

2016/03/04

[2016-동계세미나-확률 기초]

Chapter 6 연속형 균일분포 (2)

- 6.4~6.10 -

이 부 형(boohyung@pel.smuc.ac.kr)

상명대학교 프로토콜공학연구실

Contents

- 이항분포의 정규근사
- 감마분포와 지수분포
- 카이제곱분포
- 베타분포
- 로그정규분포
- 와이블 분포

이항분포의 정규근사

- 이항분포의 정규근사: 이항분포에서 n 이 충분히 크다면 정규분포의 면적을 이용하여 이항분포의 근사값을 계산할 수 있는 원리
- 이항분포에서 n 이 크고, p 가 아주 작거나 크지 않은 경우
- 이항분포에서 n 이 작고, p 가 $\frac{1}{2}$ 에 가까운 값일 경우

- X 가 $\mu = np$ 이고 $\sigma^2 = npq$ 인 이항확률변수이면, $n \rightarrow \infty$ 일 때

$$Z = \frac{X - np}{\sqrt{npq}}$$

는 표준정규분포, 즉 $n(z; 0, 1)$ 을 따름

이항분포의 정규근사

- 연속성 수정: 이항분포의 정규근사에서, 이항분포는 이산형 분포이기 때문에 연속형 분포로 더 적합하게 근사시켜 확률을 정확하게 구하기 위해 수정하는 값

- $X \pm 0.5$

- X 를 모수 n 과 p 를 갖는 이항확률변수라고 하자.
그러면 X 는 평균이 $\mu = np$ 이고 분산이 $\sigma^2 = npq$ 인 정규분포를 근사적으로 따르게 됨

$$P(X \leq x) = \sum_{k=0}^x b(k; n, p) \approx P\left(Z \leq \frac{x + 0.5 - np}{\sqrt{npq}}\right)$$

- 이항분포의 정규근사는 np 와 nq 가 5 이상일 때 더 적합
 - ref. 교재에서 표 6.1 정규근사와 실제누적이항확률(표)

이항분포의 정규근사

- 예제 6.15) 빈혈환자가 회복될 확률은 0.4라고 한다. 100명의 빈혈환자 중에서 회복되는 환자의 수가 30보다 적을 확률은?

풀이) 이항변수 X 는 회복될 환자의 수, $n = 100$

$$\mu = np = 100(0.4) = 40$$

$$\sigma = \sqrt{npq} = \sqrt{100(0.4)(0.6)} \approx 4.899$$

연속성 수정에 의해 $x = 30 - 0.5 = 29.5$

$$Z = \frac{29.5 - 40}{4.899} = -2.14$$

$$P(X < 30) \approx P(Z < -2.14) = 0.0162$$

이항분포의 정규근사

- 예제 6.16) 4지선다형 문제 200개가 있다고 하자. 그 시험에 대해 전무한 학생이 200문제 중 80문제의 답을 추측만으로도 골랐을 때, 정답이 25개에서 30개일 확률은?

풀이) X 가 그 학생이 맞춘 정답의 수, $p = 0.4$

$$P(25 \leq X \leq 30) = \sum_{x=25}^{30} b(x; 80, \frac{1}{4})$$


$$\mu = np = 80 \left(\frac{1}{4} \right) = 20$$

이항분포의 정규근사

- 예제 6.16) 4지선다형 문제 200개가 있다고 하자. 그 시험에 대해 전무한 학생이 200문제 중 80문제의 답을 추측만으로도 골랐을 때, 정답이 25개에서 30개일 확률은?

풀이) $\sigma = \sqrt{npq} = \sqrt{80\left(\frac{1}{4}\right)\left(\frac{3}{4}\right)} \approx 3.873$

- 표준편차의 의미
 - 표본의 68.2%: 16.127~23.873
 - 표본의 95.4%: 12.254~27.746



이항분포의 정규근사

- 예제 6.16) 4지선다형 문제 200개가 있다고 하자. 그 시험에 대해 전무한 학생이 200문제 중 80문제의 답을 추측만으로도 골랐을 때, 정답이 25개에서 30개일 확률은?

