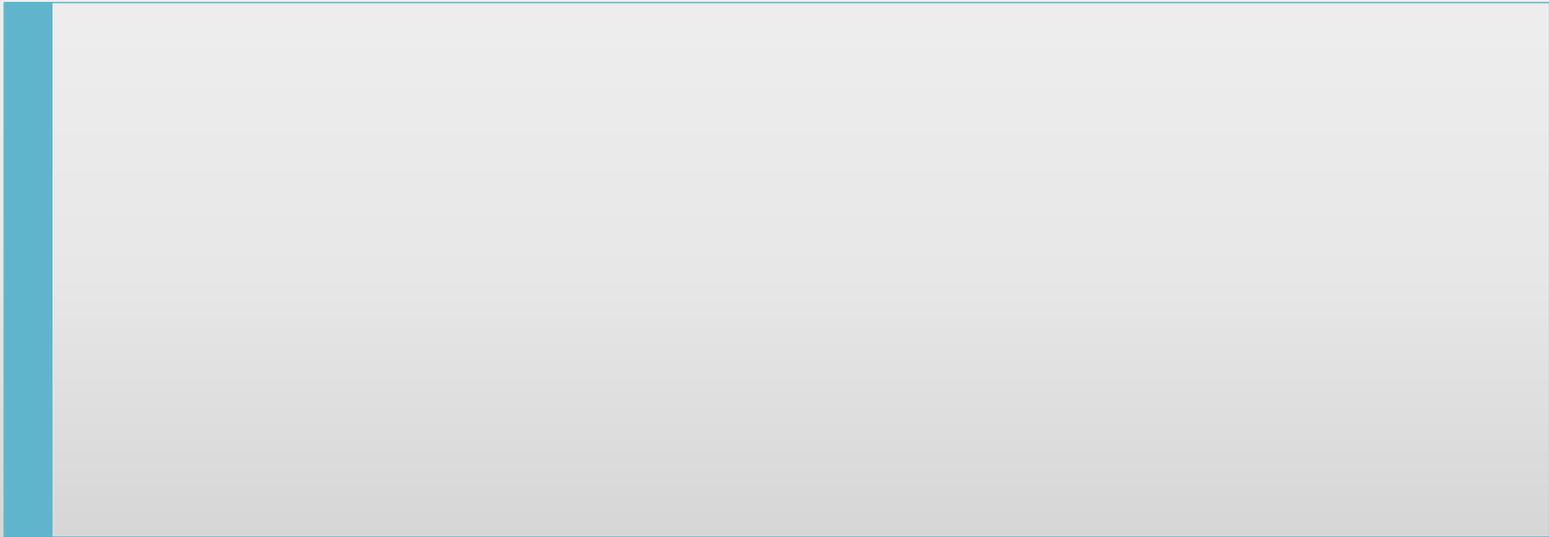


7주

제4장 확률변수(3) – 이항분포의 정규근사



이항분포의 정규근사

▶ 이항분포

- 어느 특정한 속성을 가지는 개체의 비율을 p , 이러한 집단으로부터 임의로 추출된 크기가 n 인 확률표본에서 그 특정한 속성을 가지는 원소의 수를 X 라고 하자.
- 확률변수 X 는 평균이 np 이고 표준편차가 $\sqrt{np(1-p)}$ 인 이항확률분포를 따름, 이항확률분포

$$f(x) = P[X = x] = \binom{n}{x} p^x (1-p)^{n-x}, \quad x = 0, 1, \dots, n.$$

- $X \sim B(n, p)$ 일 때, np 와 $\sqrt{np(1-p)}$ 가 둘 다 크면(대체로 5보다 클 때) X 는 평균이 np 이고 표준편차가 $\sqrt{np(1-p)}$ 정규분포에 매우 잘 근사함

$$Z = \frac{X - np}{\sqrt{np(1-p)}}$$

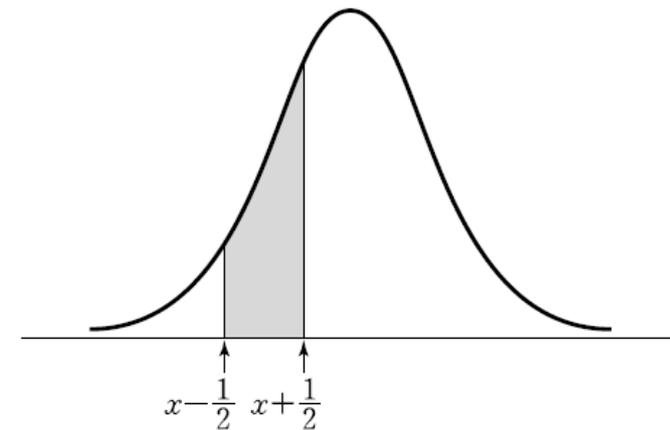
이 근사적으로 표준정규분포를 따른다

▶ 연속성의 수정(continuity correction)

