

10. Kalkyyliä pistetodennäköisyysfunktioille

Tarkastellaan disjunkteja sm:ia (sm = satunnaismuuttuja), X, Y, K , joista kukin voi saada vain äärellisen määrän eri arvoja; arvojoukot S_X, S_Y, S_K äärellisiä joukkoja. Oletetaan epäideellisten vaikeuksien välttämiseksi, että

$$P(X=x, Y=y, K=k) > 0 \quad \forall x \in S_X, y \in S_Y, k \in S_K$$

Tällöin kaiketi alla käytetyt ehdolliset tnt:t ovat hyvin määritellyjä. Jatkossa jätetään ehdot $x \in S_X, y \in S_Y, k \in S_K$ kirjoittamatta.

Marginalisointi, eli miten siirytään yhteisjakaumasta reunajakaukseen:

$$P(X=x, Y=y) = \sum_k P(X=x, Y=y, K=k)$$

(todennäköisyyden additiivisuus!)

$$P(X=x) = \sum_y P(X=x, Y=y)$$

$$= \sum_y \sum_k P(X=x, Y=y, K=k)$$

jne.

Yhteis-ptnf:stä (ptnf = pistetodennäköisyys-funktio) saadaan reuna-ptnf summaamalla siitä tarpeeton muuttuja tai tarpeettomat muuttujat pois.

Ehdollinen ptnf \equiv ehdollinen tn. Esim.

$$P(X=x | Y=y) = \frac{P(X=x, Y=y)}{P(Y=y)}$$

Kertolaskukaava (eli -sääntö)

$$\begin{aligned} P(X=x, Y=y) &= P(X=x) P(Y=y | X=x) \\ &= P(Y=y) P(X=x | Y=y) \end{aligned}$$

(on sama asia kuin ehdollisen ptnf:n määritelmä.)

Riippumattomuus: $X \perp\!\!\!\perp Y$, jos

$$P(X=x, Y=y) = P(X=x) P(Y=y) \quad \forall x, y$$

Jos $X \perp\!\!\!\perp Y$, niin $P(Y=y) = P(Y=y | X=x)$ kaikilla x, y , ja $P(X=x) = P(X=x | Y=y)$ kaikilla x, y . Tämä seuraa riippumattomuuden määritelmästä sekä kertolaskukaavasta.

Marginalisointi onnistuu samalla tavalla myös ehdolliselle yhteis-ptnf:lle:

$$P(X=x | K=k) = \sum_y P(X=x, Y=y | K=k)$$

(ehdollinen tn $B \mapsto P(B | K=k)$ on additiivinen!)

Ehdollinen riippumattomuus: $X \perp\!\!\!\perp Y | K$, eli

X ja Y ovat riippumattomia ehdolla K , jos ne ovat riippumattomia ehdollisessa yhteisjakaumassa

$$P(X=x, Y=y | K=k) \quad \forall k$$

ts. jos

$$P(X=x, Y=y | K=k) = P(X=x | K=k) P(Y=y | K=k)$$

$$\forall x, y, k$$

Vaihtoehtoinen luonnolinen ehdolliselle riippumattomuudelle (HT):

$$X \perp\!\!\!\perp Y \mid K, \text{ jos}$$

$$P(X=x \mid Y=y, K=k) = P(X=x \mid K=k)$$

tai

$$P(Y=y \mid X=x, K=k) = P(Y=y \mid K=k)$$

$$\forall x, y, k$$

Huomautus: nämä kaiteki kaavat pätevät myös, jos X onkin (diskreetti) satunnaisvektori, esim.

$$X = \underline{X} = (X_1, X_2, \dots, X_n)$$

tai Y on (diskreetti) satunnaisvektori tai K on (diskreetti) satunnaisvektori.

Lisäksi nämä kaavat yleistyvät myös jatkuvien jakaumien tapauksiin, jolloin summien sijasta pitää laskea integraaleja. Palautamme jatkuvan tapaukseen myöhemmin.

11. Ennustaminen: mikä pallo seuraavaksi?

[AS: jaksot 1.5]

Pallot kulhossa: olemme havainneet

$$\underline{X} = \underline{x} \text{ eli } X_1 = x_1, X_2 = x_2, \dots, X_n = x_n$$

Millä todennäköisyydellä seuraava nosto tuottaa valkeisen pallon, eli $X_{n+1} = 1$?

Tähän kysymykseen on hankala antaa vastauksia frekventistisen paradigman perusteissa; voitaisiin yrittää ennustaa sijoittamalla parametriin K järkevä frekventistinen estimaatti kaavaan K/N ts. ennuste olisi \hat{K}/N .

Tällöin täytyy sivustella se ongelma, että K :n estimointiin liittyy epävarmuutta.

Bayesläisessä paradigmassa ennustaminen on periaatteessa suoraviivaista: pitää tarkastella ennuste- eli predikttiivistä todennäköisyyttä

$$P(X_{n+1} = 1 \mid \underline{X} = \underline{x})$$

Tämä tapa ottaa huomioon parametrin estimointiin liittyvän epävarmuuden!

Miten ennuste todennäköisyys laskeetaan?

Yksinkertaisin tapa on hyvädyntää ehdollista riippumattomuutta. Kun $K=k$, on

$$\begin{aligned} & P(\underline{X} = \underline{x}, X_{m+1} = x_{m+1} \mid K = k) \\ &= \left(\frac{k}{N}\right)^{x_1} \left(1 - \frac{k}{N}\right)^{1-x_1} \dots \left(\frac{k}{N}\right)^{x_m} \left(1 - \frac{k}{N}\right)^{1-x_m} \left(\frac{k}{N}\right)^{x_{m+1}} \left(1 - \frac{k}{N}\right)^{1-x_{m+1}} \\ &= P(\underline{X} = \underline{x} \mid K = k) P(X_{m+1} = x_{m+1} \mid K = k) \end{aligned}$$

Siis $\underline{X} \perp\!\!\!\perp X_{m+1} \mid K$.

Nyt

$$\begin{aligned} & P(X_{m+1} = x_{m+1} \mid \underline{X} = \underline{x}) \\ &= \sum_k P(X_{m+1} = x_{m+1}, K = k \mid \underline{X} = \underline{x}) \quad (\text{marginalisointi}) \\ &= \sum_k P(K = k \mid \underline{X} = \underline{x}) P(X_{m+1} = x_{m+1} \mid \underline{X} = \underline{x}, K = k) \\ & \quad \quad \quad (\text{kertolaskukaava}) \\ &= \sum_k P(K = k \mid \underline{X} = \underline{x}) P(X_{m+1} = x_{m+1} \mid K = k) \\ & \quad \quad \quad (\underline{X} \perp\!\!\!\perp X_{m+1} \mid K) \end{aligned}$$

Tässä siis summataan posteriorin $P(K = k \mid \underline{X} = \underline{x})$ kertaa

$$P(X_{m+1} = x_{m+1} \mid K = k) = \begin{cases} \frac{k}{N}, & \text{jos } x_{m+1} = 1 \\ 1 - \frac{k}{N}, & \text{jos } x_{m+1} = 0 \end{cases}$$

Ennustejakauma on tietenkin p:n:n, eli

$$\underbrace{P(X_{m+1} = 0 \mid \underline{X} = \underline{x})}_{\geq 0} + \underbrace{P(X_{m+1} = 1 \mid \underline{X} = \underline{x})}_{\geq 0} = 1.$$