

クレジット:

UTokyo Online Education 統計データ解析 I 2017 小池祐太

ライセンス:

利用者は、本講義資料を、教育的な目的に限ってページ単位で利用することができます。特に記載のない限り、本講義資料はページ単位でクリエイティブ・コモンズ 表示-非営利-改変禁止 ライセンスの下に提供されています。

<http://creativecommons.org/licenses/by-nc-nd/4.0/>

本講義資料内には、東京大学が第三者より許諾を得て利用している画像等や、各種ライセンスによって提供されている画像等が含まれています。個々の画像等を本講義資料から切り離して利用することはできません。個々の画像等の利用については、それぞれの権利者の定めるところに従ってください。



統計データ解析 (I) 第 5 回

小池祐太

2017 年 10 月 25 日

① 基本的な描画 (続き)

- ヒストグラム
- 箱ひげ図
- 棒グラフ
- 円グラフ
- 散布図行列
- 3次元のグラフ
- プロット環境の設定

基本的な描画 (日本語を含む図の描画)

- OSによっては日本語を含む図を描画すると文字化けする場合があります
- その場合、関数 `par()` のオプション `family` に適当なフォントファミリーを指定することで文字化けを回避できる場合があります
- 例えば、Mac OS のデフォルトの設定では日本語を含む図は文字化けしてしまうが、以下のコマンドをコンソール上で実行することで文字化けを回避できる

```
par(family = "HiraginoSans-W4")
```

- ▶ フォントファミリーとしてヒラギノ角ゴシック W4 を指定している (数字を変えると太さが変わる)
- 実行例 `plot-kion.r`

図の保存

- 作成したグラフは保存することができる
- RStudio の機能を使う場合, 右下ペインの「Plots」タブの「Export」をクリックすると, 形式やサイズを指定して保存できる (もしくはクリップボードにコピーもできる)
- コマンドで実行することも可能であるが, それについての詳細は `help(png)` や `help(dev.copy)` を参照すること

ヒストグラム

● ヒストグラム

- ▶ データの値の範囲をいくつかの区間に分割し、各区間に含まれるデータの個数を棒グラフにしたもの
- ▶ 棒グラフの横幅が区間に対応し、面積が区間に含まれるデータの個数に比例するようにグラフを作成する
- ▶ データの分布の仕方 (どのあたりに値が集中しているか、どの程度値にばらつきがあるかなど) を可視化するのに有効

● ヒストグラムは関数 `hist()` で作成できる

ヒストグラム

● 基本書式

`hist(x, breaks, freq)`

- ▶ `x`: ヒストグラムを描画するベクトル
- ▶ `breaks`: 区間の分割の仕方を指定. 数字を指定するとデータ範囲をその数字に近い個数に等分割する. デフォルトの個数は Sturges の公式によって決定される. すなわち, データ数を n とすると, $\lceil \log_2 n + 1 \rceil$ である.¹ その他の指定方法もある (ヘルプ参照)
- ▶ `freq`: TRUE 指定すると縦軸をデータ数にし, FALSE 指定すると縦軸をデータ数/全データ数とする. デフォルトは TRUE (`breaks` の指定によって変わる場合あり)
- ▶ 他にも `plot` で指定できるオプションが利用可能

● 実行例 `hist3.r`

¹ $\lceil x \rceil$ は x 以下の最大の整数を表す.

ヒストグラム

演習 1

実行例 `hist3.r` で紹介した Weyl の一様分布定理において, 無理数 a を別の値に変更しても, x の分布の仕方は区間 $(0, 1)$ 上でほぼ均一となることを確かめよ (どの程度均一に近くなるかは a によって異なるため, いくつか確かめてみよ)

箱ひげ図

● 箱ひげ図

- ▶ データの中心, 散らばり具合および外れ値を考察するための図 (ヒストグラムの簡易版)
- ▶ 複数のデータの分布の比較の際に有効
- ▶ データの第1四分位点を下端, 第3四分位点を上端とする長方形 (箱) と, 第1四分位点, 第3四分位点からそれぞれ箱の長さの1.5倍以内にあるデータのうちの最小の値, 最大の値を下端, 上端とする直線 (ひげ) からなる
- ▶ ひげの外側のデータは点で表示される
- ▶ 中央値は太線で表示される

