

Teorie informace

Mirko Navara
Centrum strojového vnímání
katedra kybernetiky FEL ČVUT
Karlovo náměstí, budova G, místnost 104a
<http://cmp.felk.cvut.cz/~navara/psi>

3. 1. 2017

Obsah

1 Informace	1
2 Entropie	3
2.1 Entropie jako střední hodnota	4
2.2 Vlastnosti entropie	4
3 Informační divergence	5
3.1 Informační divergence jako střední hodnota	6
3.2 Vlastnosti informační divergence	7
4 Sdružená entropie	7
4.1 Podmíněná entropie	8
5 Vzájemná informace	9
5.1 Shrnutí vlastností vzájemné informace a podmíněné entropie	10

1 Informace

Teorie pravděpodobnosti popisovala systém, v němž bude proveden náhodný pokus.

Jeho výsledky (i dílčí) popisuje **informace**.

Informací může být určení výsledku náhodného pokusu, tj. hodnoty náhodné veličiny,

- předpověď,
- stanovení výsledku,
- sdělení výsledku.

Předpokládáme **diskrétní** rozdělení.

Příklad 1.1 (provozování loterie). V loterii bude $\doteq 500\,000$ losů po 4 \$, z nichž 1 vyhraje 1 M\$.

Certifikované losovací zařízení s 500 000 výsledky není.

(Např. ruleta o průměru 1 km.)

Losy očíslujeme a necháme **nezávisle** vylosovat číslice.

Problém: Kolik máme zaplatit za vylosování číslic?

(1. číslice má jen 5 stejně pravděpodobných hodnot.)

Řešení: Podle hry větší-menší vylosujeme 19 nezávislých binárních číslic, čímž rozlišíme $2^{19} = 524\,288$ možností.

Máme za vylosování každé číslice zaplatit stejně?

Ano! (Mj. proto, že všechny hody mincí mají stejnou pracnost.)

K výběru 1 z 2^k ($k \in \mathbb{N}$) stejně pravděpodobných možností potřebujeme informaci

$$I(2^k) := k I(2) = k \text{ b}, \quad I(2) = 1 \text{ b (bit)}.$$

Rychlejší řešení: Vždy vylosujeme ze 3 možností, postačí 12 nezávislých pokusů, $3^{12} = 531\,441$.
Kolik informace $I(3)$ dává výběr ze 3 stejně pravděpodobných možností?

$$\begin{aligned} 3^5 &= 243 \doteq 256 = 2^8, & I(3) &\doteq \frac{8}{5} = 1.6, \\ 3^{12} &= 531\,441 \doteq 524\,288 = 2^{19}, & I(3) &\doteq \frac{19}{12} = 1.583, \\ &\dots & & \\ 3^{\log_3 M} &= M = 2^{\log_2 M}, & I(3) &= \frac{\log_2 M}{\log_3 M} = \log_2 3 \doteq 1.585. \end{aligned}$$

Obecně výběr 1 z n stejně pravděpodobných možností nese informaci

$$I(n) := \log_2 n.$$

$I =$ **Hartleyho míra informace**. Je to jediná funkce $I: \mathbb{N} \rightarrow \mathbb{R}$ s vlastnostmi:


- $I(m \cdot n) = I(m) + I(n)$,
- I je neklesající,
- $I(2) = 1$.

Základ logaritmu je 2, čímž je dána jednotka informace (b = bit).

Speciálně pro $n = 2^k$: $I(2^k) = k$.

Nadále základ neoznačujeme,

$$\log = \log_2.$$



Funkce $-\log p$ pro $p \in (0, 1)$

Derivace:

$$(\log x)' = \left(\frac{\ln x}{\ln 2} \right)' = \frac{1}{x \ln 2} \doteq \frac{1}{0.693 x} \doteq \frac{1.443}{x}.$$

Kolik informace dostaneme, když se dovíme, že správná z n stejně pravděpodobných možností patří do skupiny s $k < n$ prvky?

Chybí informace $I(k)$, abychom určili jediný výsledek, tj. abychom měli celkem $I(n)$; nyní máme

$$I(n) - I(k) = \log n - \log k = \log \frac{n}{k}.$$

Záleží jen na poměru $\frac{n}{k}$, tj. na pravděpodobnosti $p := \frac{k}{n}$, což dovoluje zobecnění

$$I\left(\frac{n}{k}\right) = I\left(\frac{1}{p}\right) := \log \frac{n}{k} = \log \frac{1}{p} = -\log p.$$

I pro iracionální $p \in (0, 1)$ definujeme jako jedinou spojitou funkci s výše uvedenými hodnotami pro racionální argumenty:

$$I\left(\frac{1}{p}\right) := -\log p.$$

(Nepravděpodobnější výsledek \Rightarrow větší informace.)