- 이항확률변수 X 에 대한 확률을 표준정규분포를 이용하여 계산
- 근사 확률을 계산할 때 이산형의 확률 값을 연속형의 표준정규분포로 근사시키는 것이기 때문에 연속성의 수정을 하여야함
- 이산확률변수 X 에 대한 확률 $P[X = x]$ 를 다음과 같이 수정

$$P[X = x] \simeq P[x - 1/2 \leq X \leq x + 1/2]$$

- ▶ 연속확률변수의 경우는 한 값을 취할 확률이 항상 0이기 때문에 이산확률변수의 확률을 얻기 위해서는 $1/2$ 을 더해주고 빼서 구간의 형태로 수정한 후 연속확률변수에 대한 확률을 근사 시킴



|그림 4.13| 연속성의 수정

- ▶ 예) 우리나라 중·고교생 가운데 근시인 학생은 20%라고 한다. 이제 우리나라 중·고교생 중에서 100명을 표본으로 추출하여 시력을 검사하였다. 그 중에서 근시인 학생이 15명에서 18명 사이로 나타날 확률을 구하여 보자. (출처: 통계학의 이해)
- $X \sim B(100, 0.2)$
 - 물론 근시인지 아닌지 두 가지 결과로 나타나는 현상이기 때문에 근시인 학생 수는 이항분포를 한다. 그러므로 이항분포로부터 확률을 구할 수는 있다.
 - $n = 100, p = 0.20$ 이므로 X 가 15에서 18 사이에 갖게 될 확률

$$\begin{aligned}
 P(15 \leq X \leq 18) &= P(X = 15) + P(X = 16) + P(X = 17) + P(X = 18) \\
 &= \frac{100!}{15!85!} (0.20)^{15} \cdot (0.80)^{85} + \dots + \frac{100!}{18!82!} (0.2)^{18} (0.8)^{82} \\
 &= \text{????}
 \end{aligned}$$

■ 풀이

▶ 이항확률변수 X 는 $n = 100$ 이고 $p = 0.20$, $X \sim B(100, 0.2)$

□ 평균= $np=20$

□ 분산= $np(1-p)=16$

□ 표준편차= 4

▶ 표본 크기가 충분히 크기 때문에 정규분포로 접근시켜 확률을 구함

무수히 많은 표본을 뽑는다면 근시인 학생 수는 확률변수 X 로서 평균이 20 이고 분산이 16 인 정규분포에 접근한다.

따라서 $P(15 \leq X \leq 18)$ 은 연속성 수정하여 $P(14.5 < X < 18.5)$ 로 구함

$$P(15 \leq X \leq 18) = P\left(\frac{14.5 - \mu}{\sigma} < Z < \frac{18.5 - \mu}{\sigma}\right)$$

$$\begin{aligned}
& P(15 \leq X \leq 18) \\
&= P\left(\frac{(14.5 - \mu)}{\sigma} < Z < \frac{(18.5 - \mu)}{\sigma}\right) \\
&= P\left(\frac{14.5 - 20}{4} < \frac{X - \mu}{\sigma} < \frac{18.5 - 20}{4}\right) \\
&= P(-1.38 < Z < -0.38) ; \text{좌우대칭분포이므로} \\
&= P(Z < -0.38) - P(Z < -1.38) ; \text{표준정규분포로부터 값을 구하면} \\
&= (1 - 0.6480) - (1 - 0.9162) \\
&= 0.3520 - 0.0838 \\
&= 0.2682
\end{aligned}$$

∴ 따라서 중 · 고교생 가운데서 100 명을 뽑았을 때
근시인 학생이 15 명에서 18 명 사이로 나타날 확률은 26.82 %

- ▶ [예제 4.21] 5년 전에 행해진 대규모 조사에서 성인의 10%가 왼손을 주로 사용하는 왼손잡이라고 한다. 만일 이 비율이 현재에도 적용된다면 성인 1000명의 확률표본에서 왼손잡이인 사람이
- (a) 120명 이하일 확률은 얼마인가?
- (b) 90명 이상 100명 이하일 확률은 얼마인가?

