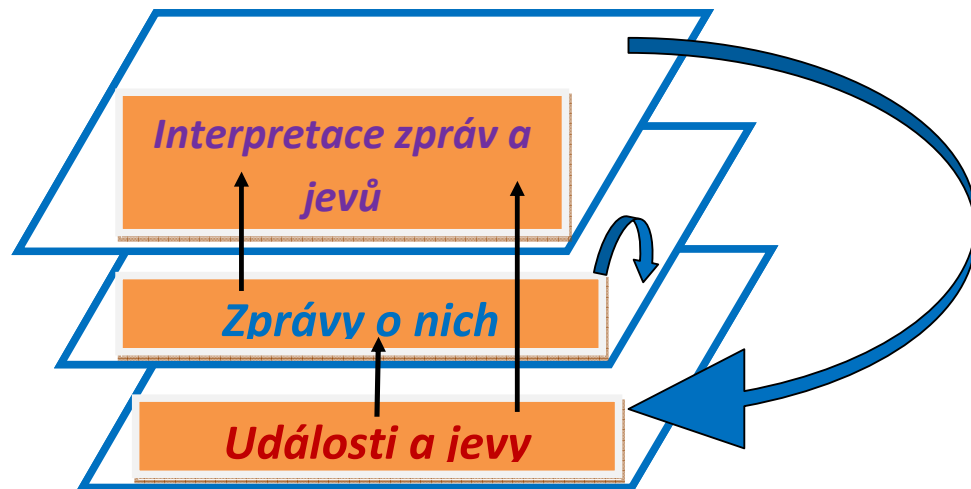


Teorie informace a aférologie, s příkladem pro případ ZČU

(některé poznámky k modelování hromadného sdělování)

František Vávra, květen 2011

Tři vrstvy obecného sdělování



Pět základních (lokálních) problémů současné doby

1. Generování (pravdivých i jiných) zpráv nad prázdným jevem („reklama“, ...).
2. Ze zpráv zjistit co se vlastně stalo, zprávy o zprávách.
3. Z interpretací zjistit na co vlastně reagují.
4. Interpretace generující nové události a jevy.
5. Rychlost (tzv. rychlé smyčky, „hazardy“), mnohost a dostupnost zpráv.

Základní pojmy Shannonova teorie, diskrétní případ:

Konečné abecedy X, Y a nad nimi pravděpodobnosti elementárních jevů = prvků abecedy:

$$x \in X : p(x) \geq 0; \sum_{x \in X} p(x) = 1; [(x_1, x_2 \in X) \wedge (x_1 \neq x_2)] \Rightarrow p(x_1, x_2) = p(x_1 \wedge x_2) = 0$$

$$y \in Y : p(y) \geq 0; \sum_{y \in Y} p(y) = 1; [(y_1, y_2 \in Y) \wedge (y_1 \neq y_2)] \Rightarrow p(y_1, y_2) = p(y_1 \wedge y_2) = 0$$

Elementární informace:

1. $i(x) = i(p(x))$, **informační míra je funkcí pravděpodobnosti** (odvození z pravděpodobnosti obecně není nutné).
2. $x_1, x_2 \in X \wedge p(x_1) > p(x_2) \Rightarrow i(x_1) < i(x_2)$, **koncepte překvapení**; pokud je přijata méně pravděpodobná zpráva, dostáváme více informace.
3. $x \in X; y \in X; x, y$ nezávislé $\Rightarrow i(x, y) = i(x) + i(y)$, **pozorování nezávislého jevu, přijetí nezávislé zprávy poskytuje úplně novou informaci**. Aditivita odvozená ze sčítání také není obecně nutná, může být pojata obecněji
 $x \in X; y \in X; x, y$ nezávislé $\Rightarrow i(x, y) = i(x) \oplus i(y)$, kde operace \oplus je nějaká grupová (komutativní) operace, např. $i(x) \oplus i(y) = i(x) + i(y) - i(x)i(y)$.
4. $i(p(x)) = i(p)$ je **spojitou funkcí pravděpodobnosti**.

Z uvedených čtyř **základních** (před diskusí) požadavků lze odvodit, že $i(p(x)) = -\log_z p(x); z > 1$.
Důkaz [1], str. 46-49. Běžně je užíváno $i(p(x)) = -\log_2 p(x) = -lb[p(x)]$, často také $i(p(x)) = -\log_e p(x) = -lg[p(x)]$.

Střední informace, míra informace zdroje - entropie:

$$H(X) = E\{i(x)\} = \sum_{x \in X} p(x)i(x) = \sum_{x \in X} p(x)(-\log p(x)) = E\{-\log p(x)\} = -\sum_{x \in X} p(x) \log p(x),$$

pokud je $p(x) = 0$, dodefinovává se $p(x) \log p(x) = 0$; vychází se z $\lim_{p \rightarrow 0^+} p \log p = 0$.

$$\text{Platí: } 0 \leq H(X) \leq \log|X|. \quad H(X) = 0 \Leftrightarrow \exists x \in X; p(x) = 1; \quad H(X) = \log|X| \Leftrightarrow \forall x \in X; p(x) = \frac{1}{|X|}.$$

Odtud též název neurčitost informačního zdroje.

Koncepce přenosu, vazby nebo sdílení:

Dva, propojené informační zdroje s abecedami X, Y

$$H(X, Y) = E\{i(x, y)\} = - \sum_{x \in X, y \in Y} p(x, y) \log p(x, y)$$

$$H(X / Y) = E\{i(x / y)\} = - \sum_{x \in X, y \in Y} p(x, y) \log p(x / y), \text{ podmíněná entropie.}$$

$$H(Y / X) = E\{i(y / x)\} = - \sum_{x \in X, y \in Y} p(x, y) \log p(y / x)$$

$$\text{Platí: } H(X) \geq H(X / Y). \text{ Důkaz: } H(X) - H(X / Y) = - \sum_{x \in X, y \in Y} p(x, y) \log p(x) + \sum_{x \in X, y \in Y} p(x, y) \log p(x / y) =$$

$$= \sum_{x \in X, y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} = \sum_{x \in X, y \in Y} p(x, y) \left(-\log \frac{p(x)p(y)}{p(x, y)} \right) \geq$$

daná nerovnost je Jensenovou

$$\geq -\log \left(\sum_{x \in X, y \in Y} p(x, y) \left(\frac{p(x)p(y)}{p(x, y)} \right) \right) = -\log(1) = 0$$

nerovností (viz: [3], str. 82-84).

$$I(X : Y) \stackrel{\text{def}}{=} H(X) - H(X / Y) = H(Y) - H(Y / X) = \sum_{x \in X, y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \geq 0, \text{ vazební,}$$

sdílená informace, informace.

