

# Machine Learning

-KNN, Cluster Analysis-

SCH Univ.  
Dept. of AI and Bigdata  
Kim JinSeong

# Contents

1. K-Nearest Neighbor (KNN)

2. Cluster Analysis

# K-Nearest Neighbor (KNN)

# Model for Classification and Prediction

---

- Model-Based Learning

- 선형/비선형모델 (e.g., linear regression, logistic regression)
- Neural Network
- Decision Tree
- Support Vector Machine

➔ 데이터로부터 모델을 생성하여 분류/예측 진행

- Instance-Based Learning

- K-Nearest Neighbor (KNN)
- Locally weighted regression

➔ 별도의 모델 생성 없이 인접 데이터를 분류/예측에 사용

# Model for Classification and Prediction

---

- Model-Based Learning

- 선형/비선형모델 (e.g., linear regression, logistic regression)
- Neural Network
- Decision Tree
- Support Vector Machine

➔ 데이터로부터 모델을 생성하여 분류/예측 진행

(1)



분류/예측 모델

- Instance-Based Learning

- K-Nearest Neighbor (KNN)
- Locally weighted regression

➔ 별도의 모델 생성 없이 인접 데이터를 분류/예측에 사용


# Model for Classification and Prediction

---

- Model-Based Learning

- 선형/비선형모델 (e.g., linear regression, logistic regression)
- Neural Network
- Decision Tree
- Support Vector Machine

➔ 데이터로부터 모델을 생성하여 분류/예측 진행



- Instance-Based Learning

- K-Nearest Neighbor (KNN)
- Locally weighted regression

➔ 별도의 모델 생성 없이 인접 데이터를 분류/예측에 사용

# Model for Classification and Prediction

---

- Model-Based Learning

- 선형/비선형모델 (e.g., linear regression, logistic regression)
- Neural Network
- Decision Tree
- Support Vector Machine

➔ 데이터로부터 모델을 생성하여 분류/예측 진행

- Instance-Based Learning

- K-Nearest Neighbor (KNN)
- Locally weighted regression

➔ 별도의 모델 생성 없이 인접 데이터를 분류/예측에 사용



# Model for Classification and Prediction

---

- Model-Based Learning



- 선형/비선형모델 (e.g., linear regression, logistic regression)
- Neural Network
- Decision Tree
- Support Vector Machine

➔ 데이터로부터 모델을 생성하여 분류/예측 진행

- Instance-Based Learning

- K-Nearest Neighbor (KNN)
- Locally weighted regression

➔ 별도의 모델 생성 없이 인접 데이터를 분류/예측에 사용




# Model for Classification and Prediction

- Model-Based Learning

- 선형/비선형모델 (e.g., linear regression, logistic regression)
- Neural Network
- Decision Tree
- Support Vector Machine


➔ 데이터로부터 모델을 생성하여 분류/예측 진행



- Instance-Based Learning

- K-Nearest Neighbor (KNN)
- Locally weighted regression

➔ 별도의 모델 생성 없이 인접 데이터를 분류/예측에 사용



# Model for Classification and Prediction

- Model-Based Learning

- 선형/비선형모델 (e.g., linear regression, logistic regression)
- Neural Network
- Decision Tree
- Support Vector Machine


➔ 데이터로부터 모델을 생성하여 분류/예측 진행



- Instance-Based Learning

- K-Nearest Neighbor (KNN)
- Locally weighted regression


➔ 별도의 모델 생성 없이 인접 데이터를 분류/예측에 사용



# Nearest Neighbor

---


- 1-nearest neighbor



# Nearest Neighbor

---


- 1-nearest neighbor



# Nearest Neighbor

---


- 3-nearest neighbor



# Nearest Neighbor

---

- 3-nearest neighbor



# K-Nearest Neighbor (KNN) Algorithm

---

X1	X2	Class
3	3.5	1
4	5	1
2	4.5	1
1	1	2
3.5	7	2
6	5.5	2

# K-Nearest Neighbor (KNN) Algorithm

---

X1	X2	Class
3	3.5	1
4	5	1
2	4.5	1
1	1	2
3.5	7	2
6	5.5	2

New

3	2	?
---	---	---

# K-Nearest Neighbor (KNN) Algorithm


---

X1	X2	Class
3	3.5	1
4	5	1
2	4.5	1
1	1	2
3.5	7	2
6	5.5	2


New

3	2	?
---	---	---


# K-Nearest Neighbor (KNN) Algorithm



# K-Nearest Neighbor (KNN) Algorithm



# K-Nearest Neighbor (KNN) Algorithm



- 새로운 데이터가 발생한 이후 예측 수행


# Property of KNN Algorithm

---

- Instance-Based Learning
  - 각각의 관측치(Instance) 만을 이용해 새로운 data에 대한 예측 진행
- Memory-Based Learning
  - 모든 학습 data를 메모리에 저장한 후, 이를 바탕으로 예측 시도
- Lazy Learning
  - 모델을 별도로 학습하지 않는 testing data가 들어와야 비로소 작동하는 게으른(lazy) 알고리즘

# Comparison of Linear Regression and KNN


---






# KNN Classification Model

---



# KNN Classification Model

---




$K = \#$  of nearest neighbors

$K = 1 :$

# KNN Classification Model

---




$K = \#$  of nearest neighbors

$K = 1$  : **Orange**

# KNN Classification Model

---




$K = \#$  of nearest neighbors

$K = 1$  : **Orange**

$K = 3$  :

