

# PCA(Principal Component Analysis)

SCH Univ.  
Dept. of AI and Bigdata  
Lee Howoo

# 개요


1. 주성분 분석 개요
2. 주성분 분석 수리적 배경
3. 주성분 분석 알고리즘
4. 주성분 분석 예제

# 주성분 분석 개요 – 고차원 데이터

변수 관측치	$X_1$	...	$X_i$	...	$X_p$
$N_1$	$X_{11}$	...	$X_{1i}$	...	$X_{1p}$
...	...	...	...	...	...
$N_i$	$X_{i1}$	...	$X_{ii}$	...	$X_{ip}$
...	...	...	...	...	...
$N_n$	$X_{n1}$	...	$X_{ni}$	...	$X_{np}$

- 3차원 이상의 데이터 → 시각적 표현 한계
- 차원이 클수록 계산복잡도 ↑, 모델링 비효율적
- 따라서 중요한 변수들로 차원을 줄일 필요가 있음

# 주성분 분석 개요



장점: 선택한 변수들의 해석이 용이함


단점: 변수간 상관관계 고려가 어려움

장점: 변수간 상관관계 고려함

단점: 추출된 변수의 해석이 어려움

# 주성분 분석 개요

---



# 주성분 분석 개요

---

**Supervised feature selection:** Information Gain, Stepwise regression, LASSO, Genetic algorithm

**Supervised feature extraction:** Partial least squares (PLS)

**Unsupervised feature selection:** PCA loading

**Unsupervised feature extraction:** Principal component analysis (PCA), Wavelets transforms, Autoencoder

# 주성분 분석 개요

---

Supervised feature selection: Information Gain, Stepwise regression, LASSO, Genetic algorithm

Supervised feature extraction: Partial least squares (PLS)

Unsupervised feature selection: PCA loading

**Unsupervised feature extraction:** Principal component analysis (PCA), Wavelets transforms, Autoencoder

# 주성분 분석 개요

**PCA의 개념:** 고차원 데이터를 효과적으로 분석하기 위한 대표적 분석 기법  
목적) 차원 축소, 군집화, 시각화, 압축 등

**PCA**는  $n$ 개 관측치,  $p$ 개 변수로 구성된 데이터를 **상관관계가 없는**  $k$ 개의 변수로 구성된 데이터로  
요약하는 방식으로, 이 때 요약된 변수는 **기존 변수의 선형 조합**으로 생성됨

원래 데이터의 **분산을 최대한 보존**하는 새로운 축을 찾고, 그 축에 데이터를 사영 시키는 기법

주요 목적은 데이터 차원 축소 ( $n$  by  $p \rightarrow n$  by  $k$ , where  $k << p$ )와 데이터 시각화 및 해석

전체 분석 과정 중 주로 초기에 사용됨 (변수 많을 때)

# 주성분 분석 개요

	$X_1$	$X_2$	...	$X_{p-1}$	$X_p$
1					
2					
...					
N-1					
N					

	$Z_1$	$Z_2$
1		
2		
...		
N-1		
N		

	$Z_1$	$Z_2$	$Z_3$
1			
2			
...			
N-1			
N			

$Z_1, Z_2, Z_3$ 은 기존 변수인  $X_1, X_2, \dots, X_p$ 의 선형 조합으로 새롭게 생성된 변수

# 주성분 분석 개요

Z is linear combination (선형 결합) of the original all p variables in X

$$Z_1 = \alpha_1^T X = \alpha_{11}X_1 + \alpha_{12}X_2 + \cdots + \alpha_{1p}X_p$$

$$Z_2 = \alpha_2^T X = \alpha_{21}X_1 + \alpha_{22}X_2 + \cdots + \alpha_{2p}X_p$$

$$\vdots \qquad \vdots$$

$$Z_p = \alpha_p^T X = \alpha_{p1}X_1 + \alpha_{p2}X_2 + \cdots + \alpha_{1p}X_p$$


$X_1, X_2, \dots, X_p$ : 원래 변수 (Original Variable)

$\alpha_i = [\alpha_{i1}, \alpha_{i2}, \dots, \alpha_{ip}]$ : i번째 기저(basis) 또는 계수 (Loading)


$Z_1, Z_2, \dots, Z_p$ : 각 기저로 사영 변환 후 변수 (주성분, Score)