확률변수 X 를 성인 1000명의 확률표본에서 왼손을 주로 사용하는 사람의 수라고 하자. 그러면 X 는 $n = 1000$ 이고 $p = 0.1$ 인 이항분포를 따른다.

$$np = 100, \quad \sqrt{np(1-p)} = \sqrt{90} = 9.49$$

이므로 확률변수 X 는 근사적으로 $N(100, 9.49^2)$ 을 따른다. 따라서

$$\begin{aligned} \text{(a)} \quad P[X \leq 120] &\simeq P\left[Z \leq \frac{120 - 100}{9.49}\right] \\ &= P[Z \leq 2.11] \\ &= 0.9826 \end{aligned}$$

$$\begin{aligned} \text{(b)} \quad P[90 \leq X \leq 100] &\simeq P\left[\frac{90 - 100}{9.49} \leq Z \leq \frac{100 - 100}{9.49}\right] \\ &= P[-1.05 \leq Z \leq 0] \\ &= 0.5 - 0.1469 = 0.3531 \end{aligned}$$



- ▶ 예) 어느 영어시험에서의 점수 X 는 평균이 497점이고 표준편차가 120인 정규모집단에서의 관측 값으로 간주할 수 있다고 한다. 이 때 다음을 구하라.
- (a) 600점 이상의 사람들만 합격한다고 했을 때 합격자의 비율을 구하라.
- (b) 상위 10%에 해당되는 사람들만 합격한다고 했을 때, 합격자 중에서 최저 점수는 얼마인가?

$$X \sim N(497, 120^2)$$

$$(a) P(X \geq 600) = ?$$

$$P(X \geq 600) = P\left(Z \geq \frac{600 - 497}{120}\right) = P(Z \geq 0.86)$$

$$= 1 - P(Z \leq 0.86) = 1 - 0.8051 = 0.1949$$

$$\therefore 19.49\%$$

$$(b) Z_{0.1} = 1.28, X = ?$$

$$\frac{X - 497}{120} = 1.28$$

$$\therefore X = 650.6 \text{ 점}$$

- ▶ 예) A 지역에 거주하는 성인의 30%가 습관적으로 술을 마신다고 한다. 이 지역에서 성인 1000명을 임의로 추출했을 때, 그 중에 습관적으로 술을 마시는 사람이
- (a) 280명 이하일 확률은 얼마인가?
- (b) 300명 이상 330명 이하일 확률은 얼마인가?

$$(a) X \sim B(1000, 0.3) \approx N(300, 210^2)$$

$$\bullet E(X) = np = 1000 \times 0.3 = 300$$

$$\bullet \text{Var}(X) = npq = 1000 \times 0.3 \times 0.7 = 210$$

$$P(X \leq 280) = ?$$

$$P(X \leq 280) = P\left(Z < \frac{280.5 - 300}{\sqrt{210}}\right) = P(Z < -1.35)$$

$$= 1 - P(Z < 1.35) = 1 - 0.9115 = 0.0885$$

$$(b) P(300 \leq X \leq 330) = P\left(\frac{299.5 - 300}{\sqrt{210}} < Z < \frac{330.5 - 300}{\sqrt{210}}\right)$$

$$= P\left(\frac{-0.5}{\sqrt{210}} < Z < \frac{30.5}{\sqrt{210}}\right) = P(-0.035 < Z < 2.10)$$

$$= P(Z < 2.10) - (1 - P(Z < 0.035))$$

$$= 0.9821 - .484 = .4981$$

-
- ▶ 예) 어느 회사에서 직원들의 60%가 아파트에 거주하고 있음을 알았다. 회사 직원 20명을 대상으로 아파트 거주여부를 조사하였다.

(a) 아파트에 거주하는 직원의 수(X)가 10명 이상 14명 미만일 확률을 구하라.

$$X \sim B(20, 0.6)$$

$$P(10 \leq X < 14) = P(X \leq 13) - P(X \leq 9)$$

$$= 0.750 - 0.128$$

$$= 0.622$$

(b) 만약 150명의 직원을 대상으로 아파트 거주여부를 조사하였다면, 아파트에 거주하는 직원의 수(Y)가 82명 초과 101명 이하일 확률을 구하라.

$$Y \sim B(150, 0.6) \approx N(90, 36)$$

$$P[82 < Y \leq 101] \approx P[82.5 < Y < 101.5]$$

$$= P\left[\frac{82.5 - 90}{6} < Z < \frac{101.5 - 90}{6}\right]$$

$$= P[-1.25 < Z < 1.92]$$

$$= 0.9726 - (1 - 0.8944) = 0.867$$

SPSS를 이용한 실습

- ▶ SPSS에 정의된 다음의 함수들을 이용하면 이항확률분포, 정규분포 등의 확률분포의 확률 값을 계산할 수 있다. 관련된 함수들을 정리하면 다음과 같다.

PDF.BINOM(x, n, p) : 모수가 n, p 인 이항확률변수가 x 값이 되는 확률 값을 반환한다.

CDF.BINOM(x, n, p) : 모수가 n, p 인 이항확률변수가 x 값보다 작거나 같을 누적 확률을 반환한다.

CDF.NORMAL(z) : 표준정규확률변수가 z 값보다 작을 확률을 반환한다.

