

要約

1. データ X の主成分分析は、各点からの垂線の距離（情報損失量）が最小になるように、固有ベクトルを決める。
2. 主成分得点の分散の最大化も、これと同じことをしている。
3. 固有値は、最小化された情報損失量であり、最大化された主成分得点の分散でもある。
4. Rで主成分分析は `prcomp()` 関数を使う。
5. 固有値の平方根（主成分スコアの標準偏差） `$sdev` とノルム 1 で直交する固有ベクトル `$rotation` が出力される。
6. 主成分スコアは `$x` で出力される。
7. 主成分負荷量はデータ X と主成分スコアとの相関係数として定義され、データが `x01` で分析結果が `pr01` なら `cor(x01,pr01$x)` で求められる。
8. 各主成分の寄与率（各主成分が何%データの分散を説明しているか）は、`summary(pr01)` で出力される。
9. 通常、主成分分析では、各変数の分散は1に標準化した方がよいが、これは引数 `scale.=T` でできる。
10. `biplot()` 関数を使うと、スコアと主成分負荷量という別種の値が1つのグラフにプロットされるが、これらの値は、特異値分解（ $X = UDV'$ ）で得られるもので、上記のそれらとは値が異なる。
11. `biplot()` 関数によるプロット図は、引数 `scale=1`（デフォルト）を与えると、主成分スコアはノルム1に標準化されて出力され、各主成分のスコアのバラツキが見えなくなる（特異値分解の U に相当する）。
12. `biplot()` 関数によるプロット図は、引数 `scale=1`（デフォルト）を与えると、主成分負荷量は、データ X と主成分スコアとの相関係数に X の標準偏差 $\times \sqrt{n-1}$ を掛けた（値特異値分解の VD に相当する）。スケールが違うが、 X と主成分との遠近関係はわかる。
13. `biplot()` 関数によるプロット図は、引数 `scale=0` を与えると、主成分スコアは定義通りに出力される（特異値分解の UD に相当する）。
14. `biplot()` 関数によるプロット図は、引数 `scale=0` を与えると、主成分負荷量として、固有ベクトルが描画される（値特異値分解の V に相当する）。

考え方

主成分分析のかみ砕いた解説（咀嚼説明）は、有馬・石村（1987）¹にあります。


以下はそのフォローです。

成分ベクトルと X との距離の最小化であり、
スコアの分散の最大化でもある。

情報損失量 I の最小化

$x_i = (x_{i1}, x_{i2})$ と直線 $a_2 x_{i1} - a_1 x_{i2} + a_0 = 0$ との距離を l_i で表す。

ただし、 $a_1^2 + a_2^2 = 1$ とする。



ヘッセの標準形から

$$l_i = |a_2x_{i1} - a_1x_{i2} + a_0|$$

ヘッセの標準形

点 (x_1, y_1) から直線 $ax + by + c = 0$ に下した垂線の長さは

$$\frac{|ax_1 + by_1 + c|}{\sqrt{a^2 + b^2}}$$

情報損失量 I を以下で定義して,

$$I(a_2, a_1, a_0) = \sum_i l_i^2 = \sum_i (a_2x_{i1} - a_1x_{i2} + a_0)^2$$

I を最小化するような a_2, a_1, a_0 を見つけたい.

言い換えれば...

$$\min_{a_2, a_1, a_0} I(a_2, a_1, a_0)$$

$$\text{s.t. } a_2^2 + a_1^2 = 1$$

なので, ラグランジュ乗数法より

$$\min_{a_2, a_1, a_0} L = I - \lambda_0(a_2^2 + a_1^2 - 1) \quad \dots(1)$$

1 階の条件として

$$\frac{\partial U}{\partial a_0} = 2 \sum_i (a_2x_{i1} - a_1x_{i2} + a_0) = 0 \quad \dots(2)$$

なので, x_{i1} と x_{i2} の平均を, それぞれ $\bar{X}_1, \bar{X}_2$ とすると,

$$a_2\bar{X}_1 - a_1\bar{X}_2 + a_0 = 0$$

ということであり, $z_{i1} = x_{i1} - \bar{X}_1, z_{i2} = x_{i2} - \bar{X}_2$ とすると,

$$a_2x_{i1} - a_1x_{i2} + a_0 = a_2z_{i1} - a_1z_{i2}$$

なので,

$$\frac{\partial I}{\partial a_2} = 2 \sum_i z_{i1}(a_2z_{i1} - a_1z_{i2}) - 2\lambda_0a_2 = 0 \quad \dots(3)$$

$$\frac{\partial I}{\partial a_1} = -2 \sum_i z_{i2}(a_2z_{i1} - a_1z_{i2}) - 2\lambda_0a_1 = 0 \quad \dots(4)$$

