５日目：エクセルでデータを準備し，読み込む

これまでは，データ分析とほど遠い感じの内容だったかもしれませんが，今日からは，データ分析のイメージに近い内容になってきます。今日は，エクセルで入力したデータをRに読み込ませてみたいと思います。

もちろん，集めたデータを直接Rに入力していくこともできますが，現実的ではないと思います。SPSSを使う場合と同様に，まずはエクセル(などの表計算ソフト)に入力して，それをRに読み込ませるのが適当でしょう。

エクセル上でのデータ入力は，SPSS用を意識しておけば，その他に特にRのために留意する点はないように思います。項目名はアルファベットでも日本語でも構いません。また「．」（ピリオド),「＿」(アンダーバー）も使えます。しかし，数字で始めることはできません。またRの関数などになっている単語(printやcorなど)も使えますが，紛らわしくなるので避けた方がよいでしょう。欠損値は空欄にしておけばよいです。

今回は，下図のようなデータを例にしましょう。エクセルに入力してください。

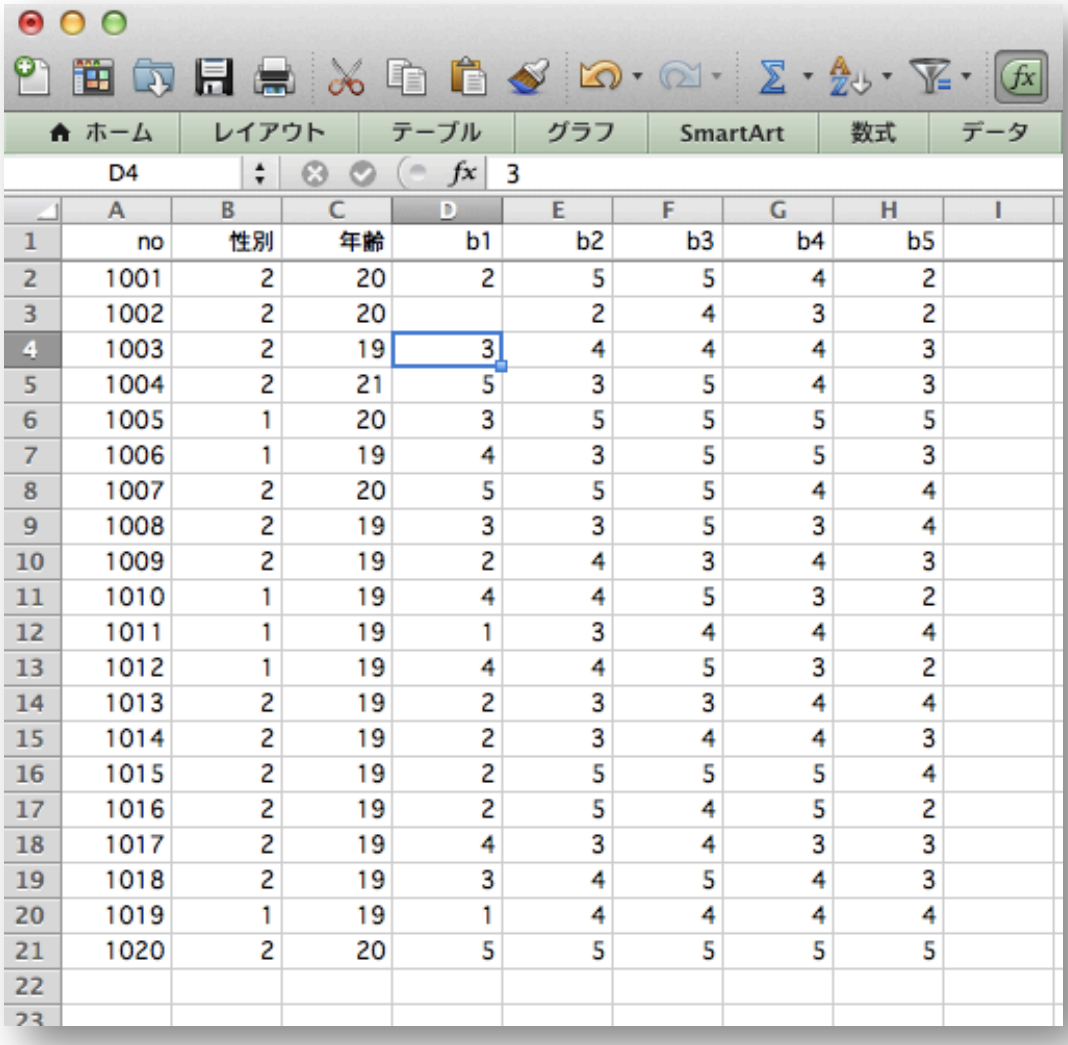

	A	B	C	D	E	F	G	H	I
1	no	性別	年齢	b1	b2	b3	b4	b5	
2	1001	2	20	2	5	5	4	2	
3	1002	2	20		2	4	3	2	
4	1003	2	19	3	4	4	4	3	
5	1004	2	21	5	3	5	4	3	
6	1005	1	20	3	5	5	5	5	
7	1006	1	19	4	3	5	5	3	
8	1007	2	20	5	5	5	4	4	
9	1008	2	19	3	3	5	3	4	
10	1009	2	19	2	4	3	4	3	
11	1010	1	19	4	4	5	3	2	
12	1011	1	19	1	3	4	4	4	
13	1012	1	19	4	4	5	3	2	
14	1013	2	19	2	3	3	4	4	
15	1014	2	19	2	3	4	4	3	
16	1015	2	19	2	5	5	5	4	
17	1016	2	19	2	5	4	5	2	
18	1017	2	19	4	3	4	3	3	
19	1018	2	19	3	4	5	4	3	
20	1019	1	19	1	4	4	4	4	
21	1020	2	20	5	5	5	5	5	
22									