Divergenční míry

Mějme abecedu elementárních zpráv (elementárních jevů) X a nad ní různá pravděpodobnostní rozdělení $P(x)$, $Q(x)$. Opět bude předpokládáno $\forall x \in X; P(x), Q(x) > 0$.

Divergence pravděpodobnostních modelů je zavedena klasicky $D(P||Q) = \sum_{x \in X} P(x) \log \frac{P(x)}{Q(x)}$. Je to

vlastně střední hodnota skóre testu jednoduché hypotézy (pozorování se řídí pravděpodobnostním rozdělením $P(x)$) proti jednoduché alternativě (pozorování se řídí pravděpodobnostním rozdělením $Q(x)$) za předpokladu, že platí hypotéza.

$$D(P||Q) \geq 0. \text{ Důkaz: } D(P||Q) = \sum_{x \in X} P(x) \log \frac{P(x)}{Q(x)} \geq \sum_{x \in X} P(x) \left(1 - \frac{Q(x)}{P(x)} \right) = 1 - 1 = 0.$$

Jeffreysova J-divergence

Je zřejmé, že nemusí obecně platit $D(P||Q) = D(Q||P)$. Tedy divergence není symetrická. Proto se zavádí symetrická divergence $J(P, Q) = D(P||Q) + D(Q||P)$ (J-divergence, Jeffreysova divergence).


Platí:

$$H(X,Y) = H(Y,X), H(X,Y) = H(X/Y) + H(Y), H(X,Y) = H(Y/X) + H(X)$$

$$I(X:Y) = I(Y:X), I(X:Y) = H(Y) - H(Y/X), I(X:Y) = H(X) - H(X/Y)$$

$$H(X,Y) = H(X) + H(Y) - I(X:Y)$$

Odtud interpretace pomocí Vénova diagramu:



Platí: X, Y nezávislé $\Leftrightarrow I(X:Y) = 0$.

Popis sdělování (prezentace)

Mějme konkrétní zdroj informace s abecedou zpráv: $X = \{x_1, x_2, \dots, x_i, \dots, x_n\}$ takové zprávy jsou věrně prezentovány příjemci s jeho abecedou $X = \{y_1, y_2, \dots, y_i, \dots, y_n\}$ s maticí přenosu

$$P(y_i/x_j) = \begin{cases} 1 & \Leftrightarrow i = j \\ 0 & \Leftrightarrow i \neq j \end{cases}; i, j = 1, \dots, n \quad \text{a s pravděpodobnostmi výskytu jednotlivých zpráv}$$

$$P(x_i) = p_i; i = 1, \dots, n. \text{ Potom: } H(X) = H(Y) = -\sum_{i=1}^n p_i \lg p_i, \quad I(X:Y) = \sum_{i=1}^n \sum_{j=1}^n p(i,j) \lg \frac{p(i,j)}{p_i p_j} =$$

$$= \sum_{i=1}^n p_i \lg \frac{p_i}{p_i p_i} = -\sum_{i=1}^n p_i \lg p_i = H(X).$$

„Štěpení“ zprávy při prezentaci


Nechť je nyní prezentační abeceda obohacena „rozštěpením“ jedné k -té zprávy $y_k \rightarrow \begin{matrix} y_{k,1} \\ y_{k,2} \end{matrix}$, potom:

$$p_k = p(y_k) = p(x_k) = p(y_{k,1}) + p(y_{k,2}).$$

Takové „rozštěpení“ má reálný podklad, původní zpráva $x_k \equiv$ „**stala se nehoda**“ je prezentována jako $y_{k,1} \equiv$ „stala se **tragická** nehoda“. Taková prezentace samozřejmě vyvolá dojem (a i implicitní existenci) toho, že existuje jiná doplňková zpráva $y_{k,2} \equiv$ „stala se **nikoliv tragická** nehoda“.

Matice přenosu má po takové „úpravě“ tvar:

$$P(y_i / x_j) = \begin{cases} 1 & \Leftrightarrow i = j \neq k \\ 0 & \Leftrightarrow (i \notin \{(k,1), (k,2)\}) \wedge (j \neq k) \\ q_{1,k} & \Leftrightarrow (y_i = y_{k,1}) \wedge (j = k) \\ q_{2,k} & \Leftrightarrow (y_i = y_{k,2}) \wedge (j = k) \end{cases}; \quad i, j = 1, \dots, n; \quad q_{1,k}, q_{2,k} > 0; \quad q_{1,k} + q_{2,k} = 1$$



$$\begin{aligned} I(X:Y) &= \sum_{i=1}^n \sum_{j=1}^n p(i,j) \lg \frac{p(i,j)}{p_i p_j} = \sum_{i=1}^n p_i \lg \frac{p_i}{p_i p_i} + q_{1,k} p_k \lg \frac{q_{1,k} p_k}{p_k (q_{1,k} p_k)} + q_{2,k} p_k \lg \frac{q_{2,k} p_k}{p_k (q_{2,k} p_k)} = \\ &= \sum_{i=1}^n p_i \lg \frac{p_i}{p_i p_i} + q_{1,k} p_k \lg \frac{1}{p_k} + q_{2,k} p_k \lg \frac{1}{p_k} = \sum_{i=1}^n p_i \lg \frac{p_i}{p_i p_i} + (q_{1,k} + q_{2,k}) p_k \lg \frac{1}{p_k} = \sum_{i=1}^n p_i \lg \frac{p_i}{p_i p_i} + p_k \lg \frac{1}{p_k} = \\ &= - \sum_{i=1}^n p_i \lg p_i \end{aligned}$$

