

## MDS 개요

### Dimension Reduction

- $(n \times p)$  데이터 행렬의 차원 축소를 통해 내재된 구조 발견
- 변수  $p$  축소
  - 주성분 분석 ( $Y=LX$ ): 원변수 선형결합, 선형계수  $L$  (loading 값)
  - 요인분석 ( $X=LF$ ): 원변수 그룹, 요인점수( $F$ )
- 개체  $n$  축약
  - 군집분석: 유사성(거리) 개념으로 개체 군집화

### 범주형 데이터 차원 축약?

- 변수 축약
  - 변수들간의 연관관계는 교차표(분할표)에 의해서 표현되므로 상관관계 값에 의한 변수의 축약은 가능하지 않음
- 개체 축약
  - 개체간의 유사성(거리)을 측정할 수 있나? 범주형 변수의 범주(가질 수 있는 값)는 빈도로만 정리할 수 있는데...

### MDS 개념

- $n$ 개의 개체를 2차원 가시적 공간에 나타내는 방법
- 각 개체간 유사성(similarity) 혹은 거리는 저차원으로 옮겨지더라도 원래 유사성 크기를 갖는다.
- 유사성 개념
  - 개체를 저 차원 가시적 공간(2차원)에 나타내려면 각 개체간 거리(유사성)를 측정해야 한다.
  - MDS는 개체(행), 변수(열) 모두 저차원 공간 표현 가능

### 개체간 유사성 측정

- metric 방법
  - Euclidean distance ▶ (측정형 변수 거리)
  - 각 개체의 유사성(거리)을 사람들이 리커드 척도나 순위 평가
  - 유사성을 계산하여 개체를 분류하는 면에서는 군집분석과 유사
  - 군집분석은 개체를 군집화 하고, 주성분 점수에 의해 개체를 표현하나, MDS는 유사성에 의해 단지 2차원 공간에 표현
- non-Metric 방법
  - 평가자 들이 개체를 주관적으로 분류하게 하고 그로부터 얻어지는 빈도로부터 유사성을 측정



MDS (개념, 페이지 278)

■ 개체를 저차원 공간에 표현

- 개체의 유사성(similarity)의 상대적 크기를 2-3차원 공간에 표현

■ 유사성 측정


■ Metric 방법

- 개체 (i, j) 유사성: 거리 개념
- 변수 유형  $S_{ij} = \sqrt{(x_{i1} - x_{j1})^2 + (x_{i2} - x_{j2})^2 + \dots + (x_{ip} - x_{jp})^2}$ 
  - 개체 속성을 측정하는 변수: 군집분석의 변량과 동일
  - 리커트 척도, 우선 순위: (회사 1, 회사2, 회사3, ...) 혹은 (속성1, 속성2, 속성3, ...)
  - (p>2)일 때도 유사성(거리)을 계산

■ Non-metric 방법

- 개체에 대한 빈도표를 이용
- (상대)빈도(f<sub>ij</sub>)가 개체간 유사성 (S<sub>ij</sub>) 측정

	변수	X <sub>1</sub>	X <sub>2</sub>	...	X <sub>p</sub>
개체					
1		x <sub>11</sub>	x <sub>12</sub>	...	x <sub>1p</sub>
2		x <sub>21</sub>	x <sub>22</sub>	...	x <sub>2p</sub>
↓		↓	↓	...	↓
n		x <sub>n1</sub>	x <sub>n2</sub>	...	x <sub>np</sub>



■ 예제 (non-metric)

- 유사 상품 분류: 마케팅 전문가 15명에게 n개 상품을 주관적인 판단에 의해 임의로 분류하게 한 후 상대빈도표(?/15) 작성
- 예: (상품 (1, 2) 유사성 계산) 상품 (1, 2)를 동일 군집으로 분류한 전문가가 10명이라면 유사성은 10/15가 된다.