2 Entropie

Příklad 2.1.

hodnota	0	1
pravděpodobnost	$\frac{1}{3}$	$\frac{2}{3}$
informace	$I(3) = \log 3 \doteq 1.585$	$I\left(\frac{3}{2}\right) = \log \frac{3}{2} = \log 3 - 1 \doteq 0.585$

Cena "předplacené" informace je střední hodnota

$$h\left(\frac{1}{3}, \frac{2}{3}\right) := \frac{1}{3} \log 3 + \frac{2}{3} \log \frac{3}{2} = \log_2 3 - \frac{2}{3} \doteq 0.918.$$

Obecněji:

hodnota	x_1	x_2
pravděpodobnost	p	$1-p$
informace	$I\left(\frac{1}{p}\right) = -\log p$	$I\left(\frac{1}{1-p}\right) = -\log(1-p)$


$$h(p, 1-p) := \underbrace{-p \log p}_{\iota(p)} - \underbrace{(1-p) \log(1-p)}_{\iota(1-p)},$$

kde


$$\iota(p) := -p \log p, \quad p > 0,$$

$$\iota(0) := 0.$$

$h(p, 1-p)$ = entropie alternativního rozdělení.



Funkce $-p \log p$ pro $p \in \langle 0, 1 \rangle$



Funkce $h(p, 1-p)$ pro $p \in \langle 0, 1 \rangle$

Obecně:

hodnota	x_1	x_2	...
pravděpodobnost	p_1	p_2	...
informace	$I\left(\frac{1}{p_1}\right) = -\log p_1$	$I\left(\frac{1}{p_2}\right) = -\log(p_2)$...

Entropie rozdělení s pravděpodobnostmi $\mathbf{p} = (p_1, p_2, \dots)$, $\sum_i p_i = 1$:

$$h(\mathbf{p}) = h(p_1, p_2, \dots) := \sum_i \iota(p_i) = -\sum_i p_i \log p_i.$$

(Výsledků je spočetně mnoho, nutno předpokládat konvergenci sumy.)

Entropie náhodné veličiny X s **různými** hodnotami x_1, x_2, \dots a pravděpodobnostní funkcí p_X :

$$\begin{aligned} H(X) &:= h(p_X(x_1), p_X(x_2), \dots) = \sum_x \iota(p_X(x)) = -\sum_x p_X(x) \log p_X(x) = \\ &= -E \log p_X(X). \end{aligned}$$

$\neq -E \log X$

Příklad 2.2.

hodnota	x	1	4	9
pravděpodobnost	$p_X(x)$	$\frac{1}{2}$	$\frac{1}{4}$	$\frac{1}{4}$
informace	$-\log p_X(x)$	1	2	2

$$H(X) = h\left(\frac{1}{2}, \frac{1}{4}, \frac{1}{4}\right) = \frac{1}{2} \cdot 1 + \frac{1}{4} \cdot 2 + \frac{1}{4} \cdot 2 = \frac{3}{2}.$$

Příklad 2.3.

hodnota	x	-6	0	0.001	1000
pravd.	$p_X(x)$	0.1	0.2	0.2	0.5
inf.	$-\log p_X(x)$	$\log 10 \doteq 3.322$	$\log 5 \doteq 2.322$	$\log 5 \doteq 2.322$	$\log 2 = 1$

$$H(X) = h(0.1, 0.2, 0.2, 0.5) = 0.1 \cdot \log 10 + 0.2 \cdot \log 5 + 0.2 \cdot \log 5 + 0.5 \cdot 1 = \\ = 0.5 \cdot \log 5 + 0.6 \doteq 1.761.$$

2.1 Entropie jako střední hodnota

Nahradili jsme hodnoty náhodné veličiny X jejich pravděpodobnostmi (jen na těch záležitostech!), tím jsme dostali náhodnou veličinu $W = p_X(X)$ s hodnotami v $\langle 0, 1 \rangle$.

Její rozdělení popisuje *pravděpodobnosti pravděpodobností* náhodné veličiny X .

$$p_W(w) = P[p_X(X) = w]$$

= pravděpodobnost, že X nabývá hodnoty, jejíž pravděpodobnost je $w \in \langle 0, 1 \rangle$.

Příklad 2.4.

hodnota	x	A	B	C	D	E	F
pravd.	$p_X(x)$	0.1	0.1	0.15	0.2	0.2	0.25
informace (přibl.)	$-\log p_X(x)$	$\log 10$ 3.322	$\log 10$ 3.322	$\log \frac{20}{3}$ 2.737	$\log 5$ 2.322	$\log 5$ 2.322	2

$W = p_X(X)$:

hodnota	w	0.1	0.15	0.2	0.25
pravděpodobnost	$p_W(w)$	0.2	0.15	0.4	0.25
informace v x	$-\log w$	$\log 10 \doteq 3.322$	$\log \frac{20}{3} \doteq 2.737$	$\log 5 \doteq 2.322$	2

První řádek vznikl opsáním všech různých hodnot z 2. řádku první tabulky.