Tedy: přenesen **je shodný informační obsah** zdroje jako v případě věrného přenosu. Na vstupní = zdrojové straně zůstává také původní stav $-\sum_{i=1}^n p_i \lg p_i = H(X)$ ale na výstupní straně

$$\begin{aligned} \text{bude:} \quad H_{k,q_{1,k},q_{2,k}}(Y) &= - \sum_{i=1}^n p_i \lg p_i - q_{1,k} p_k \lg(q_{1,k} p_k) - q_{2,k} p_k \lg(q_{2,k} p_k) = \\ &= - \sum_{i=1}^n p_i \lg p_i - q_{1,k} p_k \lg(q_{1,k}) - q_{1,k} p_k \lg(p_k) - q_{2,k} p_k \lg(q_{2,k}) - q_{2,k} p_k \lg(p_k) = \\ &= - \sum_{i=1}^n p_i \lg p_i - q_{1,k} p_k \lg(q_{1,k}) - q_{2,k} p_k \lg(q_{2,k}) = - \sum_{i=1}^n p_i \lg p_i - p_k (q_{1,k} \lg(q_{1,k}) + q_{2,k} \lg(q_{2,k})) \end{aligned}$$

Shrnuto: $H(Y) = - \sum_{i=1}^n p_i \lg p_i - p_k (q_{1,k} \lg(q_{1,k}) + q_{2,k} \lg(q_{2,k})) \equiv$ **střední poskytovaná informace (entropie) prezentační úrovně se zvětší o hodnotu $- p_k (q_{1,k} \lg(q_{1,k}) + q_{2,k} \lg(q_{2,k}))$ a ta nabývá svého maxima pro $q_{1,k} = q_{2,k} = 1/2$ s hodnotou $p_k \lg(2)$.**

Ještě jednou shrnuto: $H_{k,q_{1,k},q_{2,k}}(Y) = H(Y) - p_k(q_{1,k} \lg(q_{1,k}) + q_{2,k} \lg(q_{2,k})) \leq H(Y) + p_k \lg(2)$

Celý postup měření je založen na následující „triviální“ nerovnosti. Nechť je zpráva x s pravděpodobností výskytu p „rozštěpena“ do dvou zpráv x_1, x_2 s pravděpodobnostmi výskytu p_1, p_2 ; $p_1 + p_2 = p$; $0 < p_1, p_2, p < 1$. Pak platí:

$$-(p_1 + p_2) \log(p_1 + p_2) < -p_1 \log(p_1) - p_2 \log(p_2)$$

Odvození:

1. $-(p_1 + p_2) \log(p_1 + p_2) \mapsto -p_1 \log(p_1) - p_2 \log(p_2)$
2. $\log(p_1 + p_2)^{-(p_1+p_2)} \mapsto \log(p_1^{-p_1}) + \log(p_2^{-p_2})$
3. $(p_1 + p_2)^{-(p_1+p_2)} \mapsto (p_1^{-p_1})(p_2^{-p_2})$
4. $(p_1 + p_2)^{-p_1} (p_1 + p_2)^{-p_2} \mapsto (p_1^{-p_1})(p_2^{-p_2})$
5. $\left(\frac{p_1 + p_2}{p_1}\right)^{-p_1} \left(\frac{p_1 + p_2}{p_2}\right)^{-p_2} \mapsto 1$
6. $\left(\frac{p_1}{p_1 + p_2}\right)^{p_1} \left(\frac{p_2}{p_1 + p_2}\right)^{p_2} \mapsto 1$ a zde je evidentní, že:
7. $\left(\frac{p_1}{p_1 + p_2}\right)^{p_1} \left(\frac{p_2}{p_1 + p_2}\right)^{p_2} < 1$


Důkaz: Opačným postupem od bodu 7. k bodu 1.

Uvedená nerovnost je speciálním případem obecnější (Log-Sum inequality, [C])


$$\sum_{i=1}^n a_i \log \frac{a_i}{b_i} \geq \left(\sum_{i=1}^n a_i \right) \log \frac{\left(\sum_{i=1}^n a_i \right)}{\left(\sum_{i=1}^n b_i \right)}; a_i, b_i \geq 0 \forall i = 1, \dots, n$$

Shrnutí:

„Štěpení zprávy“




„Sloučení zpráv“



Zprávy z druhé ruky

Model - Markovská soustava.



Obecně platí: $P(x, y, z) = P(z/y, x)P(y, x) = P(z/y, x)P(y/x)P(x)$. Takovou přenosovou soustavu budeme nazývat markovskou pokud platí $P(z/y, x) = P(z/y)$ a bude to značeno $X \rightarrow Y \rightarrow Z$. Pro markovskou soustavu proto bude:

$$P(x, y, z) = P(z/y, x)P(y, x) = P(z/y, x)P(y/x)P(x) = P(z/y)P(y/x)P(x). \text{ Dále } P(x, z/y) = \frac{P(x, z, y)}{P(y)} = \frac{P(z/y)P(y/x)P(x)}{P(y)} = \frac{P(z/y)P(x, y)}{P(y)} = P(z/y)P(x/y).$$

Shrnuto $P(x, z/y) = P(z/y)P(x/y)$. Odtud:

Definice: Abecedy X a Z budeme nazývat podmíněně nezávislé při daném Y , pokud platí: $P(x, z/y) = P(z/y)P(x/y) \quad \forall x \in X \quad \forall y \in Y \quad \forall z \in Z$. Daný pojem je vázán na pravděpodobnost nad danými abecedami. [C] str. 21-23.

Proti tomu je klasická nezávislost:

Definice: Abecedy X a Z budeme nazývat nezávislé, pokud platí: $P(x, z) = P(x)P(z) \quad \forall x \in X \quad \forall z \in Z$. Opět je daný pojem vázán na pravděpodobnost nad danými abecedami.

Tvrzení: Podmíněná nezávislost neimplikuje nepodmíněnou nezávislost.

Tvrzení: Nepodmíněná nezávislost neimplikuje podmíněnou nezávislost.

Důkaz: je v příloze = příklady kdy hypoteticky předpokládané implikace neplatí.

Tvrzení: Je-li $X \rightarrow Y \rightarrow Z$, pak je i $Z \rightarrow Y \rightarrow X$

Důkaz: K tomu stačí dokázat $P(x/y, z) = P(x/y)$. Ale $P(x/y, z) = \frac{P(x, y, z)}{P(y, z)} = \frac{P(z/y)P(y/x)P(x)}{P(y, z)} = \frac{P(z/y)P(y)P(y/x)P(x)}{P(y)P(y, z)} = \frac{P(y/x)P(x)}{P(y)} = \frac{P(x, y)}{P(y)} = P(x/y)$.