■ 예제 (metric)

- Under-arm Deodorant 생산 회사에서 판매 전략을 세우기 위하여 각 제품들이 서로 얼마나 유사한지(가까운지) 알아보려고 한다. 이를 위하여 소비자를 임의로 선택하여 제품의 각 분야(향기, 냄새 제거 정도, 사용 편리 정도, 옷에 묻어나는 정도)를 10점 만점으로 평가
  - 고객 평가점수에 의한 제품의 유사성 정도를 2차원 공간에 표현
  - 제품 평가 유사성에 따른 고객 세분화

	개체	1	2	...	n
개체					
1		0			
2		S <sub>21</sub>	0		
↓		↓	↓	0	
n		S <sub>n1</sub>	S <sub>n2</sub>	...	0



**MDS (알고리즘, 페이지 280)**

▪ **표현 방법**

- 각 개체간 유사성(거리)을 측정한다.
- 개체의 개수가 n개인 경우 k=n(n-1)/n개 유사성 그룹이 존재한다.
- 유사성이 작은 것부터 크기 순으로 배열한다.
  - 이를 이용하여 개체를 m(= 2)차원으로 공간으로 줄일 경우 개체간의 거리를 구한다.
- 임의의 한 좌표에 한 개체를 표현하고 나머지 개체들은 상대적 유사성을 고려하여 좌표에 표현한다.

▪ **Stress 값**

- 2차원 공간으로 줄일 수 있는지를 알아 보는 측정치
- Sr은 차원이 2차원으로 줄었을 때 개체의 유사성

$stress = \frac{[\sum_{i<j} (S_{ij} - S_{ij}^r)^2 / S_{ij}]}{\sum_{i<j} (S_{ij})}$	Stress	Goodness of fits
	20%	Poor
	10%	Fair
	5%	Good
	2.5%	Excellent

▪ **차원(dimension)과 위치(coordination)의 의미**

- 아무 의미 없음
- 개체 간 유사성은 얼마나 가까이 있느냐에 의해 해석됨

▪ **예제 데이터 CITY.xls**

- 미국 도시간 거리(도시간 유사성)
- 개체 유사성 행렬 (similarity matrix)

ID	Altanta	Chicago	Denver	Houston	LA	Miami	NY	SF	Seattles	DC
Altanta	0									
Chicago	567	0								
Denver	1212	920	0							
Houston	701	940	879	0						
LA	1936	1745	831	1374	0					
Miami	604	1188	1726	968	2339	0				
NY	748	713	1631	1420	2451	1092	0			
SF	2139	1858	949	1645	347	259	2571	0		
Seattles	2128	1737	1021	1891	959	2734	2408	678	0	
DC	543	597	1494	1220	2300	923	205	2442	2329	0

http://wolfpack.hnu.ac.kr



▪ R 프로그램

```
> city=read.table("도시거리.csv",header=T,
+ sep=";",na.string=".")
> citys=city[2:10,2:10]
> citys
      Altanta Chicago Denver Houston   LA Miami  NY
2      567      NA      NA      NA  NA  NA  NA
3     1212      920      NA      NA  NA  NA  NA
4      701      940      879      NA  NA  NA  NA
5     1936     1745      831     1374  NA  NA  NA
6      604     1188     1726      968 2339  NA  NA
7      748      713     1631     1420 2451 1092  NA
8     2139     1858      949     1645   347   259 2571
9     2128     1737     1021     1891   959  2734 240E
10     543      597     1494     1220 2300   923   20E
> city.mds=cmdscale(citys,eig=TRUE, k=2)
이하에 예러cmdscale(citys, eig = TRUE, k = 2) :
'd'에서 NA값은 허용되지 않습니다
```

- I just give up? I don't know how to delete "NA"

▪ 결과

```
> city=read.table("도시거리.csv",header=F,
+ sep=";",fill=T,flush=T)
> citys=city[3:11,2:10]
> citys0=citys
> fix(citys)
> city=read.table("도시거리.csv",header=F,
+ sep=";",fill=T,flush=T)
> citys=city[3:11,2:10]
> citys0=citys
> fix(citys)
```

R 자료 편집기

	row.names	V2	V3	V4	V5
1	3	567			
2	4	1212	920		
3	5	701	940	879	
4	6	1936	1745	831	1374
5	7	604	1188	1726	968
6	8	748	713	1631	1420