# 주성분 분석 개요

**Find the new axis that  
maximizes the variance of data**




**Find the new axis that  
minimizes the variance of data**




# 주성분 분석 개요

**Find the new axis that  
maximizes the variance of data**




**Find the new axis that  
minimizes the variance of data**




# 주성분 분석 개요

Find the new axis that  
**maximizes** the variance of data




Find the new axis that  
**minimizes** the variance of data




# 주성분 분석 개요

Find the new axis that  
**maximizes** the variance of data




Find the new axis that  
**minimizes** the variance of data




# 주성분 분석 개요

Find the new axis that  
**maximizes** the variance of data




Find the new axis that  
**minimizes** the variance of data




# 주성분 분석 개요

Find the new axis that  
**maximizes** the variance of data




Find the new axis that  
**minimizes** the variance of data




# 주성분 분석 개요

Find the new axis that  
**maximizes** the variance of data



Find the new axis that  
**minimizes** the variance of data



# 주성분 분석 수리적 배경

변수 관측치	$X_1$	...	$X_i$	...	$X_p$
$N_1$	$X_{11}$	...	$X_{1i}$	...	$X_{1p}$
...	...	...	...	...	...
$N_i$	$X_{i1}$	...	$X_{ii}$	...	$X_{ip}$
...	...	...	...	...	...
$N_n$	$X_{n1}$	...	$X_{ni}$	...	$X_{np}$

$$\bar{X} = \begin{bmatrix} \bar{X}_1 \\ \bar{X}_2 \\ \vdots \\ \bar{X}_p \end{bmatrix}$$

Mean vector

$$C_n = \begin{bmatrix} S_{11} & \cdots & S_{1p} \\ \vdots & \ddots & \vdots \\ S_{p1} & \cdots & S_{pp} \end{bmatrix}$$

Covariance Matrix

$$R = \begin{bmatrix} 1 & r_{12} & \cdots & r_{1p} \\ r_{21} & 1 & \cdots & r_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ r_{p1} & r_{p2} & \cdots & 1 \end{bmatrix}$$

Correlation Matrix

# 주성분 분석 수리적 배경


- 공분산 (Covariance)의 성질
  - $X$ 를  $p$ 개의 변수와  $n$ 개의 개체로 구성된  $n$  by  $p$  행렬로 정의할 때  $X$ 의 공분산 행렬은 다음과 같음

$$Cov(X) = \frac{1}{n} (X - \bar{X}) (X - \bar{X})^T$$

- 공분산 행렬의 대각 성분은 각 변수의 분산과 같으며, 비대각행렬은 대응하는 두 변수의 공분산과 같음
- 데이터의 총분산은 공분산행렬의 대각성분들의 합으로 표현됨

# 주성분 분석 수리적 배경

- 사영 (Projection)
  - 한 벡터  $\vec{b}$ 를 다른 벡터  $\vec{a}$ 에 사영시킨다는 것은 벡터  $\vec{b}$ 로부터 벡터  $\vec{a}$ 에 수직인 점까지의 길이를 가지며 벡터  $\vec{a}$ 와 같은 방향을 갖는 벡터를 찾는다는 것을 의미



$$(\vec{b} - p\vec{a})^T \vec{a} = 0 \Rightarrow \vec{b}^T \vec{a} - p\vec{a}^T \vec{a} = 0 \Rightarrow p = \frac{\vec{b}^T \vec{a}}{\vec{a}^T \vec{a}}$$

$$\vec{x} = p\vec{a} = \frac{\vec{b}^T \vec{a}}{\vec{a}^T \vec{a}} \vec{a}$$

If  $\vec{a}$  is unit vector

$$p = \vec{b}^T \vec{a} \Rightarrow \vec{x} = p\vec{a} (\vec{b}^T \vec{a}) \vec{a}$$

# 주성분 분석 수리적 배경

---

- 고유값(eigenvalue) 및 고유벡터(eigenvector)
  - 어떤 행렬  $A$ 에 대해 상수  $\lambda$ 와 벡터  $x$ 가 다음 식을 만족할 때,  
 $\lambda$ 와  $x$ 를 각각 행렬  $A$ 의 고유값, 고유벡터라고 함

$$Ax = \lambda x \rightarrow (A - \lambda I)x = 0$$

- 벡터에 행렬을 곱한다는 것은 해당 벡터를 선형변환(linear transformation)한다는 의미 → 고유벡터는 이 변환에 의해 방향이 변하지 않는 벡터를 의미