Definice: Podmíněná informace. $I(X : Y/Z) = \sum_{x, y, z \in X \times Y \times Z} P(x, y, z) \log \frac{P(x, y/z)}{P(x/z)P(y/z)}$

Tvrzení: $I(X : Y / Z) \geq 0$

$$\begin{aligned} \text{Důkaz: } \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x,y/z)}{P(x/z)P(y/z)} &= \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \left[-\log \frac{P(x/z)P(y/z)}{P(x,y/z)} \right] \geq \\ &\geq -\log \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \left[\frac{P(x/z)P(y/z)}{P(x,y/z)} \right] = -\log \sum_{x,y,z \in X \times Y \times Z} P(x/z)P(y/z)P(z) = -\log \sum_{x,z \in X \times Y \times Z} P(x/z)P(z) = -\log(1) = 0. \end{aligned}$$

Tvrzení: $I(X : Y / Z) = I((X,Z) : (Y,Z)) - H(Z)$, kde $I((X,Z) : (Y,Z)) = \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x,y,z)}{P(x,z)P(y,z)}$.

Důkaz: Prostým výpočtem.

Tvrzení: $X \rightarrow Y \rightarrow Z \Rightarrow I(X : Y / Z) = H(X / Z) - H(Y / Z)$

$$\begin{aligned} \text{Důkaz: } X \rightarrow Y \rightarrow Z \Rightarrow P(z/y,x) &= P(z/y) \text{ a pak } \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x,y/z)}{P(x/z)P(y/z)} = \\ &= \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x,y,z)}{P(x/z)P(y/z)P(z)} = \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(z/x,y)P(x,y)}{P(x/z)P(y/z)P(z)} = \\ &= \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(z/y)P(x,y)}{P(x/z)P(y/z)P(z)} = \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x,y)}{P(x/z)P(y)} = \\ &= \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x/y)}{P(x/z)} = H(X / Z) - H(X / Y) \end{aligned}$$

Důsledek: $X \rightarrow Y \rightarrow Z \Rightarrow H(X / Z) \geq H(Y / Z)$

Tvrzení: $X \rightarrow Y \rightarrow Z \Rightarrow I(X : Z / Y) = 0$

Důkaz:

$$\begin{aligned} I(X : Z / Y) &= \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x,z/y)}{P(x/y)P(z/y)} = \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x,y,z)}{P(x/y)P(z/y)P(y)} = \\ &= \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x/y,z)P(y,z)}{P(x/y)P(y,z)} = \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x/y)}{P(x/y)} = 0 \end{aligned}$$

Tvrzení: $X \rightarrow Y \rightarrow Z \Rightarrow I(X : (Y, Z)) = I(X : Y)$

$$\begin{aligned} \text{Důkaz: } I(X : (Y, Z)) &= \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x,y,z)}{P(x)P(y,z)} = \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x/y,z)}{P(x)} = \\ &= \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x/y)}{P(x)} = \sum_{x,y,z \in X \times Y \times Z} P(x,y,z) \log \frac{P(x,y)}{P(x)P(y)} = I(X : Y) \end{aligned}$$

Tvrzení: $X \rightarrow Y \rightarrow Z \Rightarrow I(X : (Y, Z)) = I(X : Y / Z) + I(X : Z)$

Důkaz:

$$\begin{aligned} I(X : (Y, Z)) &= \sum_{x,y,z \in XxYxZ} P(x, y, z) \log \frac{P(x, y, z)}{P(x)P(y, z)} = \sum_{x,y,z \in XxYxZ} P(x, y, z) \log \frac{P(x, y/z)P(z)}{P(x)P(y/z)P(z)} = \\ &= \sum_{x,y,z \in XxYxZ} P(x, y, z) \log \frac{P(x, y/z)}{P(x/z)P(y/z)} \frac{P(x/z)}{P(x)} = I(X : Y / Z) + \sum_{x,y,z \in XxYxZ} P(x, y, z) \log \frac{P(x/z)}{P(x)P(z)} = \\ &= I(X : Y / Z) + I(X : Z) \end{aligned}$$

Srovnáním obou předchozích tvrzení dostaneme: $X \rightarrow Y \rightarrow Z \Rightarrow I(X : Y) = I(X : Y / Z) + I(X : Z)$ a odtud: $X \rightarrow Y \rightarrow Z \Rightarrow I(X : Y) \geq I(X : Z)$ s rovností při podmíněné nezávislosti X a Y při daném Z , tj. $I(X : Y / Z) = 0 \Leftrightarrow \forall x, y, z \in XxYxZ; P(x, y / z) = P(x / z)P(y / z)$.

A obdobně $X \rightarrow Y \rightarrow Z \Rightarrow I(X : Y) \geq I(X : Y / Z)$

Námět: Dokažte, že předpoklad $X \rightarrow Y \rightarrow Z$ pro platnost nerovnosti $I(X : Y) \geq I(X : Y / Z)$ je podstatný.

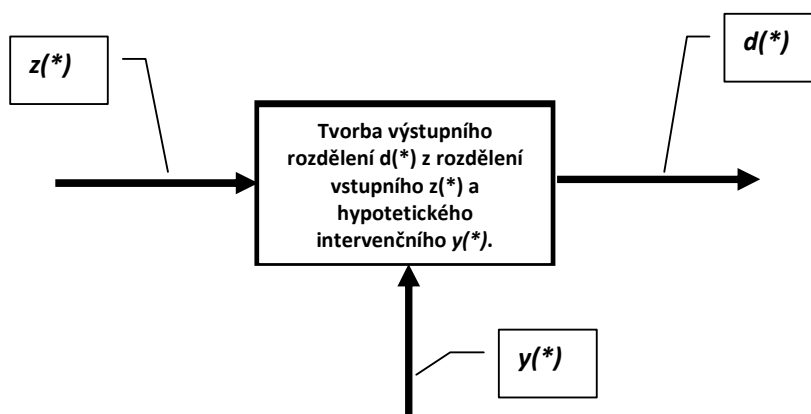
Tj. $\exists P(*, *, *)$ na $XxYxZ; I(X : Y) > I(X : Y / Z)$ a i $\exists P(*, *, *)$ na $XxYxZ; I(X : Y) < I(X : Y / Z)$.