23									

エクセルでこのようなデータを入力できたら，とりあえず保存しておきます。次にこれをCSV形式で保存します。エクセルのメニューバーから「ファイル」を選び，「名前を付けて保存」を選びます。

保存画面の中央辺りに，「フォーマット」の選択がありますので，ここでCSV形式を選択します。そして，３日目に作成したRの練習のための専用フォルダに保存してください。

名前は適当につけてかまいませんが，とりあえず今回は「練習.csv」にしておきたいと思います。

CSVという形式はエクセルの標準フォーマットもよりも情報量が少ないので，注意喚起の質問が出てきますが，「続行」してください。

保存ができたら，今度はRでこのファイルを読み込んでみます。

Rを起動してください。起動したら，まずは作業ディレクトリを変更します。ディレクトリとは，フォルダと同じようなものだと思ってください。Rが作業をする場所を設定するというイメージです。

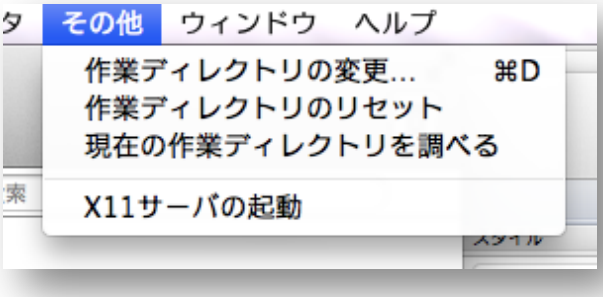

Rのメニューバーから「その他」を選びます。すると右図のような選択肢が出てくるので，「作業ディレクトリの変更」を選びます。

すると，フォルダを指定する画面が出てきますので，先にデータファイルを保存した，Rの練習用のフォルダを選び「開く」をクリックします。

これで作業ディレクトリの変更は終わりですが，Rコンソールには何のメッセージも出ません。そこで，ちゃんと作業ディレクトリがデータファイルの置いてあるフォルダに設定されているかを確認してみます。

先と同様に，Rのメニューバーから「その他」，そして「現在の作業ディレクトリを調べる」を選びます。するとRコンソールにメッセージが出てくるでしょう。私の場合だと，以下のように出てきます。

```
> getwd()
[1] "/Users/urakami*******/Desktop/R/データ"
```

getwd()というのは，現在の作業ディレクトリを調べるための命令です。メニューバーから選択しなくても，このコマンドを打ち込めば同じことをやってくれます。

２行目がディレクトリ（フォルダ）の位置になります。私はデスクトップに「R」というフォルダを作り，さらにその中に「データ」というフォルダを作って，そこにデータファイルを置きました。確かに，合っています。

