

Chapter 3

Descriptive Statistics II: Numerical Descriptive Techniques

경영대학 재무금융학과
윤선중

0

Objectives (1)

- 기술통계량 (Descriptive Statistic)
 - 그래프 기법 (Graphical Technique)
 - 수치 방법 (Numerical Technique)
- 중심위치 (central location)
 - 평균 (mean), 중앙값 (median), 최빈값 (mode)
- 변동성 (Variability)
 - 범위 (range), 분산 (variance), 표준편차 (standard deviation), 변동계수 (variance coefficient)
- 경험법칙 (empirical rule)
 - 평균으로부터 1표준편차, 2표준편차의 대략적인 비율
 - 채비세프의 정리 (Chebyshev's Theorem)

Objectives (2)

- 상대위치의 척도 (Measures of Relative Standing)
 - 백분위수 (Percentile)
 - 사분위수 (Quartile)

- 변수간의 선형관계
 - 공분산(Covariance)
 - 상관계수 (Coefficient of Correlation)
 - 결정계수 (Coefficient of Determination)
 - 최소자승선 (Least Square Line)

2

I. Central Tendency

3

Terminology

- N : 모집단의 수
- n : 표본샘플의 수
- μ : 모집단의 평균
- \bar{x} : 표본생풀의 평균

4

Mean (Arithmetic Average)

- 정의
 - 관측치들을 모두 더한 후, 이를 관측치의 개수로 나눈 값
 - 모평균:
$$\mu = \frac{\sum_{i=1}^N x_i}{N}$$
 표본평균:
$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$
- 산술평균 vs. 기하평균 (geometric average)
 - 기하평균:
$$R_g = \sqrt[n]{(1 + R_1)(1 + R_2) \dots (1 + R_n)} - 1$$
 - 10,000원을 2년간 투자한다고 가정
 - 첫해의 수익률 100%; 이듬해의 수익률 -50%
 - 최종 투자가치는?
 - 평균수익률?
 - 산술평균과 기하평균

5

Mean (Arithmetic Average)

■ 예제 2.4: 평균 장거리 전화비용; Xm02-04

The screenshot shows a Microsoft Excel spreadsheet titled "Microsoft Excel - Xm02-04". The formula bar at the top displays "=AVERAGE(A1:A201)". The main area shows a table with columns A through G. Column A contains labels and values: 1. Bills, 2. 42.19, 3. 38.45, 4. 29.23, 5. 89.35, 6. 118.04, 7. 110.46, 8. 0.00, 9. 72.88, 10. 83.05, 11. 95.73, 12. 103.15. The formula =AVERAGE(A1:A201) is entered into cell C5, and its definition is displayed in the status bar below the formula bar.

	A	B	C	D	E	F	G
1	Bills						
2	42.19						
3	38.45						
4	29.23						
5	89.35		=AVERAGE(A1:A201)				
6	118.04		AVERAGE(number1, [number2], ...)				
7	110.46						
8	0.00						
9	72.88						
10	83.05						
11	95.73						
12	103.15						

6

Median

■ 정의

- 모든 관측치들을 오름차순 혹은 내림차순으로 정리하였을 때, 중앙에 해당되는 관측치
- 자료의 개수가 짝수인 경우에는 중앙에 오는 두 개의 값을 더한 후, 이를 2로 나누어서 사용

■ 예제 Xm02-04

-

The screenshot shows a Microsoft Excel spreadsheet titled "Microsoft Excel - Xm02-04". The formula bar at the top displays "=median(a1:a201)". The main area shows a table with columns A through F. Column A contains labels and values: 1. Bills, 2. 42.19, 3. 38.45, 4. 29.23, 5. 89.35, 6. 118.04, 7. 110.46, 8. 0.00, 9. 72.88, 10. 83.05. The formula =median(a1:a201) is entered into cell C7, and its definition is displayed in the status bar below the formula bar.

