

# Insinöörimatematiikka: Todennäköisyyslaskenta

Mika Hirvensalo  
mikhirve@utu.fi

Matematiikan ja tilastotieteen laitos  
Turun yliopisto

2024

## Määritelmä

Lähtökohtana on diskreetti satunnaismuuttuja  $X$ , joka voi saada  $n$  arvoa  $x_1, \dots, x_n$  todennäköisyyksillä  $p_1, \dots, p_n$ .

Jakauman  $p_1, \dots, p_n$  *Shannon-entropia* on

$$H(p_1, \dots, p_n) = -K(p_1 \ln p_1 + \dots + p_n \ln p_n),$$

missä  $K > 0$  on vakio. Jos  $K = \frac{1}{\ln 2}$ , sanotaan entropiaa binääriseksi. Tällöin  $\frac{\ln p_i}{\ln 2} = \log_2 p_i$ . Määritellään lisäksi  $0 \cdot \ln 0 = 0$ . Jos diskreetillä satunnaismuuttujalla  $X$  on jakauma  $p_1, \dots, p_n$ , merkitään ylläolevaa entropiaa myös  $H(X)$ :llä.

## Esimerkki

Jos kaikki arvot  $x_i$  ilmaantuvat samalla todennäköisyydellä  $\frac{1}{n}$ , on

$$H\left(\frac{1}{n}, \dots, \frac{1}{n}\right) = -\left(\frac{1}{n} \log_2 \frac{1}{n} + \dots + \frac{1}{n} \log_2 \frac{1}{n}\right) = \log_2 n.$$

Tämä merkitsee sitä, että satunnaismuuttujan  $X$  esittämän viestin välittämiseen tarvitaan keskimäärin  $\log_2 n$  bittiä.

## Esimerkki

Jos satunnaismuuttuja  $X$  saa arvon  $x_1$  todennäköisyydellä 1 ja muut arvot  $x_2, \dots, x_n$  todennäköisyydellä 0, on

$$H(X) = -(1 \cdot \log_2 1 + 0 \cdot \log_2 0 + \dots + 0 \cdot \log_2 0) = 0$$

## Esimerkki

Satunnaismuuttuja  $X$  saa kaksi arvoa  $x_0$  ja  $x_1$ , molemmat todennäköisyydellä  $\frac{1}{2}$ . Tällöin

$$H(X) = -\left(\frac{1}{2} \log_2 \frac{1}{2} + \frac{1}{2} \log_2 \frac{1}{2}\right) = 1.$$

## Esimerkki

Satunnaismuuttuja  $X$  saa arvon  $x_0$  todennäköisyydellä  $\frac{1}{4}$  ja arvon  $x_1$  todennäköisyydellä  $\frac{3}{4}$ . Tällöin

$$H(X) = -\left(\frac{1}{4} \log_2 \frac{1}{4} + \frac{3}{4} \log_2 \frac{3}{4}\right) = 0,811278\dots$$

## Lause

Oletetaan että reaaliarvoinen funktio  $H(p_1, \dots, p_n)$  toteuttaa seuraavat ehdot:

- $H(p_1, \dots, p_n)$  on symmetrinen ja jatkuva
- $H(\frac{1}{n}, \dots, \frac{1}{n})$  on ei-negatiivinen, aidosti kasvava
- Todennäköisyysjakaumille  $(p_1, \dots, p_n)$  ja  $(q_1, \dots, q_m)$  on voimassa

$$\begin{aligned} & H(p_1, \dots, p_n) + p_n H(q_1, \dots, q_m) \\ = & H(p_1, \dots, p_{n-1}, p_n q_1, \dots, p_n q_m). \end{aligned}$$

Tällöin

$$H(p_1, \dots, p_n) = -K(p_1 \ln p_1 + \dots + p_n \ln p_n),$$

missä  $K > 0$  on vakio.

## Yhdistetty entropia

$$H(X, Y) = - \sum p(x, y) \log_2 p(x, y)$$

## Ehdollinen entropia

$$H(X | y_j) = - \sum p(x | y_j) \log_2 p(x | y_j)$$

$$H(X | Y) = \sum p(y_j) H(X | y_j)$$

## Informaatio

$$I(X | Y) = H(X) - H(X | Y)$$

## Määritelmä

Mikäli  $n$ -pituisen jono satunnaismuuttujan  $X$  arvoista muodostuvia viestejä voidaan koodata  $m = \lfloor rn \rfloor$ -pituisilla bittijonoilla, sanotaan, että koodaus onnistuu tahdilla (rate)  $r$ .

## Shannonin lause

Jos  $r > H(X)$ , on mahdollista koodata  $X$ :n arvot binääriseen aakkostoon tahdilla  $r$  siten että dekodausvirheen todennäköisyys lähenee nollaa.

Jos  $r < H(X)$ , edellämainittu koodaus ei ole mahdollista, vaan dekodausvirheen todennäköisyys lähenee ykköstä.

