

rd-9. テーブルデータ 処理, 並べ替え (ソー ト), 集計・集約

データサイエンス演習
(R システムを使用)
<https://www.kkaneko.jp/de/rd/index.html>

金子邦彦



アウトライン



9-1 データテーブル

9-2 選択, 射影, 自然結合, 直積

9-3 並べ替え (ソート)

9-4 集約

9-5 演算の組み合わせ

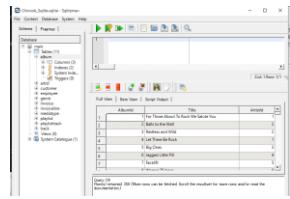
9-1 テーブルデータ

想定する処理の流れ

```

5.1.0.0.222222229,-2.5,0.625,-1,-4,0.0770981,-0.2,0.041666667,setsosa
4.2.0.166666667,2.0,-4.01666667,1,-4.0.08770981,0.2,-0.041666667,setsosa
5.1.0.111111111,3.2,0.5,-3.0.059047456,-0.2,0.041666667,setsosa
4.6.0.083333333,3.1,-1.0,-0.88333333,1,-5.0,-0.084745763,0.2,0.041666667,setsosa
5.0.194444444,-3.6,0.698666667,-1,-4.0,-0.0770981,-0.2,0.041666667,setsosa
5.4.0.083333333,3.1,-0.5,-0.88333333,1,-5.0,-0.084745763,0.2,0.041666667,setsosa
4.8.0.083333333,3.4,-0.5,-0.88333333,1,-4.0,-0.08770981,-0.3,-0.083333333,setsosa
5.0.194444444,-3.4,0.593333333,1,-5.0,0.084745763,0.2,-0.041666667,setsosa
4.4.0.166666667,-3.0,-0.3,0.0770981,-0.2,0.041666667,setsosa
4.9.0.166666667,2.0,-0.3,0.0770981,-0.2,0.041666667,setsosa
5.4.0.305555556,3.7,-0.088333333,1,-5.0,-0.084745763,0.2,0.041666667,setsosa
4.9.0.166666667,3.4,-0.5,-0.88333333,1,-5.0,-0.084745763,0.2,0.041666667,setsosa
4.9.0.166666667,3.4,-0.5,-0.88333333,1,-5.0,-0.084745763,0.2,0.041666667,setsosa
4.3.0.0.1,-0.1,-0.1,0.08770981,1,-1.0,0.08949153,0.1,-0.1,setsosa
5.8.0.416666667,4.0,-0.933333333,1,-2.0,0.03989895,0.2,-0.041666667,setsosa
5.7.0.388888889,4.4,-0.69991,1.5,-0.084745763,0.4,0.125,setsosa
5.4.0.305555556,3.9,-0.701666667,1,-3.0,0.059047456,0.4,0.125,setsosa
  
```

データファイル




リレーションナル
データベース




```


> x1 <- tb1_df( data.frame( 年次=c(1985, 1990, 1995, 2000, 2005, 2010),
+   出生数=c(1432, 1222, 1187, 1191, 1063, 1071),
+   死亡数=c(752, 820, 922, 962, 1084, 1197) ) )
  
```



R システム



Web
データソース



コンストラクタ



- ◆ グラフ
- ◆ 新しいデータ
- ◆ 解析結果

テーブルデータの例



科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

成績テーブル

```
library(dplyr)
d1 <- data_frame(
  科目=c("国語", "国語", "算数", "算数", "理科"),
  受講者=c("A", "B", "A", "B", "A"),
  得点=c(90, 80, 95, 90, 80) )
```

コンストラクタ

科目	教室
国語	101
算数	201
理科	301

教室テーブル

```
library(dplyr)
d3 <- data_frame(
  科目=c("国語", "算数", "理科"),
  教室=c("101", "201", "301") )
```

コンストラクタ

9-2 選択、射影、自然結合、直積

選択



テーブルの中から、選択条件に合致するレコードのみを選択する。結果は、新しいテーブルになる

テーブル
成績

科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

選択



科目	受講者	得点
国語	A	90
算数	A	95

新しいテーブル

結合条件は
「得点 ≥ 90 」

選択条件で用いる比較演算子



等しいか等しくないか

== 等しい

!= 等しくない

大小の比較

> より大きい

>= 以上

< より小さい

<= 以下

選択



科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

元データ

選択を行うテーブルのオブジェクト名	d1
選択条件	得点 >= 90

行いたいこと

科目 (chr)	受講者 (chr)	得点 (dbl)
1 国語	A	90
2 算数	A	95
3 算数	B	90

結果

```
library(dplyr)
d1 <- data_frame(
  科目=c("国語", "国語", "算数", "算数", "理科"),
  受講者=c("A", "B", "A", "B", "A"),
  得点=c(90, 80, 95, 90, 80) )
d1 %>% filter(得点 >= 90)
```