První část je triviální, druhá nalezením příkladu.

Námět: Za jakých podmínek na $P(*, *, *)$ na $XxYxZ$ bude platit $I(X : Y) = I(X : Y / Z)$

Shrnutí: Vložením prostředníka [umělý propojovací jev(y) nebo zpráva(y)] při sdělování, lze vyvolat „dojem“ souvislosti jevu a zprávy, které ve skutečnosti nemají nic společného. Nebo i naopak. Tento „dojem“ lze modelovat a lze ho i měřit.

Model intervence



Předpokládáme, že daný model pracuje s konečnou množinou stavů, tu budeme nahrazovat čísly $\{1, 2, \dots, n\}$ pro všechny vstupy a výstup, shodnou.

Pro analýzu budeme předpokládat model směsi rozdělení:

$$d(i) = (1 - \alpha)z(i) + \alpha y(i); 0 < \alpha \leq 1$$

Odtud pro intervenční rozdělení $y(i)$ platí: $y(i) = \frac{d(i) - (1 - \alpha)z(i)}{\alpha} = \frac{d(i) - z(i)}{\alpha} + z(i)$. Z toho, že $y(i); i = 1, \dots, n$ je pravděpodobnostní rozdělení pak pro koeficient směsi α (= síla intervence do změny) musí platit:

$$0 \leq \frac{d(i) - (1 - \alpha)z(i)}{\alpha} \leq 1 \text{ a } \sum_{i=1}^n \frac{d(i) - (1 - \alpha)z(i)}{\alpha} = 1. \text{ Ke splnění poslední rovnosti je nutné a stačí}$$

$\alpha \neq 0$. Nadále bude zkoumána první dvojice nerovností: $0 \leq \frac{d(i) - (1 - \alpha)z(i)}{\alpha}$ a

$\frac{d(i) - (1 - \alpha)z(i)}{\alpha} \leq 1$. Z první nerovnosti plyne: $\alpha \geq \frac{z(i) - d(i)}{z(i)}; i = 1, \dots, n$ a z druhé lze odvodit:

$$\alpha \geq \frac{d(i) - z(i)}{1 - z(i)}; i = 1, \dots, n, \text{ odtud plyne potřeba } 0 < z(i) < 1^1.$$

Odtud pro volbu síly intervence $\alpha \geq \max \left\{ \frac{z(i) - d(i)}{z(i)}, \frac{d(i) - z(i)}{1 - z(i)}; i = 1, \dots, n \right\}$

Je evidentní, že se jeden člen z dvojice $\frac{z(i) - d(i)}{z(i)}, \frac{d(i) - z(i)}{1 - z(i)}$ pro každé i neuplatní (bude alespoň

pro jedno i záporný a obecně nekladný). Pokud tomu tak nebude, jsou vstupní a výstupní rozdělení shodná a to vede na triviální řešení $\alpha=0$ (tento případ bude nadále vynecháván). Aby existovalo

„použitelné netriviální řešení pro α “ musí platit: $0 < \max \left\{ \frac{z(i) - d(i)}{z(i)}, \frac{d(i) - z(i)}{1 - z(i)}; i = 1, \dots, n \right\} < 1$.

¹ To může být např. zabezpečeno volbou metody odhadu vstupních pravděpodobností.

První nerovnost (kladnost) je splněna triviálně (za výše uvedeného předpokladu). Pro druhou budeme analyzovat dva možné případy:

$$1. \max \left\{ \frac{z(i) - d(i)}{z(i)}, \frac{d(i) - z(i)}{1 - z(i)}; i = 1, \dots, n \right\} = \frac{z(k) - d(k)}{z(k)}$$

$$2. \max \left\{ \frac{z(i) - d(i)}{z(i)}, \frac{d(i) - z(i)}{1 - z(i)}; i = 1, \dots, n \right\} = \frac{d(l) - z(l)}{1 - z(l)}$$

První případ vede na podmínku $\frac{z(k) - d(k)}{z(k)} < 1 \Leftrightarrow z(k) - d(k) < z(k) \Leftrightarrow -d(k) < 0$. K jejímu splnění je nutné a stačí aby $d(k) > 0$.

Druhý případ vede na podmínku $\frac{d(l) - z(l)}{1 - z(l)} < 1 \Leftrightarrow d(l) < 1$. I tuto podmínku lze přijmout pro běžné situace.

Pokud by došlo k volbě: $\alpha = \max \left\{ \frac{z(i) - d(i)}{z(i)}, \frac{d(i) - z(i)}{1 - z(i)}; i = 1, \dots, n \right\}$, pak by ve výše

uvedeném **prvním případě** platilo: $y(k) = \frac{d(k) - z(k)}{\alpha} + z(k) = \frac{d(k) - z(k)}{\frac{z(k) - d(k)}{z(k)}} + z(k) = 0$. Při téže

volbě by v **druhém případě** platilo: $y(l) = \frac{d(l) - z(l)}{\alpha} + z(l) = \frac{d(l) - z(l)}{\frac{d(l) - z(l)}{1 - z(l)}} + z(l) = 1$ a v tom

případě pro $i \neq l \Rightarrow y(i) = \frac{d(i) - z(i)}{\frac{d(l) - z(l)}{1 - z(l)}} + z(i) = 0 \Leftrightarrow \frac{d(i) - z(i)}{d(l) - z(l)} (1 - z(l)) + z(i) = 0 \Leftrightarrow$

$$\Leftrightarrow (d(i) - z(i))(1 - z(l)) + z(i)(d(l) - z(l)) = 0 \Leftrightarrow \frac{d(i)}{z(i)} = \frac{1 - d(l)}{1 - z(l)} \Rightarrow i \neq l \Rightarrow d(i) = kz(i) \Rightarrow$$

$\Rightarrow \forall i \neq l; \frac{z(i) - d(i)}{z(i)} = \frac{z(i) - kz(i)}{z(i)} = 1 - k = 1 - \frac{1 - d(l)}{1 - z(l)} = \frac{d(l) - z(l)}{1 - z(l)}$. Toto je důležitý případ,

kteří říká: **pokud nastane druhý případ, nastává i první**. Proto $\alpha \geq \max \left\{ \frac{z(i) - d(i)}{z(i)}; i = 1, \dots, n \right\}$

A odtud, shrnuto: **Aby existovala netriviální intervence** $(\alpha \neq 0) \wedge (\alpha \neq 1)$, **musí být splněno** $\exists i = 1, \dots, n; d(i) \neq z(i)$ **a zároveň** $\forall i = 1, \dots, n; d(i) > 0$.

