

# 확률 및 통계

제3주 수치를 통한 연속형 자료의 요약

[hylee@silla.ac.kr](mailto:hylee@silla.ac.kr)

# 수치를 통한 연속형 자료의 요약

- ◎ 그래프가 자료를 이해하기 위한 유용한 도구이기는 하나 주관적이고 일관성이 없는 결과를 도출할 가능성이 있다.
- ◎ 객관적이고 일관성 있는 결과를 위해서 수치가 사용된다.
- ◎ 자료 요약을 위한 측도의 종류로는 중심 위치의 측도, 퍼진 정도의 측도 등이 있다.
  - 중심 위치의 측도 : 평균, 중앙값, 최빈값
  - 퍼진 정도의 측도 : 분산, 표준편차, 범위, 사분위수범위

# 평균


◎ 평균 (Mean) : 가장 많이 쓰이는 중심위치의 측도

■ 자료 :  $x_1, \dots, x_n$

■ 표본평균

$$\bar{x} = \frac{x_1 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i$$

■ 예: 4.5 2.4 3.8 9.1 7.2  $\sum x_i = 27$   $\bar{x} = \frac{1}{n} \sum x_i = 5.4$



# 중앙값 - 1

- 중앙값 (Median) : 자료를 순서대로 배열했을 때, 가운데 위치하는 값.
  - 자료 :  $x_1, \dots, x_n$
  - 크기 순으로 배열 :  $x_{(1)}, \dots, x_{(n)}$
  - 앞의 예에서 2.4 3.8 4.5 7.2 9.1
    - 자료의 개수가 홀수인 경우
      - 중앙값은  $\frac{n+1}{2}$  번째 관측값 =  $x_{((n+1)/2)}$
      - 예에서 자료의 개수는 5개이므로 3번째 작은 값  $x_{(3)} = 4.5$  이 중앙값이다.

## 중앙값- 2

- 자료의 개수가 짝수인 경우
  - 중앙값은  $\frac{n}{2}$  번째와  $\frac{n}{2}+1$  번째 자료값의 평균이다.

$$\frac{x_{(n/2)} + x_{((n+1)/2)}}{2}$$

- 예로써 5.0 의 값이 추가되었다면 자료의 개수가 6개이므로

2.4 3.8 4.5 5.0 7.2 9.1


$$\text{중앙값 : } \frac{x_{(3)} + x_{(4)}}{2} = \frac{4.5 + 5.0}{2} = 4.75$$

# 최빈값


◎ 최빈값 (Mode) : 가장 자주 나오는 자료값.

■ 질적 자료나 그룹화한 수치 자료에서 자주 쓰임

■ 예 :




최빈값 = 4



최빈값 = 3,5

여러 개의 값이


될 수 있다.




최빈값 =  $(4.5+5.5)/2 = 5$

# 표본평균, 중앙값, 최빈값의 특징


- 자료가 선형 변환될 때 평균과 중앙값도 같은 선형 변환으로 표현된다.
- 평균은 중앙값에 비해 아주 크거나 작은 값에 영향을 잘 받는다.
- 분포에 따라서 대표값들의 상대적인 위치가 다르다.




표본평균  
중앙값  
최빈값



최빈값    표본평균    최빈값  
중앙값



최빈값    중앙값    표본평균



표본평균    중앙값    최빈값

그림 : 분포의 모양에 따른 표본평균, 중앙값, 최빈값의 위치

# 분산과 표준편차

- 분산과 표준편차 (Variance, Standard deviation) : 자료가 얼마나 퍼져 있는가를 숫자로 표현한 것.

- 편차 : 관측값 - 평균 =  $x_i - \bar{x}$

- 특징 :  $\sum_{i=1}^n (x_i - \bar{x}) = 0, \sum_{i=1}^n x_i - n\bar{x} = 0$

- 표본분산

$$s^2 = \frac{1}{n-1} (\text{편차의 제곱합}) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

- 계산식

$$s^2 = \frac{1}{n-1} \left( \sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) = \frac{1}{n-1} \left( \sum_{i=1}^n x_i^2 - n \left( \frac{\sum_{i=1}^n x_i}{n} \right)^2 \right) = \frac{1}{n-1} \left( \sum_{i=1}^n x_i^2 - \frac{1}{n} \left( \sum_{i=1}^n x_i \right)^2 \right)$$

