

1 Náhodné veličiny

1.1 Základní pojmy

Při studiu reálných dějů se neomezujeme pouze na jejich sledování a popis. Bývá zapotřebí stanovit zákonitosti dějů a využít je k určení jejich dalšího průběhu. K tomu se často používají matematické modely, mezi něž patří také modely pravděpodobnostní a statistické.

Není-li výsledek nějakého pokusu nebo děje jednoznačně určen podmínkami, za nichž se odehrává, můžeme různé možné výsledky považovat za *elementární jevy*. Označujeme je symbolem ω s případnými indexy. Množinu všech elementárních jevů označujeme Ω a nazýváme ji *prostor elementárních jevů*. Většinou se nezajímáme o jednotlivé elementární jevy, ale o určité jejich množiny. Z matematického hlediska se ukázalo výhodné zajímat se o takový systém množin elementárních jevů, který tvoří σ -algebru. Nechť je tedy na prostoru Ω dána nějaká σ -algebra \mathcal{A} jeho podmnožin. Tyto podmnožiny se nazývají *náhodné jevy*. Jednotlivým množinám patřícím do \mathcal{A} (a jenom jim) se pak připisuje pravděpodobnost pomocí nějaké pravděpodobnostní míry P . Trojice (Ω, \mathcal{A}, P) se nazývá *pravděpodobnostní prostor*.

V matematické statistice se stává, že na \mathcal{A} je dán celý systém pravděpodobnostních měr $\{P_\alpha\}$. Tím je dán celý systém modelů náhodného děje. Na základě analýzy reálných dat je pak třeba rozhodnout, které z těchto modelů se dají použít a které je třeba zamítnout.

Nechť \mathbb{R} je reálná přímka a \mathcal{B} systém jejích borelovských množin. Nechť $X(\omega)$ je měřitelná funkce z (Ω, \mathcal{A}, P) do $(\mathbb{R}, \mathcal{B})$. Pak se $X(\omega)$ nazývá *náhodná veličina* a značí se stručně X . Každé borelovské množině $B \in \mathcal{B}$ lze přiřadit její vzor $X^{-1}(B) = \{\omega \in \Omega : X(\omega) \in B\}$ a pravděpodobnostní míru $Q(B) = P\{X^{-1}(B)\}$. Míra Q se nazývá *indukovaná míra* (je indukovaná funkcí X) nebo také *zákon rozdělení náhodné veličiny X* . Většinou se říká stručně jen *rozdělení*. Ve statistice se často píše $\mathcal{L}(X)$ místo Q . Pak je vidět, které veličině rozdělení přísluší. To je výhodné tam, kde se vyšetřuje několik náhodných veličin. Písmeno \mathcal{L} vzniklo z anglického slova law (zákon).

Položíme-li speciálně $B = (-\infty, x)$, dostaneme

$$F(x) = P\{X < x\}.$$

Funkce F se nazývá *distribuční funkce*. Z teorie míry je známo, že mezi Q a F je vzájemně jednoznačný vztah. V teorii pravděpodobnosti se dokazuje, že každá

distribuční funkce je neklesající, zleva spojitá a platí pro ni $\lim_{x \rightarrow -\infty} F(x) = 0$, $\lim_{x \rightarrow \infty} F(x) = 1$. Distribuční funkce může mít nejvýše spočetně mnoho bodů nespojitosti. V matematické statistice mají nejdůležitější uplatnění následující dva typy distribučních funkcí:

- a) Distribuční funkce F je funkce skoků. V tomto případě říkáme, že jde o *diskrétní rozdělení*. Jak jsme připomněli, bodů nespojitosti může být nejvýš spočetně mnoho, a tak je můžeme označit x_1, x_2, \dots . Nechť p_k je velikost skoku funkce F v bodě x_k . Lze zjistit, že platí $p_k = P\{X = x_k\}$.
- b) Existuje taková funkce $f(x)$, že platí

$$F(x) = \int_{-\infty}^x f(t) dt. \quad (1.1)$$

Pak jde o *spojité rozdělení*. Jak známo, F má vyjádření (1.1) tehdy a jen tehdy, je-li absolutně spojitá. Protože F je neklesající, musí platit $f(x) \geq 0$ skoro všude. Je-li třeba, upraví se $f(x)$ tak, aby byla všude nezáporná. Proto dále pod pojmem hustota budeme rozumět jen nějakou její nezápornou verzi.