# KNN Classification Model

---




$K = \#$  of nearest neighbors

$K = 1$  : **Orange**

$K = 3$  : **Green**

# KNN Classification Model

---



$K = \#$  of nearest neighbors

$K = 1$  : **Orange**

$K = 3$  : **Green**

- 인접한  $k$ 개의 데이터로부터 **majority voting** 시행

# Example of KNN Classification Model

유전자 정보

환자 상태

사람	유전자 A	유전자 B	유전자 C	유전자 D	질병유무
A	2.54	4.33	3.99	2.57	정상
B	3.12	3.87	3.84	3.04	정상
C	2.76	4.17	5.63	3.28	정상
D	3.87	3.56	4.25	3.65	질병
E	3.55	3.91	2.68	4.22	질병
F	4.12	2.86	3.30	3.71	질병

# Example of KNN Classification Model

유전자 정보

환자 상태

사람	유전자 A	유전자 B	유전자 C	유전자 D	질병유무
A	2.54	4.33	3.99	2.57	정상
B	3.12	3.87	3.84	3.04	정상
C	2.76	4.17	5.63	3.28	정상
D	3.87	3.56	4.25	3.65	질병
E	3.55	3.91	2.68	4.22	질병
F	4.12	2.86	3.30	3.71	질병
G	3.24	3.68	3.82	3.77	?

# Example of KNN Classification Model

유전자 정보

사람	유전자 A	유전자 B	유전자 C	유전자 D
A	2.54	4.33	3.99	2.57
B	3.12	3.87	3.84	3.04
C	2.76	4.17	5.63	3.28
D	3.87	3.56	4.25	3.65
E	3.55	3.91	2.68	4.22
F	4.12	2.86	3.30	3.71
G	3.24	3.68	3.82	3.77

환자 상태

질병유무
정상
정상
정상
질병
질병
질병
?

새로운 관측치와의 거리

1.54
0.76
2.00
0.78
1.28
1.31

# Example of KNN Classification Model

유전자 정보

사람	유전자 A	유전자 B	유전자 C	유전자 D
A	2.54	4.33	3.99	2.57
B	3.12	3.87	3.84	3.04
C	2.76	4.17	5.63	3.28
D	3.87	3.56	4.25	3.65
E	3.55	3.91	2.68	4.22
F	4.12	2.86	3.30	3.71
G	3.24	3.68	3.82	3.77

환자 상태

질병유무
정상
정상
정상
질병
질병
질병
?

새로운 관측치와의 거리

1.54
0.76
2.00
0.78
1.28
1.31

K = 1 :

# Example of KNN Classification Model

유전자 정보

사람	유전자 A	유전자 B	유전자 C	유전자 D
A	2.54	4.33	3.99	2.57
B	3.12	3.87	3.84	3.04
C	2.76	4.17	5.63	3.28
D	3.87	3.56	4.25	3.65
E	3.55	3.91	2.68	4.22
F	4.12	2.86	3.30	3.71
G	3.24	3.68	3.82	3.77

환자 상태

질병유무
정상
정상
정상
질병
질병
질병
정상

새로운 관측치와의 거리

1.54
0.76
2.00
0.78
1.28
1.31

K = 1 : 정상

# Example of KNN Classification Model

유전자 정보

사람	유전자 A	유전자 B	유전자 C	유전자 D
A	2.54	4.33	3.99	2.57
B	3.12	3.87	3.84	3.04
C	2.76	4.17	5.63	3.28
D	3.87	3.56	4.25	3.65
E	3.55	3.91	2.68	4.22
F	4.12	2.86	3.30	3.71
G	3.24	3.68	3.82	3.77

환자 상태

질병유무
정상
정상
정상
질병
질병
질병
정상

새로운 관측치와의 거리

1.54
0.76
2.00
0.78
1.28
1.31

K = 1 : 정상  
K = 3 :

# Example of KNN Classification Model

유전자 정보

사람	유전자 A	유전자 B	유전자 C	유전자 D
A	2.54	4.33	3.99	2.57
B	3.12	3.87	3.84	3.04
C	2.76	4.17	5.63	3.28
D	3.87	3.56	4.25	3.65
E	3.55	3.91	2.68	4.22
F	4.12	2.86	3.30	3.71
G	3.24	3.68	3.82	3.77

환자 상태

질병유무
정상
정상
정상
질병
질병
질병
질병

새로운 관측치와의 거리

1.54
0.76
2.00
0.78
1.28
1.31

K = 1 : 정상  
K = 3 : 질병


# KNN Classification Algorithm

---

- 분류 알고리즘
  1. 분류할 관측치  $x$ 를 선택
  2.  $X$ 로부터 인접한  $k$ 개의 학습 데이터를 탐색
  3. 탐색된  $k$ 개 학습 데이터의 majority class  $c$ 를 정의
  4.  $c$ 를  $x$ 의 분류 결과로 반환


# KNN Prediction Model

---



# KNN Prediction Model

---




$k$  = number of nearest neighbors

$k = 1$  :

# KNN Prediction Model

---




$k$  = number of nearest neighbors

$k = 1 : \text{new} = 15$

# KNN Prediction Model

---




$k$  = number of nearest neighbors

$k = 1$  : new = 15

$k = 3$  :