Ve skutečnosti potřebujeme jejich logaritmy, jsou v posledním řádku.

Druhý řádek obsahuje odpovídající pravděpodobnosti (každá byla vynásobena počtem svých výskytů ve 2. řádku první tabulky).

$$H(X) = -E \log p_X(X) = -E \log W \doteq \\ \doteq 0.2 \cdot 3.322 + 0.15 \cdot 2.737 + 0.4 \cdot 2.322 + 0.25 \cdot 2 \doteq 2.504.$$

2.2 Vlastnosti entropie

$$0 \leq H(X) \leq \log n,$$

kde n je počet různých hodnot náhodné veličiny X (je-li konečný).

$0 = H(X)$ jen pro Diracovo rozdělení,

$H(X) = \log n$ (kde n je počet možných hodnot) jen pro rovnoměrné rozdělení:

Věta 2.1. *Maximální entropie se nabývá jen pro rovnoměrné rozdělení.*

Důkaz. Předpokládejme, že rozdělení (p_1, p_2, \dots, p_n) není rovnoměrné. Pak některá z pravděpodobností je větší a některá menší než $\frac{1}{n}$; BÚNO* $p_1 > \frac{1}{n}$, $p_2 < \frac{1}{n}$.

Změnou $p_1 := p_1 - \varepsilon$, $p_2 := p_2 + \varepsilon$ o malé $\varepsilon \geq 0$ se entropie změní o

$$\Delta(\varepsilon) = h(p_1 - \varepsilon, p_2 + \varepsilon, p_3, \dots, p_n) - h(p_1, p_2, p_3, \dots, p_n) = \\ = \iota(p_1 - \varepsilon) + \iota(p_2 + \varepsilon) - \iota(p_1) - \iota(p_2),$$

kde

$$\iota'(p) = (-p \log p)' = -\frac{1}{\ln 2} - \log p.$$

Funkce Δ je diferencovatelná, $\Delta(0) = 0$,

$$\Delta'(\varepsilon) = -\iota'(p_1 - \varepsilon) + \iota'(p_2 + \varepsilon) = \log(p_1 - \varepsilon) - \log(p_2 + \varepsilon) = \log \frac{p_1 - \varepsilon}{p_2 + \varepsilon}.$$

Pro dostatečně malé $\varepsilon > 0$ je

$$p_1 - \varepsilon > \frac{1}{n} > p_2 + \varepsilon,$$

$\Delta'(\varepsilon) > 0$ a $\Delta(\varepsilon) > 0$.

Tedy entropie $h(p_1, p_2, \dots, p_n)$ není maximální. □

* *BÚNO = bez újmy na obecnosti*

Důsledek 2.1. Entropie rozdělení s nekonečně mnoha hodnotami může být libovolně velká.

Věta 2.2.

$$h(p_1, p_2, p_3, \dots) = h(p_1 + p_2, p_3, \dots) + (p_1 + p_2) h\left(\frac{p_1}{p_1 + p_2}, \frac{p_2}{p_1 + p_2}\right).$$

Důkaz.

$$\begin{aligned} h(p_1, p_2, p_3, \dots) - h(p_1 + p_2, p_3, \dots) &= \\ &= \iota(p_1) + \iota(p_2) - \iota(p_1 + p_2) = \\ &= -p_1 \log p_1 - p_2 \log p_2 + (p_1 + p_2) \log(p_1 + p_2) = \\ &= -p_1 \log \frac{p_1}{p_1 + p_2} - p_2 \log \frac{p_2}{p_1 + p_2} = \\ &= (p_1 + p_2) \left(-\frac{p_1}{p_1 + p_2} \log \frac{p_1}{p_1 + p_2} - \frac{p_2}{p_1 + p_2} \log \frac{p_2}{p_1 + p_2} \right) = \\ &= (p_1 + p_2) h\left(\frac{p_1}{p_1 + p_2}, \frac{p_2}{p_1 + p_2}\right). \end{aligned}$$

□

3 Informační divergence

Příklad 3.1 (chybný předpoklad rovnoměrného rozdělení). Předpokládali jsme rozdělení $\mathbf{q} = (\frac{1}{2}, \frac{1}{2})$ a odhadli entropii $h(\frac{1}{2}, \frac{1}{2}) = 1$.

Ve skutečnosti bylo rozdělení $\mathbf{p} = (\frac{1}{3}, \frac{2}{3})$ a entropie $h(\frac{1}{3}, \frac{2}{3}) \doteq 0.918$.

O kolik jsme nadhodnotili jeden znak?

$$h\left(\frac{1}{2}, \frac{1}{2}\right) - h\left(\frac{1}{3}, \frac{2}{3}\right) \doteq 1 - 0.918 = 0.082.$$

Příklad 3.2 (chybný předpoklad nerovnoměrného rozdělení). Předpokládali jsme rozdělení $\mathbf{q} = (\frac{1}{3}, \frac{2}{3})$ a odhadli entropii $h(\frac{1}{3}, \frac{2}{3}) \doteq 0.91$.

