

# Tilastomatematiikka

## Ensimmäinen välikoe 18.02.2022

1. Tarkastellaan erään kuukauden aikana sairaalahoitoa vaativan koronatartuntojen esiintyvyyttä ikäryhmittäin ja rokotussuojan mukaan kokoa  $N = 200000$  olevassa sairaudelle alttiissa populaatiossa.

		Ikäryhmät				Yhteensä
		12-29	30-49	50-69	70+	
Sairaalahoitoon	Ei rokotettu	2	5	5	2	
	Rokotettu	1	1	3	5	
Alttiita yhteensä		46221	57365	59061	37353	200000
Rokotusaste		82 %	85 %	92 %	95 %	

Taulukko 1: Sairaalahoitoa vaativan taudin esiintyminen ikäryhmittäin ja rokotussuojan mukaan

Vastaa aineiston perusteella seuraaviin kysymyksiin.

- a) Millä todennäköisyydellä henkilö on alle 30-vuotias? (1p)
  - b) Millä todennäköisyydellä henkilö on rokotettu? (2p)
  - c) Jos henkilö on rokotettu, niin millä todennäköisyydellä hän saa sairaalahoitoa vaativan koronatartunnan? (3p)
2. a) Diskreetin satunnaismuuttujan  $X$  jakauma on

$x$	1	2	3
$\mathbb{P}(X = x)$	$\frac{1}{3}$	$\frac{1}{3}$	$\frac{1}{3}$

Laske odotusarvo  $\mathbb{E}(X)$  ja varianssi  $\text{Var}(X)$ .

- b) Jatkuvan satunnaismuuttujan  $Y$  tiheysfunktio on

$$f(y) = \begin{cases} \frac{1}{3}, & 0 < y < 3, \\ 0, & \text{muulloin.} \end{cases}$$

Laske odotusarvo  $\mathbb{E}(Y)$  ja todennäköisyys  $\mathbb{P}(Y > 1)$ .

3. Tuotteita poimitaan tuotantolinjalta satunnaisesti tarkastusta varten. Pitkän aikavälin kokemus on osoittanut, että keskimäärin 3% tuotteista on tavalla tai toisella rikki.
  - a) Eräänä maanantaina 110 tuotetta poimittiin tarkastettavaksi. Millä todennäköisyydellä poimittujen tuotteiden joukossa oli ainakin kolme tavalla tai toisella rikki?
  - b) Laske normaalijakauma-approksimaatiolla todennäköisyys, että 110 tuotteesta korkeintaan 5 on rikki? Käytä jatkuvuuskorjausta.

## Tehtävien ratkaisuperiaatteet

1. a) Aineiston perusteella alle 30-vuotiaita on yhteensä 46221, joten henkilö on alle 30-vuotias todennäköisyydellä  $p = \frac{46221}{200000} \approx 23\%$ .

- b) Merkitään tapahtumia

$R =$  ”henkilö on rokotettu”,

$A_i =$  ”henkilö kuuluu ikäryhmään  $i$ ,  $i = 1, 2, 3, 4$ ,

missä ikäryhmä viittaa järjestyksessään taulukoissa annettuihin ikäryhmiin. Kokonaistodennäköisyyden mukaan

$$\begin{aligned}\mathbb{P}(R) &= \mathbb{P}(R|A_1)\mathbb{P}(A_1) + \mathbb{P}(R|A_2)\mathbb{P}(A_2) + \mathbb{P}(R|A_3)\mathbb{P}(A_3) + \mathbb{P}(R|A_4)\mathbb{P}(A_4) \\ &= 0.82 \cdot \frac{46221}{200000} + 0.85 \cdot \frac{57365}{200000} + 0.92 \cdot \frac{59061}{200000} + 0.95 \cdot \frac{37353}{200000} \\ &\approx 88\%.\end{aligned}$$