# KNN Prediction Model

---



$k$  = number of nearest neighbors

$k = 1$  :  $\text{new} = 15$

$k = 3$  :  $\text{new} = (15+21+30)/3 = 22$

# Example of KNN Prediction Model

기존 영화 평점

영화 평점

사람	미녀와 야수	그린북	라라랜드	극한직업	명량	항거
A	7.5	7.5	7.0	9.5	8.5	5.0
B	7.5	7.0	7.5	8.0	8.0	6.0
C	8.0	7.0	8.0	8.0	8.5	8.5
D	8.5	8.0	9.5	7.5	6.0	7.0
E	10.0	9.5	9.0	7.5	7.5	10.0
F	9.0	9.0	8.0	8.0	8.0	9.0

# Example of KNN Prediction Model

기존 영화 평점

영화 평점

사람	미녀와 야수	그린북	라라랜드	극한직업	명량	항거
A	7.5	7.5	7.0	9.5	8.5	5.0
B	7.5	7.0	7.5	8.0	8.0	6.0
C	8.0	7.0	8.0	8.0	8.5	8.5
D	8.5	8.0	9.5	7.5	6.0	7.0
E	10.0	9.5	9.0	7.5	7.5	10.0
F	9.0	9.0	8.0	8.0	8.0	9.0
G	9.0	8.5	8.0	7.0	8.0	?

# Example of KNN Prediction Model

기존 영화 평점

사람	미녀와 야수	그린북	라라랜드	극한직업	명량
A	7.5	7.5	7.0	9.5	8.5
B	7.5	7.0	7.5	8.0	8.0
C	8.0	7.0	8.0	8.0	8.5
D	8.5	8.0	9.5	7.5	6.0
E	10.0	9.5	9.0	7.5	7.5
F	9.0	9.0	8.0	8.0	8.0
G	9.0	8.5	8.0	7.0	8.0

영화 평점

항거
5.0
6.0
8.5
7.0
10.0
9.0
?

새로운 관측치와의 거리

3.28
2.40
2.12
2.65
1.87
1.12

# Example of KNN Prediction Model

기존 영화 평점

사람	미녀와 야수	그린북	라라랜드	극한직업	명량
A	7.5	7.5	7.0	9.5	8.5
B	7.5	7.0	7.5	8.0	8.0
C	8.0	7.0	8.0	8.0	8.5
D	8.5	8.0	9.5	7.5	6.0
E	10.0	9.5	9.0	7.5	7.5
F	9.0	9.0	8.0	8.0	8.0
G	9.0	8.5	8.0	7.0	8.0

영화 평점

항거
5.0
6.0
8.5
7.0
10.0
9.0
9.0

새로운 관측치와의 거리

3.28
2.40
2.12
2.65
1.87
1.12

K = 1 : 9.0

# Example of KNN Prediction Model

기존 영화 평점

사람	미녀와 야수	그린북	라라랜드	극한직업	명량
A	7.5	7.5	7.0	9.5	8.5
B	7.5	7.0	7.5	8.0	8.0
C	8.0	7.0	8.0	8.0	8.5
D	8.5	8.0	9.5	7.5	6.0
E	10.0	9.5	9.0	7.5	7.5
F	9.0	9.0	8.0	8.0	8.0
G	9.0	8.5	8.0	7.0	8.0

영화 평점

항거
5.0
6.0
8.5
7.0
10.0
9.0
9.17

새로운 관측치와의 거리

3.28
2.40
2.12
2.65
1.87
1.12

$K = 1 : 9.0$

$K = 3 : (9.0+10.0+8.5)/3 = 9.17$

# KNN Prediction Algorithm

---

- 예측 알고리즘
  1. 예측할 관측치  $x$ 를 선택
  2.  $x$ 로부터 인접한  $k$ 개의 학습 데이터를 탐색
  3. 탐색된  $k$ 개 학습 데이터의 평균을  $x$ 의 예측 값으로 반환

# Hyperparameter of KNN

---


## 1. K

- 인접한 학습 데이터를 몇 개까지 탐색할 것인가?


## 2. Distance Measures

- 데이터 간 거리는 어떻게 측정할 것인가?


# The result according to K




**1-nearest neighbor**



**5-nearest neighbor**



**15-nearest neighbor**




**50-nearest neighbor**


$1 \leq k \leq \text{데이터의 개수}$

# The result according to K

- K가 매우 작을 경우 : 데이터의 지역적 특성을 지나치게 반영함 (overfitting)
- K가 매우 클 경우 : 다른 범주의 개체를 너무 많이 포함하여 오분류할 위험 (underfitting)



**1-nearest neighbor**



**50-nearest neighbor**

# How to select K

---

- 일정 범위 내로  $k$ 를 조정하여 ( $1 \sim k^*$ ), 가장 좋은 예측 결과를 보이는  $k$ 값을 선정

- 분류 모델


$$\text{MisclassError}_k = \frac{1}{k} \sum_{i=1}^k I(c_i \neq \hat{c}_i) \text{ for } k = 1, 2, \dots, k^*$$

$I()$ : Indicator Function


- 예측 모델

$$\text{SSE}_k = \sum_{i=1}^k (y_i - \hat{y}_i)^2 \text{ for } k = 1, 2, \dots, k^*$$