Ve skutečnosti bylo rozdělení $\mathbf{p} = (\frac{1}{6}, \frac{5}{6})$ a entropie $h(\frac{1}{6}, \frac{5}{6}) \doteq 0.65$.

O kolik jsme nadhodnotili jeden znak?

Odpověď:

$$h\left(\frac{1}{3}, \frac{2}{3}\right) - h\left(\frac{1}{6}, \frac{5}{6}\right) \doteq 0.918 - 0.65 = 0.268.$$

Špatně!

Správná odpověď:

hodnota	x_i	x_1	x_2
předp. pravd.	q_i	$\frac{1}{3}$	$\frac{2}{3}$
předp. informace	$-\log q_i$	$\log 3 \doteq 1.585$	$\log \frac{3}{2} \doteq 0.585$
skut. pravd.	p_i	$\frac{1}{6}$	$\frac{5}{6}$
skut. informace	$-\log p_i$	$\log 6 \doteq 2.585$	$\log \frac{6}{5} \doteq 0.263$
předp. – skut. inf.	$\log p_i - \log q_i = \log \frac{p_i}{q_i}$	-1	$\log \frac{5}{4} \doteq 0.322$

Střední chyba odhadu informace je

$$p_1 \log \frac{p_1}{q_1} + p_2 \log \frac{p_2}{q_2} \doteq \frac{1}{6} \cdot (-1) + \frac{5}{6} \cdot 0.322 \doteq 0.102.$$

Příklad 3.3 (chybný předpoklad *nerovnoměrného* rozdělení 2). Vyměníme rozdělení z předchozího příkladu: Předpokládali jsme rozdělení $\mathbf{q} = (\frac{1}{6}, \frac{5}{6})$ a odhadli entropii $h(\frac{1}{6}, \frac{5}{6}) \doteq 0.65$.

Ve skutečnosti bylo rozdělení $\mathbf{p} = (\frac{1}{3}, \frac{2}{3})$ a entropie $h(\frac{1}{3}, \frac{2}{3}) \doteq 0.91$.

O kolik jsme “nadhodnotili” jeden znak?

Špatná odpověď: $h(\frac{1}{6}, \frac{5}{6}) - h(\frac{1}{3}, \frac{2}{3}) \doteq 0.65 - 0.918 = -0.268$.

Správná odpověď:

hodnota	x_i	x_1	x_2
předp. pravd.	q_i	$\frac{1}{6}$	$\frac{5}{6}$
předp. inf.	$-\log q_i$	$\log 6 \doteq 2.585$	$\log \frac{6}{5} \doteq 0.263$
skut. pravd.	p_i	$\frac{1}{3}$	$\frac{2}{3}$
skut. inf.	$-\log p_i$	$\log 3 \doteq 1.585$	$\log \frac{3}{2} \doteq 0.585$
předp. – skut. inf.	$\log p_i - \log q_i = \log \frac{p_i}{q_i}$	1	$\log \frac{4}{5} \doteq -0.322$

Střední chyba odhadu informace je

$$p_1 \log \frac{p_1}{q_1} + p_2 \log \frac{p_2}{q_2} \doteq \frac{1}{3} \cdot 1 - \frac{2}{3} \cdot 0.322 \doteq 0.119.$$

Odhad byl opět nadhodnocený! (Ne stejně.)

Obecně: Předpokládali jsme rozdělení $\mathbf{q} = (q_1, q_2, \dots)$,

ve skutečnosti bylo $\mathbf{p} = (p_1, p_2, \dots)$.

hodnota	x_i	x_1	x_2	...
předp. pravd.	q_i	q_1	q_2	...
předp. inf.	$-\log q_i$	$-\log q_1$	$-\log q_2$...
skut. pravd.	p_i	p_1	p_2	...
skut. inf.	$-\log p_i$	$-\log p_1$	$-\log p_2$...
předp. – skut. inf.	$\log p_i - \log q_i = \log \frac{p_i}{q_i}$	$\log \frac{p_1}{q_1}$	$\log \frac{p_2}{q_2}$...

Střední chyba odhadu informace je

$$D(\mathbf{p}||\mathbf{q}) := \sum_i p_i \log \frac{p_i}{q_i} = \underbrace{\sum_i p_i \log p_i}_{-h(p_1, p_2, \dots)} - \sum_i p_i \log q_i,$$

kde $0 \log 0 := 0$, $0 \log \frac{0}{0} := 0$, $r \log \frac{r}{0} := \infty$ pro $r \in (0, 1)$.

$D(\mathbf{p}||\mathbf{q}) = \mathbf{Kullbackova-Leiblerova divergence} = \mathbf{informační divergence}$ rozdělení \mathbf{p}, \mathbf{q} .