さらに,

$$\frac{\partial I}{\partial \lambda_0} = -(a_2^2 + a_1^2 - 1) = 0 \quad \dots(5)$$

を満たす (a_1, a_2) について (本当は $a_1 = a_1^*, a_2 = a_2^*$ と書くべきだが面倒なので書きません。そう読み替えてください)

(3)式から

$$a_2Var(X_1) - a_1Cov(X_1, X_2) = \frac{\lambda_0}{n-1}a_2 \quad \dots(6)$$

(4)式から

$$-a_2 \text{Cov}(X_1, X_2) + a_1 \text{Var}(X_2) = \frac{\lambda_0}{n-1} a_1 \dots (7)$$

$\lambda = \lambda_0 / (n-1)$ と書き換えると,

$$\begin{pmatrix} \text{Var}(X_1) & \text{Cov}(X_1, X_2) \\ \text{Cov}(X_1, X_2) & \text{Var}(X_2) \end{pmatrix} \begin{pmatrix} a_2 \\ -a_1 \end{pmatrix} = \lambda \begin{pmatrix} a_2 \\ -a_1 \end{pmatrix} \dots (8)$$

ということであり, $(a_2, -a_1)$ というのは, n 行 2 列の行列 $X = (X_1, X_2)$ の分散・共分散行列の**固有ベクトル**!

λ は, X の分散・共分散行列の**固有値**!

...ということ.

さらに, (6) 式に a_2 を掛けて, (7) 式に a_1 を掛けて足し合わせると

$$a_2^2 \text{Var}(X_1) - 2a_1 a_2 \text{Cov}(X_1, X_2) + a_1^2 \text{Var}(X_2) = \lambda(a_2^2 + a_1^2)$$

なので,

$$\text{Var}(a_2 X_1 - a_1 X_2) = \lambda \dots (9)$$

であり, これは,

$$\sum_i (a_2 x_{i1} - a_1 x_{i2} + a_0)^2 = (n-1)\lambda = \lambda_0$$

のことなので, λ_0 は**情報損失量** I ということ. つまり,

$$I = \lambda_0$$

■ スコアの最大化

$a_1 X_1 + a_2 X_2$ を**主成分得点** (principal component score) あるいは単に**スコア** (score) と呼ぶ.

n 行 2 列の行列 $X = (X_1, X_2)$ でスコア $a_1 X_1 + a_2 X_2$ の分散を最大化するノルム 1 の (a_1, a_2) を求める.

$$\max_{a_1, a_2} \text{Var}(a_1 X_1 + a_2 X_2)$$

$$\text{s.t } a_1^2 + a_2^2 = 1$$

であるから, ラグランジュ乗数法で

$$\max_{a_1, a_2} L = \text{Var}(a_1 X_1 + a_2 X_2) - \mu(a_1^2 + a_2^2 - 1)$$

$$= a_1^2 \text{Var}(X_1) + 2a_1 a_2 \text{Cov}(X_1, X_2) + a_2^2 \text{Var}(X_2) - \mu(a_1^2 + a_2^2 - 1) \dots (10)$$

1 階の条件は

$$\frac{\partial L}{\partial a_1} = 2a_1 \text{Var}(X_1) + 2a_2 \text{Cov}(X_1, X_2) - 2\mu a_1 = 0 \dots (11)$$

$$\frac{\partial L}{\partial a_2} = 2a_1 \text{Cov}(X_1, X_2) + 2a_2 \text{Var}(X_2) - 2\mu a_2 = 0 \dots (12)$$

したがって,

$$\begin{pmatrix} \text{Var}(X_1) & \text{Cov}(X_1, X_2) \\ \text{Cov}(X_1, X_2) & \text{Var}(X_2) \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = \mu \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} \dots (13)$$

ということであり, $(a_2, -a_1)$ というのは, n 行 2 列の行列 $X = (X_1, X_2)$ の分散・共分散行列の**固有ベクトル**!

μ は, その固有値.

$$a_1^2 \text{Var}(X_1) + 2a_1 a_2 \text{Cov}(X_1, X_2) + a_2^2 \text{Var}(X_2) = \mu(a_1^2 + a_2^2)$$

なので

$$\text{Var}(a_1 X_1 + a_2 X_2) = \mu \dots (14)$$

つまり,

$$\sum_i (a_1 z_{i1} + a_2 z_{i2})^2 = (n-1)\mu = \mu_0$$

でもある.