# 주성분 분석 알고리즘 – 주성분 추출

- Assume that we have the centered data (i.e.,  $\bar{X}_i = 0$ ,  $i = 1, \dots, p$ )
- Let  $X$  be an  $p$ -dimensional random vector with the covariance matrix  $\Sigma$
- Let  $\alpha$  be an  $p$ -dimensional vector of length one (i.e.,  $\alpha^T \alpha = 1$ )
- Let  $Z = \alpha^T X$  be the projection of  $X$  onto the direction  $\alpha$

The main purpose in PCA is  
to find  $\alpha$  that produces the largest variance of  $Z$

$$\begin{aligned} \text{Max } Var(Z) &= Var(\alpha^T X) = \alpha^T \text{Var}(x) \alpha = \alpha^T \Sigma \alpha \\ \text{s.t. } \|\alpha\| &= \alpha^T \alpha = 1 \end{aligned}$$

# 주성분 분석 알고리즘 – 주성분 추출

$$\Sigma = E\Lambda E^T$$

$$\text{Max } \alpha^T \Sigma \alpha = \alpha^T E \Lambda E^T \alpha$$

$$\text{s.t. } \|\alpha\| = 1$$

$$\text{Max } \beta^T \Lambda \beta \text{ where } \beta = E^T \alpha$$

$$\text{s.t. } \|\beta\| = 1$$

$$\text{Max } \lambda_1 \beta_1^2 + \lambda_2 \beta_2^2 + \cdots + \lambda_p \beta_p^2$$

$$\text{s.t. } \beta_1^2 + \beta_2^2 + \cdots + \beta_p^2 = 1$$
$$\lambda_1 > \lambda_2 > \cdots > \lambda_p$$

eigenvalues and eigenvector of  $\Sigma$

$$[E \wedge V] = svd(\Sigma)$$

$$\lambda_1 \geq \cdots \lambda_p \geq 0$$

$$e_1, \dots, e_p$$

$$\Lambda = diag(\lambda_1, \dots, \lambda_p)$$

Thus, the optimal value is  $\lambda_1$  and  $\alpha = e_1$

# 주성분 분석 알고리즘 – 주성분 추출

$$\Sigma = E\Lambda E^T$$

$$\text{Max } \alpha^T \Sigma \alpha = \alpha^T E \Lambda E^T \alpha$$

$$\text{s.t. } \|\alpha\| = 1$$

$$\text{Max } \beta^T \Lambda \beta \text{ where } \beta = E^T \alpha$$

$$\text{s.t. } \|\beta\| = 1$$

$$\text{Max } \lambda_1 \beta_1^2 + \lambda_2 \beta_2^2 + \cdots + \lambda_p \beta_p^2$$

$$\text{s.t. } \beta_1^2 + \beta_2^2 + \cdots + \beta_p^2 = 1$$
$$\lambda_1 > \lambda_2 > \cdots > \lambda_p$$

eigenvalues and eigenvector of  $\Sigma$

$$[E \wedge V] = svd(\Sigma)$$

$$\lambda_1 \geq \cdots \lambda_p \geq 0$$

$$e_1, \dots, e_p$$

$$\Lambda = diag(\lambda_1, \dots, \lambda_p)$$

$$\begin{bmatrix} \lambda_1 & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \lambda_2 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \lambda_p \end{bmatrix}$$

Thus, the optimal value is  $\lambda_1$  and  $\alpha = e_1$

# 주성분 분석 알고리즘 – 주성분 추출

$$\Sigma = E\Lambda E^T$$

$$\text{Max } \alpha^T \Sigma \alpha = \alpha^T E \Lambda E^T \alpha$$

$$\text{s.t. } \|\alpha\| = 1$$

$$\text{Max } \beta^T \Lambda \beta \text{ where } \beta = E^T \alpha$$

$$\text{s.t. } \|\beta\| = 1$$

$$\text{Max } \lambda_1 \beta_1^2 + \lambda_2 \beta_2^2 + \cdots + \lambda_p \beta_p^2$$