# How to select K



# How to select K



# Distance measurement (1-similarity)

---

- 다양한 거리측도 (Distance measure) 존재  
(e.g., Euclidean Distance, Correlation Distance, ...)
- 데이터 내 변수들이 각기 다른 데이터 범위, 분산 등을 가질 수 있으므로, 데이터 정규화 (혹은 표준화)를 통해 이를 맞추는 것이 중요
  - 거리를 계산할 때, 단위가 큰 특정 변수(들)가 거리를 결정하는 것 방지
  - ex) 키(1.5m~1.8m), 몸무게(90lb~300lb), 연봉(20,000,000원~100,000,000원)

# Types of Distance measurement

---

- Euclidean Distance
- Manhattan Distance
- Mahalanobis Distance
- Correlation Distance
  - Pearson Correlation
  - Spearman Rank Correlation


# Euclidean Distance

---


$$d_{(X,Y)} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

- 가장 흔히 사용하는 거리측도
- 대응되는  $X, Y$  값 간 차이 제곱합의 제곱근으로써, 두 관측치 사이의 직선거리 의미

# Euclidean Distance




$$d_{(A,B)} = \sqrt{(3 - 1)^2 + (3 - 1)^2} = \sqrt{8}$$





$$d_{(A,B)} = \sqrt{(0 - 2)^2 + (3 - 0)^2 + (2 - 0)^2} = \sqrt{17}$$


# Manhattan Distance



# Manhattan Distance




# Manhattan Distance




# Manhattan Distance

---

$$d_{\text{Manhattan}}(X, Y) = \sum_{i=1}^n |x_i - y_i|$$



Manhattan



Euclidean

- X에서 Y로 이동 시 각 좌표축 방향으로만 이동할 경우에 계산되는 거리

# Mahalanobis Distance

---

$$d_{\text{Mahalanobis}}(X, Y) = \sqrt{(X - Y)^T \Sigma^{-1} (X - Y)}$$

$\Sigma^{-1}$  : inverse of covariance matrix

- 변수 내 분산, 변수 간 공분산을 모두 반영하여  $X, Y$  간 거리를 계산하는 방식
- 데이터의 covariance matrix가 identity matrix인 경우는 Euclidean Distance와 동일함

# Mahalanobis Distance

---

$$\sqrt{(X - Y)^T \Sigma^{-1} (X - Y)} = c \quad (c \text{ is Mahalanobis Distance})$$

$$\Rightarrow (X - Y)^T \Sigma^{-1} (X - Y) = c^2$$

$$\text{Let } X = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}, Y = \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}, \Sigma^{-1} = \begin{pmatrix} s_{11}^{-1} & s_{12}^{-1} \\ s_{21}^{-1} & s_{22}^{-1} \end{pmatrix}, \text{ then}$$

$$\Rightarrow (X - Y)^2 s_{11}^{-1} + 2(x_1 - y_1)(x_2 - y_2) s_{12}^{-1} + (x_2 - y_2)^2 s_{22}^{-1} = c^2 (\because s_{12}^{-1} = s_{21}^{-1})$$

It can be considered as the squared Mahalanobis distance between a certain point X, and the fixed point Y.

$$\text{Let } Y = \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \text{ then}$$

$$\Rightarrow x_1^2 s_{11}^{-1} + 2x_1 x_2 s_{12}^{-1} + x_2^2 s_{22}^{-1} = c^2$$

which is a general equation of the ellipse


# Mahalanobis Distance

---

$$\Sigma = \Sigma^{-1} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

(identity matrix)


$$\Sigma = \begin{pmatrix} 4 & 0 \\ 0 & 1 \end{pmatrix}, \Sigma^{-1} = \begin{pmatrix} \frac{1}{4} & 0 \\ 0 & 1 \end{pmatrix}$$




# Mahalanobis Distance

$$\Sigma = \Sigma^{-1} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

(identity matrix)



$$\Sigma = \begin{pmatrix} 4 & 0 \\ 0 & 1 \end{pmatrix}, \Sigma^{-1} = \begin{pmatrix} \frac{1}{4} & 0 \\ 0 & 1 \end{pmatrix}$$




# Mahalanobis Distance

---


$$\Sigma = \begin{pmatrix} 4 & 0 \\ 0 & 1 \end{pmatrix}, \Sigma^{-1} = \begin{pmatrix} \frac{1}{4} & 0 \\ 0 & 1 \end{pmatrix}$$

$$\Sigma = \begin{pmatrix} 4 & \sqrt{2} \\ \sqrt{2} & 1 \end{pmatrix}, \Sigma^{-1} = \begin{pmatrix} \frac{1}{2} & -\sqrt{\frac{1}{2}} \\ \sqrt{\frac{1}{2}} & 2 \end{pmatrix}$$




# Mahalanobis Distance

$$\Sigma = \begin{pmatrix} 4 & 0 \\ 0 & 1 \end{pmatrix}, \Sigma^{-1} = \begin{pmatrix} \frac{1}{4} & 0 \\ 0 & 1 \end{pmatrix}$$



$$\Sigma = \begin{pmatrix} 4 & \sqrt{2} \\ \sqrt{2} & 1 \end{pmatrix}, \Sigma^{-1} = \begin{pmatrix} \frac{1}{2} & -\sqrt{\frac{1}{2}} \\ \sqrt{\frac{1}{2}} & 2 \end{pmatrix}$$