■ 行列表記で

n 行 2 列の重心 $(0, 0)$ の行列 $X = (X_1, X_2)$ を考える。

$$X = \begin{pmatrix} z_{11} & z_{12} \\ z_{21} & z_{22} \\ \dots & \dots \\ z_{n1} & z_{n2} \end{pmatrix}$$

X' を X の転置行列とすると...

情報損失量を最小化する条件式(8)は

$$X'X \begin{pmatrix} a_2 \\ -a_1 \end{pmatrix} = \lambda_0 \begin{pmatrix} a_2 \\ -a_1 \end{pmatrix} \quad \dots(15)$$

スコアの分散を最大化する条件式(13)は

$$X'X \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = \mu_0 \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} \quad \dots(16)$$

つまり, (a_1, a_2) は $X'X$ の固有ベクトルであり, λ_0, μ_0 は $X'X$ の固有値。(この例だと固有値は2個ある。)

■ 固有ベクトル, 固有値の求め方

特異値分解

$X'X$ の固有ベクトルは X を**特異値分解**で求められる。(具体的な分解はRがやってくれる, 後述)

$$X = UDV'$$

ここで,

- U : 左固有特異ベクトル (n 行 p 列の直交行列, この例だと $p = 2$)
- D : 特異値 (p 行 p 列の対角行列)
- V : 右特異ベクトル (p 行 p 列の直交行列)

ここで

- V は $X'X$ の**固有ベクトル**
 - $X'X = (UDV')'UDV' = VD'UUDV' = VD^2V'$ (U は $UU' = I$ となる直交行列)
 - $X'X = VD^2V'$ は**固有値分解**の形。
 - この場合, V は $X'X$ の直交する固有ベクトル。
- D は $X'X$ の**特異値**
 - D^2 は $X'X$ の固有値 $\mu_{01}, \dots, \mu_{0p}$ を対角成分とする対角行列。
 - つまり D は $X'X$ の特異値 $\sqrt{\mu_{01}}, \dots, \sqrt{\mu_{0p}}$
- UD は**主成分スコア** ($UD = XV'$)
 - $XV' = UDVV' = UD$ (V はノルム1の直交行列なので, $V'V = I$)
- VD は**主成分負荷量(loading)** (の $\sqrt{\text{Var}(X_1)(n-1)}, \dots, \sqrt{\text{Var}(X_p)(n-1)}$ 倍)
 - 主成分負荷量は X とスコア($XV' = UD$)との相関係数 $\text{Cor}(X, XV')$
 - VD に左から $\left(\frac{1}{\sqrt{\text{Var}(X_1)(n-1)}}, \dots, \frac{1}{\sqrt{\text{Var}(X_p)(n-1)}} \right)$ の対角行列を掛けると定義通りの主成分負荷量

$Cor(X, XV')$ になる

Rで

```
library(tidyverse)
```

Rの `pcrcom` 関数で

データ


わかりやすいデータを作成して、元のデータ X が主成分分析でどんな主成分ベクトルによってどんなスコアが与えられるかを確認したい。

もとのデータとして、 $X = (X_1, X_2)$ の2変数9個を与えてみよう。

```
x01<-c(0,0,  
 2+0.5,1-1,  
 2-0.5,1+1,  
 4+0.5,2-1,  
 4-0.5,2+1,  
 -2+0.5,-1-1,  
 -2-0.5,-1+1,  
 -4+0.5,-2-1,  
 -4-0.5,-2+1  
)%>%  
matrix(ncol=2,byrow=T)
```

こんな感じ

```
plot(x01,asp=1)  
grid()  
text(1:9,x=x01[,1],y=x01[,2],pos = 1)  
abline(h=0)  
abline(v=0)  
abline(a=0,b=0.5,col=4)  
abline(a=0,b=-2,col=3)
```



横軸が X_1 (`x01[,1]`) , 縦軸が X_2 (`x01[,2]`)

8つの点が、 $(2, 1)$ の方向の原点を通る直線に対して垂直に、長さ $\sqrt{0.5^2 + 1^2} = \sqrt{1.25}$ で対称にばらついている。

分析しなくても主成分ベクトルは、 $(2, 1)$ の方向と $(-1, 2)$ の方向でしょう。

平均は2変数とも0 (中心化されている, 標準化ではない=分散は1ではない) .

```
apply(x01,2,mean)%>%  
  round(4)
```

```
[1] 0 0
```