Tedy: Prakticky u všech dvojic zdrojů nad stejnou abecedou lze nalézt hypotetický, alespoň aproximativní, intervenční zdroj, který intervencí z jednoho rozdělení stavů (zpráv, událostí, ...) vytváří rozdělení druhé.


Hypotetická „spiklenecká intervence“

$$\mathbf{y(i)} = \boldsymbol{\varepsilon}; i = 1, \dots, k - 1, k + 1, \dots, n; \mathbf{y(k)} = \mathbf{1} - (n - 1)\boldsymbol{\varepsilon}; 0 < \boldsymbol{\varepsilon} \leq \frac{1}{n - 1}$$

Příklad takové rekonstrukce:

Pižeňská právnická fakulta (pravděpodobnost výskytu) v sekci "zprávy" serveru IDNES


	2008	2009	intervence	Rekonstrukce 2009 s předpokladem intervence
Výskyt	0,00057	0,00824	0,99900	0,00824
Ne-výskyt	0,99943	0,99176	0,00100	0,99176



epsilon=	0,00100
alfa=	0,00768

Pižeňská právnická fakulta (pravděpodobnost výskytu) v sekci "zprávy" serveru IDNES

	2008	2009	intervence	Rekonstrukce 2009 s předpokladem intervence
Výskyt	0,00057	0,00824	0,50000	0,00824
Ne-výskyt	0,99943	0,99176	0,50000	0,99176




epsilon=	0,50000
alfa=	0,01536


Prezentace jak je možné aproximovat (zde přesně) k danému (libovolnému)spikleneckému intervenčnímu rozdělení jeho sílu.

Další příklad takové rekonstrukce:

	Vstupní	Výstupní	intervence	Rekonstrukce výstupního s předpokladem intervence
Jev A	0,50	0,20	0,05	0,20
Jev B	0,30	0,70	0,90	0,70
Jev C	0,20	0,10	0,05	0,10



	Vstupní	Výstupní	intervence	Rekonstrukce výstupního s předpokladem intervence
Jev A	0,50	0,20	0,10	0,18
Jev B	0,30	0,70	0,80	0,70
Jev C	0,20	0,10	0,10	0,12



Prezentace jak je možné aproximovat (zde přibližně) k danému (libovolnému) spikleneckému intervenčnímu rozdělení jeho sílu.

Příklad opačného postupu, hledání intervence, k cenovým průběhům (např. sezónní podněty):

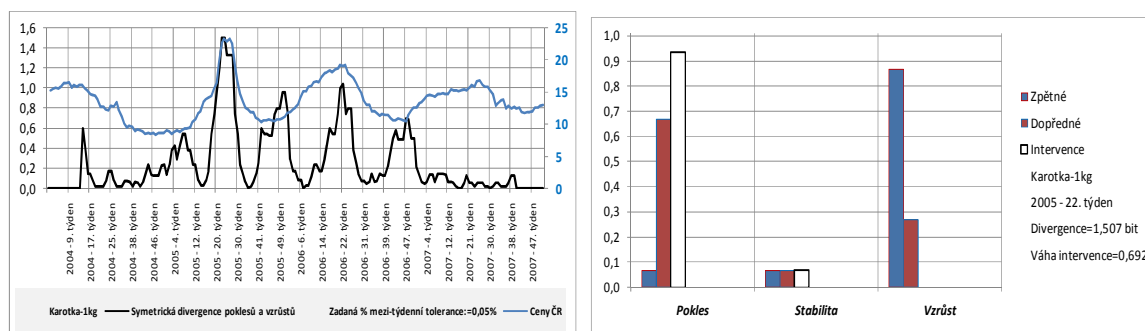
Průměrné týdenní ceny vybraných komodit za celou ČR z šetření ČSÚ

Zavedené stavy této časové řady:

$$\varepsilon = 0,0005$$

Stavová diferenční paměť (doba, ze které jsou odhadovány pravděpodobnosti výskytu ve stavu) 12 týdnů zpět a dopředu včetně aktuálního týdne.

Jev	Číselný kód = $dif(t)$	Podmínka
Pokles	-1	$\frac{c(t) - c(t-1)}{c(t)} \leq -\varepsilon$
Stabilita	0	$\frac{ c(t) - c(t-1) }{c(t)} < \varepsilon$
Růst	+1	$\frac{c(t) - c(t-1)}{c(t)} \geq +\varepsilon$




Situace v rozděleních stavového popisu v maximum divergence.

Dynamika „afér“

Spouštění „afér“

Každá „aféra“ je spuštěna nějakým podnětem. Technickým modelem pro ni je „jednopulzní spoušť“, s náhodnou dobou trvání, která se převážně řídí exponenciálním rozdělením.



„Prodlužování afér“

Pokud přijde v době trvání (těže) aféry další podnět, pak se je generována doba odezvy na základě již naběhlé délky reakce na **nejbližší předcházející podnět** a to tak, že **střední hodnota trvání reakce** odpovídající tomuto podnětu je rovna:

$$\begin{aligned} \text{střední hodnota reakce na předcházející podnět} &= \frac{\text{střední hodnota reakce na předcházející podnět}}{\text{doba trvání reakce na předcházející podnět}} = \\ &= \frac{(\text{střední hodnota reakce na předcházející podnět})^2}{\text{doba trvání reakce na předcházející podnět}} \end{aligned}$$

Tedy doby odezvy na podněty mají jakousi „martingalovou“ vlastnost. Střední doba reakce následujícího podnětu je dána realizací (náhodou) podnětu bezprostředně předcházejícího.

To umožňuje modelovat procesy „rozvinutí“ aféry a i její doznívání.