풀이) 이항분포를 정규곡선에 근사시키면

$$x_1 = 24.5, x_2 = 30.5$$

$$z_1 = \frac{24.5 - 40}{3.873} = 1.16, \quad z_2 = \frac{30.5 - 40}{3.873} = 2.71$$

$$P(25 \leq X \leq 30) = \sum_{x=25}^{30} b(x; 80, 0.25)$$

$$\approx P(1.16 < Z < 2.71) = 0.9966 - 0.8770 = 0.1196$$


감마분포와 지수분포

- 감마함수(factorial 함수의 정의역 확장: 복소수까지)

$\alpha > 0$ 인 α 에 대해서

$$\Gamma(\alpha) = \int_0^{\infty} x^{\alpha-1} e^{-x} dx$$

- $\Gamma(n) = (n-1)(n-2) \dots (1)\gamma(1) = (n-1)!$
- $\Gamma(1) = 1$
- $\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$



감마분포와 지수분포

- 감마분포: 특정한 횟수만큼의 포아송 사건이 발생할 때까지의 시간을 나타내는 분포

- 특정한 횟수가 모수 α


- 연속확률변수 X 의 확률밀도함수가

$$f(x; \alpha, \beta) = \begin{cases} \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-\frac{x}{\beta}}, & x > 0 \\ 0, & \text{다른 곳에서(단, } \alpha > 0, \beta > 0) \end{cases}$$

과 같이 주어질 때, X 는 모수 α, β 를 가지는 감마분포를 따름

감마분포와 지수분포

- 감마분포의 그래프(그래프에서 $k = \alpha, \theta = \beta$)



- 감마분포의 평균과 분산

$$\mu = \alpha\beta, \quad \sigma^2 = \alpha\beta^2$$

감마분포와 지수분포

- 지수분포: $\alpha = 1$ 인 감마분포

연속형 확률변수 X 의 밀도함수가

$$f(x; \beta) = \begin{cases} \frac{1}{\beta} e^{-\frac{x}{\beta}}, & x > 0 \\ 0, & \text{다른 곳에서(단, } \beta > 0) \end{cases}$$

과 같이 주어질 때, X 는 모수 β 를 가지는 지수분포를 따름

- 포아송 분포(이산) \rightarrow 지수분포(연속)

- 어느 사건이 포아송분포를 따른다면, 이러한 사건들이 발생하는 사이에 경과되는 시간은 지수분포를 따름

감마분포와 지수분포

- 포아송 분포(이산) → 지수분포(연속)
- 어느 사건이 포아송 분포를 따른다면, 이러한 사건들이 발생하는 사이에 경과되는 시간은 지수분포를 따름
- 예제(네트워크)
 - 라우터에 패킷 도착: 포아송 분포
 - 라우터에서 패킷이 머무르는 동안의 처리 시간: 지수분포

감마분포와 지수분포

• 지수분포의 예


- 전자제품이나 기계가 시간이 지날수록 고장 나지 않을 확률
- 시간이 지날수록 휴대폰 배터리가 남아 있을 확률
- 사람이 나이를 먹을수록 살아있을 확률

• 지수분포의 평균과 분산

$$\mu = \beta, \quad \sigma^2 = \beta^2$$

- λ 를 이용한 평균과 분산, 표준편차 계산

$$\text{평균} = \frac{1}{\lambda}, \quad \text{분산} = \frac{1}{\lambda^2}, \quad \text{표준편차} = \sqrt{\frac{1}{\lambda^2}}$$



감마분포와 지수분포

- 예제 6.18) 전화교환기에 도착되는 호출신호는 분당 평균이 5회인 포아송 과정을 따른다고 한다. 1분 내에 2번의 호출신호가 도착될 확률은?