X_1, X_2 の分散・共分散行列 M は

```
var(x01)
```

```
      [,1] [,2]  
[1,] 10.25  4.5  
[2,]  4.50  3.5
```

主成分分析を行う

`prcomp()` 関数

```
pr01<-prcomp(x01)  
pr01
```

```
Standard deviations (1, ..., p=2):  
[1] 3.535534 1.118034
```

```
Rotation (n x k) = (2 x 2):  
      PC1      PC2  
[1,] -0.8944272 -0.4472136  
[2,] -0.4472136  0.8944272
```

固有値

`Standard deviations` というのは、スコアの標準偏差 $\sqrt{\mu}$.

```
pr01$sdev
```

```
[1] 3.535534 1.118034
```

二乗するとスコアの分散であり、 X の分散・共分散行列 M の固有値 μ 。つまり、式(13)の μ に相当。

```
pr01$sdev^2
```

```
[1] 12.50  1.25
```

この場合固有値は2個あるので、2つ出力。最初が第1主成分の、次が第2主成分の固有値。第1主成分の方に分散が大きいことがわかる。

主成分のベクトル

`rotation` は、主成分のベクトル (a_1, a_2)

```
pr01$rotation
```

```
      PC1      PC2  
[1,] -0.8944272 -0.4472136  
[2,] -0.4472136  0.8944272
```

これも2種類あって、1列目が第1主成分で、2列目が第2主成分で、直交している。

第1主成分が $(-2, -1)$ の方向で、第2主成分が $(-1, 2)$ の方向で、ノルムが1となっている。

```
pr01$rotation[,1]^2
```

```
[1] 0.8 0.2
```

(横軸が X_1 、縦軸が X_2 の場合) 左下方向と左上方向で、思っていたのと逆だが、どちら方向にスコアをとるかだけの問題で、本質的に違いはない。

各点のスコア

各点のスコアは, `$x` で取り出せる.

```
pr01$x
```

	PC1	PC2
[1,]	0.000000	0.000000
[2,]	-2.236068	-1.118034
[3,]	-2.236068	1.118034
[4,]	-4.472136	-1.118034
[5,]	-4.472136	1.118034
[6,]	2.236068	-1.118034
[7,]	2.236068	1.118034
[8,]	4.472136	-1.118034
[9,]	4.472136	1.118034

スコアは $a_1x_1 + b_1x_2$ のことから, `x01` と `Rotation` を掛け合わせても得られる.

```
x01%*%pr01$rotation
```

	PC1	PC2
[1,]	0.000000	0.000000
[2,]	-2.236068	-1.118034
[3,]	-2.236068	1.118034
[4,]	-4.472136	-1.118034
[5,]	-4.472136	1.118034
[6,]	2.236068	-1.118034
[7,]	2.236068	1.118034
[8,]	4.472136	-1.118034
[9,]	4.472136	1.118034

各点のスコアのグラフ

第1主成分が横軸, 第2主成分が縦軸

```
plot(pr01$x,asp=1)
grid()
abline(h=0,col=4)
abline(v=0,col=3)
text(1:9,x=pr01$x[,1],y=pr01$x[,2],pos=1)
```


スコアのプロットをマイナス45度回して, さらに+ -をひっくり返した形. (青い線がもとの真ん中を通る直線)

例えば, 2番目の点の第一主成分のスコアは, 原点を通る傾き1/2の直線(第1主成分方向)に垂線を下した点が(2, 1)だから, 第1主成分が $-\sqrt{2^2 + 1^2} = -\sqrt{5}$

```
-sqrt(2^2+1^2)
```

```
[1] -2.236068
```


第1主成分だけで点2 ($x_{21} = 2.5, x_{22} = 0$)のスコアと情報損失は以下のように図示できる(図が描きにくいので a_1, a_2 はあえて正方向にしている)



第2主成分のスコアは、 $(2.5, 0)$ の点から原点を通り傾き -2 の直線に落とした垂線が、 $-\sqrt{0.5^2 + (-1)^2} = -\sqrt{1.25}$

```
-sqrt(0.5^2+(-1)^2)
```

```
[1] -1.118034
```



スコアの分散は、（前述のとおり）固有値

```
var(pr01$x)%>%  
  round(4)
```

```
PC1  PC2  
PC1 12.5 0.00  
PC2 0.0 1.25
```

