

Vi avslutade förra föreläsningen med centrala gränsvärdessatsen som sade att för en ändlig följd av oberoende, likafördelade s.v. X_1, \dots, X_n, \dots med $E(X_i) = \mu$ och $V(X_i) = \sigma^2$, så gäller det att

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \in \text{AsN}(\mu, \sigma/\sqrt{n}) \quad \text{då } n \rightarrow \infty.$$

Från sambandet mellan allmänna och standardiserade normalfördelade s.v. så får vi approximationen

$$P(a < \bar{X}_n \leq b) \approx \Phi\left(\frac{b-\mu}{\sigma/\sqrt{n}}\right) - \Phi\left(\frac{a-\mu}{\sigma/\sqrt{n}}\right)$$

som alltså är användbar även om X_i :na inte är normalfördelade. Vi kommer att undersöka ytterligare några approximationer under dagens föreläsning. Vi repeterar först binomialfördelningen. Betrakta ett försök där en händelse A inträffar med sannolikhet p . Om vi upprepar försöket n gånger och låter X vara antalet gånger som A inträffar så gäller $X \in \text{Bin}(n, p)$, dvs

$$p_X(k) = \binom{n}{k} p^k (1-p)^{n-k} \quad \text{för } k=0, 1, \dots, n.$$

Vi kan också komma fram till binomialfördelningen på följande sätt. Till vart och ett av de n försöken kan vi koppla en Bernoullifördelad s.v. I_i som är ett om A inträffar (sker med sannolikhet p) och noll annars. Antalet gånger som A inträffar på n försök kan då skrivas $X = I_1 + I_2 + \dots + I_n \in \text{Bin}(n, p)$. Notera att de s.v. I_i är oberoende och likafördelade. Vi använder detta skrivsätt för att bestämma väntevärde och varians av binomialfördelade s.v.

$$E(X) = E(I_1 + \dots + I_n) = n E(I_i) = n(p \cdot 1 + (1-p) \cdot 0) = np$$

$$V(X) = V(I_1 + \dots + I_n) \stackrel{I_i \text{ oberoende}}{=} n V(I_i) = n(E(I_i^2) - \underbrace{(E(I_i))^2}_{p^2}) = n(p \cdot 1^2 + (1-p) \cdot 0^2 - p^2) = np(1-p)$$

Sats: Låt $X_1 \in \text{Bin}(n_1, p)$ och $X_2 \in \text{Bin}(n_2, p)$ vara oberoende. Då är $X_1 + X_2 \in \text{Bin}(n_1 + n_2, p)$

Satsen är naturlig om vi tänker på X_1 och X_2 som summor av oberoende $\text{Be}(p)$ -fördelade s.v. Från representationen $X = I_1 + \dots + I_n$ följer också att vi kan använda centrala gränsvärdessatsen på $X \in \text{Bin}(n, p)$.

Sats: Om $X \in \text{Bin}(n, p)$ och $np(1-p) \geq 10$, så gäller approximativt $X \in \text{N}(np, \sqrt{np(1-p)})$

Därmed gäller


$$P(a < X \leq b) \approx \Phi\left(\frac{b-np}{\sqrt{np(1-p)}}\right) - \Phi\left(\frac{a-np}{\sqrt{np(1-p)}}\right)$$

Vi approximerar här en diskret s.v. (för vilken $P(X \leq k)$ är skilt från $P(X < k)$ för alla $k \in \{0, 1, \dots, n\}$) med en kontinuerlig s.v. (för vilken $P(X \leq k) = P(X < k)$ för alla $k \in \{0, 1, \dots, n\}$). Approximationen blir därför bättre om använder så kallade halukorrekton, dvs

$$P(X < k) = \Phi\left(\frac{k - \frac{1}{2} - np}{\sqrt{np(1-p)}}\right) \quad P(X \leq k) = \Phi\left(\frac{k + \frac{1}{2} - np}{\sqrt{np(1-p)}}\right)$$

vilket ger $P(a < X \leq b) \approx \Phi\left(\frac{b + \frac{1}{2} - np}{\sqrt{np(1-p)}}\right) - \Phi\left(\frac{a + \frac{1}{2} - np}{\sqrt{np(1-p)}}\right)$

Med halukorrekton blir approximationen god för $np(1-p) \geq 3$.



Ex: Vi kastar en tärning 60 gånger och låter X beteckna antalet gånger vi får en sexa $X \in \text{Bin}(60, \frac{1}{6})$. Vi vill bestämma $P(X > 13)$. Det exakta antalet är $\sum_{k=14}^{60} \binom{60}{k} (\frac{1}{6})^k (\frac{5}{6})^{60-k} = 0,115$. Med normalapproximation får vi

$$P(X > 13) = 1 - \Phi\left(\frac{13 - 60 \cdot \frac{1}{6}}{\sqrt{60 \cdot \frac{1}{6} \cdot \frac{5}{6}}}\right) = 0,149 \quad \text{och med halv-korrekton} \quad P(X > 13) = 1 - \Phi\left(\frac{13 + \frac{1}{2} - 60 \cdot \frac{1}{6}}{\sqrt{60 \cdot \frac{1}{6} \cdot \frac{5}{6}}}\right) = 0,113$$

Notera att $np(1-p) = 8,33$ här

Vi har tidigare sett att när n är stort och p litet så är $X \in \text{Bin}(n, p)$ approximativt $Po(\mu p)$ -fördelat, dvs

$$p_X(k) \approx \frac{\mu^k}{k!} e^{-\mu}, \quad k=0, 1, 2, \dots \quad \text{för } \mu = np.$$