풀이) 2번의 호출신호가 도착되기까지의 소요 시간을 X 라고 하면, 이는 2번의 포아송 사건이 발생되기까지 소요된 시간

$$\alpha = 2, \quad \beta = \frac{1}{5}$$
$$P(X \leq 1) = \int_0^1 \frac{1}{\beta^2} x e^{-\frac{x}{\beta}} dx = 25 \int_0^1 x e^{-5x} dx$$
$$= 1 - e^{-5} (1 + 5) = 0.96$$

카이제곱분포

• 카이제곱분포

- 분산이 퍼져있는 모습을 분포로 만든 것
- 감마분포의 두 번째 특수한 경우

- $\alpha = \frac{\nu}{2}, \beta = 2$ (ν : 자유도)

- 카이제곱분포의 정의: 표준정규 확률변수 X 의 확률분포가

$$f(x; \nu) = \begin{cases} \frac{1}{2^{\frac{\nu}{2}} \Gamma(\frac{\nu}{2})} x^{\frac{\nu}{2}-1} e^{-\frac{x}{2}}, x > 0 \\ 0, \text{ 다른 곳에서(단, } \nu \text{는 양의 정수)} \end{cases}$$


와 같이 주어질 때, X 는 자유도 ν 인 카이제곱분포를 따른다고 함

- 카이제곱분포의 평균과 분산


$$\mu = \nu, \quad \sigma^2 = 2\nu$$

카이제곱분포

- 카이제곱분포
 - 카이제곱분포의 그래프
 - $k = \nu$ (자유도)



카이제곱분포



• 카이제곱분포


• 자유도의 의미

- 주어진 조건에서 자유롭게 뽑을 수 있는 수
 - 표본의 수 - 1
- 예제> 대한민국 전체 고등학교 3학년 학생의 수학 점수의 평균이 50점이다. 이때, 몇몇 대표할만한 학생들의 수학 성적을 바탕으로 정보를 추출하려고 한다. 표본의 수는 100명으로 정하고 평균은 50점이다.

→ 99명은 임의로 뽑을 수 있지만 나머지 1명은 모집단의 평균과 표본집단의 평균은 같아야 하므로 임의로 뽑을 수 없음
(∵ 표본집단은 모집단을 대표한다)

$$\text{자유도 } \nu = 100 - 1 = 99$$

카이제곱분포



• 카이제곱분포

• 자유도의 의미

- 주어진 조건에서 자유롭게 뽑을 수 있는 수
 - 표본의 수 - 1
- 예제> 대한민국 전체 고등학교 3학년 학생의 수학 점수의 평균이 50점이다. 이때, 몇몇 대표할만한 학생들의 수학 성적을 바탕으로 정보를 추출하려고 한다. 표본의 수는 100명으로 정하고 평균은 50점이다.

→ 100명의 표본을 추출할 때, 만약 99명의 점수 합이 4,928 점이라면, 나머지 1명을 뽑을 때는 무조건 점수가 72점인 학생을 뽑아야 함

(∵ 100명의 총 점수 합 = 5,000)

카이제곱분포

- 카이제곱분포

- 이용: 카이제곱 검정

- 두 변수의 연관성에 대한 검정

- 각 범주에 대한 기대값을 구함

- 범주별 카이제곱 값 구하기

- 카이제곱 값 = $(\text{관측값} - \text{기대값})^2 / \text{기대값}$

- 전체 카이제곱 값 구하기

- 자유도 구하기

- 유의수준에 해당하는 카이스퀘어 값과 비교하여 결론

- 유의수준(p-value): 귀무가설을 기각할 수 있는 최소한의 확률

- 이 예제에서 귀무가설은 “흡연과 주량은 연관성이 없다.”

- 예제. 흡연량과 음주량 사이에는 연관성이 있는가?

카이제곱분포

- 카이제곱분포

- 이용: 카이제곱 검정

- 두 변수의 연관성에 대한 검정

- 예제. 흡연량과 음주량 사이에는 연관성이 있는가?