# Mahalanobis Distance

$$\Sigma = \begin{pmatrix} 4 & \sqrt{2} \\ \sqrt{2} & 1 \end{pmatrix}, \Sigma^{-1} = \begin{pmatrix} \frac{1}{2} & -\sqrt{\frac{1}{2}} \\ \sqrt{\frac{1}{2}} & 2 \end{pmatrix}$$

Equation of Ellipse

$$\frac{1}{2}x_1^2 + 2x_2^2 - \sqrt{2}x_1x_2 = c^2$$




# Mahalanobis Distance

$$\Sigma = \begin{pmatrix} 4 & \sqrt{2} \\ \sqrt{2} & 1 \end{pmatrix}, \Sigma^{-1} = \begin{pmatrix} \frac{1}{2} & -\sqrt{\frac{1}{2}} \\ \sqrt{\frac{1}{2}} & 2 \end{pmatrix}$$

Equation of Ellipse

$$\frac{1}{2}x_1^2 + 2x_2^2 - \sqrt{2}x_1x_2 = c^2$$




# Mahalanobis Distance


$$\Sigma = \begin{pmatrix} 4 & \sqrt{2} \\ \sqrt{2} & 1 \end{pmatrix}, \Sigma^{-1} = \begin{pmatrix} \frac{1}{2} & -\sqrt{\frac{1}{2}} \\ \sqrt{\frac{1}{2}} & 2 \end{pmatrix}$$

Equation of Ellipse


$$\frac{1}{2}x_1^2 + 2x_2^2 - \sqrt{2}x_1x_2 = c^2$$




# Mahalanobis Distance



# Mahalanobis Distance



# Mahalanobis Distance




# Correlation Distance

---

$$d_{\text{Corr}}(X,Y) = 1 - r$$

Where  $r = \sigma_{XY}$



- 데이터 간 Pearson correlation을 거리측도로 사용하는 방식으로, 데이터 패턴의 유사도를 반영할 수 있음

# Correlation Distance


$$d_{\text{Corr}}(X,Y) = 1 - r$$

Where  $r = \sigma_{XY}$

$r = \text{correlation}, -1 \leq r \leq 1$



$$0 \leq d \leq 2$$



- 데이터 간 Pearson correlation을 거리측도로 사용하는 방식으로, 데이터 패턴의 유사도를 반영할 수 있음

# Spearman Rank Correlation Distance

---

$$d_{\text{Spearman}}(X, Y) = 1 - p$$

$$\text{Where } p = 1 - \frac{6 \sum_{i=1}^n (\text{rank}(x_i) - \text{rank}(y_i))^2}{n(n^2 - 1)}$$

- P를 Spearman Correlation이라 하며, 이는 데이터의 rank를 이용하여 correlation distance를 계산하는 방식임
- P의 범위는 -1부터 1로, Pearson Correlation과 동일

# Spearman Rank Correlation Distance

$$1 - \frac{6 \sum_{i=1}^n (\text{rank}(x_i) - \text{rank}(y_i))^2}{n(n^2 - 1)}$$

지역	계절 평균 낮 최고 기온			
	봄	여름	가을	겨울
서울	17.06	28.43	19.07	3.50
뉴욕	16.32	28.22	18.37	5.43
시드니	22.23	17.03	21.90	25.63



지역	지역 별 계절 기온 순위			
	봄	여름	가을	겨울
서울	3	1	2	4
뉴욕	3	1	2	4
시드니	2	4	3	1

# Spearman Rank Correlation Distance

$$1 - \frac{6 \sum_{i=1}^n (\text{rank}(x_i) - \text{rank}(y_i))^2}{n(n^2 - 1)}$$

지역	계절 평균 낮 최고 기온			
	봄	여름	가을	겨울
서울	17.06	28.43	19.07	3.50
뉴욕	16.32	28.22	18.37	5.43
시드니	22.23	17.03	21.90	25.63



지역	지역 별 계절 기온 순위			
	봄	여름	가을	겨울
서울	3	1	2	4
뉴욕	3	1	2	4
시드니	2	4	3	1

Spearman correlation distance between Seoul - New York

$$p = 1 - \frac{6\{(3-3)^2 + (1-1)^2 + (2-2)^2 + (4-4)^2\}}{4(4^2 - 1)} = 1 \quad \longrightarrow \quad d_{(\text{Seoul,NewYork})} = 1 - 1 = 0$$

# Spearman Rank Correlation Distance

$$1 - \frac{6 \sum_{i=1}^n (\text{rank}(x_i) - \text{rank}(y_i))^2}{n(n^2 - 1)}$$

지역	계절 평균 낮 최고 기온			
	봄	여름	가을	겨울
서울	17.06	28.43	19.07	3.50
뉴욕	16.32	28.22	18.37	5.43
시드니	22.23	17.03	21.90	25.63



지역	지역 별 계절 기온 순위			
	봄	여름	가을	겨울
서울	3	1	2	4
뉴욕	3	1	2	4
시드니	2	4	3	1

Spearman correlation distance between Seoul - New York

$$p = 1 - \frac{6\{(3-3)^2 + (1-1)^2 + (2-2)^2 + (4-4)^2\}}{4(4^2 - 1)} = 1 \longrightarrow d_{(\text{Seoul,NewYork})} = 1 - 1 = 0$$

Spearman correlation distance between Seoul - Sydney

$$p = 1 - \frac{6\{(3-2)^2 + (1-4)^2 + (2-3)^2 + (4-1)^2\}}{4(4^2 - 1)} = -1 \longrightarrow d_{(\text{Seoul,Sydney})} = 1 - (-1) = 2$$