	A	B	C	D	E	F
1	Bills					
2	42.19					
3	38.45					
4	29.23					
5	89.35					
6	118.04					
7	110.46		=median(a1:a201)			
8	0.00		MEDIAN(number1, [number2], ...)			
9	72.88					
10	83.05					

7

Mode

■ 정의

- 관측치들 중에서 가장 큰 빈도수를 가지는 관측치
- 최빈값은 하나의 값이 아닐 수 있음

■ 예제 (Xm02-04)

The screenshot shows a Microsoft Excel spreadsheet titled "Microsoft Excel - Xm02-04". The formula bar displays "=MODE(A1:A201)". The spreadsheet contains a table with columns A, B, C, D, E, and F. Column A has data labeled "Bills" and numerical values from 1 to 11. Column C contains the formula results: cell C2 is 42.19, C3 is 38.45, C4 is 29.23, C5 is 89.35, C6 is 118.04, C7 is 110.46, C8 is 26.905, C9 is 72.88, C10 is 83.05, and C11 is 95.73. The formula bar also shows the function definition: "=MODE(number1, [number2], ...)".

	A	B	C	D	E	F
1	Bills					
2	42.19					
3	38.45					
4	29.23					
5	89.35		43.5876			
6	118.04					
7	110.46		26.905			
8	0.00		=MODE(A1:A201)			
9	72.88		MODE(number1, [number2], ...)			
10	83.05					
11	95.73					

8

Which is better?

■ 예제 1

- 5aud의 상인들의 월 평균 수익은 다음과 같다
 - 300만원, 200만원, 100만원, 200만원, 4000만원
- 평균 vs 평균값 vs 최빈값?

■ 예제 2

- 5명 학생의 수학과 영어 성적은 다음과 같다
 - 수학: 100, 80, 70, 50, 30
 - 영어: 75, 70, 68, 45, 25
- 학생들이 어느 과목을 잘 하는가?

■ Mean vs. Median

- 극단치 (outlier)가 포함된 경우 Mean은 좋은 중심값이 될 수 없음
- 계산 및 비교 등의 용도에서는 Mean이 더 좋은 특성을 가지고 있음

9

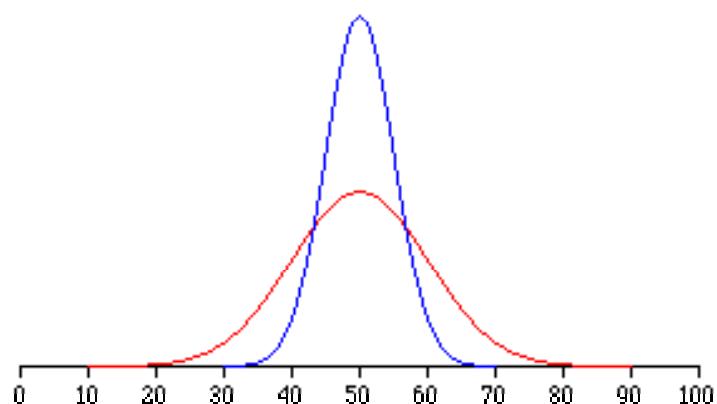
II. Dispersion

10

Measure of Dispersion

■ 정의

- 중심으로부터 흩어진 정도를 나타내는 척도
- 아래의 두 그래프가 평균은 같음에도 불구하고 다른 산포도를 가질 수 있음



11

Range

■ 정의

- 관측치 중 가장 큰 값과 가장 작은 값의 차이
- 최대 관측치 – 최소 관측치

■ 예제 Xm02-04

The screenshot shows an Excel spreadsheet with data in columns A and B. Column A is labeled 'Bills' and contains values from 1 to 11. Column B contains the formula =max(a2:a201)-min(a2:a201) in cell B3, which is highlighted in orange. The status bar at the bottom shows the formula =max(a2:a201)-min(a2:a201).