$$\beta_1 = 1$$

$$\text{s.t. } \beta_1^2 + \beta_2^2 + \cdots + \beta_p^2 = 1$$

$$\beta_2 = 0$$

$$\lambda_1 > \lambda_2 > \cdots > \lambda_p$$

$$\begin{matrix} \vdots \\ \beta_p = 0 \end{matrix}$$

eigenvalues and eigenvector of  $\Sigma$

$$[E \wedge V] = svd(\Sigma)$$

$$\lambda_1 \geq \cdots \geq \lambda_p \geq 0$$

$$e_1, \dots, e_p$$

$$\Lambda = diag(\lambda_1, \dots, \lambda_p)$$

$$\begin{bmatrix} \lambda_1 & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \lambda_2 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \lambda_p \end{bmatrix}$$

Thus, the optimal value is  $\lambda_1$  and  $\alpha = e_1$

# 주성분 분석 알고리즘 – 주성분 추출

$$\Sigma = E\Lambda E^T$$

$$\text{Max } \alpha^T \Sigma \alpha = \alpha^T E \Lambda E^T \alpha$$

$$\text{s.t. } \|\alpha\| = 1$$

$$\text{Max } \beta^T \Lambda \beta \text{ where } \beta = E^T \alpha$$

$$\text{s.t. } \|\beta\| = 1$$

$$\text{Max } \lambda_1 \beta_1^2 + \lambda_2 \beta_2^2 + \cdots + \lambda_p \beta_p^2$$

$$\text{s.t. } \beta_1^2 + \beta_2^2 + \cdots + \beta_p^2 = 1$$

$$\lambda_1 > \lambda_2 > \cdots > \lambda_p$$

$$\beta_1 = 1$$

$$\beta_2 = 0 \quad \alpha = E\beta$$

$$\begin{matrix} \vdots \\ \beta_p = 0 \end{matrix}$$

eigenvalues and eigenvector of  $\Sigma$

$$[E \wedge V] = svd(\Sigma)$$

$$\lambda_1 \geq \cdots \geq \lambda_p \geq 0$$

$$e_1, \dots, e_p$$

$$\Lambda = diag(\lambda_1, \dots, \lambda_p)$$

$$\begin{bmatrix} \lambda_1 & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \lambda_2 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \lambda_p \end{bmatrix}$$

Thus, the optimal value is  $\lambda_1$  and  $\alpha = e_1$

# 주성분 분석 알고리즘 – 주성분 추출

$$\Sigma = E\Lambda E^T$$

$$\text{Max } \alpha^T \Sigma \alpha = \alpha^T E \Lambda E^T \alpha$$

$$\text{s.t. } \|\alpha\| = 1$$

$$\text{Max } \beta^T \Lambda \beta \text{ where } \beta = E^T \alpha$$

$$\text{s.t. } \|\beta\| = 1$$

$$\text{Max } \lambda_1 \beta_1^2 + \lambda_2 \beta_2^2 + \cdots + \lambda_p \beta_p^2$$

$$\text{s.t. } \beta_1^2 + \beta_2^2 + \cdots + \beta_p^2 = 1$$

$$\lambda_1 > \lambda_2 > \cdots > \lambda_p$$

$$\begin{aligned} \beta_1 &= 1 \\ \beta_2 &= 0 \\ &\vdots \\ \beta_p &= 0 \end{aligned}$$

$$\alpha = E\beta = [e_1 \ \cdots \ e_p]$$

eigenvalues and eigenvector of  $\Sigma$

$$[E \wedge V] = svd(\Sigma)$$

$$\lambda_1 \geq \cdots \geq \lambda_p \geq 0$$

$$e_1, \dots, e_p$$

$$\Lambda = diag(\lambda_1, \dots, \lambda_p)$$

$$\left[ \begin{array}{cccc} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \lambda_p \end{array} \right]$$