- c) Merkitään  $S =$  ”henkilö saa sairaalahoitoa vaativan koronatartunnan”. Kysytään todennäköisyyttä  $\mathbb{P}(S|R)$ , joka voidaan laskea vaikkapa ”lukumäärien” avulla. Rokotettuja joutuu sairaalahoitoon yhteensä  $1 + 1 + 3 + 5 = 10$  henkilöä. Edellisen kohdan mukaan rokotettuja on yhteensä  $\mathbb{P}(R)N$ , joten

$$\mathbb{P}(S|R) = \frac{\mathbb{P}(S \cap R)}{\mathbb{P}(R)} = \frac{10}{200000 \cdot \mathbb{P}(R)} \approx 5.7 \cdot 10^{-5},$$

eli alle 6 henkilöä 100000:sta.

2. Molemmat satunnaismuuttujat ovat tasajakautuneita, joten odotusarvon voi päätellä ”arkijärjellä”.

- a) Koska jakauma on tasainen, niin ”arkijärjen” mukaan odotusarvo on  $\mathbb{E}(X) = 2$ , joka voidaan todeta myös laskemalla

$$\mathbb{E}(X) = \sum_{k=1}^3 k \cdot \mathbb{P}(X = k) = \frac{1 + 2 + 3}{3} = 2.$$

Varianssi sen sijaan joudutaan laskemaan esimerkiksi kaavakokoelmasta löytyvällä kaavalla  $\text{Var}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2$ , jonka mukaan

$$\text{Var}(X) = \sum_{k=1}^3 k^2 \cdot \mathbb{P}(X = k) - 2^2 = \frac{1^2 + 2^2 + 3^2}{3} - 4 = \frac{2}{3}.$$

- c) Tässä molemmat menevät ”intuitiolla” tai ”arkijärjellä”, joten odotusarvo  $\mathbb{E}(X) = \frac{3}{2}$  on ”puolivälissä” ja  $\mathbb{P}(Y > 1) = \frac{2}{3}$ , sillä  $\{Y > 1\}$  kattaa  $\frac{2}{3}$  välistä  $[0, 3]$ . Sama asia voidaan todeta myös laskemalla

$$\mathbb{E}(X) = \int_0^3 y f(y) dy = \int_0^3 \frac{1}{3} y = \frac{3}{2} \quad \text{ja} \quad \mathbb{P}(Y > 1) = \int_1^3 f(y) dy = \int_1^3 \frac{1}{3} dy = \frac{2}{3}.$$

3. a) Merkitään  $X =$  ”rikki olevien tuotteiden lukumäärä otoksessa”, joka noudattaa binomijakaumaa  $\text{Bin}(110, 0.03)$ . Kysytään todennäköisyyttä  $\mathbb{P}(X \geq 3)$ . ”Komplementin kautta” saadaan

$$\mathbb{P}(X \geq 3) = 1 - \mathbb{P}(X < 3) = 1 - (\mathbb{P}(X = 0) + \mathbb{P}(X = 1) + \mathbb{P}(X = 2)) \approx 64\%.$$

- b) Normaalijakauma-approksimaatiota varten tarvitaan tunnusluvut  $\mathbb{E}(X) = np = 110 \cdot 0.03 = 3.3$  ja  $\text{Var}(X) = np(1 - p) = 110 \cdot 0.03 \cdot 0.97 = 3.201$ . Kysytyksi todennäköisyydeksi saadaan

$$\begin{aligned}\mathbb{P}(X \leq 5) &= \mathbb{P}(X \leq 5.5) && \text{(jatkuvuuskorjaus)} \\ &= \mathbb{P}\left(\frac{X - \mathbb{E}(X)}{\sqrt{\text{Var}(X)}} \leq \frac{5.5 - 3.3}{\sqrt{3.201}}\right) && \text{(standardointi)} \\ &\approx \Phi(1.23) && \text{(normaaliapproksimaatio)} \\ &\approx 89\%. && \text{(taulukosta)}\end{aligned}$$

Binomijakaumalla laskettu tarkka todennäköisyys  $88.6\% \approx 89\%$ .