特異値分解との関係

特異値分解 $X = UDV'$ は `svd` 関数

```
px01<-svd(x01)
```

左特異ベクトル U は `$u`

```
U01<-px01$u
```

右特異ベクトル V は `$v`

```
V01<-px01$v
```

特異値 D は `$d`（対角行列にする必要がある）

```
D01<-px01$d %>% diag()
```

V は固有ベクトルそのもの。 `prcomp` 関数の出力 `$rotation` と一致する。

```
pr01$rotation
```

```
      PC1      PC2  
[1,] -0.8944272 -0.4472136  
[2,] -0.4472136  0.8944272
```

```
V01
```

```
      [,1]      [,2]  
[1,] -0.8944272 -0.4472136  
[2,] -0.4472136  0.8944272
```

V のノルムは1

```
norm(V01,"2")
```

```
[1] 1
```


Uのノルムも1

```
norm(U01,"2")
```

```
[1] 1
```

UDは主成分スコア。prcomp 関数の出力 \$x と一致する。

```
U01%*%D01 %>% round(4)
```

```
      [,1] [,2]
[1,]  0.0000 0.000
[2,] -2.2361 -1.118
[3,] -2.2361  1.118
[4,] -4.4721 -1.118
[5,] -4.4721  1.118
[6,]  2.2361 -1.118
[7,]  2.2361  1.118
[8,]  4.4721 -1.118
[9,]  4.4721  1.118
```

```
pr01$x %>% round(4)
```

```
      PC1    PC2
[1,]  0.0000  0.000
[2,] -2.2361 -1.118
[3,] -2.2361  1.118
[4,] -4.4721 -1.118
[5,] -4.4721  1.118
[6,]  2.2361 -1.118
[7,]  2.2361  1.118
[8,]  4.4721 -1.118
[9,]  4.4721  1.118
```

当然XV'とも一致する

```
x01%*%t(V01) %>% round(4)
```

```
      [,1] [,2]
[1,]  0.0000 0.000
[2,] -2.2361 -1.118
[3,] -2.2361  1.118
[4,] -4.4721 -1.118
[5,] -4.4721  1.118
[6,]  2.2361 -1.118
[7,]  2.2361  1.118
[8,]  4.4721 -1.118
[9,]  4.4721  1.118
```

Dは、スコアの標準偏差の $\sqrt{n-1}$ 倍。つまり、 $\sqrt{(n-1)\mu} = \sqrt{\mu_0}$

主成分分析 prcomp 関数の standard deviation で出力される特異値は $\sqrt{\mu}$ の方。

```
pr01$sdev
```

```
[1] 3.535534 1.118034
```

特異値分解の sd で出力されるのは $\sqrt{\mu_0}$ 。 $\sqrt{n-1}$ で割ると $\sqrt{\mu}$ に一致する。

```
px01$d/sqrt(9-1)
```

```
[1] 3.535534 1.118034
```

Xとスコアとの相関係数

Xの個々の点の特徴を、2つの主成分に分けて見れることはわかった。

それでは X_1 という変数は、主成分から見てどんな変数か、 X_2 はどうか、というのが**主成分負荷量**(principal component loading). 単に**負荷量**(loading)と呼ぶ場合も。(因子負荷量 (factor loading)と呼ぶ人もいるが、因子分析の用語で気持ち悪い.)

Xとスコアとの相関係数で定義される。

$$\frac{\text{Cov}(X_1, a_1 X_1 + a_2 X_2)}{\sqrt{\text{Var}(X_1)} \sqrt{\text{Var}(a_1 X_1 + a_2 X_2)}}$$

`prcomp` の出力には負荷量がない！しかし、ふつうに元データ `x01` とスコア `$x` との相関係数を求めればよい。

```
cor(x01, pr01$x)%>%
  round(4)
```

```
      PC1      PC2
[1,] -0.9877 -0.1562
[2,] -0.8452  0.5345
```

相関係数なので、主成分負荷量は $[-1, 1]$ の間の値をとる。

変数 X_1 は、第1主成分と-0.9877の相関があるが、第2主成分とは-0.1562しかない。

変数 X_2 は、第1主成分と-0.8452の相関があり、第2主成分とも0.5345の相関がある。

特異値からも求められる

主成分負荷量は以下でも求められる。(上の方法で求められるなら、それでいいじゃないかと思うが、固有値や特異値分解のVDの意味がよくわかるので、理解しておこう。)

$$\frac{\text{Cov}(X_1, a_1 X_1 + a_2 X_2)}{\sqrt{\text{Var}(X_1)} \sqrt{\text{Var}(a_1 X_1 + a_2 X_2)}} = \frac{a_1 \text{Var}(X_1) + a_2 \text{Cov}(X_1, X_2)}{\sqrt{\text{Var}(X_1)} \sqrt{\mu}} = \frac{a_1 \mu}{\sqrt{\text{Var}(X_1)} \sqrt{\mu}}$$