- 표본표준편차 :

$$s = +\sqrt{s^2}$$

# 선형 변환시 분산과 표준편차의 변화

$$y = ax + b \quad s_y^2 = a^2 s_x^2 \quad s_y = |a| s_x$$

$$s_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n-1} \sum_{i=1}^n (ax_i - a\bar{x})^2 = \frac{a^2}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = a^2 s_x^2$$

$$\bar{y} = 59 \quad y_i = 10x_i + 5$$

$$s_y^2 = \frac{1}{4} (30^2 + 16^2 + 9^2 + 18^2 + 37^2) = 732.5 = 100 \times 7.325$$


$$\sqrt{s_y} = \sqrt{732.5} = 27.065 = 10 \times 2.7065$$

◎ 예

■ 자료 : 29 43 50 77 96

# 백분위수

- 제  $100p$ -번째 백분위수 : 전체의 관측값을  $100(1-p)\%$  와  $100p\%$  로 나누는 값
- 즉, 관측값의 개수가 그 값 이하에  $n(1-p)$  개 이상, 그 값 이상에  $np$  개 이상 있어야 한다.
- 구하는 방법
  - 자료를 크기 순으로 재배열한다.
  - $np$  가 정수가 아닌 경우 : 제  $100p$  백분위수 =  $x_{(\lfloor np \rfloor + 1)}$        $\lfloor t \rfloor$  :  $t$ 의 정수부분
  - $np$  가 정수인 경우 : 제  $100p$  백분위수 =  $\frac{x_{(np)} + x_{(np+1)}}{2}$



# 사분위수와 사분위수범위

## ◎ 사분위수 (Quartile)

- 제 1 사분위수 = 제 25 백분위수
- 제 2 사분위수 = 제 50 백분위수 = 중앙값
- 제 3 사분위수 = 제 75 백분위수

## ◎ 사분위수 범위 ( $IQR$ : Interquartile range)

- $IQR$  = 제 3 사분위수 - 제 1 사분위수
- 자료가 29 43 50 77 96인 경우
  - 제 1 사분위수  $Q_1$  :  $n=9$   $p=0.25$   $np=2.25$   $Q_1 = x_{(3)} = 1.9$   
 $n=9$   $p=0.75$   $np=6.75$   $Q_3 = x_{(7)} = 3.4$
  - 제 3 사분위수  $Q_3$  :  $IQR = Q_3 - Q_1 = 3.4 - 1.9 = 1.5$

## 표준편차와 사분위수 범위의 비교

- ◎ 표준편차는 평균의 장단점을, 사분위수 범위는 중앙값의 장단점을 갖는다.
- ◎ 즉 표준편차는 관측값의 퍼진 정도를 골고루 반영하나 극단적인 값에 크게 영향을 받는다.
- ◎ 사분위수 범위는 제1,제3 사분위수 바깥의 분포의 퍼져있는 정도는 반영이 안되고, 따라서 극단적인 값들에 영향을 받지 않는다.

# 기타 퍼진 정도의 측도

- ◎ 변동계수 (CV : Coefficient of Variation)

$$CV = \frac{s}{y} \times 100$$


- ◎ 범위 (Range)
  - 범위 : 최대값 - 최소값
  - 표준편차와 사분위수 범위의 단점을 모두 가지고 있다. 퍼진 정도의 측도로 적절치 않다.

# 상자그림 (BOX PLOT)

중양값, 사분위수 등을 이용하여 자료에 대한 정보를 하나의 그림으로 함축 시켜 그리는 요약 방법

## 방법

- 최소사분위수  $Q_1$ , 최대값을 구한다.
- $Q_3$ ,  $Q_1$  를 상자로 값 연결하고 중앙값을 수직으로 표현
- 상자의 양끝으로부터  $1.5 * IQR$  내에 있는 최소값과 최대값까지 선으로 연결
- 양 경계를 벗어나는 자료 값들을 \*로 표시




# 상자그림 예 - 1

$n = 20$    248   260   270   274   295   301   308   310   315   315  
320   325   332   333   334   334   356   368   370   388


최소값=248,  $Q_1 = \frac{295+301}{2} = 298$ , 중앙값=  $\frac{315+320}{2} = 317.5$ ,  $Q_3 = 334$ , 최대값=388

$IQR = Q_3 - Q_1 = 334 - 298 = 36$ ,  $1.5 \times IQR = 54$ ,  $298 - 54 = 244$ ,  $334 + 54 = 388$



## 상자그림 예 - 2



### ◎ 호텔 객실 이용률 예



- 호텔 A의 이용률은 변화가 심하다.
- 호텔 B의 이용률이 A보다 상대적으로 높다.



