

## Övning 1 Sannolikhetsteorins grunder

Två händelser  $A$  och  $B$  är disjunkta om  $\{A \cap B\} = \emptyset$ , det vill säga att snittet inte innehåller några element. Om vi har en mängd händelser  $A_1, A_2, A_3, \dots, A_n$ , vilka är parvis oförenliga, innebär detta att  $\{A_i \cap A_j\} = \emptyset$  för  $j \neq i$ .

### Kolmogorovs axiomsystem

1. *Axiom 1*: För en händelse  $A \subset \Omega$ , gäller  $0 \leq P(A) \leq 1$ .
2. *Axiom 2*: För utfallsrummet  $\Omega$  gäller,  $P(\Omega) = 1$ .
3. *Axiom 3*: Additionsformeln: om  $A_1, A_2, A_3, \dots, A_n$  är en ändlig, eller uppräknligt oändlig, följd av disjunkta händelser så är  $P(A_1 \cup A_2 \cup A_3 \dots \cup A_n) = P(A_1) + P(A_2) + \dots + P(A_n)$ . Därmed fås för två disjunkta händelser som bekant att:  $P(A \cup B) = P(A) + P(B)$ , ty deras snitt är tomma mängden.

**Additionssatsen** för två godtyckliga mängder  $A \subset \Omega$  and  $B \subset \Omega$  gäller

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

Ur detta följer **Booles olikhet**

$$P(A \cup B) \leq P(A) + P(B).$$

Ty om  $A$  och  $B$  disjunkta fås  $P(A \cap B) = 0$ , och om de är icke-disjunkta fås  $P(A \cap B) > 0$ .

**De Morgans regler** är hjälpsamma då man ska hantera komplement eller snitt/unioner av ett flertal händelser. De är

$$(A \cap B)^* = A^* \cup B^*, \quad (A \cup B)^* = A^* \cap B^*$$

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$$

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$$

Den **klassiska sannolikhetsdefinitionen** lyder: Vid likformigt sannolikhetsmått är sannolikheten för en händelse lika med kvoten mellan antalet för händelsen gynnsamma utfall och antal möjliga utfall.

Där **likformigt sannolikhetsmått** innebär att  $P(\omega_i) = 1/m$ ,  $i = 1, 2, \dots, m$ . Ett exempel är ett tärningskast, här fås utfallsrummet  $\Omega = \{\omega_1, \omega_2, \omega_3, \omega_4, \omega_5, \omega_6\} = \{1, 2, 3, 4, 5, 6\}$ , där alla utfall har samma sannolikhet att inträffa och då fås att  $P(\omega_i) = 1/6$ , då vi har  $m = 6$ .

För teori kring kombinatorik vänligen se kursboken eller föreläsninganteckningar.

## Övning 2 och 3 Betingade sannolikheter, oberoende händelser

**Betingade sannolikheter**, låt  $A$  och  $B$  vara två händelser, den betingade sannolikheten för  $B$ , givet  $A$  motsvarar

$$P(B|A) = \frac{P(A \cap B)}{P(A)} = \frac{P(B \cap A)}{P(A)}$$

Om  $P(A) = 0$  låter vi ovanstående sannolikhet vara obestämd. Idén bakom betingade sannolikheter är att om vi vet att händelsen  $A$  inträffat så befinner vi oss i ett mindre och mer begränsat utfallsrum, således "normerar" vi alla sannolikheter med  $1/P(A)$  för att summan av alla sannolikheter i  $A$  ska motsvara 1, i enlighet med Kolmogorovs andra axiom. Man kan tänka att  $P(A) = P(A|\Omega) = P(A \cap \Omega)/P(\Omega) = P(A \cap \Omega) = P(A)$ , d.v.s. att vi implicit betingar på hela utfallsrummet då bara sannolikheten för  $A$  söks.

Betingade sannolikheter uppfyller axiomsystemet:  $P(B^*|A) = 1 - P(B|A)$ , då axiomsystemet säger att

$$P(\Omega) = P(B \cup B^*) = \{B \text{ och } B^* \text{ disjunkta}\} = P(B) + P(B^*) = 1$$

**Lagen om total sannolikhet** lyder: Om händelserna  $H_1, H_2, \dots, H_n$  är parvis oförenliga och  $\cup_{i=1}^n H_i = \Omega$ , alltså att händelserna täcker hela utfallsrummet, gäller för varje händelse  $A \subset \Omega$  att

$$\begin{aligned} P(A) &= P(A \cap H_1) + P(A \cap H_2) + \dots + P(A \cap H_n) = \sum_{i=1}^n P(A \cap H_i) = \\ &= \{\text{använd formeln för betingad sannolikhet}\} = \sum_{i=1}^n P(A|H_i)P(H_i) \end{aligned}$$

Tolkning av detta är att vi delar upp försöket då  $A$  kan inträffa i  $n$  delfall, motsvarande  $H_1, H_2, \dots, H_n$ , där  $P(A|H_i)$  är sannolikheten att  $A$  inträffar i varje delfall. Då fås  $P(A)$  som summan av snitten mellan  $A$  och vardera  $H_i$ , vilket kan uttryckas i termer av betingade sannolikheter.