3.1 Informační divergence jako střední hodnota

Máme náhodnou veličinu X , skutečnou pravděpodobnostní funkci p_X a předpokládanou pravděpodobnostní funkci q_X . (To zde *není* kvantilová funkce.)

Dva pravděpodobnostní modely budeme rozlišovat indexy, např

$$E_p X = \sum_x x p_X(x), \quad H_p(X) = -E_p \log p_X(X) = h(p_X(x_1), p_X(x_2), \dots),$$

$$E_q X = \sum_x x q_X(x), \quad H_q(X) = -E_q \log q_X(X) = h(q_X(x_1), q_X(x_2), \dots).$$

Při výsledku x je předpokládaná informace $-\log q_X(x)$ a skutečná $-\log p_X(x)$. Střední hodnota rozdílu při **skutečném** rozdělení p je

$$D(\mathbf{p}_X||\mathbf{q}_X) = E_p \log \frac{p_X(X)}{q_X(X)} = E_p (\log p_X(X) - \log q_X(X)) = \underbrace{E_p \log p_X(X)}_{=H_p(X)} - \underbrace{E_p \log q_X(X)}_{\neq H_q(X)}.$$

Příklad 3.4 (chybný předpoklad *rovnoměrného* rozdělení – pokr.). Proč nám to *prvně* vyšlo *správně*? Protože $q_X(X) = \frac{1}{2}$ byla konstanta,

$$H_q(X) = -E_q \log q_X(X) = -\log \frac{1}{2} = -E_p \log q_X(X).$$

3.2 Vlastnosti informační divergence

Může být $D(\mathbf{p}||\mathbf{q}) \neq D(\mathbf{q}||\mathbf{p})$.

Věta 3.1. $D(\mathbf{p}||\mathbf{q}) \geq 0$; rovnost nastává, právě když $\mathbf{p} = \mathbf{q}$.

Důkaz. Předpokládejme $\mathbf{p} \neq \mathbf{q}$, BÚNO $p_1 < q_1, p_2 > q_2$. Výraz

$$V(q_1, q_2, q_3, \dots) := \sum_i p_i \log q_i$$

se změnou $q_1 := q_1 - \varepsilon, q_2 := q_2 + \varepsilon$ o malé $\varepsilon \geq 0$ změní o

$$\begin{aligned} \Delta(\varepsilon) &= V(q_1 - \varepsilon, q_2 + \varepsilon, q_3, \dots) - V(q_1, q_2, q_3, \dots) = \\ &= p_1 \log(q_1 - \varepsilon) + p_2 \log(q_2 + \varepsilon) - p_1 \log q_1 - p_2 \log q_2. \end{aligned}$$

Funkce Δ je diferencovatelná, $\Delta(0) = 0$,

$$\Delta'(\varepsilon) = -\frac{1}{\ln 2} \frac{p_1}{q_1 - \varepsilon} + \frac{1}{\ln 2} \frac{p_2}{q_2 + \varepsilon}.$$

Pro dostatečně malé $\varepsilon > 0$ je

$$\frac{p_1}{q_1 - \varepsilon} < 1 < \frac{p_2}{q_2 + \varepsilon},$$

$\Delta'(\varepsilon) > 0$ a $\Delta(\varepsilon) > 0$.

Tedy $V(q_1, q_2, q_3, \dots)$ není maximální.

Uvedený argument nelze použít jedině pro $\mathbf{p} = \mathbf{q}$, pak nabývá výraz maxima, a to

$$\begin{aligned} V(p_1, p_2, p_3, \dots) &:= \sum_i p_i \log p_i = -h(p_1, p_2, p_3, \dots), \\ D(\mathbf{p}||\mathbf{p}) &= 0. \end{aligned}$$

□

4 Sdružená entropie

Sdružená entropie $H(X, Y)$ náhodných veličin X, Y je entropie náhodného vektoru (X, Y) , počítaná podle stejného principu:

X nabývá hodnot x_1, x_2, \dots ,

Y nabývá hodnot y_1, y_2, \dots ,

(X, Y) nabývá hodnot

$$\begin{aligned} &(x_1, y_1), (x_1, y_2), \dots, \\ &(x_2, y_1), (x_2, y_2), \dots, \\ &\dots, \end{aligned}$$

zajímají nás jen jejich pravděpodobnosti $p_{X,Y}(x_i, y_j)$, z nichž vypočteme

$$\begin{aligned} H(X, Y) &:= \sum_i \sum_j \iota(p_{X,Y}(x_i, y_j)) = - \sum_i \sum_j p_{X,Y}(x_i, y_j) \log p_{X,Y}(x_i, y_j) = \\ &= \sum_x \sum_y \iota(p_{X,Y}(x, y)) = - \sum_x \sum_y p_{X,Y}(x, y) \log p_{X,Y}(x, y) = \\ &= -E \log p_{X,Y}(X, Y). \end{aligned}$$