- 箱ひげ図は関数 `boxplot()` で描画できる

箱ひげ図

- ベクトル x に対する箱ひげ図は `boxplot(x, ...)` で描画できる (...に関数 `plot()` と同様のオプションを指定可能)
- データフレーム x に対して, `boxplot(x, ...)` は列ごとの箱ひげ図を描画
- データフレーム x において, 変数 A が「分類」を表す変数 (性別, 植物の種類など)² の場合, 別の変数 B に対して,

`boxplot(B ~ A, data = x, ...)`

は変数 B を変数 A で分類した場合の, 分類ごとの箱ひげ図を描画する

- 実行例 `boxplot3.r`

²質的変数と呼ばれる

箱ひげ図

演習 2

データセット `kikou2016.csv` において、気温以外の変数についても月ごとの箱ひげ図を作成せよ (グラフタイトル・色などのグラフィックパラメーターは適当に調節せよ)

棒グラフ

- 棒グラフは関数 `barplot()` で作成できる
- 基本書式

```
barplot(x, width = 1, space = NULL, legend.text = NULL,  
        beside = FALSE, args.legend = NULL)
```

- ▶ `x`: 棒グラフを作成するベクトル/行列 (データフレームは不可)
 - ▶ `width`: 棒の幅を指定するパラメーター
 - ▶ `space`: 棒グラフ間・変数間のスペースを指定
 - ▶ `legend.text`: 凡例を指定
 - ▶ `beside`: 変数が複数あるときに、棒グラフを縦に並べるか・横に並べるか
 - ▶ `args.legend`: 関数 `legend()` に渡す引数の指定
 - ▶ 他にも `plot` で指定できるオプションが利用可能
- 実行例 `barplot.r`

棒グラフ

演習 3

データセット `airquality` について、`Month`, `Day` 以外の変数の月ごとの平均の棒グラフを作成せよ

円グラフ

- 円グラフは関数 `pie()` で作成できる
- 基本書式

```
pie(x, clockwise = FALSE)
```

- ▶ `x`: 円グラフを作成するベクトル
 - ▶ `clockwise`: 時計回りに書くか否か
 - ▶他にも `plot` で指定できるオプションが利用可能
- 実行例 `pie.r`

散布図行列

- データフレーム x に対して `plot(x, ...)` もしくは `pairs(x, ...)` を実行すると、すべての列のペアに対する散布図を行列状に並べた図を作成する
 - ▶ 変数 A_1, \dots, A_k のみ考えたい場合、`plot(~ A1 + ... + Ak, data = x, ...)` もしくは `pairs(~ A1 + ... + Ak, data = x, ...)` を利用
- 実行例 `pairs.r`

3次元のグラフ

- 3次元のグラフを2次元に射影した俯瞰図は、関数 `persp()` を用いて描くことができる
- 基本書式

```
persp(x, y, z, theta = 0, phi = 15, expand = 1)
```

- ▶ `x, y, z`: `x, y, z` 座標
 - ★ `z` は点 $(x[i], y[j])$ に対応する値を (i, j) 成分とする行列で与える
 - ▶ `theta, phi`: グラフの角度を指定する極座標
 - ▶ `expand`: `z` 軸の拡大度を指定
 - ▶ 他にも `plot` で指定できるオプションが利用可能
- 実行例 `plot3d.r`

3次元のグラフ

- 様々な種類の3次元のグラフを描画するために多くのパッケージが開発されている
- そのうちの1つパッケージ `scatterplot3d` には、3次元の散布図を書くための関数 `scatterplot3d()` が用意されている
- 基本書式

```
scatterplot3d(x, color, angle=40)
```

- ▶ `x`: x, y, z 座標を指定するデータフレーム (関数 `persp()` のように直接指定することも可能)
 - ▶ `color`: 色を指定 (`col` ではない). デフォルトは黒
 - ▶ `angle`: x 軸と y 軸の間の角度
 - ▶ 他にも `plot` で指定できるオプションが利用可能
- 実行例 `plot3d.r`

プロット環境の設定

- プロットの際の線の種類や色, 点の形等のデフォルト値は関数 `par()` で設定できる
- 設定可能なグラフィックスパラメーターは `help(par)` で確認できる
- 特に, 以下の例のように, 関数 `par()` によってプロット環境の設定 (複数図の配置, 余白の設定) ができる
- 実行例 `par.r`

プロット環境の設定

- プロット環境は非常に細かく設定でき、またそれぞれの描画関数独自のパラメーターも存在するため、ここでは紹介しきれない。必要に応じてヘルプファイル、またはインターネット上の情報を参照すること