# Kaavoja

## Todennäköisyyden ominaisuuksia

$$\begin{aligned}\mathbb{P}(A \cup B) &= \mathbb{P}(A) + \mathbb{P}(B) - \mathbb{P}(A \cap B), \\ \mathbb{P}(A \setminus B) &= \mathbb{P}(A \cap \overline{B}) = \mathbb{P}(A) - \mathbb{P}(A \cap B), \\ \mathbb{P}(\overline{A}) &= 1 - \mathbb{P}(A), \\ \mathbb{P}(A|B) &= \mathbb{P}(A \cap B) / \mathbb{P}(B), \\ \mathbb{P}(B|A) &= \frac{\mathbb{P}(B) \mathbb{P}(A|B)}{\mathbb{P}(A)}\end{aligned}$$

## Odotusarvoja ja variansseja

Ptnf. tai tf.	$\mu_X := \mathbb{E}(X)$	$\sigma_X^2 := \text{Var}(X)$
$\mathbb{P}(X = x)$	$\sum_x x \mathbb{P}(X = x)$	$\sum_x (x - \mu_X)^2 \mathbb{P}(X = x)$
$f_X(x)$	$\int_{-\infty}^{\infty} x f_X(x) dx$	$\int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$
$\binom{n}{x} p^x (1-p)^{n-x}$	$np$	$np(1-p)$
$p(1-p)^{x-1}$	$1/p$	$(1-p)/p^2$
$\frac{a^x}{x!} e^{-a}$	$a$	$a$
$1/(b-a)$	$(a+b)/2$	$(b-a)^2/12$
$\theta e^{-\theta x}$	$1/\theta$	$1/\theta^2$
$\frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$	$\mu$	$\sigma^2$

$$\mathbb{E}(aX + bY) = a\mathbb{E}(X) + b\mathbb{E}(Y), \quad \text{Var}(X) = \mathbb{E}((X - \mathbb{E}(X))^2) = \mathbb{E}(X^2) - \mathbb{E}(X)^2$$

## Eräitä testimuuttujia

$$\begin{aligned}\frac{\overline{X} - \mu}{\sigma/\sqrt{n}} &\sim N(0, 1) \text{ (likimain, kun "n on suuri")}, \\ \frac{\overline{X} - \mu}{S/\sqrt{n}} &\sim t_{n-1}, \\ \frac{(\overline{X} - \overline{Y}) - (\mu_X - \mu_Y)}{\sqrt{\frac{1}{n} + \frac{1}{m} \sqrt{\frac{(n-1)S_x^2 + (m-1)S_y^2}{n+m-2}}} &\sim t_{n+m-2}, \\ \sqrt{n-1} s_x \frac{\frac{S_{xy}}{S_{xx}} - \beta}{S_r} &\sim t_{n-2}\end{aligned}$$

## Regressio, korrelaatio ja kovarianssi

$$\begin{aligned}r &= \frac{s_{xy}}{\sqrt{s_{xx}}\sqrt{s_{yy}}}; \quad s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}); \quad s_{xx} = s_x^2; \\ y &= a + bx; \quad b = \frac{s_{xy}}{s_{xx}}; \quad a = \bar{y} - b\bar{x}; \\ s_r^2 &= \frac{1}{n-2} \sum_{i=1}^n (y_i - a - bx_i)^2 = \frac{n-1}{n-2} (1-r^2) s_{yy}; \\ \sigma_{XY} &= \text{Cov}(X, Y) = \mathbb{E}((X - \mathbb{E}(X))(Y - \mathbb{E}(Y))), \quad \sigma_{XX} = \sigma_X^2; \\ &= \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y) \\ \rho(X, Y) &= \frac{\sigma_{XY}}{\sigma_X \cdot \sigma_Y}\end{aligned}$$