射影



テーブルの中の、必要なフィールド名リストを指定する。結果は、新しいテーブルになる

テーブル
成績

科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80



射影

科目	受講者
国語	A
国語	B
算数	A
算数	B
理科	A

新しいテーブル

フィールド名リストは
「受講者, 得点」

射影



科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

元データ

射影を行うテーブル
のオブジェクト名 d1
フィールド名リスト 科目, 受講者

行いたいこと

結果

科目	受講者
(chr)	(chr)
1	国語
2	国語
3	算数
4	算数
5	理科

```
library(dplyr)
d1 <- data_frame(
  科目=c("国語", "国語", "算数", "算数", "理科"),
  受講者=c("A", "B", "A", "B", "A"),
  得点=c(90, 80, 95, 90, 80) )
d1 %>% select(科目, 受講者)
```

自然結合




2つのテーブルの結合属性を用いて結合する。
結果は、新しいテーブルになる

科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

科目	教室
国語	101
算数	201
理科	301

自然結合



科目	受講者	得点	教室
国語	A	90	101
国語	B	80	101
算数	A	95	201
算数	B	90	201
理科	A	80	301

新しいテーブル

自然結合



科目	受講者	得点	科目	教室
国語	A	90	国語	101
国語	B	80	算数	201
算数	A	95	算数	301
算数	B	90	理科	
理科	A	80	理科	

元データ

自然結合を行なうテーブルのオブジェクト名
d1,
d3

行いたいこと

科目	受講者	得点	教室
(chr)	(chr)	(dbl)	(chr)
1 国語	A	90	101
2 国語	B	80	101
3 算数	A	95	201
4 算数	B	90	201
5 理科	A	80	301

結果

```
library(dplyr)
d1 <- data_frame(
  科目=c("国語", "国語", "算数", "算数", "理科"),
  受講者=c("A", "B", "A", "B", "A"),
  得点=c(90, 80, 95, 90, 80) )
d3 <- data_frame(
  科目=c("国語", "算数", "理科"),
  教室=c("101", "201", "301") )
inner_join(d1, d3)
```

直積



直積は、2つのテーブルの全レコードの組み合わせ。結果は、新しいテーブルになる

科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

科目	教室
国語	101
算数	201
理科	301

直積

	科目.x (chr)	受講者 (chr)	得点 (dbl)	科目.y (chr)	教室 (chr)
1	国語	A	90	国語	101
2	国語	A	90	算数	201
3	国語	A	90	理科	301
4	国語	B	80	国語	101
5	国語	B	80	算数	201
6	国語	B	80	理科	301
7	算数	A	95	国語	101
8	算数	A	95	算数	201
9	算数	A	95	理科	301
10	算数	B	90	国語	101
11	算数	B	90	算数	201
12	算数	B	90	理科	301
13	理科	A	80	国語	101
14	理科	A	80	算数	201
15	理科	A	80	理科	301

新しいテーブル

参考 Web ページ: <http://www.alfredo.motta.name/data-manipulation-primitives-in-r-and-python/>

直積



科目	受講者	得点	科目	教室
国語	A	90	国語	101
国語	B	80	算数	201
算数	A	95	理	301
算数	B	90	科	
理科	A	80		

元データ

直積を行う
テーブルの
オブジェクト名

d1,
d3



行いたいこと

	科目.x (chr)	受講者 (chr)	得点 (db1)	科目.y (chr)	教室 (chr)
1	国語	A	90	国語	101
2	国語	A	90	算数	201
3	国語	A	90	理科	301
4	国語	B	80	国語	101
5	国語	B	80	算数	201
6	国語	B	80	理科	301
7	算数	A	95	国語	101
8	算数	A	95	算数	201
9	算数	A	95	理科	301
10	算数	B	90	国語	101
11	算数	B	90	算数	201
12	算数	B	90	理科	301
13	理科	A	80	国語	101
14	理科	A	80	算数	201
15	理科	A	80	理科	301