## Määritelmä

Binäärisen symmetrisen kanavan *kapasiteetti* on

$$C(p) = 1 - H_2(p),$$

missä  $p$  on kanavan virhetodennäköisyys.

Koodin  $C_n$  *informaatiosuhde* on

$$R(C_n) = \frac{\log_2 |C_n|}{n}.$$

## Shannonin lause 2

Jos  $p < \frac{1}{2}$  ja  $R < C(p)$  ja  $\epsilon > 0$ , niin on sellainen rajaluku  $N = N(p, R, \epsilon)$ , että aina kun  $n \geq N$ , niin on olemassa  $n$ -pituinen binäärikoodi  $C_n$  jolle  $R(C_n) \geq R$  ja  $\mathbb{P}_{er}(C_n) < \epsilon$ .



## Lähtökohdat

- Havainnot  $x_1, \dots, x_n$  jostakin ilmiöstä.
- Tyypillisesti ei tiedetä miten havainnoitava ilmiö on jakautunut.
- $i$ :s havainto  $x_i$  on satunnaismuuttujan  $X_i$  arvo.
- Satunnaismuuttujat  $X_i$  riippumattomat.
- Satunnaisotos:  $X_1, X_2, \dots, X_n$ .
- Pyrkimys: Hyvät arviot ainakin odotusarvolle  $\mathbb{E}(X_i) = \mu$  ja varianssille  $\text{Var}(X_i) = \sigma^2$ .

## Odotusarvo

Otoskeskiarvo

$$\bar{X}_n = \frac{1}{n}(X_1 + \dots + X_n).$$

Tällöin

$$\mathbb{E}(\bar{X}_n) = \frac{1}{n} \cdot (\mathbb{E}(X_1) + \dots + \mathbb{E}(X_n)) = \mu.$$

Tätä ominaisuutta sanotaan *harhattomuudeksi*

## Tarkentuvuus

$$\begin{aligned}\text{Var}(\overline{X}_n) &= \text{Var}\left(\frac{1}{n}X_1\right) + \dots + \text{Var}\left(\frac{1}{n}X_n\right) \\ &= \frac{1}{n^2} \text{Var}(X_1) + \dots + \frac{1}{n^2} \text{Var}(X_n) \\ &= n \cdot \frac{1}{n^2} \sigma^2 = \frac{\sigma^2}{n} \xrightarrow{n \rightarrow \infty} 0.\end{aligned}$$

Tällöin sanotaan, että  $\overline{X}_n$  on *tarkentuva* estimaattori.

## Varianssi

Koska

$$\sigma^2 = \text{Var}(X_i) = \mathbb{E}(X_i^2) - \mathbb{E}(X_i)^2 = \mathbb{E}(X_i^2) - \mu^2,$$

on

$$\mathbb{E}(X_i^2) = \sigma^2 + \mu^2$$

Samoin

$$\frac{\sigma^2}{n} = \text{Var}(\bar{X}_n) = \mathbb{E}(\bar{X}_n^2) - \mathbb{E}(\bar{X}_n)^2 = \mathbb{E}(\bar{X}_n^2) - \mu^2,$$

josta

$$\mathbb{E}(\bar{X}_n^2) = \frac{\sigma^2}{n} + \mu^2.$$

## Varianssi

$$\mathbb{E}\left(\sum_{k=1}^n (X_k - \bar{X}_n)^2\right) = (n-1)\sigma^2.$$

Tämän vuoksi määritellään *otosvarianssi*

$$S_n^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X}_n)^2,$$

jolloin

$$\mathbb{E}(S_n^2) = \sigma^2.$$

$S_n^2$  on siis harhaton. Myös tarkentuva:  $\text{Var}(S_n^2) = \frac{\mu_4}{n} + \frac{3-n}{n(n-1)}\sigma^4$ .

## Lause

Jos satunnaismuuttujat  $X_1, \dots, X_n$  ovat jakautuneet  $N(\mu, \sigma^2)$  mukaisesti, on

$$T = \frac{\bar{X}_n - \mu}{S_n/\sqrt{n}}$$

jakautunut jakauman  $t(n-1)$  (Student's  $t$ -distribution) mukaisesti.

## Seuraus

Olkoon  $\alpha \in (0, 1)$  ja  $a$  sellainen, että  $\mathbb{P}(-a < T < a) = 1 - \alpha$ .

Tällöin

$$\mathbb{P}\left(\bar{X}_n - a\frac{S_n}{\sqrt{n}} \leq \mu \leq \bar{X}_n + a\frac{S_n}{\sqrt{n}}\right) = 1 - \alpha.$$

Jos esim.  $\alpha = 0,05$ , on kyseessä 95% luottamusväli. Huom.

Tyypillisesti merkitään  $a = t_{n-1; \alpha/2}$ .