3項目への変換は

$$\begin{pmatrix} \text{Var}(X_1) & \text{Cov}(X_1, X_2) \\ \text{Cov}(X_1, X_2) & \text{Var}(X_2) \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = \mu \begin{pmatrix} a_1 \\ a_2 \end{pmatrix}$$

からきている。

`prcomp` 関数の出力 `$rotation` (固有ベクトル a) と `$sdev` (特異値 $\sqrt{\mu}$) の対角行列を掛けて、それぞれ $\sqrt{\text{Var}(X_1)}$, $\sqrt{\text{Var}(X_2)}$ で割ればよい。

つまり、こういうこと。

まず $\sqrt{\text{Var}(X_1)}$, $\sqrt{\text{Var}(X_2)}$ を求める

```
vx01<-apply(x01,2,sd)
vx01
```

```
[1] 3.201562 1.870829
```

$a_1 \sqrt{\mu}$, $a_2 \sqrt{\mu}$ を求めて $\sqrt{\text{Var}(X_1)}$, $\sqrt{\text{Var}(X_2)}$ で割る

```
pr01$rotation**diag(pr01$sdev)%>%
  sweep(.,1,vx01,"/") %>%
  round(4)
```

```
      [,1]      [,2]
[1,] -0.9877 -0.1562
[2,] -0.8452  0.5345
```

特異値分解のVDを使う場合は、これは `$sdev` (特異値 $\sqrt{\mu}$) の $\sqrt{(n-1)}$ 倍なので、 $\sqrt{(n-1)}$ でも割らないといけない。


```
V01*%D01%>%
  sweep(.,1,vx01,"/") %>%
  sweep(.,1,sqrt(9-1),"/") %>%
  round(4)
```

```
      [,1]      [,2]
[1,] -0.9877 -0.1562
[2,] -0.8452  0.5345
```

biplot

主成分分析のスコアと主成分負荷量は、 `biplot()` 関数で出力できる。

```
biplot(pr01,asp=1)%>%
  grid()
```



スコアと負荷量は**全く別種の数値が無理やり1つのグラフに入れてある**。

下と左の目盛が**スコア用**で、上と右が**主成分負荷量**のための目盛。

しかも、よくわからないスケーリングをしてあるので、余計によくわからない。

1～9の数字が各点のスコアで、赤い矢印が負荷量…だと思ったが、何か数値が違う。

`biplot()` 関数には `scale=` という引数があり、デフォルトで `scale=1` が与えられている。

UD で各点のスコアとなることは説明した。固有値が2つある場合は、

$$D = \begin{pmatrix} \sqrt{\mu_{0,1}} & 0 \\ 0 & \sqrt{\mu_{0,2}} \end{pmatrix}$$

```
D01 %>% round(4)
```

```
      [,1]      [,2]
[1,]  10  0.0000
[2,]   0  3.1623
```

…であるはずなのだが、 `biplot()` 関数では、 D に以下のような小細工をして UD を求めている。

$$U = \begin{pmatrix} \sqrt{\mu_{0,1}}^{1-scale} & 0 \\ 0 & \sqrt{\mu_{0,1}}^{1-scale} \end{pmatrix}$$


さらに、主成分負荷量は VD をそのまま使っている。ただし、この時の D にも以下のような小細工をしている。

$$V \begin{pmatrix} \sqrt{\mu_{0,1}^{scale}} & 0 \\ 0 & \sqrt{\mu_{0,2}^{scale}} \end{pmatrix}$$

ただし、 $scale$ は、 $[0, 1]$ の実数。

$scale = 1$ の場合

```
biplot(pr01,scale=1,asp=1)
grid()
```



対角行列 D の各要素を σ_k 乗したものを D^k と表すと...