Pro X, Y **nezávislé** je

$$p_{X,Y}(x, y) = p_X(x) \cdot p_Y(y),$$

$$-\log p_{X,Y}(x, y) = -\log p_X(x) - \log p_Y(y),$$

pro všechna x, y , tedy i pro střední hodnoty

$$H(X, Y) = -E \log p_{X,Y}(X, Y) = -E \log p_X(X) - E \log p_Y(Y) =$$

$$= H(X) + H(Y).$$

Co znamená zápis $H(\cdot)$?

p. argumentů	typ argumentů	význam	příklad
1	náhodná veličina	entropie náh. veličiny	$H(X)$
> 1	náhodné veličiny	entropie náh. vektoru (sdr. entropie náh. veličin)	$H(X, Y)$

Co znamená zápis $h(\cdot)$?

p. argumentů	typ argumentů	význam	příklad
> 1	čísla $\in \langle 0, 1 \rangle$ se součtem 1	entropie rozdělení	$h\left(\frac{1}{2}, \frac{1}{3}, \frac{1}{6}\right)$
1	číslo $\in \langle 0, 1 \rangle$	zkratka pro entropii alternativního rozdělení	$h\left(\frac{1}{3}\right) = h\left(\frac{1}{3}, \frac{2}{3}\right) = h\left(\frac{2}{3}\right)$

Příklad 4.1 (poklad na ostrově).

$p_{X,Y}(x, y)$:

x	y	A	B	C	$p_X(x)$
	1	$\frac{1}{6}$	$\frac{1}{6}$	0	$\frac{1}{3}$
	2	$\frac{1}{6}$	$\frac{1}{6}$	0	$\frac{1}{3}$
	3	0	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{3}$
	$p_Y(y)$	$\frac{1}{3}$	$\frac{1}{2}$	$\frac{1}{6}$	1

$$H(X) = \log 3 \doteq 1.585,$$

$$H(Y) = \frac{1}{3} \log 3 + \frac{1}{2} + \frac{1}{6} \log 6 \doteq 1.459,$$

$$H(X, Y) = \log 6 \doteq 2.585 <$$

$< H(X) + H(Y) \doteq 1.585 + 1.459 = 3.044$. Závislost X, Y nás připravila o $H(X) + H(Y) - H(X, Y) \doteq 3.044 - 2.585 = 0.459$. Jak vyčíslit ztrátu informace z jedné proměnné, když jsme se dověděli druhou?

4.1 Podmíněná entropie

Pokud nastal jev $Y = y$, aktualizujeme pravděpodobnosti hodnot veličiny X pomocí podmíněných pravděpodobností

$$p_{X|Y}(x|y) := P[X = x|Y = y] = \frac{P[X = x, Y = y]}{P[Y = y]} = \frac{p_{X,Y}(x, y)}{p_Y(y)}.$$

V tomto modelu udává střední hodnotu informace veličiny X **podmíněná entropie**

$$H(X|Y = y) := \sum_x \iota(p_{X|Y}(x|y)) = - \sum_x p_{X|Y}(x|y) \log p_{X|Y}(x|y).$$

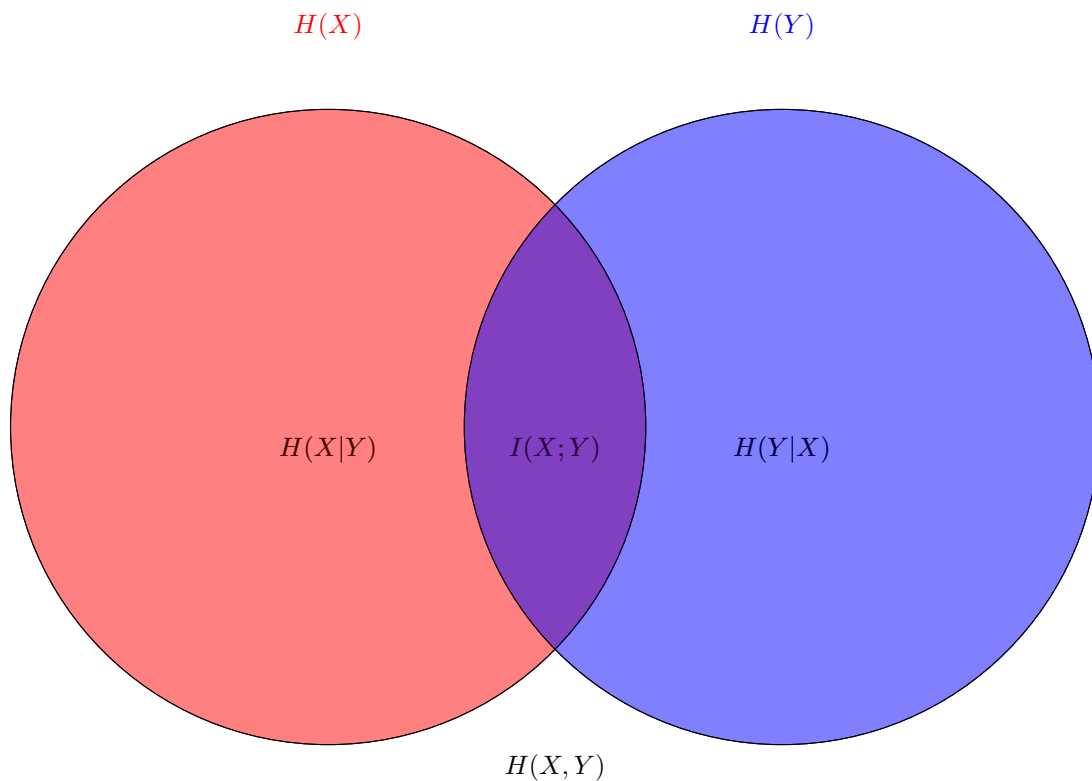
Její střední hodnota v závislosti na Y je **střední podmíněná entropie**