	1갑 이상	1갑 이하	안피움	계
반 병 이상	23	21	63	107
반 병 이하	31	48	159	238
못마심	13	23	119	155
계	67	92	341	500

- 범주별 기대값 구하기

- 1갑 이상 + 반 병 이상은 23명
 - $67(1갑\ 이상의\ 계) * 107(반\ 병\ 이상의\ 계) / 500(총계) = 14.338$

카이제곱분포

- 카이제곱분포

- 이용: 카이제곱 검정

- 두 변수의 연관성에 대한 검정

- 예제. 흡연량과 음주량 사이에는 연관성이 있는가?

- 범주별 카이제곱 값 구하기

$$\chi^2 = \frac{(\text{관측값} - \text{기대값})^2}{\text{기대값}}$$

- 전체 카이제곱 값 구하기(예제에서 전체 카이제곱 값은 12.87)

- 흡연량과 음주량의 자유도는 각각 2; 카이제곱 검정을 위한 자유도는 $2 * 2 = 4$


카이제곱분포

- 카이제곱분포

- 이용: 카이제곱 검정

- 두 변수의 연관성에 대한 검정

- 예제. 흡연량과 음주량 사이에는 연관성이 있는가?



- 카이제곱분포표를 확인하여 기준 카이제곱 값을 결정
 - 서로 비교하여 계산한 카이제곱 값이 크다면, 귀무가설을 기각
 - 결과: 음주량과 흡연량은 연관성이 있음

베타분포

- 베타분포

- 균일분포의 일반화

- 베타함수($\alpha, \beta > 0$ 이고 $\Gamma(\alpha)$ 는 감마함수)


$$B(\alpha, \beta) = \int_0^1 x^{\alpha-1} (1-x)^{\beta-1} dx = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha+\beta)}$$

- 정의: 연속형 확률변수 X 의 밀도함수가 다음과 같을 때 확률변수 X 는 모수가 $\alpha > 0$ 이고 $\beta > 0$ 인 베타분포를 따름

$$f(x) = \begin{cases} \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1}, & 0 < x < 1 \\ 0, & \text{다른 곳에서} \end{cases}$$

베타분포

- 베타분포
- 베타분포의 그래프



베타분포

- 베타분포

- 베타분포의 평균과 분산

$$\mu = \frac{\alpha}{\alpha + \beta}, \sigma^2 = \frac{\alpha\beta}{(\alpha + \beta)^2(\alpha + \beta + 1)}$$

- 베타분포의 활용

- 제조과정에서의 불량품의 비율(불량율)
- 화학약품의 불순률
- 기계의 가동률

베타분포

- 베타분포

- 예제> 공급받은 제품중 불량율을 나타내는 확률변수 X 는 $B(6, 3)$ 을 따른다. 불량인 제품이 80%이상일 확률은?

풀이) $B(6, 3) = \frac{\Gamma(6)\Gamma(3)}{\Gamma(9)} = \frac{1}{168}$

$$f(x) = 168x^5(1-x)^2, 0 < x < 1$$

$$\begin{aligned} P(X \geq 0.8) &= \int_{0.8}^1 168x^5(1-x)^2 dx \\ &= 168 \left[\frac{x^6}{6} - \frac{2x^7}{7} + \frac{x^8}{8} \right]_{0.8}^1 = 0.2013 \end{aligned}$$

로그정규분포

- 로그정규분포


확률변수 $Y = \ln(x)$ 가 평균 μ 이고 표준편차 σ 인 정규분포를 따를 때, 확률변수 X 의 분포

$$f(x; \mu, \sigma) = \begin{cases} \frac{1}{\sqrt{2\pi}\sigma x} e^{-\frac{1}{2\sigma^2}[\ln(x)-\mu]^2}, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

- 확률변수 x 에 자연로그를 취했을 때, 그 결과가 정규분포를 따름
- 활용: 신뢰도 분석, 보험에서 손해액 추정

로그정규분포

- 로그정규분포
- 로그정규분포의 그래프



- 로그정규분포의 평균과 분산

$$\mu = e^{\mu + \frac{\sigma^2}{2}}, \quad \sigma^2 = e^{2\mu + \sigma^2} (e^{\sigma^2} - 1)$$