各点のスコアは $UD^{1-1} = U$ で、 U のもの

```
U01 %>% round(4)
```

```
      [,1]      [,2]
[1,]  0.0000  0.0000
[2,] -0.2236 -0.3536
[3,] -0.2236  0.3536
[4,] -0.4472 -0.3536
[5,] -0.4472  0.3536
[6,]  0.2236 -0.3536
[7,]  0.2236  0.3536
[8,]  0.4472 -0.3536
[9,]  0.4472  0.3536
```

主成分負荷量は $VD^1 = VD$

```
V01*%D01 %>% round(4)
```

```
      [,1]      [,2]
[1,] -8.9443 -1.4142
[2,] -4.4721  2.8284
```

行が変数名、列が主成分名。負荷量の定義通りではなく X の標準偏差 $\times \sqrt{n-1}$ で割られていない値。


つまり、`biplot()` 関数に引数 `scale=1` を与えた場合、プロットされる各店のスコアは、ノルム1に標準化されたスコア。この例の場合、第1主成分のスコアのバラツキが大きく第2主成分のスコアのバラツキは小さいが、`biplot()` 関数の出力では、同じようなバラツキに見えることになる。

主成分負荷量は、 X とスコアの相関なので、値が $[-1, 1]$ の範囲の値をとるはずなのに、この例では、 $[-1, 1]$ の範囲を軽くはみ出している。またもともと標準偏差の大きかった変数の矢印が長くなっている。

解釈の仕方としては、各点のスコアのプロットの位置関係は、軸ごとに頭を切り替えて読むべき。各変数の主成分負荷量は、矢印の長さはもともとの各変数の標準偏差であって、主成分分析として意味があるのは、各主成分の軸との近さ（傾き）でしょう。

$scale = 0$ の場合

```
biplot(pr01,scale=0,asp=1)
grid()
```



各点のスコアは $UD^{1-0} = UD$ で定義通りのスコア。

```
U01%>%D01%>%
  round(4)
```

```
      [,1] [,2]
[1,]  0.0000 0.000
[2,] -2.2361 -1.118
[3,] -2.2361  1.118
[4,] -4.4721 -1.118
[5,] -4.4721  1.118
[6,]  2.2361 -1.118
[7,]  2.2361  1.118
[8,]  4.4721 -1.118
[9,]  4.4721  1.118
```

主成分負荷量は $VD^0 = V$ となってしまう、これは主成分ベクトルそのもの。


```
V01%>%
  round(4)
```

```
      [,1] [,2]
[1,] -0.8944 -0.4472
[2,] -0.4472  0.8944
```

`biplot()` 関数に引数 `scale=0` を与えた場合のプロットは、正確な各点のスコアがプロットされる。ただし、因子負荷量は、各スコアの各主成分方向のパラツキを反映していない主成分ベクトルの傾きだけしか示さない。矢印の長さは常に1。主成分ベクトルそのものだから、2変数だと矢印は直交する。

$scale = 0.5$

```
biplot(pr01,scale=0.5,asp=1)
grid()
```



スコアは $UD^{\frac{1}{2}}$, 主成分負荷量は $VD^{\frac{1}{2}}$, 計算もプロットもできるが, 解釈に苦しむ。

X を標準化する

$X = (X_1, X_2)$ を平均0 (もともと0だが) , 標準偏差1に標準化してみたらどうか?


X を標準化する

```
x01_s<-scale(x01)
x01_s
```

```
      [,1]      [,2]
[1,]  0.000000  0.000000
[2,]  0.7808688  0.000000
[3,]  0.4685213  1.0690450
[4,]  1.4055639  0.5345225
[5,]  1.0932163  1.6035675
[6,] -0.4685213 -1.0690450
[7,] -0.7808688  0.000000
[8,] -1.0932163 -1.6035675
[9,] -1.4055639 -0.5345225
attr(,"scaled:center")
[1] 0 0
attr(,"scaled:scale")
[1] 3.201562 1.870829
```

プロットしてみる

```
plot(x01_s,asp=1)
grid()
abline(h=0,col=3)
abline(v=0,col=3)
text(1:9,x=x01_s[,1],y=x01_s[,2],pos=1)
```



ちょっと距離感が変わった。

主成分分析

```
pr01_s<-prcomp(x01_s)
pr01_s

Standard deviations (1, ..., p=2):
[1] 1.3233690 0.4986928

Rotation (n x k) = (2 x 2):
      PC1      PC2
[1,] -0.7071068 -0.7071068
[2,] -0.7071068  0.7071068
```

(データの動きを見たいので X を標準化したが、ふつうは `prcomp()` 関数に引数 `scale.=TRUE` を与える。これですべての X の変数が標準化できる。)

2変数とも標準化しているので、主成分ベクトルは常に45度線の方角（とその直交）。ちなみに $\sin(\pi/4) = 0.7071068$ 。

各点のスコア

```
pr01_s$x

      PC1      PC2
[1,]  0.0000000  0.0000000
[2,] -0.5521576 -0.5521576
[3,] -1.0872235  0.4246344
[4,] -1.3718482 -0.6159193
[5,] -1.9069141  0.3608727
[6,]  1.0872235 -0.4246344
[7,]  0.5521576  0.5521576
[8,]  1.9069141 -0.3608727
[9,]  1.3718482  0.6159193
```