$$H(X|Y) := \sum_y p_Y(y) H(X|Y = y) = - \sum_x \sum_y p_Y(y) p_{X|Y}(x|y) \log p_{X|Y}(x|y) =$$

$$= - \sum_x \sum_y p_{X,Y}(x, y) \log \frac{p_{X,Y}(x, y)}{p_Y(y)} =$$

$$= - \sum_x \sum_y p_{X,Y}(x, y) \log p_{X,Y}(x, y) + \sum_x \sum_y p_{X,Y}(x, y) \log p_Y(y) =$$

$$= -E \log p_{X,Y}(X, Y) + E \log p_Y(Y) = H(X, Y) - H(Y).$$



Obdobně

$$\begin{aligned}
 H(Y|X = x) &= - \sum_y p_{Y|X}(y|x) \log p_{Y|X}(y|x), \\
 H(Y|X) &= \sum_x p_X(x) H(Y|X = x) = - \sum_x \sum_y p_{X,Y}(x, y) \log p_{Y|X}(y|x) = \\
 &= -E \log p_{X,Y}(X, Y) + E \log p_X(X) = H(X, Y) - H(X).
 \end{aligned}$$

5 Vzájemná informace

Ze sdruženého rozdělení $p_{X,Y}$ vypočítáme marginální pravděpodobnosti

$$\begin{aligned}
 p_X(x) &= \sum_y p_{X,Y}(x, y), \\
 p_Y(y) &= \sum_x p_{X,Y}(x, y).
 \end{aligned}$$

Z nich vypočítáme sdružené rozdělení

$$q_{X,Y}(x, y) := p_X(x) \cdot p_Y(y),$$

které má stejné marginální pravděpodobnosti $q_X = p_X$, $q_Y = p_Y$, ale odpovídá **nezávislým** náhodným veličinám. Při rozdělení $q_{X,Y}$ by sdružená entropie vyšla $H(X) + H(Y)$. Skutečné rozdělení $p_{X,Y}$ vede na sdruženou entropii

$$H(X, Y) = - \sum_x \sum_y p_{X,Y}(x, y) \log p_{X,Y}(x, y) = -E \log p_{X,Y}(X, Y).$$

Ztrátu informace v důsledku závislosti X, Y vyjadřuje **vzájemná informace** $I(X; Y)$ náhodných veličin X, Y , což je informační divergence $D(p_{X,Y} || q_{X,Y})$:

$$\begin{aligned}
I(X; Y) &:= D(\mathbf{p}_{X,Y} \| \mathbf{q}_{X,Y}) = \mathbb{E} \log p_{X,Y}(X, Y) - \mathbb{E} \log q_{X,Y}(X, Y) = \\
&= -H(X, Y) - \mathbb{E} \log p_X(X) \cdot p_Y(Y) = \\
&= -H(X, Y) - \mathbb{E} \log p_X(X) - \mathbb{E} \log p_Y(Y) = \\
&= -H(X, Y) + H(X) + H(Y).
\end{aligned}$$

5.1 Shrnutí vlastností vzájemné informace a podmíněné entropie

Vzájemná informace vyjadřuje, kolik informace o jedné proměnné nese druhá proměnná.

$$\begin{aligned}
I(X; Y) &= H(X) + H(Y) - H(X, Y), \\
H(X|Y) &= H(X, Y) - H(Y), \\
H(Y|X) &= H(X, Y) - H(X).
\end{aligned}$$

Důsledky:

$$\begin{aligned}
I(X; Y) &= I(Y; X), \\
H(X) &= I(X; Y) + H(X|Y), \\
H(Y) &= I(X; Y) + H(Y|X), \\
0 &\leq I(X; Y) \leq \min(H(X), H(Y)), \\
I(X; Y) &= 0 \iff X, Y \text{ jsou nezávislé}, \\
I(X; Y) &= H(X) \iff \forall y \exists! x : p_{X|Y}(x|y) = 1 \text{ (podm. rozdělení jsou Diracova)}, \\
I(X; X) &= H(X).
\end{aligned}$$

Vše lze beze změny uplatnit i na náhodné vektory.