Thus, the optimal value is  $\lambda_1$  and  $\alpha = e_1$

# 주성분 분석 예제

$X =$

$X_1$	$X_2$	$X_3$
0.2	5.6	3.56
0.45	5.89	2.4
0.33	6.37	1.95
0.54	7.9	1.32
0.77	7.87	0.98

$X =$

$X_1$	$X_2$	$X_3$
-1.1930	-1.0300	1.5012
-0.0370	-0.7647	0.3540
-0.5919	-0.3257	-0.0910
0.3792	1.0739	-0.7140
1.4427	1.0464	-1.0502

normalize X to  
 $E(X_i) = 0$   
 $\text{Var}(X_i) = 1$

# 주성분 분석 예제

$X =$

$X_1$	$X_2$	$X_3$
0.2	5.6	3.56
0.45	5.89	2.4
0.33	6.37	1.95
0.54	7.9	1.32
0.77	7.87	0.98

$X =$

$X_1$	$X_2$	$X_3$
-1.1930	-1.0300	1.5012
-0.0370	-0.7647	0.3540
-0.5919	-0.3257	-0.0910
0.3792	1.0739	-0.7140
1.4427	1.0464	-1.0502

normalize X to  
 $E(X_i) = 0$   
 $\text{Var}(X_i) = 1$

$\text{Covariance}(X) =$

0.0468	0.1990	-0.1993
0.1990	1.1951	-1.0096
-0.1993	-1.0096	1.0225

$\text{Correlation}(X) =$

1	0.8417	-0.8840
0.8417	1	-0.9133
-0.8840	-0.9133	1

# 주성분 분석 예제

The eigenvalue-eigenvector pairs on the correlation matrix,  $\Sigma$

$$[E \wedge V] = svd(\Sigma)$$

$$\lambda_1 = 0.0786,$$

$${e_1}^T = [0.2590 \quad 0.5502 \quad 0.7938]$$

$$\lambda_2 = 0.1618,$$

$${e_2}^T = [0.7798 \quad -0.6041 \quad 0.1643]$$

$$\lambda_3 = 2.7596,$$

$${e_3}^T = [0.5699 \quad 0.5765 \quad -0.5855]$$

# 주성분 분석 예제

$$\lambda_1 = 0.0786, e_1^T = [0.2590 \quad 0.5502 \quad 0.7938]$$

$$\lambda_2 = 0.1618, e_2^T = [0.7798 \quad -0.6041 \quad 0.1643]$$

$$\lambda_3 = 2.7596, e_3^T = [0.5699 \quad 0.5765 \quad -0.5855]$$

**X =**

$$\lambda_3 > \lambda_2 > \lambda_1$$

<b><math>X_1</math></b>	<b><math>X_2</math></b>	<b><math>X_3</math></b>
<b>-1.1930</b>	<b>-1.0300</b>	<b>1.5012</b>
<b>-0.0370</b>	<b>-0.7647</b>	<b>0.3540</b>
<b>-0.5919</b>	<b>-0.3257</b>	<b>-0.0910</b>
<b>0.3792</b>	<b>1.0739</b>	<b>-0.7140</b>
<b>1.4427</b>	<b>1.0464</b>	<b>-1.0502</b>

normalize X to  
 $E(X_i) = 0$   
 $\text{Var}(X_i) = 1$

# 주성분 분석 예제

$$\lambda_1 = 0.0786, e_1^T = [0.2590 \quad 0.5502 \quad 0.7938]$$

$$\lambda_2 = 0.1618, e_2^T = [0.7798 \quad -0.6041 \quad 0.1643]$$

$$\lambda_3 = 2.7596, e_3^T = [0.5699 \quad 0.5765 \quad -0.5855]$$

$$\mathbf{X} =$$

$X_1$	$X_2$	$X_3$
-1.1930	-1.0300	1.5012
-0.0370	-0.7647	0.3540
-0.5919	-0.3257	-0.0910
0.3792	1.0739	-0.7140
1.4427	1.0464	-1.0502

$$\lambda_3 > \lambda_2 > \lambda_1$$

normalize X to  
 $E(X_i) = 0$   
 $\text{Var}(X_i) = 1$

$$Z_1 = e_3^T X = 0.5699 \cdot X_1 + 0.5765 \cdot X_2 - 0.5855 \cdot X_3 = 0.5699 \cdot \begin{bmatrix} -1.1930 \\ -0.0370 \\ -0.5919 \\ 0.3792 \\ 1.4427 \end{bmatrix} + 0.5765 \cdot \begin{bmatrix} -1.0300 \\ -0.7647 \\ -0.3257 \\ 1.0739 \\ 1.0464 \end{bmatrix} - 0.5855 \cdot \begin{bmatrix} 1.5012 \\ 0.3540 \\ -0.0910 \\ -0.7140 \\ -1.0502 \end{bmatrix} = \begin{bmatrix} -2.1527 \\ -0.6692 \\ -0.4718 \\ 1.2533 \\ 2.0404 \end{bmatrix}$$