	A	B	C	D	E	F	G
1	Bills						
2	42.19		Range (범위)				
3	38.45		=max(a2:a201)-min(a2:a201)				
4	29.23						
5	89.35						
6	118.04						
7	110.46						
8	0.00						
9	72.88						
10	83.05						
11	95.73						

12

Variance & Standard Deviation

■ 정의

- 편차(관측치 – 평균)를 제곱하여 더한 후 이를 관측치의 개수로 나눈 값
- 관측치들이 평균적으로 평균값에서 얼마나 떨어져 있는지 알아냄

$$\text{모분산: } \sigma^2 = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N} \quad \text{표본분산: } s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}$$

$$\text{모표준편차: } \sigma = \sqrt{\sigma^2} \quad \text{표본표준편차: } s = \sqrt{s^2}$$

■ 표준편차 vs. 변동계수 (coefficient of variation)

- 3채의 아파트 가격이 각각 1억원, 2억원, 3억원

- 3개의 주식 가격이 각각 1만원, 10만원, 100만원

$$\text{• 모 변동 계수} = CV = \frac{\sigma}{\mu} \quad \text{표본변동계수} = cv = \frac{s}{\bar{x}}$$

13

Variance & Standard Deviation

■ 예제 3.7: 여름방학 아르바이트

- Sample: 17, 15, 23, 7, 9, 13.

$$\bar{x} = \frac{\sum_{i=1}^6 x_i}{6} = \frac{17 + 15 + 23 + 7 + 9 + 13}{6} = \frac{84}{6} = 14 \text{ jobs}$$

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} = \frac{1}{6-1} [(17-14)^2 + (15-14)^2 + \dots + (13-14)^2] = 33.2$$

$$s^2 = \frac{1}{n-1} \left[\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n} \right] = \frac{1}{6-1} \left[(17^2 + 15^2 + \dots + 13^2) - \frac{(17+15+\dots+13)^2}{6} \right] = 33.2$$

14

Variance & Standard Deviation

■ 예제 Xm02-04

- 분산과 표준편차

A	B	C	D	E
Bills		Range (범위)	사분위수	
42.19		119.63	9.385	
38.45				
29.23				
89.35				
118.04				
110.46				
0.00				
72.88				
83.05				

분산
`=var(a2:a201)`

표준편차
`=stdev(A2:A201)`

15

Variance & Standard Deviation

■ 분산과 표준편차의 특징

- 분산과 표준편차는 항상 _____ 보다 크다
- 모든 데이터가 같지 않는 한, 분산과 표준편차는 _____이 아님

■ 경험법칙: 종모양에 국한

- 모든 관측치의 약 68%는 평균의 1 표준편차 이내에 속한다
- 모든 관측치의 약 95%는 평균의 2 표준편차 이내에 속한다
- 모든 관측치의 약 99.7%는 평균의 3표준편차 이내에 속한다
- 모든 관측치의 약 99.9996%는 평균의 6표준편차 이내에 속한다

16

Variance & Standard Deviation

■ 체비세브의 정리 (Chebyshev's Theorem)

- 모든 히스토그램의 모습에 적용 (경험의 법칙보다 더 일반적임)

$$1 - \frac{1}{k^2} \text{ for } k > 1$$

■ 측정 단위 혹은 규모가 다른 두 자료의 비교

- 표준화의 활용 (예: 표준점수)

$$Z = \frac{X - \mu}{\sigma}$$

- 변동계수의 활용

17

Relative Location

■ 백분위수 (Pth percentile)

- 이 값보다 적은 값들이 관측치들의 P%이고 이 값보다 큰 값들이 관측치들의 (100-P)%인 값

■ 백분위수의 위치

$$L_P = (n + 1) \frac{P}{100}$$

where L_P is the location of the P^{th} percentile

■ 예제 3.11

- Sample: 0 0 5 7 8 9 12 14 22 33
- $L_{25} = (10+1)(25/100) = 2.75$: 2번째와 3번째 수의 $\frac{3}{4}$ 위치에 존재
- $0 + 3.75 = \mathbf{3.75}$

18

Quartiles

■ 정의

- 사분위수
- 데이터를 같은 크기의 네부분으로 나누어 흩어진 정보를 측정
- 첫번째 사분위수 (first quartiles): 상위 25%
- 두번째 사분위수 (second quartiles): 상위 50%
- 참고: 십분위수(deciles), 백분위수 (percentiles)
- 사분위 범위 (inter quartile range): $Q_3 - Q_1$

