オプション」の「第 1 層の統計」で「分散分析表とイータ」をチェック
- ★  $\eta$  は 0~1 の範囲の値をとり、**独立変数の影響力**をあらわす

※ ES は最小値 0、最大値  $\infty$

3

- ★ 3 層以上で平均値を比べる場合にも相関比が使える。
- ★ このように、層別平均値をあてはめて仮想分散を求める分析法を「**分散分析**」(ANOVA: ANalysis Of VAriance) という。

4

【ES と  $\eta$  の関係】

$$ES^2 = \frac{\eta^2}{1-\eta^2} \times \frac{N^2}{n_1 n_2}$$

特に、2 層の大きさが同じ ( $n_1 = n_2$ ) なら、

$$ES^2 = \frac{4\eta^2}{1-\eta^2}$$

層の大きさがちがえば、ES はこれより大きくなる

5

※ このように ES と  $\eta$  は互いに変換できる。

→ 両方示すのは冗長

6

【課題】

- (1) 適当な変数の平均値について、男女別の平均値の差と ES,  $\eta$  を求める (併合 SD のかわりに層別 SD の単純平均を使ってよい)。表に ES と  $\eta$  を書き込んで提出。
- (2) 平均と SD の表 (前回資料) から  $\eta$  を求める方法を考えて書いてくる。

7

第 12 回「区間推定」

- 1. 記述統計と推測統計
- 2. 標本誤差の推測
- 3. 区間推定

1

【記述統計と推測統計】

記述統計＝データ (ケース) の特徴を  
数値や図表にまとめる

推測統計＝確率的な誤差を考慮して、  
母集団の特徴を推測する

(教科書 pp. 3-5)

2

【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
- ★ 標本規模が大きいほど誤差範囲が小さい

➡ 「統計的推測」によって範囲を推定できる

3

【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、 $\frac{N-n}{(N-1)n} \approx \frac{1}{n}$  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

4

【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。
- ★ その外れ方は、母集団におけるばらつき  
が小さく、標本が大きいほど小さくなる
- ★ 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)

5

平均値の「95%信頼区間」のおおよその値：

$$m \pm 1.96 \times \frac{SD}{\sqrt{n}}$$

標本平均
↓
t 臨界値
標準誤差

※ t 臨界値は自由度 (n-1)によって変化するが、  
n>200 で 1.96 に収束する (教科書 p. 281)。

6

比率の区間推定:

$$m = \text{比率}, \quad SD = \sqrt{m(1-m)}$$

と置いて上と同様に計算できる

※ ただしあまり偏っていないことが必要:  
 $0.05 < m < 0.95$

7

【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

8

【課題】

- (1) 平均=0.4, SD=0.5, n=400 のとき 95%信頼区間を求めよ
- (2) 芸能人の血液型のデータ (教科書 p.267 練習問題 10-3  
⑥) について、B 型の比率の 95%信頼区間を求めよ
- (3) (2) の問題において、標本の人数が何人いれば、「芸能人の  
B 型比率は日本人全体の B 型比率より高い」といえる  
うか
- (4) 男女別平均値の 95%信頼区間が重なっていない変数を探し、  
SPSS 出力を印刷して提出

9

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

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いけない。  
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】

Statistical test

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

※ 統計的検定の論理は本当はもっと複雑である。

5

平均値の差の検定の場合：

「5%水準で有意」とは……  
→ 95%信頼区間が 0 をふくまない  
= 少なくとも 95%の確率で、  
母集団において平均値の差がある  
といえる

6

「5%水準で非有意」とは……

→ 95%信頼区間が 0 をふくむ  
= 母集団において平均値の差がない  
という確率が 5%以上ある

7

### 【有意確率とは】

信頼区間をひろげていくと、  
どこかでゼロをふくむようになる

→このときの危険率のことを「有意確率」  
(level of significance) という。

8

分析の際は、

- ・ 前もって危険率を設定しておく  
(通常は 5%または 1%)
- ・ 有意確率はその値を  
下回っているかどうか判断する

例:

有意確率が 0.007 → 1%水準で有意 (5%水準でも有意)  
有意確率が 0.023 → 1%水準で非有意 (5%水準では有意)  
有意確率が 0.088 → 1%水準で非有意 (5%水準でも非有意)

9

### 【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

10

★ 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。  
 $\eta$  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

11

★ 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

12