# 주성분 분석 예제

$$\lambda_1 = 0.0786, e_1^T = [0.2590 \quad 0.5502 \quad 0.7938]$$

$$\lambda_2 = 0.1618, e_2^T = [0.7798 \quad -0.6041 \quad 0.1643]$$

$$\lambda_3 = 2.7596, e_3^T = [0.5699 \quad 0.5765 \quad -0.5855]$$

$$X =$$

$X_1$	$X_2$	$X_3$
-1.1930	-1.0300	1.5012
-0.0370	-0.7647	0.3540
-0.5919	-0.3257	-0.0910
0.3792	1.0739	-0.7140
1.4427	1.0464	-1.0502

normalize X to  
 $E(X_i) = 0$   
 $\text{Var}(X_i) = 1$

$$\lambda_3 > \lambda_2 > \lambda_1$$

$$Z_1 = e_3^T X = 0.5699 \cdot X_1 + 0.5765 \cdot X_2 - 0.5855 \cdot X_3 = 0.5699 \cdot \begin{bmatrix} -1.1930 \\ -0.0370 \\ -0.5919 \\ 0.3792 \\ 1.4427 \end{bmatrix} + 0.5765 \cdot \begin{bmatrix} -1.0300 \\ -0.7647 \\ -0.3257 \\ 1.0739 \\ 1.0464 \end{bmatrix} - 0.5855 \cdot \begin{bmatrix} 1.5012 \\ 0.3540 \\ -0.0910 \\ -0.7140 \\ -1.0502 \end{bmatrix} = \begin{bmatrix} -2.1527 \\ -0.6692 \\ -0.4718 \\ 1.2533 \\ 2.0404 \end{bmatrix}$$

$$Z_2 = e_2^T X = \begin{bmatrix} -0.0615 \\ 0.4912 \\ -0.2798 \\ -0.4703 \\ 0.3204 \end{bmatrix} \quad Z_3 = e_1^T X = \begin{bmatrix} 0.3160 \\ -0.1493 \\ -0.4047 \\ 0.1223 \\ 0.1157 \end{bmatrix}$$

# 주성분 분석 예제

$$\lambda_1 = 0.0786, e_1^T = [0.2590 \quad 0.5502 \quad 0.7938]$$

$$\lambda_2 = 0.1618, e_2^T = [0.7798 \quad -0.6041 \quad 0.1643]$$

$$\lambda_3 = 2.7596, e_3^T = [0.5699 \quad 0.5765 \quad -0.5855]$$

$$X =$$

$X_1$	$X_2$	$X_3$
-1.1930	-1.0300	1.5012
-0.0370	-0.7647	0.3540
-0.5919	-0.3257	-0.0910
0.3792	1.0739	-0.7140
1.4427	1.0464	-1.0502

normalize X to  
 $E(X_i) = 0$   
 $\text{Var}(X_i) = 1$

$$\lambda_3 > \lambda_2 > \lambda_1$$

$$Z_1 = e_3^T X = 0.5699 \cdot X_1 + 0.5765 \cdot X_2 - 0.5855 \cdot X_3 = 0.5699 \cdot \begin{bmatrix} -1.1930 \\ -0.0370 \\ -0.5919 \\ 0.3792 \\ 1.4427 \end{bmatrix} + 0.5765 \cdot \begin{bmatrix} -1.0300 \\ -0.7647 \\ -0.3257 \\ 1.0739 \\ 1.0464 \end{bmatrix} - 0.5855 \cdot \begin{bmatrix} 1.5012 \\ 0.3540 \\ -0.0910 \\ -0.7140 \\ -1.0502 \end{bmatrix} = \begin{bmatrix} -2.1527 \\ -0.6692 \\ -0.4718 \\ 1.2533 \\ 2.0404 \end{bmatrix}$$

$$Z_2 = e_2^T X = \begin{bmatrix} -0.0615 \\ 0.4912 \\ -0.2798 \\ -0.4703 \\ 0.3204 \end{bmatrix}$$

$$Z_3 = e_1^T X = \begin{bmatrix} 0.3160 \\ -0.1493 \\ -0.4047 \\ 0.1223 \\ 0.1157 \end{bmatrix}$$

$$\therefore Z = \begin{bmatrix} -2.1527 & -0.0615 & 0.3160 \\ -0.6692 & 0.4912 & -0.1493 \\ -0.4718 & -0.2798 & -0.4047 \\ 1.2533 & -0.4703 & 0.1223 \\ 2.0404 & 0.3204 & 0.1157 \end{bmatrix}$$