Utifrån formeln för betingade sannolikheter och LOTS, lagen om total sannolikhet, kan vi formulera **Bayes sats**

$$P(H_i|A) = \frac{P(A \cap H_i)}{P(A)} = \frac{P(A|H_i)P(H_i)}{\sum_{i=1}^n P(A|H_i)P(H_i)}.$$

## Övning 4 Diskreta stokastiska variabler

En **stokastisk variabel** betecknas ofta med en stor bokstav, ex.  $X$  eller  $Y$ . Den stokastiska variabeln  $X$  är en funktion från  $\Omega \rightarrow \mathbb{R}$ , det vill säga från utfallsrummet till reella linjen.

Det mest allmänna sättet att beskriva hur  $X$  varierar är genom dess **fördelningsfunktion**, vilken ges utav  $P(X \leq x)$ ; som ofta förkortas till  $F_X(x) = P(X \leq x)$ . Tre viktiga egenskaper hos fördelningsfunktioner är att

1. De är icke-avtagande, d.v.s. om  $x \leq y \Rightarrow F_X(x) \leq F_X(y)$ .
2. Högerkontinuerlig, vilket kan tolkas som att det inte finns några "hopp" om man närmar sig gränsvärdet från höger (om det finns ett sådant).
3. Samt att  $F_x(x) \rightarrow 1$  när  $x \rightarrow \infty$ , och  $F_x(x) \rightarrow 0$  när  $x \rightarrow -\infty$ .

Diskreta stokastiska variabler antar värden i diskreta utfallsrum. Ett exempel på en diskret stokastisk variabel är: Vi satsar pengar då vi singlar slant. Säg att vi satsar 100 kronor på att få *klave*, så att vi därmed får betala 100 kronor om det blir *krona*. Vi ser alltså att vårt utfallsrum ges utav

$$\Omega = \{\omega_1, \omega_2\} = \{\text{krona, klave}\}$$

Om vi låter den stokastiska variabeln  $X$  motsvara den vinst vi gör fås att

$$X(\omega) = \begin{cases} -100, & \text{om } \omega = \omega_1 \\ 100, & \text{om } \omega = \omega_2. \end{cases}$$

Detta är ett konkret exempel på hur en stokastisk variabel mappar mellan utfallsrummet och den reella linjen.

Vidare har vi att

$$P(a < X \leq b) = P(X \leq b) - P(X \leq a) = F_X(b) - F_X(a).$$

Notera dock att för en diskret stokastisk variabel har vi att

$$P(a < X \leq b) \neq P(a \leq X \leq b) = P(a < X \leq b) + P(X = a),$$

där

$$P(X \leq x) = \sum_{k \leq x} P(X = k).$$

Ofta förkortas  $P(X = k)$  till  $p_X(k)$ , som kallas **sannolikhetsfunktionen** för  $X$ . Från Kolmogorvs axiom har vi därefter att

- $p_X(k) \geq 0, \forall k$ .
- $\sum_{k \in \Omega} p_X(k) = 1$ .
- $P(X > b) = 1 - P(X \leq b) = 1 - F_X(b), b \in \mathbb{R}$ .

Det finns ytterligare två mått som beskriver egenskaperna för vår stokastiska variabel  $X$ , och det är dess **väntevärde** och **varians**. Väntevärdet kan löst tolkas som tyngdpunkten för sannolikhetsfunktionen, och variansen som ett mått på hur mycket  $X$  sprider ut sig kring sitt väntevärde. Vi har att väntevärdet för en diskret s.v.  $X$  motsvarar

$$\mu = E[X] = \sum_{k \in \Omega} k \cdot p_X(k).$$

Väntevärdet har linjära egenskaper och således fås att

$$E[aX + b] = aE[X] + b.$$

Variansen för en diskret s.v.  $X$  motsvarar

$$\sigma^2 = V(X) = E[(X - \mu)^2] = \{\text{efter utveckling av uttrycket och förenkling fås}\} = E[X^2] - (E[X])^2$$

. Vidare har vi att

$$E[g(X)] = \sum_{k \in \Omega} g(k)p_X(k) \quad \rightarrow \quad E[X^2] = \sum_{k \in \Omega_X} k^2 p_X(k).$$

Ytterligare ett mått på spridning är **standardavvikelsen**:  $\sigma = D(X) = \sqrt{V(X)}$ .