# 페이지 (페이지 290)

## ■ 예제 데이터 CITY1.xls

- 경제적 변인에 의해 도시를 군집화 하려 한다. 도시 이름, 12개 직종 노동시간 가중 평균(work), 물가(price), 시간당 임금(salary)

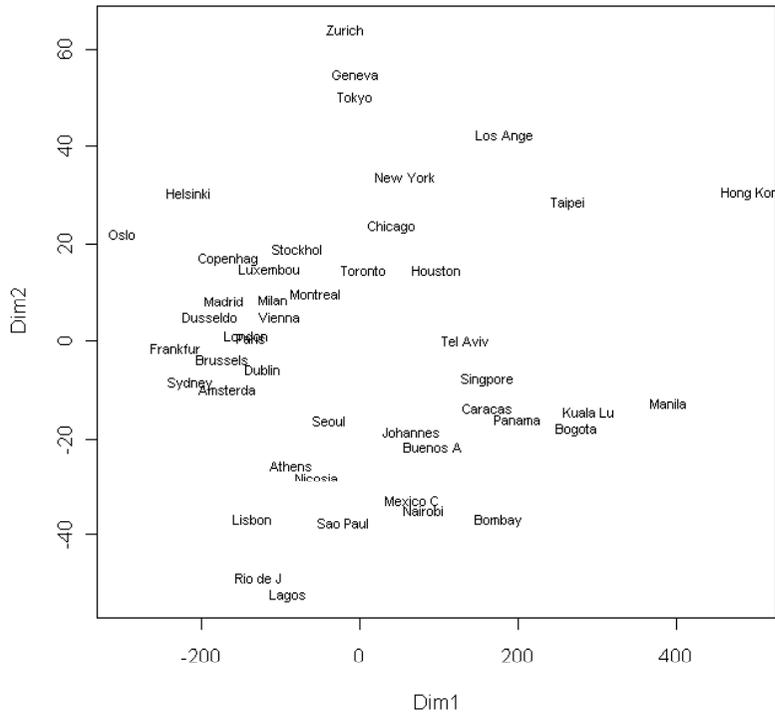
```
> city2=read.table("도시경제.csv",header=T,
+ sep=";",na.string=".")
> city2s=city2[,2:4]
> city.d=dist(city2s)
> city.mds=cmdscale(city.d,eig=TRUE, k=2)
>
> # plot solution
> x=city.mds$points[,1]
> y=city.mds$points[,2]
> plot(x, y, xlab="Dim1", ylab="Dim2",
+ main="미국도시 MDS", type="n")
> text(x, y, labels=city2$City, cex=.7)
```

```
> city2
```

	City	Work	Price	Salary
1	Amsterda	1714	66	49
2	Athens	1792	54	30
3	Bogota	2152	38	12
4	Bombay	2052	30	5
5	Brussels	1708	74	51
6	Buenos A	1971	56	13

## ■ 결과

미국도시 MDS



```
> city.d
```

	1	2	3	4
2	81.172655			
3	440.450905	360.804656		
4	342.747721	262.299447	100.563413	
5	10.198039	88.865066	447.161045	349.839963
6	259.701752	179.816573	181.895574	85.445889

http://wolfpack.hnu.ac.kr



# Correspondence Analysis 개요 (페이지 294)

http://wolfpack.hnu.ac.kr

## ■ 개념

- 범주형 변수 범주의 유사성 표현
- 교차표(분할표)로 나타내어지는 자료의 행과 열 범주를 저차원 공간상(2차원)의 좌표로 표현하여 관계를 탐구하려는 탐색적 자료 분석 기법