와이블 분포

• 와이블 분포

- 1939년 스웨덴의 물리학자 와이블(Weibull)에 의해 고안됨
- 활용: 시스템의 작동과 안전에 영향을 주는 부품의 신뢰성 문제
 - e.g., 퓨즈가 타는 문제, 강철이 휘어지는 문제, 열감지센서가 고장나는 문제
 - 동일한 환경에 적용되는 동일한 부품이라 할 지라도 고장시기를 예측하기는 힘들
- 연속확률변수 X 의 확률분포가

$$f(x; \alpha, \beta) = \begin{cases} \alpha\beta x^{\beta-1} e^{-\alpha x^\beta}, & x > 0 \\ 0, & \text{다른 곳에서(단, } \alpha > 0, \beta > 0) \end{cases}$$


과 같이 주어질 때, X 는 모수 α, β 를 가지는 와이블 분포를 따름

와이블 분포

- 와이בל 분포

- 와이בל 분포의 그래프(pdf)

- 앞의 식에서 $\alpha = \frac{1}{\lambda}, \beta = k$
 - $\alpha = 1$ 로 고정하고 β 를 변화시킴
 - $\beta = 1$ 일 때, 와이בל 분포는 지수분포가 됨
 - $\beta > 1$ 일 경우, 정규곡선과 비슷하나, 대칭을 이루지는 않음



와이블 분포

- 와이블 분포

- 와이블 분포의 평균과 분산

$$\mu = \alpha^{-\frac{1}{\beta}} \Gamma\left(1 + \frac{1}{\beta}\right), \quad \sigma^2 = \alpha^{-\frac{2}{\beta}} \left\{ \Gamma\left(1 + \frac{2}{\beta}\right) - \left[\Gamma\left(1 + \frac{1}{\beta}\right) \right]^2 \right\}$$

- 와이블 분포의 누적분포함수

$$F(x) = 1 - e^{-\alpha x^\beta}, \quad x \geq 0, \alpha > 0, \beta > 0$$

와이블 분포

- 와이בל 분포

- 와이בל 분포의 고장률: t (시간 t 까지 고장 나지 않았다고 할 때)와 $t + \Delta t$ 사이에 고장날 조건부확률의 변화율

$$\begin{aligned} Z(t) &= \lim_{\Delta t \rightarrow 0} \frac{F(t + \Delta t) - F(t)}{\Delta t} \frac{1}{R(t)} = \frac{F'(t)}{R(t)} \\ &= \frac{f(t)}{R(t)} = \frac{f(t)}{1 - F(t)} = \alpha\beta t^{\beta-1}, t > 0 \end{aligned}$$

- $R(t)$: 시점 t 에서의 주어진 부품의 신뢰도

$$= P(T > t) = \int_t^{\infty} f(t)dt = 1 - F(t)$$

- 신뢰도: 부분이나 생산품이 규정된 조건하에서 최소한 어느 특정시간까지 작동할 확률

와이블 분포

- 와이בל 분포

- 와이בל 분포의 고장률

- 고장률의 의미

- $\beta = 1$ 이면 고장률은 α (상수)
 - $\beta > 1$ 이면 $Z(t)$ 는 증가함수: 부품이 시간에 따라 마모되는 현상을 표현
 - $\beta < 1$ 이면 $Z(t)$ 는 감소함수: 시간이 지남에 따라 오히려 강해지는 것을 의미

와이블 분포

- 와이בל 분포

- 공학분야에서의 사용 예

- 수명 확률 분포: 신뢰성 공학에서 소프트웨어가 고장나기까지의 수명의 분포
 - 최적의 소프트웨어 방출 시기 지정
 - 소프트웨어 제품을 개발하여 테스트를 거친 후 사용자에게 인도하는 시기를 결정하는 문제
 - 고장발생 수명분포 계산
 - 소프트웨어의 수명분포모형 모델링
 - NHPP(Non-Homogeneous Poisson Process)
 - 의료장비 오류 발생 주기 예측