# Advantages and Limitations of KNN

---

- 장점


- 데이터 내 노이즈에 영향을 크게 받지 않으며, 특히 Mahalanobis Distance와 같이 데이터의 분산을 고려할 경우 강건함
- 학습 데이터의 수가 많을 경우 효과적임

- 한계점

- 파라미터  $k$ 의 값을 설정해야 함
- 어떤 거리 척도가 분석에 적합한 지 불분명하며, 따라서 데이터의 특성에 맞는 거리척도를 임의로 선정해야 함
- 새로운 관측치와 각각의 학습 데이터 간 거리를 전부 측정해야 하므로, 계산시간이 오래 걸리는 단점이 있음

# Weighted KNN


- 3NN 예측 모델



Q. 관측치 1,2,3,이 전부 같은 가중치를 가져야 하는가?

# Weighted KNN

- Weighted 3NN 예측 모델




$$New = \frac{(45 + 50 + 10)}{3} = 35$$

$$New_{weighted} = \left( \frac{1}{0.8^2} \cdot 45 + \frac{1}{1.3^2} \cdot 50 + \frac{1}{4.2^2} \cdot 10 \right) / \left( \frac{1}{0.8^2} + \frac{1}{1.3^2} + \frac{1}{4.2^2} \right) = 45.4$$

# Example of Weighted KNN


- 3NN 분류 모델



*New = Orange*

# Example of Weighted KNN

- Weighted 3NN 분류 모델



*New = Orange*

$$New_{weighted} = \begin{cases} \text{Orange} = \frac{1}{3.6^2} + \frac{1}{4.2^2} \cong 0.13 \\ \text{Green} = \frac{1}{0.8^2} \cong 1.56 \end{cases} = \text{Green}$$

# Example of Weighted KNN

---

- 새 data와 기존 학습 관측치 간의 거리를 가중치로 하여 예측 결과를 도출함

- 예측 모델

$$\hat{y}_{new} = \frac{\sum_{i=1}^k w_i y_i}{\sum_{i=1}^k w_i} \quad \text{where } w_i = \frac{1}{d_{(new, x_i)}^2}$$

- 분류 모델

$$\hat{c}_{new} = \max_c \sum_{i=1}^k w_i I(w_i \in c)$$

# Summary of KNN

---


- KNN은 매우 단순한 접근방식으로 새로운 관측치 분류, 예측할 수 있는 방법
- 선형모델과 같이 학습 데이터로부터 특정 형태의 모델 제시하는 것 아니라, 학습 데이터 내 유사한 관측치들 만을 토대로 새로운 데이터 예측 수행
- 일부 유사한 관측치의 반응변수의 조합 (e.g., average, majority voting)을 통해 예상되는 반응변수 값 제공
- Weighted KNN Algorithm으로 데이터의 가중치를 고려할 수 있으며, 이를 통해 보다 정확한 모델 구축 가능

# Clustering Analysis

# What is Clustering?

---

- 유사한 속성들을 갖는 관측치들을 묶어 전체 data를 몇 개의 군집(그룹)으로 나누는 것




# What is Clustering?

---


- 군집화 기준

- 동일한 군집에 소속된 관측치들은 서로 유사할수록 좋음
- 상이한 군집에 소속된 관측치들은 서로 다를수록 좋음



# What is Clustering?


- 군집화 기준
  - 동일한 군집에 소속된 관측치들은 서로 유사할수록 좋음
  - 상이한 군집에 소속된 관측치들은 서로 다를수록 좋음




# What is Clustering?

- 분류(Classification) vs 군집화(Clustering)

- 분류: 사전 정의된 범주가 있는(labeled) 데이터로부터 예측 모델을 학습하는 문제  
(지도학습: Supervised Learning)
- 군집화: 사전 정의된 범주가 없는(unlabeled) 데이터에서 최적의 그룹을 찾아나가는 문제  
(비지도학습: Unsupervised Learning)




분류



군집


# Example of Clustering

---




# Example of Clustering

---



## Segmentation Clustering


**Customer Group A**  
High value, high income, no dependents, homeowners



**Customer Group B**  
Average income, short customer lifetime, tenants




**Customer Group C**  
Low value, low income, 2+ dependents




# Example of Clustering

- 군집화 적용 사례
  - 서울시 오존농도 패턴 군집화 (25개 구)



# Example of Clustering

- 군집화 적용 사례
  - 서울시 오존농도 패턴 군집화 (25개 구)



# Considerations of Clustering

---

Q1. 어떤 거리 척도를 사용하여 유사도를 측정할 것인가?

Q2. 어떤 군집화 알고리즘을 사용할 것인가?

Q3. 어떻게 최적의 군집 수를 결정할 것인가?

Q4. 어떻게 군집화 결과를 측정/평가할 것인가?

# Clustering: Similarity Scale

---

Q1. 어떤 거리 척도를 사용하여 유사도를 측정할 것인가?