因子負荷量

```
cor(x01_s,pr01_s$x)

      PC1      PC2
[1,] -0.9357632 -0.3526291
[2,] -0.9357632  0.3526291
```

biplot () 関数出力 (`scale=1`)

```
biplot(pr01_s,scale=1,asp=1)
grid()
```



各点スコアのプロットは並びだけが見えるが、距離感は解釈が難しい。因子負荷量の矢印は、 X の2変数を標準化したので、長さが同じになった。矢印の先の位置は X とスコアの相関係数を $\sqrt{n-1}$ 倍した値（各変数を標準偏差1に標準化しているので）。


とにかく、第1主成分は x_1 軸と x_2 軸の間を通過して（標準化しているのでそうなるでしょう）、 X_1 も X_2 も第1主成分との相関が高いということだけはわかる。

```
cor(x01_s,pr01_s$x)*sqrt(8)
```

```
      PC1      PC2
[1,] -2.646738 -0.9973856
[2,] -2.646738  0.9973856
```

`biplot()` 関数出力 (`scale=0`)

```
biplot(pr01_s,scale=0,asp=1)
grid()
```



主成分負荷量は、`scale=0` の場合、主成分ベクトルと同じなので、標準化された X だと必ず45度線になり、図を見てもあまり意味ないが第1主成分方向に各点のスコアが大きくばらついていることだけはわかる。

寄与率

スコアの分散が固有値だが、分散の和における個々の分散（固有値）の割合は**寄与率**と呼ばれる。

2変数しかない場合、第2主成分までで、固有値が2つある(μ_1, μ_2)。この場合、第1主成分の寄与率は

$$\frac{\mu_1}{\mu_1 + \mu_2}$$

2変数しかない場合、 $\mu_1 + \mu_2$ が X の分散 ($Var(X_1) + Var(X_2)$) と一致するので、この寄与率は第1主成分が X の分散を説明する割合ということになる。

スコアの分散は

```
var(pr01$x)%>%
  round(4)
```

```
    PC1  PC2
PC1 12.5  0.00
PC2  0.0  1.25
```

固有値は

```
pr01$sdev^2
```

```
[1] 12.50  1.25
```

寄与率は

```
pr01$sdev^2/sum(pr01$sdev^2) %>% round(4)
```

```
[1] 0.90909091 0.09090909
```

第1主成分の寄与率が90.9%で、第2主成分の寄与率が9.09%ということ。

寄与率は、`summary()` 関数で出力できる。

```
summary(pr01)
```

```
Importance of components:
              PC1      PC2
Standard deviation    3.5355 1.11803
Proportion of Variance 0.9091 0.09091
Cumulative Proportion 0.9091 1.00000

## Importance of components:
##              PC1      PC2
## Standard deviation    3.5355 1.11803
## Proportion of Variance 0.9091 0.09091
## Cumulative Proportion 0.9091 1.00000
```

Proportion of Variance が寄与率。それを大きい方から順に足していったのが累積寄与率。**Cumulative Proportion** がそれ。この場合2変数なので、主成分は高々2個。なので、第2主成分で累積寄与率は1になる。

X を標準化した場合も見てみる。

```
summary(pr01_s)
```

```
Importance of components:
              PC1      PC2
Standard deviation    1.3234 0.4987
Proportion of Variance 0.8757 0.1244
Cumulative Proportion 0.8757 1.0000
```

第1主成分の寄与率が、標準化していない場合よりも小さくなった。

主成分分析の結果は変数のスケールに応じて変わるということ。つまり同じデータでも、例えばキログラムで測るのか、それともトンで測るのかでも結果が変わるということ。

それはまずい、ということで、**主成分分析では各変数の分散を1に揃える**のが一般的。

ただし、合計に意味があるような場合。例えば、入試の成績などでは、各科目の分散を1に揃えない方が、分析の意味づけがやりやすくなるはず、たぶん。

なお、`prcomp()` 関数だと、すべての変数の分散を1に揃えるには、引数 `scale. = TRUE` を与えればよい。

```
prcomp(x01,scale. = TRUE)
```

```
Standard deviations (1, ..., p=2):  
[1] 1.3233690 0.4986928
```

```
Rotation (n x k) = (2 x 2):  
      PC1      PC2  
[1,] -0.7071068 -0.7071068  
[2,] -0.7071068  0.7071068
```