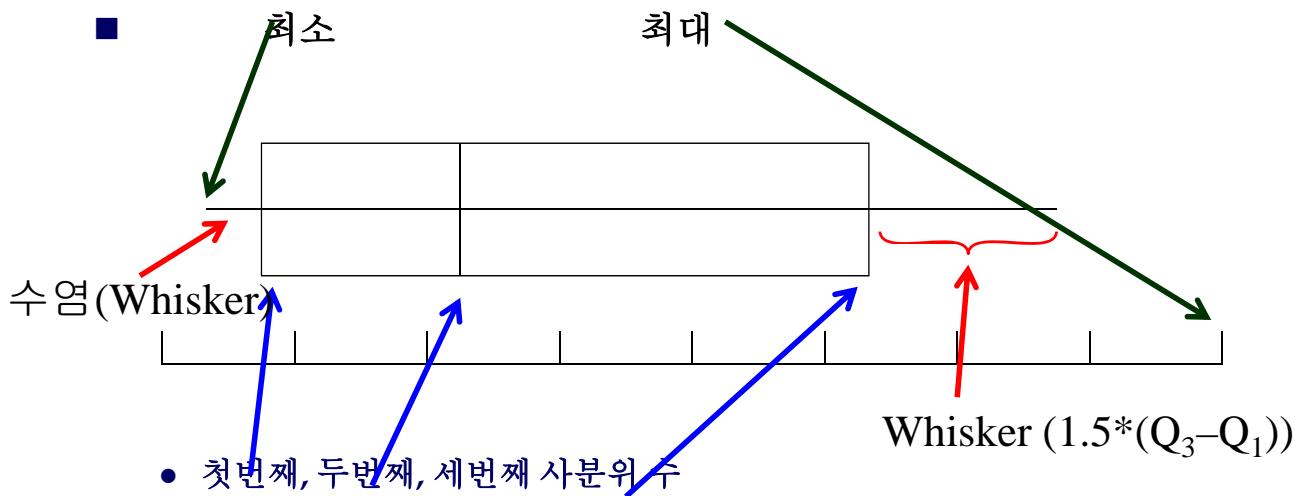
■ 예제

	A	B	C	D	E	F
1	Bills					
2	42.19		Range (범위)	사분위수		
3	38.45		119.63	=QUARTILE(A2:A201,1)		
4	29.23			QUARTILE(array, quart)		
5	89.35					
6	118.04					

19

Box Plot

- 박스그림(Box plot)은 5개의 통계치 (최소, 최대, 첫사분위수, 두번째 사분위수, 세번째사분위수)를 그림에 담을 수 있다.



- Data Analysis Plus를 통해 구현 가능

20

Skewness & Kurtosis

■ 왜도 (skewness)

- 평균을 중심으로 어느 정도 대칭적인 모양인가를 나타내는 척도
- (1) 왜도<0: _____으로 긴 꼬리
- (2) 왜도>0: _____으로 긴 꼬리
- (3) 왜도=0: _____임을 의미

■ 첨도 (kurtosis)

- 데이터들의 분포가 정규분포에 비해 얼마나 뾰족한지를 나타내는 척도
- (1) 첨도<3: 정규분포보다 _____한 분포
- (2) 첨도>3: 정규분포보다 _____한 분포
- (3) 첨도=3: 정규분포보다 _____한 분포

21

Skewness & Kurtosis

■ 예제 Xm02-04

SUM					
A	B	C	D	E	F
1 Bills					
2 42.19		Range (범위)	사분위수		
3 38.45		119.63	9.385		
4 29.23					
5 89.35					
6 118.04		표준편차			
7 110.46		38.96970945			
8 0.00					
9 72.88		=skew(a2:a201)			
10 83.05		SKEW(number1, [number2], ...)			
11 95.73					
12 103.15					