- Euclidean Distance
- Manhattan Distance
- Mahalanobis Distance
- Correlation Distance


# Clustering: Similarity Scale

## Q2. 어떤 군집화 알고리즘을 사용할 것인가?

### ■ 군집화 알고리즘의 종류



#### ✓ 계층적 군집화

- 개체들을 가까운 집단부터 차근차근 묶어나가는 방식
- 군집화 결과 뿐만 아니라 유사한 개체들이 결합되는 dendrogram 생성



#### ✓ 분리형 군집화

- 전체 데이터의 영역을 특정 기준에 의해 동시에 구분
- 각 개체들은 사전에 정의된 개수의 군집 중 하나에 속하게 됨




# Clustering: Similarity Scale

## Q2. 어떤 군집화 알고리즘을 사용할 것인가?

- 군집화 알고리즘의 종류


- ✓ 자기조직화 지도

- 2차원 격자에 각 개체들이 대응하도록 인경신경망과 유사한 학습을 통해 군집 도출



- ✓ 분포 기반 군집화



- 데이터의 분포를 기반으로 높은 밀도를 갖는 세부 영역들로 전체 영역을 구분



# Hierarchical Clustering

- 계층적 군집화


- 계층적 트리모형을 이용해 개별 개체들을 순차적/계층적으로 유사한 개체/군집과 통합
- Dendrogram을 통해 시각화 가능
  - ✓ Dendrogram: 개체들이 결합되는 순서를 나타내는 트리형태의 구조
- 사전에 군집의 수를 정하지 않아도 수행 가능
  - ✓ Dendrogram 생성 후 적절한 수준에서 자르면 그에 해당하는 군집화 결과 생성



# Hierarchical Clustering

---

- 계층적 군집화 수행 예시
  - 모든 개체들 사이의 거리에 대한 유사도 행렬 계산




	A	B	C	D
A		20	7	2
B			10	25
C				3
D				

# Hierarchical Clustering

- 계층적 군집화 수행 예시
  - 모든 개체들 사이의 거리에 대한 유사도 행렬 계산


	A	B	C	D
A		20	7	2
B			10	25
C				3
D				



# Hierarchical Clustering

- 계층적 군집화 수행 예시

- 모든 개체들 사이의 거리에 대한 유사도 행렬 계산
- 거리가 인접한 관측치끼리 군집 형성
- 유사도 행렬 업데이트




	AD	B	C	
AD		20	3	
B			10	
C				

# Hierarchical Clustering

- 계층적 군집화 수행 예시

- 모든 개체들 사이의 거리에 대한 유사도 행렬 계산
- 거리가 인접한 관측치끼리 군집 형성
- 유사도 행렬 업데이트


	<b>AD</b>	<b>B</b>	<b>C</b>	
<b>AD</b>		20	3	
<b>B</b>			10	
<b>C</b>				



# Hierarchical Clustering

- 계층적 군집화 수행 예시

- 모든 개체들 사이의 거리에 대한 유사도 행렬 계산
- 거리가 인접한 관측치끼리 군집 형성
- 유사도 행렬 업데이트
- 위의 과정 반복




	AD C	B		
AD C		10		
B				

# Hierarchical Clustering

- 계층적 군집화 수행 예시


- 모든 개체들 사이의 거리에 대한 유사도 행렬 계산
- 거리가 인접한 관측치끼리 군집 형성
- 유사도 행렬 업데이트
- 위의 과정 반복



	AD C	B		
AD C		10		
B				

# Hierarchical Clustering


- 계층적 군집화 수행 예시
  - 최종 결과



	AD CB			
AD CB				

# Hierarchical Clustering

- 핵심 수행 절차: 두 군집 사이의 유사성/거리 측정
  - ✓ Min(단일 연결), max(완전 연결), group average(평균 연결), between centroid, Ward's, ...





# Hierarchical Clustering

- Ward's method: Distance between two clusters, A and B, is how much the sum of squares will increase when they are merged

$$\text{Ward Distance} = \sum_{i \in A \cup B} \|x_i - m_{A \cup B}\|^2 - \left\{ \sum_{i \in A} \|x_i - m_A\|^2 + \sum_{i \in B} \|x_i - m_B\|^2 \right\}$$

$m_A$  is the center of cluster

Ward's distance can be considered as the merging cost of combining the clusters A and B



# K-Means Clustering

---

- K-Means Clustering
  - 대표적인 분리형 군집화 알고리즘
    - ✓ 각 군집은 하나의 **중심(centroid)**을 가짐
    - ✓ 각 개체는 가장 가까운 중심에 할당되며, 같은 중심에 할당된 개체들이 모여 하나의 군집을 형성
    - ✓ **사전에 군집의 수 K가 정해져야 알고리즘을 실행할 수 있음**


$$X = C_1 \cup C_2 \cdots C_k, C_i \cap C_j = \emptyset, \quad i \neq j$$

$$\operatorname{argmax}_c \sum_{i=1}^K \sum_{x_j \in C_i} \|x_j - c_i\|^2$$

# Example of K-Means Clustering

---


- Example (K=2)
  1. 2개의 중심을 임의로 생성



# Example of K-Means Clustering

---


- Example (K=2)
  1. 2개의 중심을 임의로 생성
  2. 생성된 중심을 기준으로 모든 관측치에 군집 할당



# Example of K-Means Clustering


---

- Example (K=2)
  1. 2개의 중심을 임의로 생성
  2. 생성된 중심을 기준으로 모든 관측치에 군집 할당
  3. 각 군집의 중심을 다시 계산



# Example of K-Means Clustering

- Example (K=2)
  1. 2개의 중심을 임의로 생성
  2. 생성된 중심을 기준으로 모든 관측치에 군집 할당
  3. 각 군집의 중심을 다시 계산
  4. 중심이 변하지 않을 때까지 위의 과정을 반복





# Procedure of K-Means Clustering

- K-Means Clustering

1. 초기 중심을 K개 임의로 생성
2. 개별 관측치로부터 각 중심까지의 거리를 계산 후, 가장 가까운 중심이 이루는 군집에 관측치 할당
3. 각 군집의 중심을 다시 계산
4. 중심이 변하지 않을 때까지 2,3의 과정을 반복


✓ 초기 중심은 종종 무작위로 설정됨: 군집화 결과가 초기 중심 설정에 따라 다르게 나타나는 경우가 발생할 수 있음



# K-Means Clustering


- 초기 중심 설정이 최종 결과에 어떤 영향을 미치는가?