結果

```
library(dplyr)
d1 <- data_frame(
  科目=c("国語", "国語", "算数", "算数", "理科"),
  受講者=c("A", "B", "A", "B", "A"),
  得点=c(90, 80, 95, 90, 80) )
d3 <- data_frame(
  科目=c("国語", "算数", "理科"),
  教室=c("101", "201", "301") )
d1$tmp = NA
d3$tmp = NA
full_join(d1, d3, by="tmp") %>% select(-tmp)
```

9-3 並べ替え (ソート)

並べ替え（ソート）の例



科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

並べ替え（ソート）前

データを一定の規則で並べ替え。
並べ替えは行単位



	科目 (chr)	受講者 (chr)	得点 (dbl)
1	国語	B	80
2	理科	A	80
3	国語	A	90
4	算数	B	90
5	算数	A	95

得点で昇順

	科目 (chr)	受講者 (chr)	得点 (dbl)
1	算数	A	95
2	国語	A	90
3	算数	B	90
4	国語	B	80
5	理科	A	80

得点で降順

並べ替え (ソート)



- データを一定の規則（昇順または降順）で並べ替え
- 並べ替えはレコード単位
- 並べ替えの結果、新しいテーブルができる
- 並べ替え時に、「キーとなるフィールド名」と「順序（昇順または降順）」を設定する必要がある

科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

並べ替え前



(chr)	(chr)	(db1)
1	国語	B 80
2	理科	A 80
3	国語	A 90
4	算数	B 90
5	算数	A 95

得点で昇順

昇順での並べ替え（ソート）



並べ替え（ソート）を行う
テーブルのオブジェクト名

d1

キー

得点

順序

昇順

	科目 (chr)	受講者 (chr)	得点 (dbl)
1	国語	B	80
2	理科	A	80
3	国語	A	90
4	算数	B	90
5	算数	A	95

```
library(dplyr)
d1 <- data_frame(
  科目=c("国語", "国語", "算数", "算数", "理科"),
  受講者=c("A", "B", "A", "B", "A"),
  得点=c(90, 80, 95, 90, 80) )
d1 %>% arrange(得点)
```

降順での並べ替え（ソート）



並べ替え（ソート）を行う
テーブルのオブジェクト名

d1

キー

得点

順序

降順

	科目	受講者	得点
	(chr)	(chr)	(dbl)
1	算数	A	95
2	国語	A	90
3	算数	B	90
4	国語	B	80
5	理科	A	80

```
library(dplyr)
d1 <- data_frame(
  科目=c("国語", "国語", "算数", "算数", "理科"),
  受講者=c("A", "B", "A", "B", "A"),
  得点=c(90, 80, 95, 90, 80) )
d1 %>% arrange(desc(得点))
```

複数フィールドでの並べ替え（ソート）



並べ替え（ソート）を行う テーブルのオブジェクト名	d1
キー	得点, 受講者
順序	得点は降順 受講者は昇順

科目 (chr)	受講者 (chr)	得点 (dbl)
1 算数	A	95
2 国語	A	90
3 算数	B	90
4 理科	A	80
5 国語	B	80
.	.	.

```
library(dplyr)  
  
d1 <- data_frame(  
    科目=c("国語", "国語", "算数", "算数", "理科"),  
    受講者=c("A", "B", "A", "B", "A"),  
    得点=c(90, 80, 95, 90, 80) )  
  
d1 %>% arrange(desc(得点), 受講者)
```


9-4 集約

集約の例



科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

元データ



Aさんは **3**科目
Bさんは **2**科目受講した

A	3
B	2

集約の例

集約で求めるもの



グループごとに、頻度や要約統計量を求める


- 頻度（数え上げ）
種類ごとの数え上げ
- 要約統計量
平均 (mean)、標準偏差 (sd)、分散 (var)
中央値 (median)、四分位点 (quantile)、
最大値 (max)、最小値 (min)

集約では、グループの基準もいろいろ



科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

元データ



A	88.33333
B	85

得点の平均

グループの基準が
科目

国語	85
算数	92.5
理科	80

得点の平均

集約の例

集約の例

① d1 %>% group_by(科目)
%>% summarise(n())

国語	2
算数	2
理科	1

データの**個数**

② d1 %>% group_by(受講者)
%>% summarise(mean(得点))

A	88.33333
B	85

得点の**合計**

③ d1 %>% group_by(科目)
%>% summarise(mean(得点))