Mnohé vlastnosti rozdělení a jeho charakteristik plynou z věty o přenosu integrace, kterou nyní připomeneme.

Věta 1.1 (o přenosu integrace) *Budiž t měřitelné zobrazení z (Ω, \mathcal{A}, P) do nějakého měřitelného prostoru (Λ, \mathcal{D}) . Budiž g měřitelná funkce na (Λ, \mathcal{D}) . Nechť Q je míra na \mathcal{D} indukovaná zobrazením t , tj. $Q(D) = P\{t^{-1}(D)\}$ pro $D \in \mathcal{D}$. Potom platí*

$$\int_{\Omega} g[t(\omega)] dP(\omega) = \int_{\Lambda} g(t) dQ(t), \quad (1.2)$$

jakmile jeden z integrálů existuje.

Důkaz. Viz Halmos (1950), věta 3 v § 39. Věta má však natolik fundamentální význam, že hlavní kroky důkazu uvedeme.

- 1) Zvolme nejprve $g = I_B$, kde I_B je charakteristická funkce množiny B . Nechť $B \in \mathcal{D}$. Připomeňme, že $I_B[t(\omega)] = 1$ pro $t(\omega) \in B$, tj. pro $\omega \in t^{-1}(B)$. Proto levá strana vztahu (1.2) je

$$\int_{\Omega} I_B[t(\omega)] dP(\omega) = \int_{t^{-1}(B)} dP(\omega) = P[t^{-1}(B)],$$

zatímco pravá strana vztahu (1.2) je

$$\int_{\Lambda} I_B(t) dQ(t) = \int_B dQ(t) = Q(B) = P[t^{-1}(B)].$$

Tím je pro měřitelnou charakteristickou funkci množiny vzorec (1.2) dokázán.

- 2) Je-li g jednoduchá měřitelná funkce, tvrzení plyne z toho, že integrál je lineární funkcionál.
- 3) Nechť g je nezáporná měřitelná funkce. Pak existuje posloupnost g_k nezáporných jednoduchých měřitelných funkcí taková, že $g_k(t) \uparrow g(t)$ pro každé $t \in \Lambda$. Dále se užije Leviho věta o monotónní konvergenci.
- 4) Je-li g reálná měřitelná funkce, užije se rozklad $g = g^+ - g^-$.
- 5) Je-li g komplexní měřitelná funkce, užije se její rozklad na reálnou a imaginární část. \square

Ve speciálním případě, kdy $(\Lambda, \mathcal{D}) = (\mathbb{R}, \mathcal{B})$ a zobrazení t je dáno náhodnou veličinou X , dostává vzorec (1.2) tvar

$$\int_{\Omega} g[X(\omega)] dP(\omega) = \int_{\mathbb{R}} g(t) dQ(t), \quad (1.3)$$

kde míra Q odpovídá distribuční funkci F . Platí-li (1.1), máme

$$\int_{\mathbb{R}} g(t) dQ(t) = \int_{\mathbb{R}} g(t) dF(t) = \int_{\mathbb{R}} g(t)f(t) dt. \quad (1.4)$$

Existuje-li hustota, pak kombinací vzorců (1.3) a (1.4) dostaneme, že platí

$$P\{X \in B\} = \int_B f(x) dx, \quad B \in \mathcal{B}.$$

Je-li F funkce skoků, která má v bodech x_1, x_2, \dots skoky o velikostech p_1, p_2, \dots , pak platí

$$P\{X \in B\} = \sum_{\{i: x_i \in B\}} p_i.$$

Ve statistice se často používají integrály náhodných veličin. Používá se pro ně symbol E (expectation). Říkáme, že $EX = \int_{\Omega} X(\omega) dP(\omega)$ je *střední hodnota* náhodné veličiny X , pokud uvedený integrál existuje. Protože obvykle bývá známa jenom distribuční funkce, většinou se provádí konkrétní výpočet podle vzorce $EX = \int_{\mathbb{R}} x dF(x)$. Je-li a nějaká konstanta, pak $Ea = a$. Poznamenejme, že se velmi často vyskytuje situace, kdy integrujeme přes celý prostor. Pro stručnost se tento prostor vynechává, a tak v dalším např. místo $\int_{\Omega} X(\omega) dP(\omega)$ budeme psát jenom $\int X(\omega) dP(\omega)$.

