

URA, 知の創出センター連携企画 クワトロセミナー(第12回)
2016年5月11日(水)16:30 - 18:00
東北大学川内南キャンパス 文科系総合研究棟11階 大会議室



統計解析環境Rを用いたデータ解析

Statistical Computing and Data Analysis with R

医学系研究科循環器EBM 開発学寄付口座

宮田 敏

miyata@cardio.med.tohoku.ac.jp

Agenda:

1. 統計解析環境Rとは
2. Rを使うその前に　—データ解析はじめの一歩—
3. Rを使ったデータ解析の実際

1. 統計解析環境Rとは

統計解析環境Rとは、統計計算とグラフィックスのための言語・環境である。

- インターネット上で配布されるオープンソースのフリーウエア。プログラムの複製、改良、再頒布が可能。
- 多様な統計手法とグラフィックスを提供。柔軟な拡張が可能。
- 高い信頼性。（FDAへの申請にも利用可能）
- 日々拡張される新機能と、パッケージとして提供される最先端の統計手法。

1. 統計解析環境Rとは




The R project for Statistical Computing: Rの入手先

<https://www.r-project.org/>

Reference:

- R Tips: 舟尾暢男「The R Tips—データ解析環境Rの基本技・グラフィックス活用集」
<http://cse.naro.affrc.go.jp/takezawa/r-tips/r.html>
- RjpWiki: <http://www.okadajp.org/RWiki/>

Rは対話型環境からコマンドを入力して利用する。ある程度のプログラミングが必要。



1. 統計解析環境Rとは


Rはプログラミングを必要とすることが、普及の妨げとなつた。マウスを使ってRを使用できるGUI(graphical user interface)が提供されている。

R commander: RのGUIラッパー

<http://socserv.socsci.mcmaster.ca/jfox/Misc/Rcmdr/>
[http://www.ec.kansai-u.ac.jp/user/arikit/R.html](http://www.ec.kansai-u.ac.jp/user/arakit/R.html)

EZR (Easy R): 医学系に強い

<http://www.jichi.ac.jp/saitama-sct/SaitamaHP.files/statmed.html>



1. 統計解析環境Rとは

それでもやっぱり、**プログラミング**を頑張ろう!!

- プログラムは、解析の記録。
- 試行錯誤をシステム化。実際の解析では、同じこと何度も繰り返すことになる。
- Rでは、計算結果の出力を柔軟にデザインできる。
- 解析の、**実行**、記録、保存を**自動化**できる。

2. Rを使うその前に データ解析はじめの一歩

データの準備：元データの取り扱い

i. データの形は長方形

- 第一行目に変数名。全角文字は避ける方が無難。
- グラフ、解析結果などを張り付けない。別ファイルで保存。
- データの形は、長方形になるはず。

systemID	hospitalID	sex	age	height	bodyweight
4	1185645	1	64	173	75.4
11	3329388	1	69	164	72
12	4022624	1	78	155.2	47.2
14	4402536	1	83	159.1	60
22	4862866	2	73	147.6	40.5

データの準備：元データの取り扱い（続き）

ii. 元データは絶対に改変しない。

- 解析の過程で、変数を変換したり、新しい変数を定義することがある。
- 新しく作ったデータを、元データに上書きしない。
- データを改変したら、新しいファイル名で保存。
- 元データを改変すると、元データが何であるか分からなくなる。元データが分からなくなれば、意図せざるデータのねつ造まであと一步。

データの準備：元データの取り扱い（続き）

iii. 患者さんの個人情報は記載しない。

- 残念ながら、いまだに氏名、カルテ番号など、患者さん個人を特定できる情報が付いたままのデータを見かける。
- 個人情報は、データ解析の立場からは無意味。
- 個人情報が漏えいすれば、研究は中止、研究者の辞表が何枚が必要。被害者には、お詫びの仕様がない。
- データを受け取ったら、個人情報はすぐに匿名化もしくは削除。

データの準備：元データの取り扱い（続き）

iv. 解析記録の保存.

- 患者さんを診察すれば、医師がカルテに記録するのは**当然**。実験をすれば、実験ノートに記録するのは**常識**。解析の記録を残すのも、それと同じ。
- 元データと解析の記録を見れば、第三者が解析を再現できる程度の記録が必要。
 - **解析の再現性**
 - **備忘録** 「三日後の自分は遠い親戚。一週間後の自分は赤の他人」
 - 出来れば、**プログラム**を書いて解析する。

データの準備：データ入手時にすべきこと：**入力ミス、異常値**の発見

Excelの**フィルター機能**が便利

- **データの範囲**：本来正の値をとるはずが、負の値をとる。小数点の間違いで、体重35kgが3.5kgになる、等。
- **全角文字と半角文字**の混在：“w”と“w”など。
- **質的変数の数字表記**： 男性: 1, 女性: 2などを、男性→M, 女性→F のように書き直す。
- **異常な値**の検出：“3.14”と“3,14”など。
- **欠測値の数**： 欠測値の数が想定より多い場合、データが正常に認識されていないことがある。

記述統計の重要性

- 記述統計はデータを要約し, データの持つ全体的な特徴, 傾向を把握する.
- 同じ目的(例: 平均の推定)でも, データの持つ性質により複数の解析方法が存在する場合がある. 適切な解析方法を選択するために, データの特徴を把握することが重要.
- データの収集が, 公正に行われていることを示す.
 - 比較対照の際, 対照のための条件以外の背景因子に, 極端な差がないことを示す.
 - データに異常な値がないことを確認.

3. Rを使ったデータ解析の実際

実際のデータ解析は、多くの変数の海の中で意味のある相関を見つけるための試行錯誤。

多くのサブグループ解析と、データの絞り込み。

- データのサブグループ（性別、疾患の有無, etc.）
：データ配列の行方向の切り分け
- 共変量の場合分け：列方向の切り分け
 - 連續変数、離散変数 検定の種類が違う
 - 共変量（データ全体 vs. 術前情報のみ, etc.）
 - 対比の入れ替え（性別、年齢層, etc.）
- アウトカムの場合分け
 - モデルの被説明変数を入れ替える。

3. Rを使ったデータ解析の実際

生存時間解析の例

1. 単変量解析

- Log-rank test, Cox比例ハザードモデル
- KM曲線の描画（pngファイルなどで保存）

2. 多変量解析

- 単変量解析で $p < 0.2$ などの共変量を抽出
- Cox比例ハザードモデルによる多変量解析

3. 変数選択

- Backward-eliminationをよく使う。

以上の解析を、アウトカム、サブグループを切り替えて自動的に行う。