Pokud reakce na předchozí podnět již odezněla, je spuštěna nezávisle aféra nová. Pracujeme tedy s dvěma náhodnými proměnnými:

1. Příznak trvání aféry.
2. Doba odezvy na podnět spouštějící aféru.

Metodika má jeden podstatný předpoklad ve dvou rovinách:

1. Teoretická rovina – dva podněty spouštějící aféru nemohou přijít současně.
2. Praktická rovina – (maskování) efekt dalšího podnětu nemá vliv, pokud přijde dostatečně brzo po předchozím. Tedy všechny podněty, které přijdou v době $t + \tau$, kde t je čas posledního podnětu, který nebyl vymaskován, jsou maskovány. Za poslední předchozí podnět je pak uvažován poslední předcházející podnět, který nebyl vymaskován.

Praktický příklad

Aférologický pohled na výskyty článků s tematikou Západočeské univerzity ve vazbě na její právnickou fakultu.

Jednotkou je jeden článek na serveru IDNES, časová jednotka sledování je jeden rok. Byly užity četnosti z let 2005-2010.

Vyhledávání bylo realizováno pomocí množin klíčových slov, vyhledávač neumožňoval využití klíčových sekvencí. Vyhledávač respektoval „ohýbání“ českých slov. Adresa vyhledávače je: <http://hledej.idnes.cz/>.

Zjištěné četnosti jsou v následujících tabulkách:

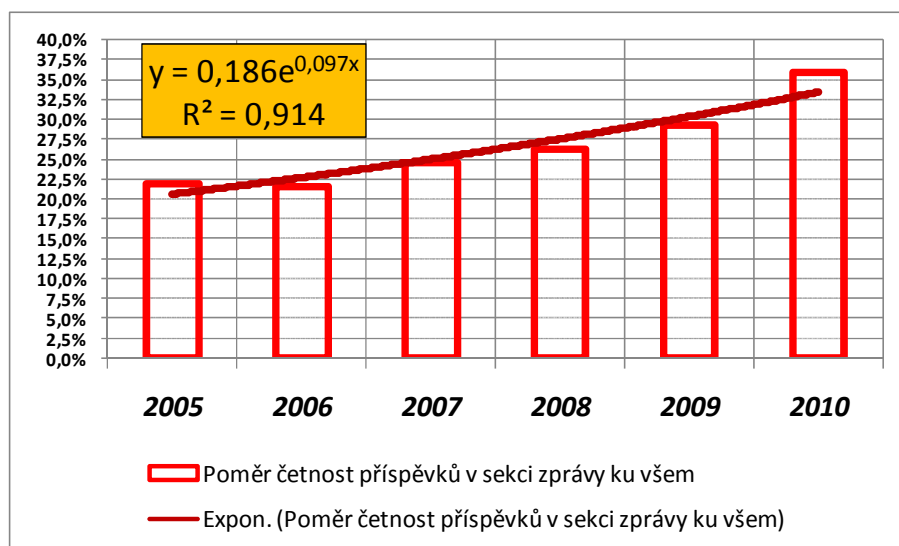
IDNES.CZ - Rubrika: Zprávy, vpravo klíčová slova		Plzeňská právnická fakulta	Západočeská univerzita	fakulta aplikovaných věd	že – jako model libovolného článku
Od	Do	Počet	Počet	Počet	Počet
1.1.2005	31.12.2005	1	4	0	8 427
1.1.2006	31.12.2006	1	13	2	8 290
1.1.2007	31.12.2007	1	13	3	10 453
1.1.2008	31.12.2008	7	29	4	12 360
1.1.2009	31.12.2009	119	87	9	14 447
1.1.2010	31.12.2010	84	84	3	18 288
IDNES.CZ - všechny rubriky, vpravo klíčová slova		Plzeňská právnická fakulta	Západočeská univerzita	fakulta aplikovaných věd	že – jako model libovolného článku
Od	Do	Počet	Počet	Počet	Počet
1.1.2005	31.12.2005	3	16	0	38 335
1.1.2006	31.12.2006	1	20	3	38 373
1.1.2007	31.12.2007	2	23	7	42 570
1.1.2008	31.12.2008	12	42	8	47 176
1.1.2009	31.12.2009	125	103	10	49 495
1.1.2010	31.12.2010	92	93	6	51 135

Aférologická (dojmologická) charakterizace uvedeného období vztažená k ZČU:

IDNES.CZ - všechny rubriky		Typická aféra nebo téma (nebo dezinformace) spojené se sledovaným tématem a obdobím (citace).
Od	Do	
1.1.2005	31.12.2005	<i>Gross by měl vydat svou rigorózní práci, soudí děkan.</i>
1.1.2006	31.12.2006	<i>František Mrázek měl úzké vztahy s policisty. Teď je vyšetřuje Inspekce ministra vnitra. Objevila u něj studijní doklad mladého policisty z Odboru pro odhalování závažné obecné kriminality.</i>
1.1.2007	31.12.2007	<i>Studentka Západočeské univerzity konkuruje pornoherečkám.</i>
1.1.2008	31.12.2008	<i>Jeden připravila společnost Consulting Company Novasoft spolu s firmou SpeechTech zřízenou Západočeskou univerzitou v Plzni, druhý Technická univerzita v Liberci spolupracující s firmou Newton IT.</i>
1.1.2009	31.12.2009	<i>Proděkan na plzeňských právech čelí obvinění z plagiátorství.</i>
1.1.2010	31.12.2010	<i>O etice na plzeňské univerzitě budou rozhodovat její vlastní akademici</i>

Empirické pozorování

Vývoj „čistých zpráv“ na úkor ne-zpráv (komentářů a volných textů):



Střední meziroční poměr 1.102.