Často se setkáváme s nezápornými náhodnými veličinami. Ty popisují třeba dobu čekání, dobu životnosti apod. Při výpočtu jejich střední hodnoty bývá užitečná následující věta.

Věta 1.2 *Nechť X je nezáporná náhodná veličina s distribuční funkcí F s konečnou střední hodnotou. Pak $EX = \int_0^{\infty} [1 - F(x)] dx$.*

Důkaz. Necht $T > 0$ je bod spojitosti distribuční funkce F . Integrací per partes dostaneme

$$\int_0^T x dF(x) = TF(T) - \int_0^T F(x) dx = -T[1 - F(T)] + \int_0^T [1 - F(x)] dx. \quad (1.5)$$

Přitom

$$T[1 - F(T)] = T \int_T^\infty dF(x) \leq \int_T^\infty x dF(x).$$

Vzhledem k předpokladu, že střední hodnota je konečná, platí $\int_T^\infty x dF(x) \rightarrow 0$ pro $T \rightarrow \infty$, takže tvrzení věty dostaneme z (1.5) limitním přechodem. \square

Označme $\mu'_k = EX^k$, $k = 1, 2, \dots$. Číslo μ'_k se nazývá *obecný moment* k -tého řádu. Existuje-li moment μ'_1 a je-li konečný, pak definujeme $\mu_k = E(X - EX)^k$, $k = 0, 1, \dots$. Číslo μ_k se nazývá *centrální moment* k -tého řádu. Nejdůležitější centrální moment je μ_2 . Nazývá se *rozptyl* a obvykle se označuje symbolem σ^2 . Přitom $\sigma \geq 0$ je *směrodatná odchylka*. Někdy místo σ^2 píšeme $\text{var } X$ a čteme *variance* veličiny X . Úpravou dostaneme, že $\sigma^2 = EX^2 - (EX)^2$. Je-li $EX^2 < \infty$, pak také $|EX| < \infty$, neboť

$$|EX| = |E(1 \cdot X)| \leq \sqrt{E1^2 \cdot EX^2} = \sqrt{EX^2} < \infty.$$

Necht a a b jsou reálná čísla. Existuje-li EX , pak $E(a + bX) = a + bEX$. Je-li $EX^2 < \infty$, pak $\text{var}(a + bX) = b^2 \text{var } X$. Máme-li náhodné veličiny X_1, \dots, X_n s konečnými středními hodnotami, pak pro libovolná reálná čísla c_1, \dots, c_n platí $E \sum_{i=1}^n c_i X_i = \sum_{i=1}^n c_i EX_i$.

Necht $EX^4 < \infty$. Pak také $EX^2 < \infty$. Předpokládejme, že $\sigma > 0$. Pak definujeme *šikmost* $\alpha_3 = \mu_3/\sigma^3$ a *špičatost* $\alpha_4 = \mu_4/\sigma^4$. Při výpočtu šikmosti a špičatosti se často používá vzorců

$$\begin{aligned} \mu_3 &= EX^3 - 3EX^2EX + 2(EX)^3, \\ \mu_4 &= EX^4 - 4EX^3EX + 6EX^2(EX)^2 - 3(EX)^4. \end{aligned}$$