Approximationen visar sig vara god för $p < 0,1$ (faktiskt oavsett n). Vi har visat att för $Y \in Po(\mu)$, så är $E(Y) = \mu$. För att bestämma $V(Y)$ beräknar vi $E(Y(Y-1))$:

$$E(Y(Y-1)) = \sum_{k=0}^{\infty} k(k-1) \frac{\mu^k}{k!} e^{-\mu} = \mu^2 \sum_{k=2}^{\infty} \frac{\mu^{k-2}}{(k-2)!} e^{-\mu} = \mu^2 e^{-\mu} \sum_{l=0}^{\infty} \frac{\mu^l}{l!} = \mu^2$$

Termerna med $k=0$ och $k=1$ är noll $l=k-2$

så $V(Y) = E(Y^2) - (E(Y))^2 = E(Y(Y-1)) + E(Y) - (E(Y))^2 = \mu^2 + \mu - \mu^2 = \mu$.

När vi undersökte summan av oberoende kontinuerliga s.v. så härledde vi faltningsformeln $f_{X+Y}(z) = \int_{-\infty}^{\infty} f_X(x) f_Y(z-x) dx$. För diskreta s.v. gäller, på samma sätt, att $p_{X+Y}(k) = \sum_{i=0}^k p_X(i) p_Y(k-i)$.

Sats: Låt $X \in Po(\mu_1)$ och $Y \in Po(\mu_2)$ vara oberoende. Då är $X+Y \in Po(\mu_1 + \mu_2)$

Bevis:
$$P(X+Y=k) = \sum_{i=0}^k P(X=i) P(Y=k-i) = \sum_{i=0}^k \frac{\mu_1^i}{i!} e^{-\mu_1} \frac{\mu_2^{k-i}}{(k-i)!} e^{-\mu_2}$$

$$= e^{-(\mu_1 + \mu_2)} \frac{1}{k!} \sum_{i=0}^k \frac{k!}{i!(k-i)!} \mu_1^i \mu_2^{k-i} = \frac{(\mu_1 + \mu_2)^k}{k!} e^{-(\mu_1 + \mu_2)}$$

Additionssatsen implicerar att om μ är ett heltal, så kan $X \in Po(\mu)$ skrivas $X = Z_1 + Z_2 + \dots + Z_\mu$, där $Z_i \in Po(1)$. Eftersom $E(Z_i) = V(Z_i) = 1$, så följer det av centrala gränsvärdesatsen att X är approximativt $N(\mu, \mu)$ -fördelat för stora μ . Approximationen fungerar även när μ inte är ett heltal och är relativt god för $\mu > 15$. Precis som vid normalapproximation av binomialfördelade s.v. förbättras approximationen med halukorrektur.

Ex: Sannolikheten för att en eller byts mot en nolla i en dataöverföring av en bit är $p = 10^{-7}$. Antalet fel X vid överföring av $8 \cdot 10^6$ bitar är $\text{Bin}(8 \cdot 10^6, 10^{-7})$ -fördelat, dvs approximativt $Po(0,8)$ -fördelat. Sannolikheten för minst tre fel $P(X \geq 3) = 1 - P(X \leq 2)$ är enligt tabellen för $Po(0,8)$ 4,74%. Med miniräknaren får vi samtidigt $P(X \geq 3) = 1 - \text{binocdf}(2, 8 \cdot 10^6, 10^{-7}) = 4,74\%$.

Vi avslutar med att undersöka den hypergeometriska fördelningen. Vi har tidigare studerat urnmodeller. Antag att en urn innehåller v vita och s svarta kulor. Låt X beteckna antalet vita kulor som fås vid dragning av n kulor utan återläggning

(med återläggning $\Rightarrow X \in \text{Bin}(n, \frac{v}{s+v})$)
$$P(X=k) = \frac{\binom{v}{k} \binom{s}{n-k}}{\binom{s+v}{n}}, \quad k=0, 1, \dots, n$$

Vi ändrar beteckningarna något och låter nu N vara totala antalet kulor ($N = s+v$) och p proportionen av vita kulor. Då får vi, för $k=0, 1, \dots, N_p$, $n-k=0, 1, \dots, N(1-p)$ att

$$P(X=k) = \frac{\binom{N_p}{k} \binom{N(1-p)}{n-k}}{\binom{N}{n}}$$

Vi säger att X är en hypergeometrisk s.v. ($X \in \text{Hyp}(N, n, p)$). Precis som för binomialfördelade s.v. så kan vi skriva $X = I_1 + \dots + I_n$ där $I_i \in \text{Be}(p)$, eftersom det gäller att vid var och en av de n dragningarna så är sannolikheten för vit kula p . I motsats till fallet med binomialfördelade s.v. så är I_i na inte oberoende, eftersom dragningen sker utan återläggning. Kovariansen mellan I_i och I_j är inte noll och i boken visas att för $X \in \text{Hyp}(N, n, p)$ så gäller

$$E(X) = np \quad V(X) = \frac{N-n}{N-1} np(1-p)$$

korrektionsfaktor $\frac{N-n}{N-1}$ för ändliga populationer

Om $n \ll N$ så spelar inte återläggningen så stor roll och $\frac{N-n}{N-1} \approx 1$. Om $X \in \text{Hyp}(N, n, p)$ och $n/N \leq 0,1$ så är X approximativt $\text{Bin}(n, p)$ -fördelat. Även normalapproximation kan användas.