## 주성분 분석 예제

$$Z = \begin{bmatrix} -2.1527 & -0.0615 & 0.3160 \\ -0.6692 & 0.4912 & -0.1493 \\ -0.4718 & -0.2798 & -0.4047 \\ 1.2533 & -0.4703 & 0.1223 \\ 2.0404 & 0.3204 & 0.1157 \end{bmatrix}$$

$$Cov(Z) = \begin{bmatrix} 2.7596 & 0 & 0 \\ 0 & 0.1618 & 0 \\ 0 & 0 & 0.0786 \end{bmatrix}$$

주성분 (Z)들은 서로 독립

# 주성분 분석 예제

$X =$

$X_1$	$X_2$	$X_3$
-1.1930	-1.0300	1.5012
-0.0370	-0.7647	0.3540
-0.5919	-0.3257	-0.0910
0.3792	1.0739	-0.7140
1.4427	1.0464	-1.0502

$Z =$

$Z_1$	$Z_2$	$Z_3$
-2.1527	-0.0615	0.3160
-0.6692	0.4912	-0.1493
-0.4718	-0.2798	-0.4047
1.2533	-0.4703	0.1223
2.0404	0.3204	0.1157

주성분 몇 개 사용?

# 주성분 분석 예제

Eigenvalues of the covariance matrix ( $\lambda_1, \lambda_2, \lambda_3$ )

= Variance of each principal component (각 주성분의 분산)

Covariance matrix of principal components


$$Cov(Z) = \begin{bmatrix} 2.7596 & 0 & 0 \\ 0 & 0.1618 & 0 \\ 0 & 0 & 0.0786 \end{bmatrix}$$

$Var(Z_1) = 2.7596 = \lambda_3$  (Largest eigenvalue)  
 $Var(Z_2) = 0.1618 = \lambda_2$   
 $Var(Z_3) = 0.0786 = \lambda_1$

Proportion of total population  
Variance due to the 1<sup>st</sup>  
Principal component

$$= \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} = \frac{2.7596}{0.0786 + 0.1618 + 2.7596} = 0.920$$

# 주성분 분석 예제



선택방식 1: 고유값 감소율이 유의미하게 낮아지는  
Elbow Point에 해당하는 주성분 수를 선택

선택방식 2: 일정 수준 이상의 분산비를 보존하는  
최소의 주성분을 선택 (70% 이상)

# 주성분 분석 알고리즘 요약

Step 1. 데이터 정규화 (mean centering)

Step 2. 기존 변수의 covariance (correlation) matrix 계산

Step 3. Covariance (correlation) matrix로부터 eigenvalue 및 이에 해당되는 eigenvector를 계산

Step 4. eigenvalue 및 해당되는 eigenvectors를 순서대로 나열

$$\lambda(1) > \lambda(2) > \lambda(3) > \lambda(4) > \lambda(5)$$

$$e(1) > e(2) > e(3) > e(4) > e(5), \quad e(i), \quad i = 1, \dots, 5 \text{ is a vector}$$

Step 5. 정렬된 eigenvector를 토대로 기존 변수를 변환

$$Z_1 = e(1)X = e_{11} \cdot X_1 + e_{12} \cdot X_2 + \dots + e_{15} \cdot X_5$$

$$Z_2 = e(2)X = e_{21} \cdot X_1 + e_{22} \cdot X_2 + \dots + e_{25} \cdot X_5$$

$$\dots \qquad \qquad = \qquad \qquad \dots$$

$$Z_5 = e(5)X = e_{51} \cdot X_1 + e_{52} \cdot X_2 + \dots + e_{55} \cdot X_5$$

# Thank you