# 히스토그램과 BOX PLOT 비교 - 1

## ◎ 대칭





# 히스토그램과 BOX PLOT 비교 - 2

◉ 왼쪽으로 쏠림



# 히스토그램과 BOX PLOT 비교 - 3

○ 오른쪽으로 쏠림



# 그룹화된 자료의 요약 - 1

- 그룹화된 자료는 원 자료의 정보를 많이 상실하기 때문에 자료의 정확한 요약이 힘들다. 그러나 자료가 방대한 경우, 그룹화된 자료를 이용하여 비교적 간편하게 자료를 요약할 수 있다.

- 각 계급에 포함되는 자료 값이 모두 계급  $l_i$  값을  $u_i$  갖는 것으로 간주하여 계산한다. 즉,  $m_i$  과 사이의 자료는 모두  $l_i + u_i$  이라는 값을 갖는 것으로 간주한다.

	계급값	횟수
$l_1 \sim u_1$	$m_1$	$f_1$
$l_2 \sim u_2$	$m_2$	$f_2$
$\vdots$	$\vdots$	$\vdots$
$l_k \sim u_k$	$m_k$	$f_k$
		$n$

계급값 : 각 계급의 중간값

$$m_i = \frac{l_i + u_i}{2}$$

# 그룹화된 자료의 요약 - 2

- 평균 ( $\bar{x}_g$ )

$$\bar{x}_g = \frac{1}{n} \sum_{i=1}^n m_i f_i = \frac{1}{n} (m_1 f_1 + \dots + m_k f_k)$$

- 분산 ( $s_g^2$ )

$$\begin{aligned} s_g^2 &= \frac{1}{n-1} \sum_{i=1}^n (m_i - \bar{x}_g)^2 f_i \\ &= \frac{1}{n-1} \left( \sum_{i=1}^n m_i^2 f_i - 2\bar{x}_g \sum_{i=1}^n m_i f_i + \bar{x}_g^2 \sum_{i=1}^n f_i \right) \\ &= \frac{1}{n-1} \left( \sum_{i=1}^n m_i^2 f_i - n\bar{x}_g^2 \right) = \frac{1}{n-1} \left( \sum_{i=1}^n m_i^2 f_i - \frac{\left( \sum_{i=1}^n m_i f_i \right)^2}{n} \right) \end{aligned}$$

$$\begin{aligned} \sum f_i &= n \\ \sum m_i f_i &= n\bar{x}_g \end{aligned}$$

# 그룹화된 자료의 요약 예 - 1

○ 줄기 잎 그림:

9		6 4 2 9 9 9
10		3 8 6 9 5 4 2 6 3 0 1
11		1 3 1 0 9 1
12		1 2 8 3 8 1
13		0
14		0 7

최소값 : 92  
10

최대값 : 147

범위 : 55

계급구간의 폭 :

## 그룹화된 자료의 요약 예 - 2

계급구간	계급값( $m_i$ )	뒀수( $f_i$ )	$m_i f_i$
89.5 - 99.5	94.5	6	567
99.5-109.5	104.5	11	1149.5
109.5-119.5	114.5	6	687
119.5-129.5	124.5	6	747
129.5-139.5	134.5	1	134.5
139.5-149.5	144.5	2	289
		32	3574

$$\sum m_i^2 f_i = 405218$$

$$\bar{x}_g = \frac{\sum m_i f_i}{32} = 111.6875$$

$$s_g^2 = \frac{1}{31} \left( \sum m_i^2 f_i - \frac{3574^2}{32} \right) = 195.060$$

$$s_g = 13.97$$

$$\sum x_i = 3561$$

$$\bar{x} = 111.281$$

$$\sum x_i^2 = 401765$$

$$s^2 = 177.18$$

$$s = 13.31$$

## 그룹화된 자료의 요약 예 - 3

계급구간	계급값( $m_i$ )	뒀수( $f_i$ )	$m_i f_i$	$m_i^2 f_i$
1-5	3	4	12	36
5-9	7	8	56	392
9-13	11	10	110	1210
13-17	15	8	120	1800
		30	298	3438

$$\bar{x}_g = \frac{298}{30} = 9.93$$

$$s_g^2 = \frac{1}{29} \left( 3438 - \frac{298^2}{30} \right) = 16.48$$

$$s_g = 4.06$$

# 종 모양의 대칭분포의 성질


- 종 모양의 대칭분포 (Symmetric bell-shaped distribution)의 성질

$\bar{x}$ ,  $s$  가 주어져 있을 때,

$\bar{x} \pm s$  구간에 68%

$\bar{x} \pm 2s$  구간에 96%

$\bar{x} \pm 3s$  구간에 99.7%의 자료가 포함된다.



# 관측값의 표준화

◉  $z$ -값 : 평균으로부터 떨어져 있는 상대적 위치의 측도

◉  $x$ 의  $z$ -값 =  $\frac{x - \bar{x}}{s}$

# Thank You!