Jak uvidíme dále, u některých rozdělení neexistuje ani první moment (např. u *Cauchyova rozdělení*). U jiných rozdělení naopak existují a jsou konečné momenty μ'_k pro všechna $k = 1, 2, \dots$. Příkladem je třeba *normální rozdělení*, ale i mnohá další. Pak se může stát, že touto posloupností momentů je takové rozdělení jednoznačně určeno (např. právě normální rozdělení). Říkáme, že jde o *determinované rozdělení* (v Hamburgerově smyslu). Naproti tomu *logaritmicko-normální rozdělení* s hustotou

$$f_1(x) = \frac{1}{\sqrt{2\pi x}} \exp \left\{ -\frac{1}{2} \ln^2 x \right\}, \quad x > 0,$$

a rozdělení s hustotou

$$f_2(x) = [1 + a \sin(2\pi \ln x)] f_1(x), \quad x > 0,$$

pro libovolné $a \in [-1, 1]$ mají stejné momenty μ'_k , $k = 1, 2, \dots$. Takové rozdělení, které není svými momenty jednoznačně určeno, se nazývá *nedeterminované*.

Nejnámější kritérium determinovanosti je obsaženo v následující větě.

Věta 1.3 Jestliže řada $\sum_{k=1}^{\infty} \mu'_k t^k / k!$ pro některé $t > 0$ absolutně konverguje, pak posloupnost momentů μ'_k , $k = 1, 2, \dots$, jednoznačně určuje distribuční funkci.

Důkaz viz Rao (1978). \square

V mnoha případech je nutné použít jemnější kritéria (viz Lin, Huang 1997). Rozdělení náhodné veličiny X je determinované, platí-li

$$\sum_{n=1}^{\infty} (\mathbb{E}X^{2n})^{-\frac{1}{2n}} = \infty$$

(Carlemanovo kritérium). Rozdělení náhodné veličiny X s hustotou g je nedeterminované, platí-li

$$\int_{-\infty}^{\infty} \frac{-\ln g(y)}{1+y^2} dy < \infty$$

(Kreinovo kritérium).

Povšimněme si, že ve všech těchto případech jsou udány pouze postačující podmínky.

K popisu rozdělení se používá i velké množství dalších charakteristik. Jednou z nich je tzv. *medián* \tilde{x} . Je to (libovolné) číslo, pro které platí $F(\tilde{x}) \leq \frac{1}{2}$, $F(\tilde{x}^+) \geq \frac{1}{2}$. Medián obecně těmito podmínkami není jednoznačně určen. Nechť $|\mathbb{E}X| < \infty$. Pak se dá dokázat, že výraz $\mathbb{E}|X - c|$ nabývá své minimální hodnoty při $c = \tilde{x}$.

Další důležitá charakteristika se nazývá *modus* a značí se \hat{x} . Je-li diskrétní rozdělení soustředěno v bodech x_1, x_2, \dots , je \hat{x} ten bod, pro který platí $\mathbb{P}(X = \hat{x}) \geq \mathbb{P}(X = x_i)$, $i = 1, 2, \dots$. Je-li rozdělení spojité s hustotou $f(x)$, pak modus je ta hodnota \hat{x} , pro kterou platí $f(\hat{x}) \geq f(x)$, $-\infty < x < \infty$. Ani modus nemusí být určen jednoznačně.

Nechť F je nějaká distribuční funkce. Zavedme funkci F^{-1} předpisem

$$F^{-1}(u) = \inf\{x : F(x) \geq u\}, \quad 0 < u < 1.$$

Pak se F^{-1} nazývá *kvantilová funkce* odpovídající distribuční funkci F . Hodnotám $F^{-1}(u)$ se říká *kvantily*. Je-li F rostoucí funkce, pak F^{-1} je obyčejná inverzní funkce k F .

Věta 1.4 Nechť náhodná veličina X má rostoucí spojitou distribuční funkci F . Pak pro náhodnou veličinu $U = F(X)$ platí

$$\mathbb{P}(U < u) = \begin{cases} 0 & \text{pro } u \leq 0, \\ u & \text{pro } 0 < u < 1, \\ 1 & \text{pro } 1 \leq u. \end{cases} \quad (1.6)$$

Důkaz. Je-li $u \leq 0$, nebo $1 < u$, je tvrzení zřejmé. Nechť $0 < u < 1$. Pak máme

$$\mathbb{P}(U < u) = \mathbb{P}[F(X) < u] = \mathbb{P}[X < F^{-1}(u)] = F[F^{-1}(u)] = u.$$