国語	85
算数	92.5
理科	80

得点の**平均**

集約 ①



科目	受講者	得点	
国語	A	90	d1
国語	B	80	
算数	A	95	
算数	B	90	
理科	A	80	
成績			
			受講者
			得点



受講者	min(得点)	Q1	median(得点)	mean(得点)	Q3	max(得点)
(chr)	(dbl)	(dbl)	(dbl)	(dbl)	(dbl)	(dbl)
1	A	80	85.0	90	88.33333	92.5
2	B	80	82.5	85	85.00000	87.5

```
library(dplyr)
d1 <- data_frame(
  科目=c("国語", "国語", "算数", "算数", "理科"),
  受講者=c("A", "B", "A", "B", "A"),
  得点=c(90, 80, 95, 90, 80) )
d1 %>% group_by(受講者) %>% summarise(min(得点),
  Q1=quantile(得点, probs=0.25), median(得点), mean(得点),
  Q3=quantile(得点, probs=0.75), max(得点))
```

集約 ②



科目	受講者	得点	
国語	A	90	d1
国語	B	80	
算数	A	95	
算数	B	90	
理科	A	80	
成績			



科目 (chr)	min(得点) (dbl)	Q1 (dbl)	median(得点) (dbl)	mean(得点) (dbl)	Q3 (dbl)	max(得点) (dbl)
1 国語	80	82.50	85.0	85.0	87.50	90
2 算数	90	91.25	92.5	92.5	93.75	95
3 理科	80	80.00	80.0	80.0	80.00	80

```
library(dplyr)
```

```
d1 <- data_frame(
```

```
    科目=c("国語", "国語", "算数", "算数", "理科"),
```

```
    受講者=c("A", "B", "A", "B", "A"),
```

```
    得点=c(90, 80, 95, 90, 80) )
```


```
d1 %>% group_by(科目) %>% summarise(min(得点), Q1=quantile(得点,  
probs=0.25), median(得点), mean(得点), Q3=quantile(得点, probs=0.75),  
max(得点))
```

ピボットテーブル（クロス集約表）の例



名前	性別	申し込み
A	男性	済
B	男性	未
C	女性	済
D	女性	未
E	男性	済
F	男性	未

元データ



	女性	男性
済	1	2
未	1	2

ピボットテーブル
(クロス集約表) の例

ピボットテーブル（クロス集計表）



名前	性別	申し込み
A	男性	済
B	男性	未
C	女性	済
D	女性	未
E	男性	済
F	男性	未

集約を行う テーブルの オブジェクト名	d4
グループの 基準	性別, 申 し込み

性別	申し込み	count
(chr)	(chr)	(int)
1	女性	済 1
2	女性	未 1
3	男性	済 2
4	男性	未 2

※ 結果は縦長形式 (long-format)

```
library(dplyr)
d4 <- data_frame(
  名前=c("A", "B", "C", "D", "E", "F"),
  性別=c("男性", "男性", "女性", "女性", "男性", "男性"),
  申し込み=c("済", "未", "済", "未", "済", "未"))
d4 %>% group_by(性別, 申し込み) %>% summarise(count=n())
```

ピボットテーブル（クロス集計表）



名前	性別	申し込み
A	男性	済
B	男性	未
C	女性	済
D	女性	未
E	男性	済
F	男性	未

集約を行う
テーブルの
オブジェクト名
d4

グループの
基準
性別, 申
し込み

申し込み	女性	男性
(chr)	(int)	(int)
1	済	1
2	未	1

※ 結果は横長形式 (wide-format)

```
library(dplyr)
library(tidyr)
d4 <- data_frame(
  名前=c("A", "B", "C", "D", "E", "F"),
  性別=c("男性", "男性", "女性", "女性", "男性", "男性"),
  申し込み=c("済", "未", "済", "未", "済", "未"))
d4 %>% group_by(性別, 申し込み) %>% summarise(count=n()) %>%
  spread(性別, count)
```

9-5 演算の組み合わせ

演算の組み合わせの例



科目	受講者	得点
国語	A	90
国語	B	80
算数	A	95
算数	B	90
理科	A	80

成績テーブル
(オブジェクト名は d1)

d1 %>%
filter(得点 >= 90) %>%
select(科目, 受講者)

科目	受講者
(chr)	(chr)
1 国語	A
2 算数	A
3 算数	B

選択 + 射影

d3 %>%
filter(教室 == 101) %>%
inner_join(d1) %>%
select(受講者)

受講者
(chr)
1 A
2 B

選択 + 結合 + 射影

d1 %>%
group_by(科目) %>%
summarise(Mean=mean(得点)) %>%
filter(Mean >= 85)

科目	Mean
(chr)	(db1)
1 国語	85.0
2 算数	92.5

集約 + 選択

部屋テーブル
(オブジェクト名は d3)