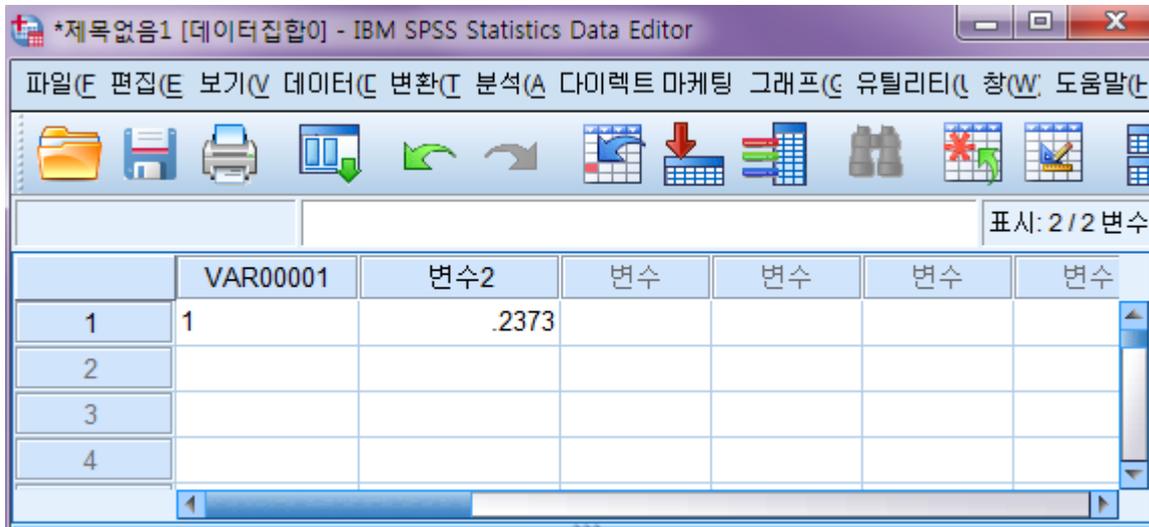
CDF.NORMAL(x, μ, σ) : 평균이 μ 이고 표준편차가 σ 인 정규확률변수가 x 보다 작을 확률 값을 반환한다. 따라서 CDF.NORMAL($x, 0, 1$)와 CDF.NORMAL(x)는 동일하다.

PROBIT($1 - \alpha$) : 표준정규확률분포의 누적 확률이 $1 - \alpha$ 가 되는 표준정규확률변수의 값을 반환한다. 즉, 본문에서 다루었던 z_α 값을 반환한다. 예를 들어 PROBIT(0.95)는 $z_{0.05}$ 로서 1.645이다.

- ▶ [예제 4.22] 예제 4.11의 문제를 SPSS를 이용해 풀어보자.
- 확률변수 X 가 $n=5$ 이고 $p=0.25$ 인 이항확률변수일 때 (a)는 $P[X=0]$ 을 구하는 문제로서 PDF.BINOM(0, 5, 0.25)가 된다. 이 확률 값은 다음의 절차를 통해 얻을 수 있음
 - 변환(T) ▷ 변수 계산(C)
 - ▶ 변수계산 창에서 새 변수 "변수2"를 정의하고 숫자 표현식에 해당되는 함수 PDF.BINOM(,,)를 찾아 옮긴 후 각각의 값을 입력하여 PDF.BINOM(0, 5, 0.25) 을 정한 후 확인을 클릭



- ▶ 다음과 같이 같이 데이터 편집기 창에 그 확률 값을 갖는 "변수2"가 생성




*제목없음1 [데이터집합] - IBM SPSS Statistics Data Editor

파일(F) 편집(E) 보기(V) 데이터(D) 변환(T) 분석(A) 다이렉트 마케팅 그래프(G) 유틸리티(U) 창(W) 도움말(H)

표시: 2 / 2 변수

	VAR00001	변수2	변수	변수	변수	변수
1	1	.2373				
2						
3						
4						

- 문제 (b)는 확률 $P[X \geq 4]$ 을 구하는 것으로 이것은 $1 - \text{CDF.BINOM}(3,5,0.25)$ 로 나타내어진다. 따라서 그림 4.16과 같이 입력하면 확률 값 0.016을 얻을 수 있다.



	VAR00001	변수2	변수3	변수
1	1	.2373	.02	

- ▶ [예제 4.23] 예제 4.18의 (a) 문제를 해결해 보자.
- 확률변수 X 가 $N(3, 2^2)$ 을 따를 때 $P[2 < X < 5]$ 의 값은 $\text{CDF.NORMAL}(5, 3, 2) - \text{CDF.NORMAL}(2, 3, 2)$ 로서 다음 그림 4.17과 같이 입력하면 구할 수 있다.