## ■ 기원

- 대응분석의 수리적인 기원은 1930년대 Hirshfeld의 논문 『상관관계와 분할표의 연관성』
- 대응분석의 기하적인 면은 1960년대 프랑스에서 Jean-Paul Benzecri에 의해서 발전되었다.
- 일본: 1950년대 Chikio Hayashi에 의해서 수량화 제3방법으로 개발되어 발전
- 프랑스: 1960년대 Jean-Paul Benzecri가 이끄는 자료분석 모임이 다양한 분야로부터 수집된 자료를 분석하는데 대응분석 기법을 응용하고 발전

$$\text{검정통계량} = \frac{\sum_{i=1}^k (O_i - E_i)^2}{E_i} \sim \chi^2(k-1)$$

## ■ RXC 분할표

Y \ X	1	2	...	C	Total
1	$\pi_{11}$	$\pi_{12}$	...	$\pi_{1c}$	$\pi_{1+}$
2	$\pi_{21}$	$\pi_{22}$	...	$\pi_{2c}$	$\pi_{2+}$
...	...	...	...	...	...
R	$\pi_{r1}$	$\pi_{r2}$	...	$\pi_{rc}$	$\pi_{r+}$
Total	$\pi_{+1}$	$\pi_{+2}$	...	$\pi_{+c}$	$\pi_{++}$

- $\pi_{ij}$ : (X, Y) 결합밀도함수
- $\pi_{i+}$ : (X) 주변밀도함수
- $\pi_{+j}$ : (Y) 주변밀도함수

## ■ Homogeneity (동질성)

- 각 행에 대해 열의 분포가 동일한가?

## ■ Independence (독립성) $H_0: \pi_{ij} = \pi_{kj}$ for $j=1,2,\dots,c$ and $k \neq i$

- (X, Y)는 서로 독립인가?

$$H_0: \pi_{ij} = \pi_{i+}\pi_{+j}$$

## ■ 결과 해석

- $\chi^2$ 검정 결과 p-value(유의확률) 0.05보다 적으면 두 변수 상관관계 존재
- 관계 해석: 행 퍼센트 혹은 열 퍼센트에 의한 차이 해석
- $R \times C$  셀이 많아지면 퍼센트에 의한 해석이 복잡해지고 신뢰도가 떨어짐
- 행 범주, 열 범주의 유사성 정도를 표현하지 못함



# Correspondence Analysis (페이지 295)

http://wolfpack.hnu.ac.kr

▪ Notation

- $n_{ij}$ : (i, j) 셀 관측빈도
- $n_{i+}$ : (i)번째 행의 관측빈도 합
- $n_{+j}$ : (j)번째 열의 관측빈도 합

▪ 방법

- (i, j) 셀의 빈도  $n_{ij} (\geq 0)$ 의 i번째 행 ( $n_{i1}, \dots, n_{ic}$ )은 총빈도가  $n_{i+} = n_{i1} + \dots + n_{ic}$  이고 C개 범주를 갖는 다항 분포
- Multinomial 분포의 대응 확률은 상대빈도  $f_{ij} = n_{ij} / n_{i+}$ : 이것을 행 프로파일 (row profile)이라 정의
- 각 행의 상대적 빈도  $f_{i+} = f_{i1} + \dots + f_{ic}$  를 선형계수로 (주성분 분석과 유사) 하여 좌표 계산
- $r_i = (f_{i1} / f_{i+}, f_{i2} / f_{i+}, \dots, f_{ic} / f_{i+})$ 는 C 차원 가중 Euclid 공간의 좌표
- 가중(weighted) Euclid 공간이란 두 개의 좌표  $r_a, r_b$  사이의 거리가 다음과 같이 정의

•  $f_{+j} = f_{1j} + \dots + f_{rj}$

$$d(r_a, r_b) = \sqrt{\sum_j \left( \frac{f_{aj}}{f_{a+}} - \frac{f_{bj}}{f_{b+}} \right)^2 / f_{+j}}$$

- 같은 방식으로 열 프로파일의 좌표 및 개체 거리 계산
- 행, 열 프로파일을 각각 2차원 공간에 표현하거나 동시에 표현

	Y	1	2	...	C	Total
X						
1		$n_{11}$	$n_{12}$	...	$n_{1c}$	$n_{1+}$
2		$n_{21}$	$n_{22}$	...	$n_{2c}$	$n_{2+}$
...		...	...	...	...	...
R		$n_{r1}$	$n_{r2}$	...	$n_{rc}$	$n_{r+}$
Total		$n_{+1}$	$n_{+2}$	...	$n_{+c}$	$n_{++}$

▪ 예제 데이터

- 학과별 영어등급 조사한 데이터이다.