Variansen har, till skillnad från väntevärdet, inga linjära egenskaper utan:  $V(aX + b) = a^2V(X)$ . Konstanten  $b$  försvinner från uttrycket då den endast förskjuter fördelningen i sidled, och inte påverkar dess spridning.

Några exempel på diskreteta fördelningar är:

- **Poissonfördelning:** Används ofta för att beskriva antalet händelser som inträffar, oberoende av varandra, under ett givet tidsintervall. En Poissonfördelad variabel antar positiva diskreta värden. Man betecknar att  $X \in \text{Po}(\lambda)$ , där  $\lambda$  är fördelningens parameter, tillika väntevärde. Ofta kallas  $\lambda$  intensitet.
- **Binomialfördelning:** Låt oss beteckna antal lyckade försök i ett experiment med den stokastiska variabeln  $X$ . Vid  $n$  oberoende upprepningar av ett och samma försök, där vardera försök har en sannolikhet  $p$  att lyckas, sägs  $X$  vara binomialfördelad. Detta betecknas med  $X \in \text{Bin}(n, p)$ .
- **För första gångs-fördelning:** Betrakta ett oberoende försök, sådant att ett visst resultat uppträder med en sannolikhet  $p$  vardera gång försöket utförs. Låt  $X$  vara antalet gånger man upprepar försöket innan resultatet uppträder. Givet detta, så vet vi att  $X$  är för första gångs-fördelad,  $X \in \text{ffg}(p)$ .

## Övning 5 Kontinuerliga stokastiska variabler

**Kontinuerliga stokastiska variabler** antar värden i ett kontinuerligt utfallsrum. Vi kan, i likhet med diskreta s.v., karakterisera en kontinuerlig stokastisk variabel med hjälp av dess **fördelningsfunktion**

$$F_x(x) = P(X \leq x) = \int_{-\infty}^x f_X(t) dt,$$

och utifrån denna kan vi definiera variabelns **täthetsfunktion**  $f_x(x) = \frac{d}{dx}(F_X(x))$ . För kontinuerliga s.v så kan man tänka att vi fördelar ut sannolikhetsmassan 1 på reella linjen i  $\Omega$ , enligt täthetsfunktionen  $f_X(x)$ . Och sannolikheten att  $X$  antar värden inom ett intervall  $A$  motsvarar:

$$P(X \in A) = \int_A f_X(x) dx \quad \rightarrow \quad P(a < X \leq b) = \int_a^b f_X(x) dx.$$

Här ser vi alltså sannolikheten som integralen av vår sannolikhetsmassa, över intervallet av intresse. Sannolikheten att  $X$  antar ett distinkt värde motsvarar alltså 0 eftersom det blir arean under en punkt och inte under ett intervall. Vidare har vi, från Kolmogorov, att  $f_X(x) \geq 0$  och att  $\int_{\mathbb{R}} f_X(x) = 1$ .

Såsom för diskreta s.v. kan vi beräkna **väntevärde**, **standardavvikelse** och **varians** av vår kontinuerliga s.v  $X$

$$\mu = E[X] = \int_{\Omega_X} x f_x(x) dx$$

och standardavvikelsen ges av  $\sigma = D(X) = \sqrt{V(X)}$  där variansen  $V(x)$  ges av

$$\sigma^2 = E[X^2] - (E[X])^2 = \left\{ E[g(X)] = \int_{\Omega_X} g(X) f_X(x) dx \right\} = \int_{\Omega_X} x^2 f_x(x) dx - \left( \int_{\Omega_X} x f_x(x) dx \right)^2$$

## Övning 6 Flerdimensionella stokastiska variabler

En **tvådimensionell stokastisk variabel**,  $(X, Y)$  karakteriseras också av dess fördelningsfunktion  $F_{XY}(x, y) = P(X \leq x, Y \leq y) = P(X \leq x \cap Y \leq y)$ . För **diskreta tvådimensionella stokastiska variabel** fås följande sannolikhetsfunktion, då  $X$  och  $Y$  antas anta diskreta heltalsvärden:

$$p_{XY}(j, k) = P(X = j, Y = k) = P(X = j \cap Y = k), \quad j, k = 0, 1, 2, 3, \dots$$