作業ディレクトリが，確かにデータファイルを置いたフォルダになっていることを確認できたら，新しいRエディタを開いてください。そして以下のような命令を書き込んでください。これがCSVファイルを読み込む命令になります。

```
# ファイル読み込み
x <- read.csv("練習.csv", header=TRUE, fileEncoding="CP932")
```

先にこの命令に関する解説をしておきましょう。まず１行目は「#」で始まっています。コメントなどとも呼ばれますが，Rは「#」で始まる部分無視します。単にRコンソールに打ち出すだけであり，計算などには影響しません。そのため，自分用のメモ，解説などに使うと便利です。

２行目のread.csvが，CSV形式のファイルを読みなさいという指示になります。続くカッコの中には，まずファイル名（「"」でくくります）を指定し，続くheader=の部分は，データの１行目が変数名である場合にはheader=TRUEと入力しておきます。変数名でない場合はheader=FALSEと入力します。TRUEとFALSEは，その通りに，「真」と「偽」を意味します。これもよく出てくるので覚えておくとよいでしょう。ちなみに，TRUEはT，FALSEはFと略記することができます。しかし，いずれにしても小文字にしてはダメです。Rは大文字と小文字を区別します。

fileEncoding="CP932"の部分は，ある意味でMacユーザーならば必ず覚えておかなければならない部分かもしれません。Windows版のRでは，この部分がなくてもほとんど問題は生じないようですが，Macで，特に変数名や変数に日本語が使われている場合だと，これを入れないとエラーになってしまう場合が多いと思います（次の図を参照してください。fileEncoding="CP932"を入れないとエラーになってしまいましたが，入れるとエラーが出ず，うまくいっています）。ファイルのエンコーディングに関する指示ですが，ひとつの呪文だと思ってRエディタに大切に残しておくとよいと思います。

ちなみに"CP932"は，Windowsの Shift_JIS を読む場合ですが，これでうまくいかなければ"UTF-8"または"UCS-2LE"なども試してみてください。他にも多く種類があるので，うまくいかない時は調べてみてください。

x <- read.csv(…という部分は，昨日やったとおりです。以上のような read.csv で読み込んだデータを，x という名前のものに代入しています。つまり，今後は x という名前で，このデータすべてを操作できることになります（これもひとつのベクトルです)。

```
>
> # ファイル読み込み
> x <- read.csv("練習.csv",  header=TRUE)
 以下にエラー make.names(col.names, unique = TRUE) :
   <90><ab><95><ca>に不正なマルチバイト文字があります
>
>
> # ファイル読み込み
> x <- read.csv("練習.csv",  header=TRUE,  fileEncoding="CP932")
>
```

本日の最後に，確かに x の中身が読み込んだデータ通りになっているか確認しておきましょう。中身を見るのはもちろん

x

です。

右図のように出力されると思います。1002 番の b2 は欠損値でした。R に読み込んでみると，ここが「NA」に変わっています。R は欠損値を「NA」と示すのです。また変数名の行には一番左の番号（行番号）がふられていないことにも注意しておいてください。番号がついていないということは，ここはデータの行ではないことを意味しています。

（まだ時間があれば，header=FALSE としてデータを読み込んで，違いを確認しておいてください)

```
> x
     no 性別 年齢 b1 b2 b3 b4 b5
1  1001    2   20  2  5  5  4  2
2  1002    2   20 NA  2  4  3  2
3  1003    2   19  3  4  4  4  3
4  1004    2   21  5  3  5  4  3
5  1005    1   20  3  5  5  5  5
6  1006    1   19  4  3  5  5  3
7  1007    2   20  5  5  5  4  4
8  1008    2   19  3  3  5  3  4
9  1009    2   19  2  4  3  4  3
10 1010    1   19  4  4  5  3  2
11 1011    1   19  1  3  4  4  4
12 1012    1   19  4  4  5  3  2
13 1013    2   19  2  3  3  4  4
14 1014    2   19  2  3  4  4  3
15 1015    2   19  2  5  5  5  4
16 1016    2   19  2  5  4  5  2
17 1017    2   19  4  3  4  3  3
18 1018    2   19  3  4  5  4  3
19 1019    1   19  1  4  4  4  4
20 1020    2   20  5  5  5  5  5
>
```

これで５日目は終了です。R エディタに適当な名前を付けて，作業ディレクトリに保存しておいてください。