➤ 바람직한 결과



# K-Means Clustering

- 초기 중심 설정이 최종 결과에 어떤 영향을 미치는가?
  - 바람직하지 않은 결과



# K-Means Clustering

---


- 무작위 초기 중심 설정의 위험을 피하고자 다양한 연구 존재
  - 반복적으로 수행하여 가장 여러 번 나타나는 군집을 사용
  - 전체 데이터 중 일부만 샘플링하여 계층적 군집화를 수행한 뒤 초기 군집 중심 설정
  - 데이터 분포의 정보를 사용하여 초기 중심 설정
  - 하지만 많은 경우 초기 중심 설정이 최종 결과에 큰 영향을 미치지 않음

# K-Means Clustering

---

- K-Means Clustering의 문제점
  - 문제점 I: 서로 다른 크기의 군집을 찾아내지 못함


정답




# K-Means Clustering

- K-Means Clustering의 문제점
  - 문제점 I : 서로 다른 크기의 군집을 찾아내지 못함

정답



K-평균 군집화 결과




# K-Means Clustering

---

- K-Means Clustering의 문제점
  - 문제점 Ⅱ: 서로 다른 밀도의 군집을 찾아내지 못함


정답




# K-Means Clustering

- K-Means Clustering의 문제점
  - 문제점 Ⅱ : 서로 다른 밀도의 군집을 찾아내지 못함

정답




K-평균 군집화 결과



# K-Means Clustering

---


- K-Means Clustering의 문제점
  - 문제점 Ⅲ: 지역적 패턴이 존재하는 군집을 판별하기 어려움




# K-Means Clustering

- K-Means Clustering의 문제점
  - 문제점 Ⅲ : 지역적 패턴이 존재하는 군집을 판별하기 어려움

정답



K-평균 군집화 결과




# K-Means Clustering

- K-Means Clustering의 문제점


※ **Geodesic Distance**

- 문제점 Ⅲ : 지역적 패턴이 존재하는 군집을 판별하기 어려움

정답




K-평균 군집화 결과



# Clustering: Determination the optional number of cluster

---


- 어떻게 최적의 군집 수를 결정?
  - ex) 20개의 관측치가 존재할 때, 최적의 군집 수는?



# Clustering: Determination the optional number of cluster

---

- 어떻게 최적의 군집 수를 결정?
  - ex) 20개의 관측치가 존재할 때, 최적의 군집 수는?





# Clustering: Determination the optional number of cluster

---



- 어떻게 최적의 군집 수를 결정?
  - ex) 20개의 관측치가 존재할 때, 최적의 군집 수는?

군집 수 = 3



# Clustering: Determination the optional number of cluster

- 어떻게 최적의 군집 수를 결정?
  - 다양한 군집 수에 대해 성능 평가 지표를 도식화하여 최적의 군집 수 선택
  - Elbow point에서 최적 군집 수가 결정되는 경우가 일반적



# Clustering: measure and evaluate the result



---

- 어떻게 군집화 결과를 측정/평가할 것인가?
- 분류 알고리즘처럼 모든 상황에 적용 가능한 평가 지표 부재
  - 내부 평가지표
    - ✓ Dunn Index, Silhouette, Sum of Squared Error, ...
  - 외부 평가 지표
    - ✓ Rand index, Jaccard Coefficient, Folks and Mallows Index, ...

# Clustering: measure and evaluate the result

- 군집화 평가 지표 I : Sum of Squared Error (SSE)


$$SSE = \sum_{i=1}^K \sum_{x \in c_i} dist(x, c_i)^2$$




# Clustering: measure and evaluate the result

- 군집화 평가 지표 I : Sum of Squared Error (SSE)

$$SSE = \sum_{i=1}^K \sum_{x \in c_i} dist(x, c_i)^2$$



But, 군집 간의 거리는 고려 X



# Clustering: measure and evaluate the result


- 군집화 평가 지표  $\Pi$ : Silhouette 통계량

- $a(i)$ : 관측치  $i$ 로부터 같은 군집 내에 있는 모든 다른 개체들 사이의 평균 거리
- $b(i)$ : 관측치  $i$ 로부터 다른 군집 내에 있는 개체들 사이의 평균 거리 중 최솟값
- 일반적으로  $\bar{S}$ 의 값 0.5보다 크면 군집 결과가 타당하다고 볼 수 있음
- -1에 가까우면 군집이 전혀 되지 않음

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}$$





$$-1 \leq s(i) \leq 1$$

$$\bar{S} = \frac{1}{n} \sum_{i=1}^n S(i)$$



# Clustering: measure and evaluate the result

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}$$



# Thank you