Således kan vi formulera fördelningsfunktionen såsom:

$$F_{XY}(x, y) = \sum_{j \leq x, k \leq y} p_{XY}(j, k)$$

Om vi vill beräkna sannolikheten att  $(X, Y)$  antar värden i en delmängd  $A \subset \Omega_{XY}$  beräknar vi detta på följande vis

$$P((X, Y) \in A) = \sum_{(j, k) \in A} p_{XY}(j, k)$$

Som innan har vi att  $\sum_{j \in \Omega_X} \sum_{k \in \Omega_Y} p_{XY}(j, k) = 1$  och att  $0 \leq p_{XY}(j, k) \leq 1, \forall j, k \in \Omega_{XY}$ .

För en **kontinuerlig tvådimensionell stokastisk variabel** har vi att fördelningsfunktionen motsvarar

$$F_{XY}(x, y) = P(X \leq x, Y \leq y) = \int_{-\infty}^x \int_{-\infty}^y f_{XY}(x, y) dy dx,$$

där  $f_{XY}(x, y)$  är täthetsfunktionen för  $(X, Y)$ . Vi har att  $f(x, y) \geq 0, \forall x, y \in \Omega_{XY}$  och  $\iint_{\Omega_{XY}} f(x, y) dx dy = 1$ , dvs att täthet är en positiv storhet och vi kan tolka att den totala sannolikhetsvolymen under  $f_{XY}(x, y)$  motsvarar 1.

Om vi har fördelningsfunktionen och vill erhålla täthetsfunktionen gör vi det på följande vis:

$$f_{XY}(x, y) = \frac{\partial^2(F_{XY}(x, y))}{\partial x \partial y},$$

vi deriverar alltså med avseende på både  $X$  och  $Y$ .

Om den simultana fördelningen  $f_{XY}(x, y)$  är given, kan man återfå  $f_X(x)$  respektive  $f_Y(y)$  genom att "marginalisera", vilket innebär att man integrerar bort en av variablerna, på följande vis

$$f_X(x) = \int_{-\infty}^{\infty} f_{XY}(x, y) dy, \quad \text{respektive} \quad f_Y(y) = \int_{-\infty}^{\infty} f_{XY}(x, y) dx$$

För oberoende stokastiska variabler kan man erhålla den simultana täthetsfunktionen enligt:

$$f_{XY}(x, y) = f_X(x) \cdot f_Y(y)$$

och om  $X$  och  $Y$  är oberoende fås att

$$P(X \in C, Y \in D) = P(X \in C \cap Y \in D) = P(X \in C)P(Y \in D), \quad \forall D \subset \Omega_X, \forall C \subset \Omega_Y.$$

Utifrån ovanstående resonemang fås redskap då man ska behandla fördelningen för  $\max$  och  $\min$  av oberoende stokastiska variabler. Säg att  $X_1$  och  $X_2$  är två oberoende stokastiska variabler, vars fördelningar är kända. Låt oss sedan bilda en ny stokastiska variabel

$$Y = \max(X_1, X_2).$$

Vilken fördelning har  $Y$ ? Detta kan vi svara på genom

$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(\max(X_1, X_2) \leq y) = \{\text{Om den största} \leq y, \text{ är båda} \leq y\} = \\ &= P(\{X_1 \leq y\} \cap \{X_2 \leq y\}) = \{X_1 \text{ och } X_2 \text{ är oberoende}\} = P(X_1 \leq y)P(X_2 \leq y) = F_{X_1}(y) \cdot F_{X_2}(y) \end{aligned}$$

Då vi känner till fördelningarna för  $X_1$  och  $X_2$ , kan denna sannolikhet enkelt beräknas.

Om vi istället har  $U = \min(X_1, X_2)$  kan vi bestämma fördelningen för  $U$  genom

$$\begin{aligned} F_U(u) &= P(U \leq u) = P(\min(X_1, X_2) \leq u) = 1 - P(\min(X_1, X_2) > u) = \\ &= \{\text{Om den minsta är större än } u, \text{ är båda större än } u\} = 1 - P(\{X_1 > u\} \cap \{X_2 > u\}) = \\ &= \{X_1 \text{ och } X_2 \text{ är oberoende}\} = 1 - P(X_1 > u)P(X_2 > u) = 1 - (1 - F_{X_1}(u))(1 - F_{X_2}(u)). \end{aligned}$$

Sammanställt av: Hanna Fredenklo Jansson