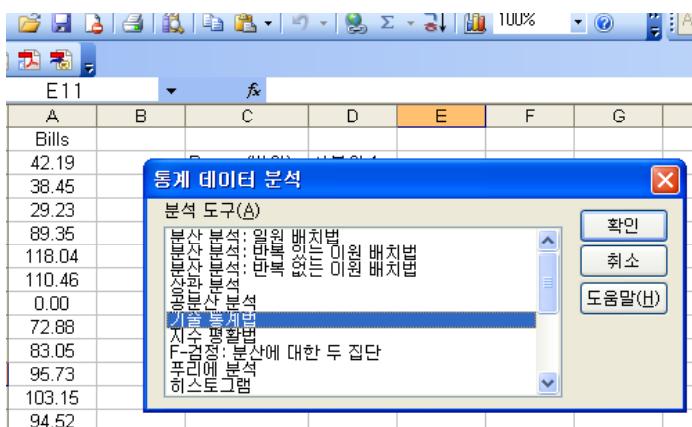
SUM					
A	B	C	D	E	F
1 Bills					
2 42.19		Range (범위)	사분위수		
3 38.45		119.63	9.385		
4 29.23					
5 89.35					
6 118.04		표준편차			
7 110.46		38.96970945			
8 0.00		왜도			
9 72.88		0.541373548			
10 83.05		첨도			
11 95.73		=kurt(a2:a201)			
12 103.15					

22

Summary Statistics

■ 예제 Xm02-04

- 도구 - 데이터분석-기술통계법
- 입력범위 A1:A201
- 요약통계량 클릭



Column1

평균	43.5876
표준 오차	2.755575
중앙값	26.905
최빈값	0
표준 편차	38.96971
분산	1518.638
첨도	-1.291907
왜도	0.541374
범위	119.63
최소값	0
최대값	119.63
합	8717.52
관측수	200

23

III. Linear Relationship

- 두 변수간의 선형관계의 강도와 방향(strength & direction)에 대한 정보를 제공하는 수치 기법에 대해 살펴봄
 - 공분산 (covariance),
 - 상관계수 (coefficient of correlation)
 - 결정계수 (coefficient of determination)

24

Covariance

- 정의
 - 두 변수의 값이 각각의 평균으로부터 얼마나 떨어져 있는지를 나타내는 수치로써, 두 변수간의 선형관계를 파악하기 위해서 사용

$$\text{Population covariance} = \sigma_{xy} = \frac{\sum_{i=1}^N (x_i - \mu_x)(y_i - \mu_y)}{N}$$
$$\text{Sample covariance} = s_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n-1} \quad s_{xy} = \frac{1}{n-1} \left[\sum_{i=1}^n x_i y_i - \frac{\sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n} \right]$$

■ 공분산의 특징

- (-inf, inf) 사이의 값을 가짐
- 공분산은 _____에 따라 두 변수간의 상관방향만을 나타낼 뿐이고, 크기는 무관

25

Correlation Coefficient

■ 정의

- 공분산을 두 변수의 표준편차의 곱으로 나누어준 값
- 공분산에는 두 변수의 scale에 대한 고려가 전혀 없는데 반해, 상관계수는 scale에 대한 고려가 포함되어 있음

$$\text{Population coefficient of correlation: } \rho = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \quad \text{Sample coefficient of correlation: } r = \frac{s_{xy}}{s_x s_y}$$

■ 특징

- 상관계수는 항상 ___과 ___사이에 존재함
- 상관계수가 1에 가까우면, ___ 상관관계를 의미
- 상관계수가 -1에 가까우면, ___ 상관관계를 의미
- 상관계수가 0에 가까우면, ___ 상관관계 의미
- (1) 두 변수가 독립이면, 두 변수간의 상관계수는 0?
- (2) 두 변수간의 상관계수가 0이면, 두 변수는 독립?