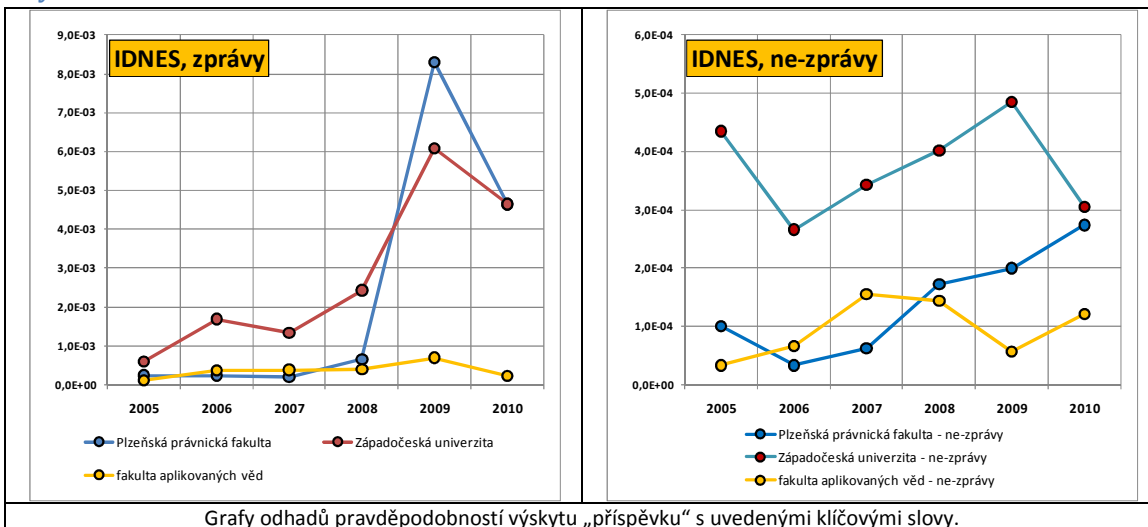
Problém současných médií je v tom, že relativně málo sdělují zprávy na úkor zpráv o zprávách, tedy komentáře, názory a autorské texty. Tedy dostáváme informaci nikoliv o tom, co se stalo, ale co si o tom, co se stalo, někdo myslí, nebo co si o tom máme myslet. Leč v tomto konkrétním případě lze pozorovat mírné zlepšování ale dle vlastní klasifikace daného média.

Vstupní data:

Rok a počty všech článků	IDNES.CZ - Rubrika: Zprávy	IDNES.CZ - všechny rubriky	Poměr četnost příspěvků v sekci zprávy ke všem
	Počet	Počet	%
2005	8 427	38 335	22,0%
2006	8 290	38 373	21,6%
2007	10 453	42 570	24,6%
2008	12 360	47 176	26,2%
2009	14 447	49 495	29,2%
2010	18 288	51 135	35,8%

Výsledky

Dynamika



Prameny:

[S]	SHANNON, C. E.	A Mathematical Theory of Communication, The Bell System Technical Journal, Vol. 27, pp. 379–423, 623–656, July, October, 1948.
[1]	NEUMAN, F.	Funkcionální rovnice, SNTL, Praha 1986
[2]	RÉNYI, A.	Teorie pravděpodobnosti, ACADEMIA, Praha 1972
[3]	RAO, C. R.	Lineární metody statistické indukce a jejich aplikace, ACADEMIA, Praha 1978
[C]	Thomas M. Cover, Joy A. Thomas	Elements of Information Theory. 1991 John Wiley & Sons, Inc. ISBN 0-471-06259-6.

Příloha

Podmíněná nezávislost neimplikuje nezávislost

$$P(x, y / z) = P(x / z)P(y / z)$$

	P(x,y/z=0)			
x,y->	0	1	p(x/z=0)	p(z=0)= 0,250
0	0,140	0,560	0,700	p(z=1)= 0,750
1	0,060	0,240	0,300	
p(y/z=0)	0,200	0,800	1,000	
	P(x,y/z=1)			
x,y->	0	1	p(x/z=1)	
0	0,200	0,200	0,400	
1	0,300	0,300	0,600	
p(y/z=1)	0,500	0,500	1,000	
	P(x,y,z=0)			
x,y->	0	1	p(x,z=0)	
0	0,035	0,140	0,175	
1	0,015	0,060	0,075	
p(y,z=0)	0,050	0,200	0,250	
	P(x,y,z=1)			
x,y->	0	1	p(x,z=1)	
0	0,150	0,150	0,300	
1	0,225	0,225	0,450	
p(y,z=1)	0,375	0,375	0,750	
	P(x,y)			
x,y->	0	1	p(x)	

	0	0,185	0,290	0,475
	1	0,240	0,285	0,525
p(y)	0,425	0,575	1,000	
P(x)P(y)				
x,y->	0	1	p(x)	
0	0,202	0,273	0,475	
1	0,223	0,302	0,525	
p(y)	0,425	0,575	1,000	

zde je $P(x, y) \neq P(x)P(y)$

Nezávislost neimplikuje podmíněnou nezávislost

$$P(x, y) = P(x)P(y)$$

P(x,y/z=0)				P(x/z=0)P(y/z=0)				
x,y->	0	1	p(x/z=0)	x,y->	0	1	p(x/z=0)	p(z=0)= 0,250
0	0,096	0,512	0,608	0	0,117	0,491	0,608	p(z=1)= 0,750
1	0,096	0,296	0,392	1	0,075	0,317	0,392	
p(y/z=0)	0,192	0,808	1,000	p(y/z=0)	0,192	0,808	1,000	
P(x,y/z=1)				P(x/z=1)P(y/z=1)				
x,y->	0	1	p(x/z=1)	x,y->	0	1	p(x/z=1)	
0	0,075	0,256	0,331	0	0,067	0,264	0,331	
1	0,128	0,541	0,669	1	0,136	0,534	0,669	
p(y/z=1)	0,203	0,797	1,000	p(y/z=1)	0,203	0,797	1,000	
P(x,y,z=0)								
x,y->	0	1	p(x,z=0)					
0	0,024	0,128	0,152					
1	0,024	0,074	0,098					
p(y,z=0)	0,048	0,202	0,250					
P(x,y,z=1)								
x,y->	0	1	p(x,z=1)					
0	0,056	0,192	0,248					
1	0,096	0,406	0,502					
p(y,z=1)	0,152	0,598	0,750					
P(x,y)								
x,y->	0	1	p(x)					
0	0,080	0,320	0,400					

1	0,120	0,480	0,600
p(y)	0,200	0,800	1,000
P(x)P(y)			
x,y->	0	1	p(x)
0	0,080	0,320	0,400
1	0,120	0,480	0,600
p(y)	0,200	0,800	1,000

zde je $P(x, y / z) \neq P(x / z)P(y / z)$