	전공	영어등급	빈도
1	경영	A	78
2	경영	B	22
3	경영	C	20
4	경제	A	65
5	경제	B	8
6	경제	C	2
7	통계	A	68
8	통계	B	30
9	통계	C	7



# 대응분석 (예제)

## R 프로그램

```

> # Correspondence Analysis
> c1=cbind(rep("경영",c(78)),rep("A",c(78)))
> c2=cbind(rep("경영",c(22)),rep("B",c(22)))
> c3=cbind(rep("경영",c(20)),rep("c",c(20)))
> c4=cbind(rep("경제",c(65)),rep("A",c(65)))
> c5=cbind(rep("경제",c(8)),rep("B",c(8)))
> c6=cbind(rep("경제",c(2)),rep("c",c(2)))
> c7=cbind(rep("동계",c(68)),rep("A",c(68)))
> c8=cbind(rep("동계",c(30)),rep("B",c(30)))
> c9=cbind(rep("동계",c(7)),rep("c",c(7)))
> mydata=data.frame(rbind(c1,c2,c3,c4,c5,c6,c7,c8,c9))
> names(mydata)
[1] "X1" "X2"
> length(mydata$X1)
[1] 300

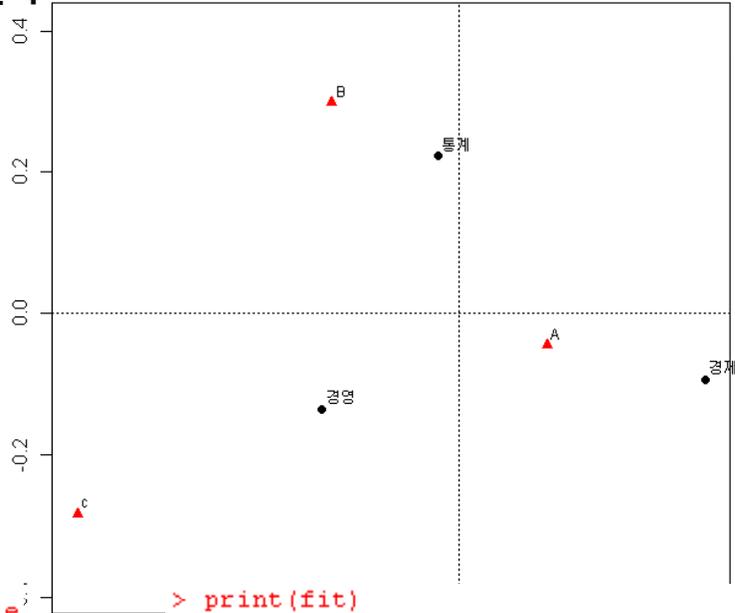
> library(ca)
> mytable=with(mydata, table(X1,X2)) # create a 2 way table
> prop.table(mytable, 1) # row percentages
      X2
X1     A         B         c
경영 0.65000000 0.18333333 0.16666667
경제 0.86666667 0.10666667 0.02666667
동계 0.64761905 0.28571429 0.06666667

> prop.table(mytable, 2) # column percentages
      X2
X1     A         B         c
경영 0.36966825 0.36666667 0.68965517
경제 0.30805687 0.13333333 0.06896552
동계 0.32227488 0.50000000 0.24137931

> fit=ca(mytable)

```

## 결과



```

> print(fit)

Principal inertias (eigenvalues):
      Value      Percentage
1 0.046172 63.12%
2 0.026982 36.88%

Rows:
      Mass      ChiDist      Inertia      Dim. 1      Dim. 2
경영 0.400000 0.236902 0.022449 -0.903071  -0.827323
경제 0.250000 0.363560 0.033044  1.633900  -0.574778
동계 0.350000 0.224630 0.017660 -0.134991  1.356068

```

http://wolfpack.hnu.ac.kr