Řetězcové pravidlo:

$$\begin{aligned}
H(X_1, X_2, \dots, X_n) &= H(X_1|X_2, \dots, X_n) + H(X_2|X_3, \dots, X_n) + \dots + \\
&+ H(X_{n-1}|X_n) + H(X_n).
\end{aligned}$$

Příklad 5.1 (poklad na ostrově – pokr.).

$p_{X,Y}(x, y)$:

x	y	A	B	C	$p_X(x)$
	1	$\frac{1}{6}$	$\frac{1}{6}$	0	$\frac{1}{3}$
	2	$\frac{1}{6}$	$\frac{1}{6}$	0	$\frac{1}{3}$
	3	0	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{3}$
	$p_Y(y)$	$\frac{1}{3}$	$\frac{1}{2}$	$\frac{1}{6}$	1

$$H(X) \doteq 1.585,$$

$$H(Y) \doteq 1.459,$$

$$H(X, Y) \doteq 2.585.$$

Model s nezávislými veličinami a stejnými marginálními rozděleními:

$p_X(x) \cdot p_Y(y)$:

x	y	A	B	C	$p_X(x)$
	1	$\frac{1}{9}$	$\frac{1}{6}$	$\frac{1}{18}$	$\frac{1}{3}$
	2	$\frac{1}{9}$	$\frac{1}{6}$	$\frac{1}{18}$	$\frac{1}{3}$
	3	$\frac{1}{9}$	$\frac{1}{6}$	$\frac{1}{18}$	$\frac{1}{3}$
	$p_Y(y)$	$\frac{1}{3}$	$\frac{1}{2}$	$\frac{1}{6}$	1

$$I(X; Y) = D(\mathbf{p}_{X,Y} \| \mathbf{p}_X \cdot \mathbf{p}_Y) = 2 \cdot \frac{1}{6} \log \frac{3}{2} + \frac{1}{6} \log 3 \doteq 0.459, \text{ též}$$

$$I(X; Y) = H(X) + H(Y) - H(X, Y) \doteq 1.585 + 1.459 - 2.585 = 0.459.$$

Kdybychom věděli, že $Y = y$, pak by X přispívalo podm. entropií $H(X|Y = y)$:
 $p_{X|Y}(x|y)$:

x	y	A	B	C
	1	$\frac{1}{2}$	$\frac{1}{3}$	0
	2	$\frac{1}{2}$	$\frac{1}{3}$	0
	3	0	$\frac{1}{3}$	1
$p_Y(y)$		$\frac{1}{3}$	$\frac{1}{2}$	$\frac{1}{6}$
$H(X Y = y)$		1	$\log 3$	0

střední hodnota $H(X|Y) = \frac{1}{3} + \frac{1}{2} \log 3 \doteq 1.126$, též

$$H(X|Y) = H(X, Y) - H(Y) \doteq 2.585 - 1.459 = 1.126.$$

Kdybychom věděli, že $X = x$, pak by Y přispívalo podm. entropií $H(Y|X = x)$:

$p_{Y|X}(y|x)$:

x	y	A	B	C	$p_X(x)$	$H(Y X = x)$
	1	$\frac{1}{2}$	$\frac{1}{2}$	0	$\frac{1}{3}$	1
	2	$\frac{1}{2}$	$\frac{1}{2}$	0	$\frac{1}{3}$	1
	3	0	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{3}$	1

střední hodnota $H(Y|X) = 1$, též

$$H(Y|X) = H(X, Y) - H(X) \doteq 2.585 - 1.585 = 1.$$

Literatura

- [Roman] Roman, S.: *Coding and Information Theory*. Graduate Texts in Mathematics, Vol. 134, Springer, 1992.
- [Moser] Moser, S.M.: *Information Theory*. National Chiao Tung University, Hsinchu, Taiwan, 2012.
- [MacKay] MacKay, D.J.C.: *Information Theory, Inference, and Learning Algorithms*. Cambridge University Press, 2003.
- [Cover, Thomson] Cover, T.M., Thomson, J.: *Elements of Information Theory*. Wiley, 1991.
- [Vajda] Vajda, I.: *Teorie informace*. ČVUT, Praha, 2004.
- [MN: PMS] Navara, M.: *Pravděpodobnost a matematická statistika*. ČVUT, Praha, 2007.
- [Apl. mat.] kol.: *Aplikovaná matematika*. Oborové encyklopedie SNTL, Praha, 1978.
- [Enc. Math.] Hazewinkel, M.: *Encyclopaedia of Mathematics*. Kluwer Academic Publishers, 1995.