26

Example

■ 예제 3.16: 공분산의 계산

	X	Y	(X- \bar{X})	(Y- \bar{Y})	(X- \bar{X})(Y- \bar{Y})	covariance
Set #1	2	13	-3	-7	21	$s_{xy} = 17.5$
	6	20	1	0	0	
	7	27	2	7	14	
Set #2	2	27	-3	7	-21	$s_{xy} = -17.5$
	6	20	1	0	0	
	7	13	2	-7	-14	
Set #3	2	20	-3	0	0	$s_{xy} = -3.5$
	6	27	1	7	7	
	7	13	2	-7	-14	

For each set: $\bar{X} = 5$ $\bar{Y} = 20$

27

Example

■ 표준편차의 계산

$$r = \frac{s_{xy}}{s_x s_y} = \frac{17.5}{(2.65)(7.0)} = .943$$

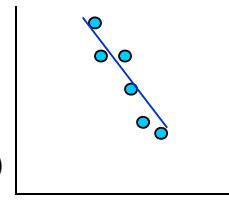
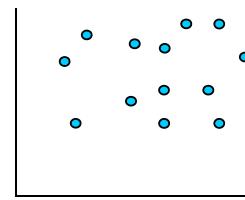
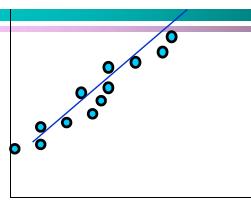
$$r = \frac{s_{xy}}{s_x s_y} = \frac{-17.5}{(2.65)(7.0)} = -.943$$

$$r = \frac{s_{xy}}{s_x s_y} = \frac{-3.5}{(2.65)(7.0)} = -.189$$

28

Correlation Coefficient vs. Scatter Diagram

$$\rho \text{ or } r = \begin{cases} +1 & \text{Strong positive linear relationship} \\ 0 & \text{No linear relationship} \\ -1 & \text{Strong negative linear relationship} \end{cases}$$



29

IV. Least Square Method

- 산포도는 선형관계의 강도와 방향을 측정
- 산포도에 직선을 그어 그 강도와 방향을 추정
- 이를 위해 개발된 방법이 최소자승법(Least Square Method)

$$\hat{y} = b_0 + b_1 x$$

$$b_1 = \frac{s_{xy}}{s_x^2}$$
$$b_0 = \bar{y} - b_1 \bar{x}$$
$$\hat{y} = b_0 + b_1 x$$

30

Least Squares Method

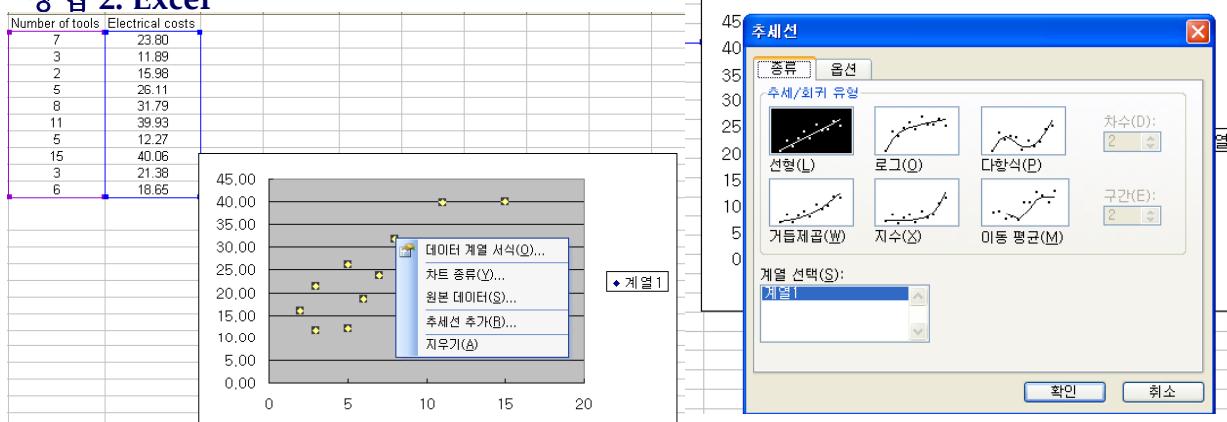
- 예제 3.17: 고정비용과 변동비용의 추정; Xm03-17

$$y = b_0 + b_1 x$$

- 단, y = 전체비용, b_0 = 고정비용, b_1 = 변동비용, x = 공구수

방법 1: 직접 계산: 교제 125페이지 참조

방법 2: Excel



31

Least Squares Method

